

Whole body MRIにおけるSegNetを利用した骨領域抽出法

Bone Region Segmentation Method Using SegNet in Whole body MRI

宮田 佳織¹⁾, 林 則夫²⁾, 岩崎 郁穂³⁾, 丸山 朋子⁴⁾, 茂木 俊一⁵⁾, 高橋 雅彦⁶⁾, 橋本 真衣子⁶⁾,
佐藤 有将⁷⁾, 渡部 晴之²⁾, 熊坂 創真⁸⁾, 対馬 義人⁸⁾

1) 前橋赤十字病院 放射線診断科
2) 博士(保健学) 群馬県立県民健康科学大学 診療放射線学部
3) SUBARU健康保険組合 太田記念病院 画像診断部
4) 修士(放射線学) 信州大学医学部附属病院 放射線部
5) 博士(医学) 国際医療福祉大学 保健医療学部
6) 伊勢崎市民病院 中央放射線科
7) 修士(放射線学) 群馬大学医学部附属病院 放射線部
8) (医師) 博士(医学) 群馬大学大学院医学系研究科 放射線診断核医学

Key words: MRI, whole-body, deep learning, bone segmentation, SegNet

【Abstract】

We investigated and evaluated a segmentation method for bone regions from WB-T₁-weighted images by deep learning using two datasets in this study. SegNet was used as the deep learning network for bone region segmentation. A network was trained and evaluated using two datasets: coronal T₁-weighted images and axial T₁-weighted images. The constructed network was able to segment bone regions with high accuracy. Accuracy and Jaccard coefficients were 0.916 and 0.681 for dataset 1, and 0.946 and 0.420 for dataset 2. The network used in this study was able to segment the entire bone region, although some over-segmentation was observed.

【要 旨】

本研究では、2つのデータセットを用いて深層学習によるWB-T₁強調画像から骨領域の領域抽出法を検討し、その精度を評価した。骨領域抽出のための深層学習ネットワークにはSegNetを用いた。冠状断T₁強調画像と横断T₁強調画像の2つのデータセットを用いてネットワークを構築した。構築したネットワークでは高い精度で領域の抽出が可能であった。AccuracyとJaccard係数はデータセット1で0.916と0.681であり、データセット2で0.946と0.420であった。本研究で使用したネットワークにより、過大抽出は見られなかったが骨領域を全体的に抽出できた。

MIYATA Kaori¹⁾, HAYASHI Norio, Ph.D.²⁾,
IWASAKI Kaho³⁾, MARUYAMA Tomoko, M.S.⁴⁾,
MOTEGI Shunichi, Ph.D.⁵⁾,
TAKAHASHI Masahiko⁶⁾, HASHIMOTO Maiko⁶⁾,
SATO Yusuke, M.S.⁷⁾, WATANABE Haruyuki, Ph.D.²⁾,
KUMASAKA Soma, M.D, Ph.D.⁸⁾,
TSUSHIMA Yoshito, M.D, Ph.D.⁸⁾

- 1) Department of Diagnostic Radiology, Mae-bashi Red Cross Hospital
- 2) Department of Radiological Technology, Gunma Prefectural College of Health Sciences
- 3) Diagnostic Imaging Department, Subaru Health Insurance Society Ota Memorial Hospital
- 4) Division of Radiology, Shinshu University Hospital
- 5) School of Health Sciences, International University of Health and Welfare
- 6) Department of Central Radiology, Isesaki Municipal Hospital
- 7) Department of Radiology, Gunma University Hospital
- 8) Department of Diagnostic Radiology and Nuclear Medicine, Gunma University Graduate School of Medicine

Received July 18, 2022; accepted February 23, 2023

緒 言

近年、前立腺癌や乳癌の罹患者数は増加傾向にある¹⁾。現在、それらの骨転移に対する診断や経過観察には骨シンチグラフィーやCTが用いられている。しかし、骨シンチグラフィーはフレア現象のため病勢を過大評価してしまうという問題点がある²⁻⁴⁾。またCTは前立腺癌や乳癌などの造骨性転移による石灰化と、放射線照射・化学療法・ホルモン療法などの治療による良性石灰化を識別できない⁵⁾。そこでそれらの骨転移の経過観察手段として、whole-body diffusion weighted imaging (WB-DWI) が注目されている。WB-DWIとは、WB-MRI検査で得られる画像の一つであり、DWIを用いて全身のがんの分布を示したもので、positron emission computed tomography (PET) と類似したMR画像を撮像することを可能にした^{6,7)}。そのため核医学検査装置を有していない施設などで期待されている。核医学検査と比較したWB-DWIの利点として、注射不要(非造影)、事前安静不要、無被ばく、安価の4つが挙げられる⁵⁾。

