


[研究助成 (C)]

深層学習を用いた OCT における
網膜下液のセグメンテーションと黄斑浮腫早期診断

22470II

研究代表者
(助成金受領者)
共同研究者京都工芸繊維大学
大学院工学科学研究科
京都工芸繊維大学
情報工学・人間科学系博士後期課程
准教授XUE XIAOZHONG
杜 偉 薇

[研究の目的]

1. 必要性：

光干渉断層撮影 (OCT) は、光干渉の原理を利用して生体組織を高解像度で断層的に描出できる非侵襲的イメージング技術であり、特に眼科領域において網膜の詳細な観察に広く活用されている [1]。また、図 1 に示すように、OCT データは三次元的に再構成することが可能であるが、臨床においては、通常、断層像を一層ずつ観察する。この断層像は B スキャンと呼ばれ、そこから網膜疾患に関連する液体領域を確認できる。

液体領域は、加齢黄斑変性症 (AMD)、網膜静脈閉塞症 (RVO)、糖尿病網膜症 (DR) といった主要な網膜疾患の診断や病態把握において重要なバイオマーカーとされている [2]。その精度の高いセグメンテーションは、自動化診断システムの開発において不可欠である。また、液体領域の体積および範囲は、臨床医が処方する抗 VEGF 薬の投与量に直接影響を与えることが知られている [3]。さらに、既存の研究では、

液体領域の大きさが患者の視力予後と有意に関連していることが報告されている [4]。したがって、液体領域の高精度かつ効率的なセグメンテーションは、眼科において不可欠である。

2. 難点：

液体領域のセグメンテーションに関しては、いくつかの研究が行われてきた。一部の研究では、アクティブ輪郭モデルなどの従来手法が用いられている [5]。

従来手法と比較して、深層学習手法は優れた頑健性と有効性を示しており、液体領域のセグメンテーションに多数のモデルが適用されている。その中には U-Net が含まれるが [6]、U-Net は細部領域のセグメンテーション性能において依然として改善の余地がある。また、Transformer に基づくモデルも提案されているが、これらは計算量が非常に大きく、臨床応用には制約がある [7]。

総じて、図 2 に示すように、OCT B スキャンから液体領域をセグメンテーションする際には、以下の三つの主要な課題が存在する。

- ・**微細領域**：液体領域と周囲組織との境界が不明瞭になりやすい。これらの領域は深層学習モデルによって見落とされたり、誤分類されたりする可能性が高い。
- ・**異質性**：血液、漿液、その他の生体成分の比率の違いなど内部構成の変動により、液体領域は反射率の異なる部分を示す場合がある。深層学習モデルは液体領域のより一貫性のあ




図1 OCT B スキャン




図2 液体領域セグメンテーションにおける難点

る部分のみをセグメンテーションする可能性がある。

- ・ **深さ情報**：液体領域の境界をより精密に描出するためには、隣接スライス間での構造的連続性を提供する体積的（3D）文脈を取り入れることが有効である。しかし、OCT 全体ボリュームを処理する場合、モデルの複雑性、メモリ消費量、および学習の難易度が大幅に増加する。

総じて、本研究の目的は、液体領域のセグメンテーションにおける微細領域、異質性、および深さ情報という三つの課題を克服し、液体領域のセグメンテーション精度を向上させることであり、これにより黄斑浮腫などの網膜疾患の自動診断の基盤を構築することである。

[研究の内容、成果]

本研究では、多次元損失関数に基づく Y 字型アーキテクチャ「**Fluid-SegNet**」を提案する。多次元損失関数は、デコーダの各段階における微細特徴の損失を軽減し、細部の構造を保持することを目的としている。Y 字型アーキテクチャは二つエンコーダを組み込み、2D および 2.5D 入力からテクスチャ情報と文脈情報を同時に抽出可能である。さらに、モデル内部には拡張畳み込みを採用し、受容野を拡大することで、液体領域の異質性特徴の捉える能力を向上

