

深層学習を用いた冠動脈 OCT 画像からの 石灰化領域抽出

及川 遼[†] 加藤 徹[†] 土井章男[†] バサビチャクラボルティ[†] 石田大[‡]

[†] 岩手県立大学ソフトウェア情報学部 〒020-0611 岩手県滝沢市菓子 152-52

[‡] 岩手医科大学 〒020-0023 岩手県盛岡市内丸 19-1

E-mail: [†] {g231t006, toru_k, doia, basabi}@iwate-pu.ac.jp, [‡] maishida@iwate-med.ac.jp

あらまし 冠動脈の狭窄や閉塞は狭心症発作や心筋梗塞を招き、冠動脈疾患は代表的な死亡原因となっている。その中でも石灰化した病変は治療が難しくその評価が重要と考えられている。ここ 10 年で冠動脈の石灰化部の診断には光干渉断層計(OCT)が広く使われるようになり、冠動脈ステントの自動抽出、内腔の評価、3D イメージの出力も可能であるが、石灰化などの病状を自動的に抽出・診断をすることはできないのが OCT の現状である。本研究では冠動脈 OCT 画像からの石灰化画像のセグメンテーション手法を提案し、評価を行った。

キーワード 深層学習, OCT 画像, セマンティックセグメンテーション

Extraction of Calcified Regions from OCT Images Using Deep Learning

Ryo OIKAWA[†] Toru KATO[†] Akio DOI[†] Basabi CHAKRABORTY[†] and Masaru ISHIDA[‡]

[†] Graduate School of Software and Information Science, Iwate Prefectural University 152-52 Sugo, Takizawa-shi,
Iwate-ken, 020-0611 Japan

[‡] Iwate Medical University 19-1 Uchimarui, Morioka-shi, Iwate-ken, 020-0023 Japan

E-mail: [†] {g231t006, toru_k, doia, basabi}@iwate-pu.ac.jp, [‡] maishida@iwate-med.ac.jp

Abstract Stenosis or occlusion of coronary arteries leads to angina attacks and myocardial infarctions, and coronary artery disease is a leading cause of death. Coronary artery disease is a leading cause of death. Calcified lesions are particularly difficult to treat, and their evaluation is considered to be important. In the last decade, optical coherence tomography (OCT) has become widely used to diagnose calcified areas in coronary arteries. Although OCT can automatically extract coronary stents, evaluate lumen, and output 3D images, it is currently unable to automatically extract and diagnose disease states such as calcification. In this study, we proposed and evaluated a segmentation method for calcification images from coronary OCT images.

Keywords Deep Learning, OCT Image, Semantic Segmentation

1. はじめに

冠動脈の狭窄や閉塞は、狭心症発作や心筋梗塞を招き、性別問わず、冠動脈疾患は代表的な死亡原因となっている。特に動脈硬化状態で動脈の壁に脂肪分が沈着することで進行すると動脈が狭くなり、死亡率が高くなる。動脈疾患は冠動脈の壁にコレステロールなどの脂肪性物質(アテロームあるいはアテローム性プラークと呼ばれる)や、カルシウムなどの石灰化物質が徐々に蓄積することによって発生し、治療には狭くなってしまった動脈を拡張する技術である経皮的冠動脈形成術(PCI)が用いられている。PCIは血管内にカテーテルを挿入し、バルーンを用いて血管をもとにもどし、ステントを固定する治療法であるが、冠動脈疾患の中で、石灰化した病変は治療が難しく、その評価が重要と考えられている。冠動脈のカテーテル検査や治療では、従来、血管内超音波(Intravascular Ultrasound:IVUS)