しかし、現状の問題点として、定量評価法が確立し

ている骨シンチグラフィ⁸⁻¹⁰⁾と異なり、WB-DWIは骨転移腫瘍の定量評価法が確立していないことが挙げられる。定量化の試みとして、先行研究¹¹⁾では、global ADCやtumor diffusion volume (tDV)を骨転移腫瘍の治療効果評価の指標として使用することができると報告しているが、確立した手法はいまだ存在しない。また骨シンチグラフィと異なり、MR画像は閾値処理により骨だけを抽出することが難しく^{11, 12)}、それに加え、アーチファクトにより偽陽性や偽陰性が発生しやすいという問題点もある¹³⁾。そこでWB-DWI画像から、骨領域を自動抽出する手法の作成を行うことが必要であると考えた。そのためには、WB-DWI画像から解剖学的領域を認識し抽出する必要があるが、DWI画像から解剖学的領域を認識し抽出することは難しい。そのため本研究では、解剖学的領域が認識しやすいT₁強調画像を用いて、WB-DWI画像から骨領域を抽出するマスク像の作成を目的とした。しかし、臓器によって抽出精度が異なるかが分からないため、まずは初期検討として深層学習を用いて、T₁強調画像の冠状断からアーチファクトが出やすい領域と関心領域である骨領域を抽出し、精度の評価を行った。本研究の深層学習にはセマンティックセグメンテーションを使用することとした。また関心領域である骨領域に対しては、T₁強調画像の横断を用いて深層学習のトレーニング枚数を増やすことで骨の抽出精度が維持できるのか、または向上できるのかについて検討した。

1. セマンティックセグメンテーション

深層学習には、画像に写っている物体を検出し、事前に決めていたカテゴリーに自動的に振り分ける「分類」や、対象領域をデジタル画像の最小単位である画素で精密に切り出す「領域分割（セグメンテーション）」などがある¹⁴⁾。セグメンテーションに用いられる深層学習ネットワークにはFCN^{15, 16)}、U-Net¹⁷⁾、SegNet¹⁸⁾がある。本研究の深層学習にはSegNetを用いた。SegNetとは、セマンティックセグメンテーションの一つであり、画像内の全画素をオブジェクトクラスに割り当てるアルゴリズムのことである。セマンティックセグメンテーションは、自動運転における歩行者と歩道の分離や、医用画像に対するがん検出など、さまざまな業界で使用されている¹⁸⁾。

セマンティックセグメンテーションは、画像内の画素にラベルを付けるため、他の物体検出の方法に比べて高精度であることが特徴である。SegNetは、encoder-decoder構造である (Fig.1)。Encoder部分では入力画像から特徴抽出を行い、decoder部分では特徴を保持したまま元の解像度まで画像の復元を行う。Encoder部分とdecoder部分の対応した特徴マップをつないでいるため、画像を復元する際に位置情報を含めることができるという特徴がある¹⁴⁾。

2. 方法

本研究では、まずアーチファクトが出やすい領域と関心領域である骨領域を抽出し、精度評価を行うために冠状断T₁強調画像を用いた深層学習ネットワークを構築した。また深層学習のトレーニング枚数を増やすことで骨の抽出精度の向上について検討するために、横断T₁強調画像を用いた深層学習ネットワークを構築した。本研究の概要をFig.2に示す。いずれの検討もWB-MR画像を収集し、収集した画像に対してラベル付けを行い教師画像を作成した。作成した教師画像と原画像をトレーニング画像として、深層学習ネットワークの教育を行った。そして各データセットによって教育したネットワークの評価を行った。