させている。

提案モデルの有効性は、2つの公開データセット（UMN [8] [9] および AROI [6]）を用いて検証した。UMN データセットにおいて平均 Dice 係数 0.8725、AROI データセットにおいて平均 Dice 係数 0.6967を達成した。さらに、OIMHS [10] データセットにおいて、UMN データセットで事前学習を行ったモデルを小規模な OIMHS サブセットでファインチューニングした場合、平均 Dice 係数 0.8020を達成した。これらの結果は、Fluid-SegNet が液体領域セグメンテーションにおいて優れた性能と高い汎化能力を有することを示している。

1. 提案法：

図2に示す Fluid-SegNet は、2D エンコーダ、2.5D エンコーダ、特徴融合モジュール、およびデコーダから構成される。

2D エンコーダは、2D OCT B-scan から特徴を抽出することを目的として設計されており、特徴抽出ユニットとダウンサンプリング層から構成される。各特徴抽出ユニットは拡張畳み込み層を含み、これにより受容野を拡張することが可能となる。大きな受容野を有することにより、モデルは液体領域の境界と異質性領域の境界を同時に観察することが可能となり、その結果、セグメンテーション時に異質性領域の影響を回避することができる。一方、2.5D エンコーダは 2.5D OCT B-scan から特徴を抽出するために設計されており、その主たる目的は深度方向の特徴を捉えることである。特徴融合モジュールは、2D エンコーダおよび 2.5D エンコーダによって対応する次元で抽出された特徴を統合し、スキップ接続を介して融合された特徴マップをデコーダへ伝達する役割を担う。最後に、デコーダはエンコーダによって抽出された特徴を入力画像の元の空間解像度に再構築し、最終的なセグメンテーション結果を出力する。

モデルのトレーニングにおいては、二種類の




図3 Fluid-SegNet

教師信号を使用した。ひとつは擬似ラベル (PL), もうひとつは医師による手動アノテーション (GT) である。擬似ラベルを用いたトレーニングでは, 提案する多次元損失関数を用いてデコーダの各次元に対してモデル出力を監督し, デコーディング過程で特徴の損失を防ぎ, 微細領域のセグメンテーション精度を向上させる。擬似ラベルを教師信号として使用する際には, 損失関数として Smooth L1 を採用した。一方, GT を教師信号として使用する場合には, Dice 損失とクロスエントロピー損失の加重和を損失関数として用いた。

2. 評価方法：

本研究では, セグメンテーション結果の精度を評価するために, Dice, Precision, Recall の3種類の評価指標を用いた。各指標の具体的な定義は式 (1), (2), (3) に示す。ここで, SR はセグメンテーション結果を, GT は医師による手動アノテーションの基準を, TP は真陽性を, FP は偽陽性を, FN は偽陰性をそれぞれ表す。

$$Dice = \frac{2|SR \cap GT|}{|SR| + |GT|} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

Dice は液体領域のセグメンテーション結果と GT (Ground Truth) との類似度を測定する指標である。Precision は, オーバーセグメンテーションの程度を評価する上で有効である。Recall は, アンダーセグメンテーションの程度を評価する上で有効である。

3. 結果：

提案する Fluid-SegNet の有効性は, 5 分割交差検証法を用いて2つの公開データセット (UMN および AROI) 上で検証した。さらに, 別の公開データセットである OIMHS を用いてクロスデータセット検証を実施した。

提案法のセグメンテーション精度を評価するために, 8 種類のモデルをベースラインとして比較を行った。まず, 医学画像セグメンテーションにおいて広く利用されている一連のモデルとして, U-Net, U-Net++, および U-Net+++ を用いた。次に, **Self-Attention** に基づく Swin-Unet と, **Mamba** に基づく Vmamba-Unet を取り上げた。二つのモデルは, いずれも画像セグメンテーションにおいて既に成熟した応用実績を有している。最後に, 関連研究において提案された Improved U-Net++, SE-Unet, FAM-U-Net の三種類のモデルを比較対象とした。ただし, Swin-Unet と Improved U-Net++ は UMN データセットにおいて他のモデルと比べて顕著に劣る性能を示したため, AROI データセットおよび OIMHS データセットにおいては, この二つのモデルに関する議論は行わないこととした。