が石灰化評価に用いられている。しかし、石灰化の後ろに信号の減衰が生じ、正確に評価することが難しい。そのため、ここ 15 年では冠動脈の血管内測定に光干渉断層法(Optical coherence tomography:OCT)が広く使用されるようになった。OCTは10~20 μ mという高い解像度を持つ、近赤外線レーザー光と光ファイバー技術を応用した血管内画像診断装置である。IVUSの10倍以上の空間分解能で評価することができ、高解像度で石灰化を明瞭に抽出することが可能なため、近年では様々な施設で導入されている。しかしながら、冠動脈 OCTでの組織診断の自動化は進んでいないのが現状である。本研究では自動抽出のための過程として深層学習を用いて血管 OCT 画像内から石灰化している部分とガイドワイヤーと判断できる部分と背景部分に対して、深層学習を用いたセマンティックセグメンテーションを行い精度の検証を行う。

2. 先行研究

2.1. OCT 画像の解析による病変の認識

Shenghua[1]らは OCT 画像中のプラークを自動的に特徴づける CNN ベースの手法を提案した。このアルゴリズムは 22 人の患者から取得した 269 枚の画像を用いて検証され、5 つの組織タイプについての総合的な精度は 86.6%であった。先行研究では石灰化の認識・分類精度が低く、精度向上が課題として挙げられていた。また、冠動脈における薄層線維性アテローム (TCFA)を検出する研究として Min[2]らの手法が存在する。彼らは 602 人の患者から作成したデータセットを学習に使用し、モデルの精度は $91.6 \pm 1.7\%$ であった。OCT 画像から病変の有無を認識しているこれらの研究に対して、本研究では、セマンティックセグメンテーションを用いて石灰化領域の検出を行う。

2.2. OCT 画像のセマンティックセグメンテーション

セマンティックセグメンテーションでは画像を画素レベルでラベル付けし、病変領域の学習を行う。近年では、石灰化領域を含む複数の領域をセマンティックセグメンテーションで分類した例が報告されている[3]。Chu らは作成したモデルを、F 値を指標として精度評価し、石灰化領域では F 値 0.848 であった。また、OCT 画像中の各プラーク領域に対して自動的な特徴付けを行い、石灰化領域におけるその精度は 88.5%であった。

2.3. FCN[4]

Fully Convolutional Networks(FCN)は近年のセグメンテーションタスクにおいて高い精度を示している、任意のサイズの画像を取り込んで、同じサイズのセグメンテーションマップを作成することができるネットワークである。ネットワーク構造を図 1 に示す。FCN は一般的な CNN の全結合層を全て畳み込み層で置き換えることにより、分類スコアの代わりに空間的なセグメンテーションマップの出力を可能としている。また、入力画像のサイズに制約がないという特徴がある。このネットワークは、アップサンプリングした深い層の特徴マップの荒さを、それ以前の浅い層の特徴マップと連結することで改善するスキップ接続によって正確なセグメンテーションを実現し、2014 年当時、最先端のセグメンテーション性能を達成した。




図 1 FCN の構造

この研究がセマンティックセグメンテーション分野

に与えた影響は大きく、その後 SegNet や U-Net 等、FCN をベースに多くのネットワークが開発された[5]。

2.4. ResNet[6]

ResNet は従来の手法よりも勾配消失しづらい学習手法として、残差関数を学習することを提案し、100 層を超えるネットワークでの学習を可能にしたモデルである。特徴として、FCN で使用されたスキップ接続を更に多用しており、図 2 に示すような畳み込み層とスキップ接続の組み合わせで作られるブロック(残差ブロック)の繰り返しでネットワーク全体が構成されている。このように ResNet は残差を学習することで層の深度の限界を引き上げることに成功し、従来のモデルよりも高い精度を達成した。本研究では、事前学習済みの ResNet-50 ネットワークから初期化された重みを使用して DeepLab v3+[7]ネットワークを作成し、学習を行う。




図 2 残差ブロック[6]

2.5. DeepLab v3+によるセグメンテーション

本研究では、DeepLab v3+を用いてセグメンテーションを行った。当モデルは 2018 年に最先端のセマンティックセグメンテーション性能を実現した機械学習モデルである。エンコーダに ASPP(Atrous Spatial Pyramid Pooling)と呼ばれるピラミッド構造の膨張畳み込み層を持ち、特徴を任意の分解能で抽出することが可能であり、より高速で強力なエンコーダ・デコーダネットワークを実現した。本論文では ResNet-50 ネットワークから初期化された重みを使用して DeepLab v3+の転移学習を行う。図 3 に DeepLabv3+の構造を示す。




