

G-001

## 深層畳み込みニューラルネットによる頭部 MRI の構造画像の分割 Segmentation of head MRI structure image by deep convolutional neural network

小川 昭利<sup>†</sup>  
Akitoshi Ogawa

小西 清貴<sup>†</sup>  
Seiki Konishi

### 1. はじめに

機械学習、とくに深層学習を用いた画像処理を医用画像へ適用するサービスの開発が最近進められている。例えば、肺 X 線 CT 画像から腫瘍の存在確率を割り出す、脳 MRI 画像から多発性硬化症である確率を割り出す、脳腫瘍部位を分割して生存日数を予測するなどである (sites.google.com/site/braintumorsegmentation)。深層学習は、Hinton の積層自己符号化器以来急速に進展している[1, 2]。画像処理においては深層畳み込みニューラルネット (DCNN) が主に用いられており、脳画像への適用も盛んである。一方、基礎研究においては、正常脳を組織に正確に分割することが重要となる。とくに白質と灰白質は脳活動・脳容積・結合性の解析に重要である。

本研究では、DCNN を用いて正常脳を灰白質、白質、脳脊髄液、頭蓋骨、軟組織の 5 組織に分割することを目指した。とくに白質の分割を評価の対象とした。深層学習の専門家ではない研究者が短時間で研究を立ち上げられるように、画像データとラベルの用意、学習器の学習と検証をすべて Matlab (The MathWorks, Inc.) で行うことを前提とした。

### 2. 方法

DCNN を使って、頭部 T1 画像を、灰白質、白質、脳脊髄液、頭蓋骨、軟組織の 5 種類に分類することを目指し、学習と検証を Leave-one-participant-out (LOPO) 法により行った。

#### 2.1 画像取得

東京大学進化認知科学研究センターの MRI を用いて T1 強調画像を取得した (13 名 (男性 10 名、女性 3 名)、平均 19.4 歳)。本実験は、順天堂大学医学部倫理委員会の承認、および、東京大学進化認知科学研究センター MRI 運営委員会の安全審査に合格して行われた。実験参加者から実験開始前に書面にて説明と同意を得た。

取得した T1 画像を、まず、SPM (The Wellcome Trust Centre for Neuroimaging at University College London) を用いて、灰白質 (gray matter, GM)、白質 (white matter, WM)、脳脊髄液 (cerebrospinal fluid, CSF)、頭蓋骨 (skull, SK)、軟組織 (soft tissue, ST) の 5 種類に分割する[3]。SPM は、画像に含まれる各ボクセルにおいて、そのボクセルがどの組織に当たるかを確率で出力する。すなわち、GM、WM、CSF、SK、ST のそれぞれの確率画像を出力する。あるボクセルがどの組織であるかは、これら確率画像から、最大確率を示す組織に決定し、教師データとして用いた。

DCNN の学習は、 $33 \times 33$  の平面画像を入力とし、その中心ボクセルの組織がいずれであるかを分類することである。図 1 に示す 9 平面上から  $33 \times 33$  の画像を切り出す。対象となるボクセルに対して、空間内の x 軸、y 軸、z 軸それぞれに平行な 3 平面と、それらから  $\pm 45^\circ$  傾けた 6 平面である。




図 1 学習・検証に用いた 9 平面の設定。

#### 2.1.1 学習・検証画像の用意

T1 画像から GM、WM、CSF、SK、ST の 5 種類に分類するための対象範囲は、確率画像の合計が 0.5 を超えるボクセルとした。それ以外のボクセルは、対象となる組織ではないとみなして学習・検証から除外した。

### 2.2 学習

1	'data'	Image Input	227x227x3 images with 'zerocenter' normalization
2	'conv1'	Convolution	96 11x11x3 convolutions with stride [4 4] and padding [0 0]
3	'relu1'	ReLU	
4	'norm1'	Cross Channel Normalization	cross channel normalization with 5 channels per element
5	'pool1'	Max Pooling	3x3 max pooling with stride [2 2] and padding [0 0]
6	'conv2'	Convolution	256 5x5x48 convolutions with stride [1 1] and padding [2 2]
7	'relu2'	ReLU	
8	'norm2'	Cross Channel Normalization	cross channel normalization with 5 channels per element
9	'pool2'	Max Pooling	3x3 max pooling with stride [2 2] and padding [0 0]
10	'conv3'	Convolution	384 3x3x256 convolutions with stride [1 1] and padding [0 1]
11	'relu3'	ReLU	
12	'conv4'	Convolution	384 3x3x192 convolutions with stride [1 1] and padding [1 1]
13	'relu4'	ReLU	
14	'conv5'	Convolution	256 3x3x192 convolutions with stride [1 1] and padding [1 1]
15	'relu5'	ReLU	
16	'pool5'	Max Pooling	3x3 max pooling with stride [2 2] and padding [0 0]
17	'fc6'	Fully Connected	4096 fully connected layer
18	'relu6'	ReLU	
19	'drop6'	Dropout	50% dropout
20	'fc7'	Fully Connected	4096 fully connected layer
21	'relu7'	ReLU	
22	'drop7'	Dropout	50% dropout
23	'fc8'	Fully Connected	5 fully connected layer
24	'prob'	Softmax	softmax
25	'output'	Classification Output	crossentropyx