表1, 表2および表3に示すように, 提案する Fluid-SegNet は, UMN, AROI, OIMHS の三つの公開データセットにおいて, いずれも最大の Dice 値および Precision 値を達成した。Dice の向上は, 提案法が液体領域セグメンテ

表1 UMN データセットにおける結果

モデル	Precision	Recall	Dice
U-Net	0.8822	0.8573	0.8555
U-Net++	0.8910	0.8569	0.8434
U-Net+++	0.8244	0.9001	0.8490
Swin-Unet	0.6714	0.5700	0.5579
Vma-Unet	0.8592	0.8236	0.8218
Im-U-Net++	0.8444	0.4057	0.4741
SE-Unet	0.8713	0.8644	0.8559
FAM-U-Net	0.7620	0.9179	0.8094
Proposed	0.8944	0.8684	0.8725

表2 AROI データセットにおける結果

モデル	Precision	Recall	Dice
U-Net	0.7062	0.6678	0.6588
U-Net++	0.7320	0.6364	0.6470
U-Net+++	0.7061	0.7054	0.6744
Vma-Unet	0.6150	0.6245	0.5783
SE-Unet	0.7186	0.6609	0.6563
FAM-U-Net	0.6974	0.6654	0.6499
Proposed	0.7472	0.6994	0.6967

ションにおいて優れた性能を有することを示している。Precision の最大は、最も低いアンダーセグメンテーションを示している。アンダーセグメンテーションは通常、背景ノイズが誤って前景としてセグメンテーションされるため、Precision の向上は提案法のノイズに対するロバスト性を反映している。

そして、三つのデータセットにおいて Fluid-SegNet の平均 Recall は最大値には達しなかったものの、他のモデルにおいては、高い Recall が顕著な Precision の低下を伴う傾向が見られた。この現象は、これらのモデルが液体領域の特徴抽出に不十分であり、セグメンテーション戦略がよりアグレッシブとなることで、より多くの領域を誤って前景として分類していることを示す。

これに対し、Fluid-SegNet は Precision を最高水準に保ちながら、なお高い Recall を維持しており、提案法の有効性をさらに実証することができる。液体領域セグメンテーションにおいて Recall が低下する主な要因は、(1) 面積

表3 OIMHS データセットにおける結果

モデル	Precision	Recall	Dice
U-Net	0.8161	0.7925	0.7885
U-Net++	0.8357	0.7752	0.7879
U-Net+++	0.7325	0.8840	0.7834
Vma-Unet	0.7901	0.7107	0.7285
SE-Unet	0.8234	0.7859	0.7881
FAM-U-Net	0.7025	0.8867	0.7597
Proposed	0.8482	0.7839	0.8020




図4 結果の例図 (赤面：セグメンテーション結果。赤線と白線：GT)

の小さい液体領域やその細部がモデルにより無視される、(2) 液体領域内の異質性の部分が無視される、の二点である。Fluid-SegNet が高い Recall を示したことは、提案法が細部特徴を効果的に抽出できることを明確に示している。

さらに、図4からも同様の結論が得られ、提案する Fluid-SegNet は微細領域および異質性領域のセグメンテーション精度を改善していることが確認できる。

4. 結論及び展望：

本研究では、OCT B スキャンから2次元特徴と深度特徴を効果的に抽出するY字型アーキテクチャを特徴とする新規深層学習モデル Fluid-SegNet を提案する。本モデルは、多次元損失関数を導入することで精緻な特徴の抽出を強化し、さらに拡張畳み込みを用いることでモデルの複雑性を増加させることなく受容野を拡張する。提案モデルの有効性は、3つの公開データセットにおいて検証され、Fluid-SegNet が精度を向上させるとともに、液体領域のセグ