図 3 DeepLabv3+の構造[7]

3. 提案手法

3.1. 提案手法概要

本研究では自動抽出のための過程として深層学習を用いて、冠動脈 OCT 画像内から石灰化部分とガイドワイヤー部分と背景の3つの領域でセグメンテーションを行った。本研究では深層学習のツールとして MATLAB を用いてラベル付け、トレーニング、および検証を行った。学習は DeepLab v3+ を使用して行った。

3.2. データセットの作成

データセットの作成は以下の流れで行った。まず、6人の患者から取得した211枚のDICOM形式の画像を Osirix を用いて JPEG 形式の画像として保存する。次に、保存した画像に対して MATLAB のイメージラベラーを用いてラベル付けを行う。セグメンテーションを医用画像に適用する際の問題点の一つとして、正解データ（ラベルデータ）の作成が難しいことが挙げられる。本研究では専門家である岩手医科大学の医師が OCT 画像の石灰化部分のトレースを行った。その後、画像に対してデータ拡張を施した。ガンマ補正を行い7倍にしたデータに対して鏡面変換をかけ、最終的な学習データ数は元データの21倍の4,431枚となった。データの拡張例を図4および図5に示す。




図4 ガンマ補正




図5 鏡面変換

3.3. 三次元での石灰化領域表示

本研究では汎用3次元画像処理システム Volume Extractor[8]を使用して石灰化領域の三次元表示を行った。出力された Volume Rendering 表示を図6に示す。

また、計測された体積を表1に示す。

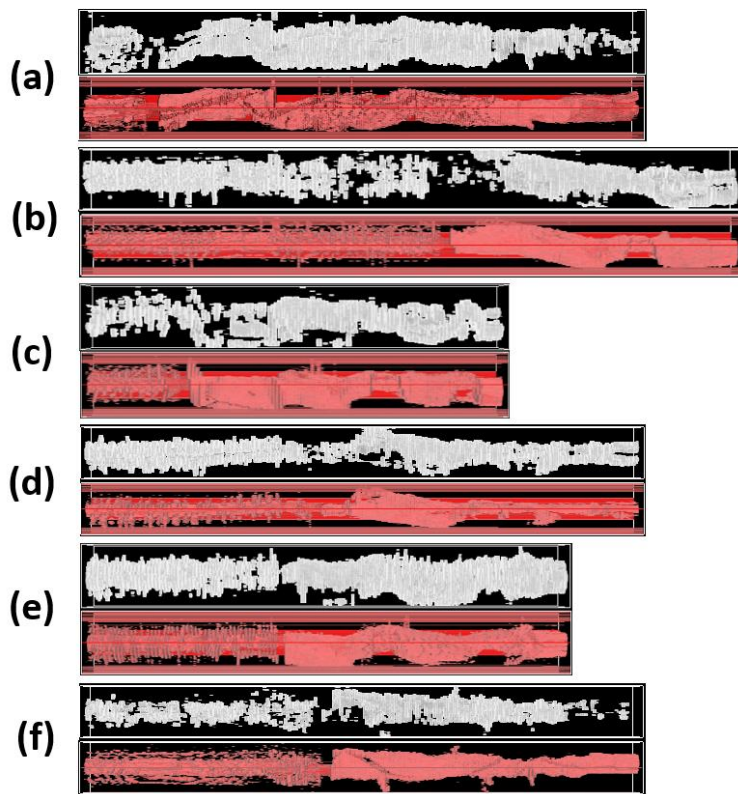


図6 Volume Rendering

表1 解析で算出された石灰化領域の体積

	体積 [mm ³]
患者(a)	46,845
患者(b)	47,224
患者(c)	26,406
患者(d)	51,691
患者(e)	46,886
患者(f)	26,906

4. 検証

4.1. 検証環境

検証環境およびハイパーパラメータを表2、表3に示す。

表2 検証環境

CPU	Intel® Core™ i9-9940X
RAM	128GB(16GB×8)
GPU	NVIDIA QUADRO RTX 8000 ×4
OS	Ubuntu 18.04 LTS
学習データ	4,431 枚
検証データ	60 枚

表 3 ハイパーパラメータ

学習回数	259epochs
画像サイズ	512×512pixels
ミニバッチサイズ	6
初期学習率	0.001
最適化手法	Adaptive moment estimation(Adam)[9]

4.2. 評価項目

本研究は以下のことを検証した.