Fig.1 Network architecture of the SegNet




Fig.2 Flowchart of a segmentation method of bone regions by using the SegNet

2-1. 使用機器および対象

本研究では、2つのデータセットを使用した。データセット1では、Philips社製のMRI装置Achieva 1.5T A-seriesを使用し撮像したWB-T₁強調冠状断像を使用した。データセット1では、アーチファクトが多く、撮像枚数が少なくても骨の抽出が可能かを知るために冠状断を使用した。シーケンスはgradient echo法を用いた。その他の撮像条件は以下の通りである。FOV 330 mm×410 mm, 収集マトリクス 272×236, スライス厚 7 mm, スライス枚数 27枚, SENSE factor 1.8, TR 195 ms, TE 2.3/4.6 ms, flip angle 75 deg, 加算回数 1回, 撮像時間 41 s. 対象は、共同研究施設においてWB-MRI検査を施行した20人（男性20人, 60から87歳（74±2.1歳））とした。データセット2では、SIEMENS社製のMRI装置MAGNETOM Aera 1.5Tを使用し撮像したWB-T₁強調横断断像を使用した。データセット2では、撮像枚数を増やしトレーニングデータを多くすることで、骨の抽出精度が向上するかを確かめるために横断を使用することとした。シーケンスは3D gradient echo法を用いた。その他の撮像条件は以下の通りである。FOV 440 mm×400 mm, 収集マトリクス 448×336, スライス厚 5 mm, スライス枚数 192~416枚, Parallel Imaging factor 4, TR 6.5 ms, TE 4.8 ms, flip angle 12 deg, 加算回数 2回, 撮像時間 188 s. 対象は、共同研究施設においてWB-MRI検査を施行した24人（男性20人, 女性4人, 54から82歳（72±6.1歳））とした。また深層学習を用いた領域抽出にはデータセット1, 2共にMATLAB r2020a（Mathworks,

Natick, MA, USA）を使用した。本研究は、全ての施設において倫理委員会の承認を得た後に実施した。また被験者にはあらかじめ十分な説明を行い、インフォームドコンセントを得て行った。

2-2. 深層学習を用いた領域抽出

2-2-1. 教師画像の作成

深層学習に必要なトレーニングに用いる教師データを作成した。原画像であるWB-T₁強調画像に対して手動でラベル付けを行った。データセット1は、アーチファクトが出やすい領域と関心領域の骨にラベル付けを行うこととした。アーチファクトが出やすい領域としては、肺・腸管・体内そして体外領域を、アーチファクトの除去を目的としたマスク像の作成のためラベル付けを行った。データセット2では、関心領域の骨のみにラベル付けを行った。それぞれのデータセットでラベル付けを行い、一つ一つの画素が各領域のラベル値を持つ教師画像として出力した。これを全症例に対して行った。ラベル付けは、MR専門技術者の認定を持つ18年の経験を有する医療関係者1人による確認を行った。

2-2-2. 深層学習ネットワークの教育

深層学習ネットワークの教育は、データセット1, 2共に同じ方法を用いて行った。深層学習を行うための準備としてトレーニング画像とテスト画像を作成した。ラベル付け前の原画像（WB-T₁強調画像）をネットワークの入力画像として、ラベル付けをした画像を教師画像とした。一対の入力画像と教師画像の8割

をトレーニング画像とし、残りの2割をテスト画像とした。また本研究で使用したMATLAB r2020aでは、学習済みのVGG16の重みを使用したSegNetの転移学習を適用することができる。転移学習はすでに他の画像を用いて学習させた畳み込みニューラルネットワークの大部分を流用する技術の総称であり、少ないデータから効率よく学習を行うことが可能になる¹⁴⁾。本研究では、深層学習ネットワークの教育を短時間かつ少ない画像で行うために、事前学習済みのVGG16ネットワークから初期化された重みをSegNetのエンコーダ部分に適応したVGG16の重み付きSegNetを使用した。トレーニング画像とその対応する教師画像を用いて、VGG16の重み付きSegNetネットワークを学習させた。学習係数は以下の通りである。Momentum 0.9, Initial Learn Rate 1e-03, L2Regularization 0.0005, Max Epochs 100, Mini Batch Size 4, Verbose Frequency 2。

2-3. 評価方法

評価法は、データセット1, 2共に5-fold cross validationを用いて抽出精度を評価した。評価指標としてAccuracyとJaccard係数を用いた。Jaccard係数は、2つの集合に含まれている要素のうち共通要素が占める割合を表しており、Jaccard係数が大きいほど2つの集合の類似度が高いことを示している。Accuracyは以下の式(1)、Jaccard係数は以下の式(2)の通りである。Aは教師画像(Label)、Bは出力

