

# Affinity graph を用いた神経細胞画像セグメンテーション

小山 詠未 Tristan Hascoet 滝口 哲也 有木 康雄

神戸大学

## 1. はじめに

電子顕微鏡(Electron Microscopy:EM)で撮影された3次元の神経細胞画像のインスタンスセグメンテーションは、機械学習を用いた神経細胞画像解析の効率化に非常に有用である。本研究では精度を向上させるモデルの構築を図ることが目的である。

インスタンスセグメンテーションの手法として、3次元神経細胞画像からAffinity graphを生成し watershed アルゴリズムと agglomeration を適用することで物体のラベルを得る Superhuman [1]を用いる。ネットワークの多層化により深層学習の精度は向上し、Superhuman の精度はすでに人間の手によるセグメンテーションよりも高い。しかし、ネットワークの構造をより多層にすることで更なる精度向上を期待できる。よって本稿では Superhuman において深層学習を用いている U-net 部分に着目し、このネットワークの多層化を図る。しかし、この実現には隠れ層の activation がメモリボトルネックとなり、ネットワークの規模がメモリサイズに依存するという問題がある。

近年逆伝搬方向でもユニット間の計算が可能 (reversible) なモデルの研究によってメモリに配慮せずネットワークの多層化が図れるようになった。本稿では、reversible なネットワークの1つである RevNet [2]を用いて、U-net のメモリ使用量を削減するに加えメモリサイズに依存せず多層化を図れるモデルを提案する。また、多層化によるセグメンテーションの精度への影響を検証する。

## 2. 提案モデル

### 2-1. U-net




図1 U-net

Superhuman において 3 次元神経細胞画像から Affinity graph を生成する U-net を図1に示す。U-net は7つの Residual Module と畳み込み演算, Upsampling, Max-pooling, Skip connection で成るネットワークである。

Residual Module を多層にすることで、U-net の多層化を図ることができる。

### 2-2. RevNet




図2 RevNet (a) 順伝搬 (b) 逆伝搬

図2に示した RevNet は出力  $Y_1, Y_2$  から入力  $X_1, X_2$  を計算可能にするモデルである。FおよびGは畳み込み演算であり、 $X_1, X_2$  および  $Y_1, Y_2$  は入力を channel 方向で2等分に分割したものである。

順伝搬時,

$$\begin{cases} y_1 = x_1 + F(x_2) & (1) \\ y_2 = x_2 + G(y_1) & (2) \end{cases}$$

逆伝搬時,

$$\begin{cases} x_2 = y_2 - G(y_1) & (3) \\ x_1 = y_1 - F(x_2) & (4) \end{cases}$$

でそれぞれ計算できる。

これにより  $x_1, x_2$  の値を順伝搬時に保管する必

**Affinity graph agglomeration for neurite segmentation**  
Emi Koyama, Tristan Hascoet, Tetsuya Takiguchi, Yasuo Ariki  
Kobe University

要がなくなり，深層学習において隠れ層の activation がメモリボトルネックであるという問題を解決できる。

### 2-3. 提案手法

深層学習においてメモリボトルネックとなるのは逆伝搬のための隠れ層の activation の保管によるものであり，破棄できればメモリ使用量を削減できる。このためには次層から現在の層の値が計算できる必要があり，これには  $i-1$  層と  $i$  層間の関係が

$$x_i = f(x_{i-1})$$

と表したとき， $f^{-1}$ が存在しなければならない。

U-net 内の CNN において次層との関係を表現する畳み込みは逆関数が存在しないため RevNet を導入して逆計算を可能にする。

図 1 において黒枠で囲った箇所が RevNet で置換可能であるため，この演算を RevNet で実現させ置換する。RevNet 部はメモリに依存せずモジュールの追加が可能なので，これにより U-net についてより多層なネットワークの構築が可能となる。

## 3. 実験

### 3-1. データセット




図 3 SNEMI3D の分割

データセットとして 3D Segmentation of neurites in EM images (SNEMI3D)を使用した。

- ネズミの皮質を電子顕微鏡で撮影
- サイズは 1024\*1024\*100 (voxel)
- 1voxel あたり 6 \* 6 \* 30 (nm)

本稿では，図 3 のように SNEMI3D を使用し実験を行った。

### 3-2. 実験および結果

		param	time	memory	acc
base		2.2M	1h20m	3.8G	91.0
Rev Net	n=1	1.4M	2h10m	2.7G	91.0
	n=2	2.2M	3h20m	2.7G	91.3
	n=3	3.0M	4h30m	2.7G	90.8
	n=4	3.7M	5h40m	2.7G	90.9

表 1 実験結果

結果を表 1 に示す。“n”は図 1 の黒枠部分に置換する RevNet の個数，“param”はネットワークのパラメータの数，“time”は 1epoch の学習に必要な時間，“memory”は学習に必要なメモリ，“acc”は accuracy で推定された物体の輪郭に対して計算したものをそれぞれ指す。なお，“base”は RevNet を使わないものである。

RevNet を導入することで，メモリ使用量を削減することに成功している。また，置換する RevNet の個数を増やしネットワークの層数およびパラメータ数が増加しても，学習時間は増加するが使用するメモリ量は変化していない。これによる accuracy の変化は見られなかった。

## 4. まとめ

RevNet を Superhuman に導入し，メモリへの負荷を削減するインスタンスセグメンテーションモデルを提案した。RevNet の導入により，ネットワークの多層化およびパラメータ増加に対して精度を損なうことなくメモリ使用量を抑えることに成功した。

## 参考文献

[1] Kisuk Lee, Jonathan Zung, Peter Li, Viren Jain, H. Sebastian Seung, “Superhuman Accuracy on the SNEMI3D Connectomics Challenge”, arXiv preprint arXiv:1706.00120, 2017

[2] Aidan N. Gomez, Mengye Ren, Raquel Urtasun, Roger B. Grosse, “The Reversible Residual Network: Backpropagation Without Storing Activations”, arXiv preprint arXiv:1706.00120, 2017