図 2 DCNN の構造。

学習器には DCNN である Alexnet [4] を用いた。Alexnet は Matlab の Neural Network Toolbox (NNT) に含まれており、その構造を利用して学習を行った (図 2)。入力信号の次元は Alexnet に合わせて調整した。学習率は 0.0001 で固定とした。画像は 9 スライス面について各 500 用意した。ミニバッチサイズは 128、最大エポック数は 80 とした。画像を切り出す 9 平面のそれぞれに対して DCNN を用意した。

学習に用いた PC のスペックは、CPU が Intel Core i7 6700-K、メモリが 32 GB、GPU が nVIDIA GeForce GTX 1080 (ベースクロック 1607MHz、CUDA コア数 2560、メモリ 8 GB GDDR5X) だった。学習と検証は、CentOS 6.8 上で動作す

<sup>†</sup> 順天堂大学医学部

る Matlab 2017a にて Parallel computing toolbox と NNT を用いて行った。

学習と検証は、参加者内法と LOPO 法で行った。参加者内法では、用意した画像を学習用と検証用に 4:1 に分けた。すなわち、各平面に対応する DCNN それぞれで 400 枚を学習に使用して残り 100 枚を検証に使い、WM の分割の正答率と False alarm (FA) を評価した。LOPO 法では、13 名のうち 12 名の画像で学習を行い、残り 1 名の画像を用いて、500 画像の分類の正答率と FA を評価し、画像を分割した白質の Dice 係数を評価した。検証時には、9 DCNN の出力をバギングした。

### 3. 結果

参加者内法での検証の結果、5 組織の平均正答率は 80.3% だった。そのうち、WM の正答率は 82.3% で FA は 16.2% だった。LOPO 法による画像分類の結果は、5 組織の正答率の参加者平均が 88.0% だった。WM の正答率の参加者平均は 93.1% で FA は 8.2% だった。

LOPO 法による画像分割は、13 名中 6 名で行い、WM の Dice 係数の参加者平均は 0.90 だった。WM の分割例を図 3 に示す。ところどころで見られる孤立したボクセルを消去するなどの後処理を行えばより精度高く画像分割ができる可能性がある。




図 3 白質の分割例。左は DCNN の出力で、右は SPM8 の白質の分割である。

### 4. 議論

本研究では、頭部の構造画像である MRI の T1 強調画像の分割を、DCNN を用いて行った。学習と検証は参加者内法と LOPO 法で行った。とくに、深層学習の専門家ではない研究者の使用を想定して、画像データとラベルの用意、学習器の学習と検証をすべて Matlab で行った。入力信号を 2 次元平面とすることで、Matlab の NNT に実装されている DCNN である Alexnet を簡単に使用することができた。

画像分類では、LOPO 法の方が参加者内法よりも良い結果になった。これは、参加者内法では、学習に用いた画像が少なかったためと考えられる。

T1 画像は 3 次元であり、入力信号を 3 次元とする DCNN が提案されている (e.g. DeepNat [5], VoxResNet [6])。単純な比較はできないが、後者の手法による T1 画像からの WM の分割の Dice 係数は 0.897 であり、本研究の手法はこれと同程度である。これらの手法と本研究のとの詳しい比較はこれからの課題である。本研究では、分類・分割の対

象となるボクセルに対して、角度が異なる 9 スライス面を用意することで、3 次元入力の一部をカバーした。もし、この手法が 3 次元の DCNN と同程度以上のパフォーマンスを示すのであれば、計算資源の観点から本研究の手法が優れているといえるだろう。

### 謝辞

データ解析にあたり神谷貴久氏の支援を受けた。本研究は科研費 16K16076 の助成を受けたものです。

### 参考文献

- [1] Hinton, G. E., Salakhutdinov, R. R., “Reducing the dimensionality of data with neural networks”, *Science*, Vol. 313 (2006).
- [2] 人工知能学会監修, “深層学習”, 近代科学社 (2015).
- [3] Ashburner, J., Friston, K. J., “Unified segmentation”, *NeuroImage*, Vol. 26 (2005).
- [4] Krizhevsky, A., Sutskever, I., Hinton, G. E., “ImageNet classification with deep convolutional neural networks”, *Advances in neural information processing systems* (2012).
- [5] Wachinger, C., Reuter, M., Klein, T., “DeepNAT: Deep convolutional neural network for segmenting neuroanatomy”, *NeuroImage* (in press).
- [6] Chen, H., Dou, Q., Yu, L., Qin, J., Heng, P.-A., “VoxResNet: Deep voxelwise residual networks for brain segmentation from 3D MR images”, *NeuroImage* (in press).