画像(Output)である。

$$Accuracy(A, B) = |A \cap B| / A \quad \dots\dots\dots (1)$$

$$Jaccard\ index(A, B) = |A \cap B| / |A \cup B| \quad \dots\dots (2)$$

2-4. 3D作成

ネットワークの抽出精度を視覚的に評価するために3Dを作成した。データセット1では、冠状断を使用して深層学習のトレーニングを行っているため枚数が少ないことや、ステアステップアーチファクトの影響が大きい。そのためボリュームレンダリングによる3D作成が難しい。よって3D作成にはデータセット2で学習させたネットワークを使用することとした。データセット2に示したやり方で学習させたネットワークに、テスト画像を入れて出力した結果を3D表示した。3Dの作成には、MATLABのボリュームビューワーを用いてボリュームレンダリングを行った。

3. 結果

データセット1の出力結果の一例をFig.3に示す。OriginalはWB-T₁強調画像であり、Labelは教師画像である。Outputは出力画像であり、Overlayは出力画像と教師画像を重ね合わせた画像である。また5-fold cross validationでAccuracyとJaccard係数を算出した結果をTable 1に示す。Table 1より、Accuracyは骨領域が最も低い値となった。Jaccard




Fig.3 Result of each region segmentation on Whole body T₁-weighted coronal MR images
(a) Original WB-T₁-weighted image, (b) Label image, (c) Output image, (d) Overlay image. The overlay image is the superimposition of the label image and output image. In the Overlay, green area is the over-segmented area and pink area is the under-segmented area on the output image.

Table 1 Accuracy and Jaccard Index for each region in Whole body T₁-weighted coronal MR
Accuracy and Jaccard Index for Inside the body, Lung, Bone, Digestive tract, Outside the body, and Total.

	Inside the body	Lung	Bone	Digestive tract	Outside the body	Total
Accuracy	0.868	0.975	0.873	0.893	0.973	0.916
Jaccard Index	0.833	0.782	0.436	0.414	0.942	0.681




Fig.4 Result of bone segmentation on Whole body T₁-weighted axial MR images
(a) Original WB-T₁-weighted image, (b) Label image, (c) Output image, (d) Overlay image. The overlay image is the superimposition of the label image and output image. In the Overlay, green area is the over-segmented area and pink area is the under-segmented area on the output image.

係数は骨と腸管が他の領域と比べて低い値となった。これより、本研究で学習させたネットワークを用いることで、骨・肺・腸管・体内・体外領域を抽出できたことが分かる。

データセットの出力結果の一例をFig.4に示す。Fig.4より、頭部・胸部・腹部・骨盤部の全てにおいて、出力画像は教師画像より太く抽出されている。Overlayの画像を見ると骨領域の過大抽出が多く見られ、過小評価されている部分もわずかだが見られた。またFig.5にはFig.4の3次元表示像を示す。Fig.5のJaccard係数は0.437であった。Fig.5は骨領域が良好に抽出されているが、一部骨領域以外が抽出されている部分も見られた。また5-fold cross validationでAccuracyとJaccard係数を算出した結果、全体のAccuracyは0.946であった。そしてJaccard係数は

全体で0.420となった。

4. 考 察

Jaccard係数は、データセット1に関しては骨と腸管が他の領域と比べて低い値となった。この原因として、両者はWB-T₁強調画像上において比較的小さい領域であり、教師画像を作成する際のラベル付けの難易度が高く、十分に正確なラベル付けが行えなかったことが考えられる。データセット2では、Accuracyはデータセット1よりも高い値となったが、Jaccard係数は低い値となった。Jaccard係数が低い原因は、Fig.4のOverlayの画像に見られる骨領域の過大抽出によるものであると考える。また骨領域以外の領域が抽出されている断面があることや、教師画像のラ




Fig.5 Surface rendered images of the bone segmented images
(a) oblique view, (b) front view, and (c) lateral view.

ベル付けの精度が悪いこともJaccard係数に影響していると考えられる。しかし、本研究の目的は、 T_1 強調画像を用いてWB-DWI画像から骨領域を抽出するマスク像の作成である。そのため今回、出力した画像はJaccard係数が低かったが、Fig.5 (3D作成)で示したように視覚的には骨領域は良好に描出されたため、今後の研究でDWI画像に重ね合わせるマスク画像としての使用用途としては有用であると考えられる。また領域の抽出の精度はデータセット1よりもデータセット2で高い値となったことから、深層学習ネットワークの教育に使用する画像の枚数を増やすことは抽出精度の向上につながると考える。