- ①三次元での石灰化領域表示, 出力例に対する目視での診断易難の評価
- ②Accuracy および IoU の評価

4.3. 実験結果

4.1.で示した環境で 42 時間の学習を行い, モデルを作成した. Accuracy および IoU を表 4 に示す. 出力例を図 7 に示す. 混同行列を図 8 に示す.

表 4 Accuracy および IoU

	Calcium	Guidewire	Background
Accuracy	0.62	0.73	0.98
IoU	0.5	0.63	0.96

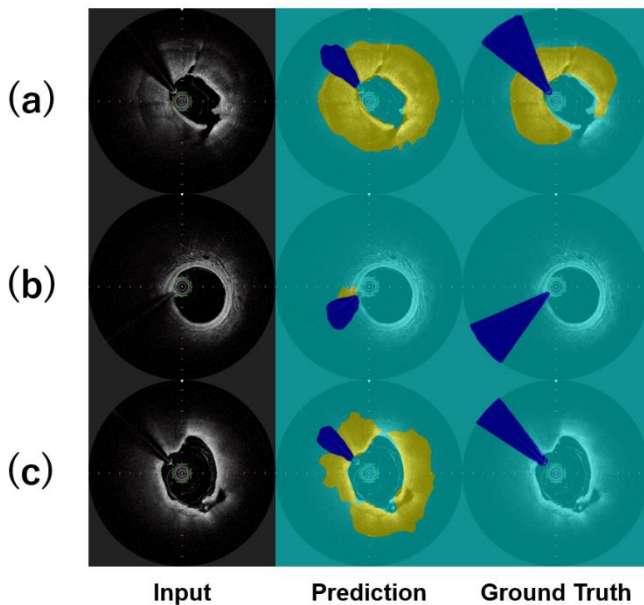


図 7 出力例

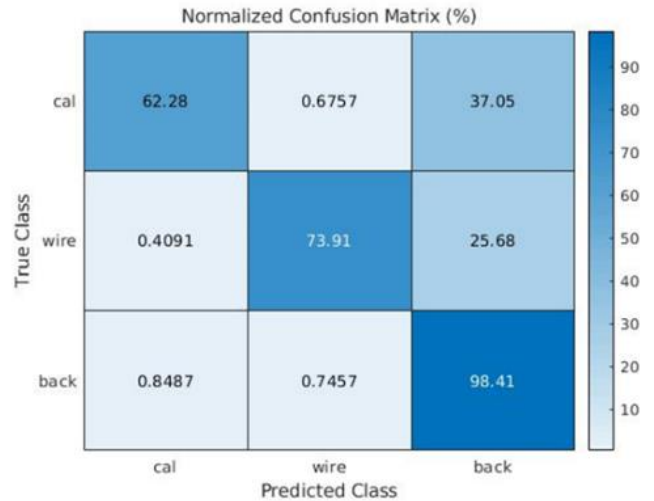


図 8 混同行列

4.4. 考察

表 4 および図 7(a)から, 石灰化領域のセグメンテーションが行えていることが確認できた. 一方で図 7(c)のように正常な領域を石灰化領域と予測してしまう場合があった. 血管内腔が円形から遠い形状をしている画像が不足していることが原因と考えられるため, 該当する学習データの増量で改善が見込める. 図 8 の混同行列では, ガイドワイヤーがある領域を背景と予測してしまう場合が多かったことが示されている. これは現状のガイドワイヤー領域のラベル付け方法が一意ではないことが原因と考えられるため, 長さ等を統一することで精度が向上すると考察する.