メンテーションにおける二つの課題, (1) 微細領域がモデルによって見落とされやすい点, (2) 液体領域の異質性に起因するアンダーセグメンテーション, を克服することが示された。さらに, Fluid-SegNet は自動診断システムや自動投薬支援システムの開発に向けた基盤を提供する。将来的な研究計画は, 本提案した Fluid-SegNet に基づき, 黄斑浮腫の自動診断システムを開発し, 臨床で本研究の有効性を検証する。

[参考文献]

- [1] Fujimoto, J., & Swanson, E. (2016). The development, commercialization, and impact of optical coherence tomography. *Investigative ophthalmology & visual science*, 57(9), OCT1-OCT13.
- [2] Gupta, M. P., Herzlich, A. A., Sauer, T., & Chan, C. C. (2016). Retinal anatomy and pathology. *Dev Ophthalmol*, 55, 7-17.
- [3] Tah, V., Orlans, H. O., Hyer, J., Casswell, E., Din, N., Sri Shanmuganathan, V., ... & Pasu, S. (2015). Anti-VEGF therapy and the retina: an update. *Journal of ophthalmology*, 2015(1), 627674.
- [4] Alasil, T., Keane, P. A., Updike, J. F., Dustin, L., Ouyang, Y., Walsh, A. C., & Sadda, S. R. (2010). Relationship between optical coherence tomography retinal parameters and visual acuity in diabetic macular edema. *Ophthalmology*, 117(12), 2379-2386.
- [5] Taubaldy, N., & Ji, Z. (2018, June). Beyond Retinal Layers: An Automatic Active Contour Model with Pre-Fitting Energy for Subretinal Fluid Segmentation in SD-OCT Images. In *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)* (pp. 326-330). IEEE.
- [6] Melinščak, M., Radmilović, M., Vatauvuk, Z., & Lončarić, S. (2021). Annotated retinal optical coherence tomography images (AROI) database for joint retinal layer and fluid segmentation. *Automa-tika: časopis za automatiku, mjerenje, elektroniku, računarstvo i komunikacije*, 62(3-4), 375-385.
- [7] Xue, X., & Du, W. (2024, January). Retinal fluid segmentation from OCT B-scan using swin-unet. In *2024 2nd International Conference on Computer Graphics and Image Processing (CGIP)* (pp. 1-6). IEEE.
- [8] Rashno, A., Nazari, B., Koozekanani, D. D., Drayna, P. M., Sadri, S., Rabbani, H., & Parhi, K. K. (2017). Fully-automated segmentation of fluid regions in exudative age-related macular degeneration subjects: Kernel graph cut in neutrosophic domain. *PloS one*, 12(10), e0186949.
- [9] Rashno, A., Koozekanani, D. D., Drayna, P. M., Nazari, B., Sadri, S., Rabbani, H., & Parhi, K. K. (2017). Fully automated segmentation of fluid/cyst regions in optical coherence tomography images with diabetic macular edema using neutrosophic sets and graph algorithms. *IEEE Transactionson Biomedical Engineering*, 65(5), 989-1001.
- [10] Ye, X., He, S., Zhong, X., Yu, J., Yang, S., Shen, Y., ... & Shen, L. (2023). Oimhs: An optical coherence tomography image dataset based on macular hole manual segmentation. *Scientific Data*, 10(1), 769.

[成果の発表, 論文など]

- [1] 薛 曉仲, 杜 偉薇, 三宅 正裕, 佐渡 恵奈. OCT の B スキャンにおける液体領域のセグメンテーション. 第 5 回日本眼科 AI 学会総会. 2025. 査読あり.
- [2] Xiaozhong Xue, Weiwei Du, Qinghua Hu, Masahiro Miyake, and Keina Sado. Fluid-SegNet: Multi-dimensional loss-driven Y-Net with dilated convolutions for OCT B-scan fluid segmentation. *Computerized Medical Imaging and Graphics*, Vol. 124, 102613, 2025. IF: 4.9.