WB-DWIは骨転移評価に有用であるとされているが、高原らは臨床では骨シンチグラフィにおけるextent of disease (EOD) 基準に準じて、大ざっぱにレポートしているのが現状であると報告している⁵⁾。このように、WB-DWIは、経過観察における全体的な病勢の把握はされているが、骨シンチグラフィと異なり定量評価法は確立されていない。先行研究では、定量化の試みとして半自動セグメンテーションを用いて、global ADCやtumor diffusion volume (tDV)によって骨転移腫瘍の治療効果判定が行えると報告されている¹¹⁾。しかし、半自動セグメンテーションは手動での修正が必要となる場合があり、手間がかかることや精度が不十分であるという問題点があった。今回、使用した深層学習ネットワークであるセマンティックセグメンテーションは、省メモリで高速な学習が可能であることから、自動運転や医療の自動化をはじめとした多様な分野の研究で活用されている技

術であり¹⁹⁾、従来の方法に比べ高精度であるという特徴がある。また丸山らがセマンティックセグメンテーションの方法であるU-Net, SegNet, VGG16の重み付きSegNetを比較したところ、最も高い抽出精度を得られたのがVGG16の重み付きSegNetであった²⁰⁾。本研究では、VGG16の重み付きSegNetを使用することで、少ないトレーニング画像によるネットワークの教育でも高い抽出精度を得ることができるようになった。そのためトレーニング画像の作成の手間を減らせるとともに、ネットワークの深層学習にかかる時間も減らすことが可能になったと考える。これまでWB-MR

画像に対するセマンティックセグメンテーションの報告はなされていないため、骨領域の自動抽出法を構築する上で本研究は有用であるといえる。

深層学習ネットワークの教育に使用する教師画像の精度は抽出精度に関係する。よって抽出精度の向上のために、より正確な教師画像の作成方法についての検討をしなければならない。本研究では、2つのメーカーの装置で撮像したデータを用いて検討を行った。そのため他のメーカーの装置で同じ条件で撮像した画像を用いた場合でも、良い結果が得られるとは限らない。また同じメーカーの装置でも、静磁場強度や撮像条件を変えた場合の結果がどうなるかが分からないため、さまざまな条件で検討していかなければならない。そして最終的には、WB-DWI画像から領域を自動抽出する手法の作成を行いたい。まずはDWI画像からの領域抽出を行うのに今回の方法が有効かどうかを評価する必要がある。

5. 結 論

深層学習を用いて、WB- T_1 強調画像から5つの領域の抽出と骨領域のみの抽出の2つの領域抽出法を検討した。その結果、構築したネットワークでは高い精度で領域の抽出が可能であった。また関心領域である骨領域の過大抽出は見られたが、骨のマスク画像としては適した出力画像が得られた。従ってセマンティックセグメンテーションを用いてWB-DWI画像から骨領域を抽出するためのマスク画像としては、本手法を用いてWB- T_1 強調画像から抽出した画像が有用である。

利益相反

筆頭著者および共著者全員に開示すべき利益相反はない。

表の説明

Table 1 WB-T₁強調冠状断像における各領域のAccuracyとJaccard係数
体内領域・肺・骨・腸管・体外領域、そして全体のAccuracyとJaccard係数の算出結果。

図の説明

- Fig.1 SegNetのネットワーク構造
Fig.2 SegNetを用いた骨領域抽出手法のフローチャート
Fig.3 WB-T₁強調冠状断像における各領域抽出結果
(a) WB-T₁強調画像, (b) 教師画像, (c) 出力画像, (d) オーバーレイ画像。オーバーレイは教師画像と出力画像を重ね合わせたものである。オーバーレイに見られる緑の領域は教師画像に対して出力画像が過大抽出された部分であり、ピンクの領域は過小抽出された部分である。
Fig.4 WB-T₁強調横断像における骨領域抽出結果
(a) WB-T₁強調画像, (b) 教師画像, (c) 出力画像, (d) オーバーレイ画像。オーバーレイは教師画像と出力画像を重ね合わせたものである。オーバーレイに見られる緑の領域は教師画像に対して出力画像が過大抽出された部分であり、ピンクの領域は過小抽出された部分である。
Fig.5 骨抽出画像のサーフェスレンダリング画像
(a) 斜位像, (b) 正面像, (c) 側面像。