三次元での石灰化領域表示を行った図 6 について, 患者(f)の石灰化領域を拡大して着色したものを図 9 に示す. 図 9 では石灰化領域の連続性について直感的に診断可能である. PCI では石灰化領域が 180 度以上連続している場合, 拡張障害が問題になるとされているため, 提案する目視診断は有効であると考察する.




図 9 三次元での石灰化領域表示による診断

5. おわりに

本研究では DeepLab v3+による深層学習を用いて OCT 画像から石灰化領域の抽出を行った. 石灰化領域は医師と技師が石灰領域の境界を対話的にマーキングし, 学習データはデータ拡張を含めた 4,431 枚のスライス画像を使用した. さらに, 石灰化領域を含むスライス画像を高さ方向に積層することで 3 次元画像表示

(Volume Rendering 表示)を行った。石灰化領域の立体的な可視化は病変の診断を容易とし、スライス画像表示に比べて視覚的な優位性を示した。

今後は学習データセットの増量、3次元セグメンテーション等の研究を引き続き行っていく。

6. 謝辞

本研究はJSPS科研費(基盤研究(C)JP20K08142)の助成を受けたものです。また、公益財団法人JKAの「令和2年度研究開発補助事業」、岩手県の「令和2年度いわて戦略的研究開発推進事業」より研究助成を得ました。ここに謝意を表します。

文 献

- [1] S. He, J. Zheng, A. Maehara, G. Mintz, D. Tang, M. Anastasio, H. Li "Convolutional neural network based automatic plaque characterization from intracoronary optical coherence tomography images" arXiv:1807.03613 10 Jul 2018.
- [2] H.-S. Min, J. H. Yoo, S.-J. Kang, J.-G. Lee, H. Cho, P. H. Lee, J.-M. Ahn, D.-W. Park, S.-W. Lee, Y.-H. Kim, C. W. Lee "Detection of optical coherence tomography-defined thin-cap fibroatheroma in the coronary artery using deep learning" EuroIntervention: journal of EuroPCR in collaboration with the Working Group on Interventional Cardiology of the European Society of Cardiology, 16.5: 404-412 Aug 2020.
, Seong-Wook Park, Seung-Jung Park,
- [3] M. Chu, H. Jia, J. L. G.-Chico, A. Maehara, Z. A. Ali, X. Zeng, L. He, C. Zhao, M. Matsumura, P. Wu1, M. Zeng, T. Kubo, B. Xu, L. Chen, B. Yu, G. S. Mintz, W. Wijns, MD, N. R. Holm, S. Tu "Artificial intelligence and optical coherence tomography for the automatic characterisation of human atherosclerotic plaques." EuroIntervention: journal of EuroPCR in collaboration with the Working Group on Interventional Cardiology of the European Society of Cardiology 17.1: 41-50 May 2021.
- [4] J. Long, E. Shelhamer, and T. Darrell "Fully convolutional networks for semantic segmentation," in Proceedings of the IEEE conference on computer vision and pattern recognition: 3431-3440 June 2015.
- [5] S. Minaee, Y. Boykov, F. Porikli, A. Plaza, N. Kehtarnavaz, D. Terzopoulos "Image Segmentation Using Deep Learning: A Survey" arXiv: 2001.05566 15 Jan 2020.
- [6] K. He, X. Zhang, S. Ren, and J. Sun "Deep residual learning for image recognition," in Proceedings of the IEEE conference on computer vision and pattern recognition: 770-778 June 2016.
- [7] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam "Encoder-decoder with atrous separable convolution for semantic image segmentation," in Proceedings of the European conference on computer vision (ECCV): 801-818 Sep 2018.
- [8] A. Doi, S. Suzuki, F. Yamasa, K. Matsui, F. Itoh, S. Mega, S. Itoh "Volume Extractor Ver.3.0 : 3D Image Processing and 3D Model Re-construction" in ITETechnicalReport VoL, 32, No.34: 73-77 Jul 2008.
- [9] D. P. Kingma, J. L. Ba "Adam: A Method for Stochastic Optimization" arXiv preprint arXiv:1412.6980 Dec 2014.