参考文献

- Hori M., Matsuda T., Shibata A., et al.: Cancer incidence and incidence rates in Japan in 2009: a study of 32 population-based cancer registries for the Monitoring of Cancer Incidence in Japan (MCIJ) project. *Jpn J Clin Oncol*, 45(9), 884-91, 2015.
- Hashisako Mikiko, Wakamatsu Kentarou, Ikegame Satoshi, et al.: Flare Phenomenon Following Gefitinib Treatment of Lung Adenocarcinoma with Bone Metastasis. *The Tohoku Journal of Experimental Medicine*, 228(2), 163-8, 2012.
- 山本泰司: 6. 前立腺がんとNM検査一前立腺がんにおける骨シンチグラフィの定量評価一. *日放技学誌*, 73(10), 1087-94, 2017.
- Scher Howard I., Halabi Susan, Tannock Ian, et al.: Design and End Points of Clinical Trials for Patients With Progressive Prostate Cancer and Castrate Levels of Testosterone: Recommendations of the Prostate Cancer Clinical Trials Working Group. *Journal of Clinical Oncology*, 26(7), 1148-59, 2008.
- 高原太郎, 有田祐起, 吉田宗一郎, 他: 全身拡散強調画像(DWIBS法) 読影のポイントと基本的な臨床応用. *画像診断*, 37(2), 229-40, 2017.
- Chen W., Jian W., Li H. T., et al.: Whole-body diffusion-weighted imaging vs. FDG-PET for the detection of non-small-cell lung cancer. How do they measure up? *Magn Reson Imaging*, 28(5), 613-20, 2010.
- Lambregts D. M., Maas M., Cappendijk V. C., et al.: Whole-body diffusion-weighted magnetic resonance imaging: current evidence in oncology and potential role in colorectal cancer staging. *Eur J Cancer*, 47(14), 2107-16, 2011.
- 河上一公: (4) 骨シンチ診断支援ソフトBONENAVIによる骨転移の評価(技術紹介). *画像通信*, 36(1), 74-7, 2013.
- Yamamoto Y., Mitsunaga S., Horikawa A., et al.: Quantitative bone scan imaging using BSI and BUV: an approach to evaluate ARONJ early. *Annals of nuclear medicine*, 34(1), 74-9, 2020.
- Umeda T., Koizumi M., Fukai S., et al.: Evaluation of bone metastatic burden by bone SPECT/CT in metastatic prostate cancer patients: defining threshold value for total bone uptake and assessment in radium-223 treated patients. *Annals of nuclear medicine*, 32(2), 105-13, 2018.
- Blackledge M. D., Collins D. J., Tunariu N., et al.: Assessment of treatment response by total tumor volume and global apparent diffusion coefficient using diffusion-weighted MRI in patients with metastatic bone disease: a feasibility study. *PLoS One*, 9(4), e91779, 2014.
- 宮田なつき, 鴨島里実, 太田 順: 骨モデル当てはめによるMR画像からの手骨位置姿勢同定. *日本ロボット学会誌*, 25(2), 241-8, 2007.
- Kwee Thomas C., Takahara Taro, Ochiai Reiji, et al.: Diffusion-weighted whole-body imaging with background body signal suppression(DWIBS): features and potential applications in oncology. *European Radiology*, 18(9), 1937-52, 2008.
- 藤田広志: 医用画像ディープラーニング入門. オーム社, 2019.
- Zhang Jianming, Lu Chaoquan, Wang Jin, et al.: Concrete Cracks Detection Based on FCN with Dilated Convolution. *Applied Sciences*, 9(13), 2686, 2019.
- Shelhamer E., Long J., Darrell T.: Fully Convolutional Networks for Semantic Segmentation. *IEEE Trans Pattern Anal Mach Intell*, 39(4), 640-51, 2017.
- Ronneberger Olaf, Fischer Philipp, Brox Thomas: U-Net: Convolutional Networks for Biomedical Image Segmentation. 9351, 234-41, 2015.
- Badrinarayanan V., Kendall A., Cipolla R.: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Trans Pattern Anal Mach Intell*, 39(12), 2481-95, 2017.
- 中村直紀, 森田賢太, 森田直樹, 他: SegNetにおける教師画像の与え方に関する一考察. *知能と情報*, 32(5), 912-6, 2020.
- Maruyama T., Hayashi N., Sato Y., et al.: Simultaneous brain structure segmentation in magnetic resonance images using deep convolutional neural networks. *Radiol Phys Technol*, 14(4), 358-65, 2021.