

奥田 正浩(Masahiro Okuda, Dr.Eng.)
同志社大学 理工学研究科 情報工学専攻 教授
(Professor, Doshisha University, Graduate School of Science and Engineering)
IEEE 電子情報通信学会 他
研究専門分野:知能情報学、信号処理工学

あらまし

本文は、MRI や CT 画像などの高次元データから画 像特徴量を抽出する Radiomics 研究を用いて、脳腫瘍 患者の術後生存期間予測の精度を向上させる手法を提 案している。従来の手法では、2 次元スライス画像か ら得られる位置特徴や体積や表面積などの形状特徴を 用いていたが、3 次元空間における腫瘍の位置や形状 をうまく利用できていなかった。ここでは3次元点群 処理と Radiomics の特徴を組み合わせた手法を提案 している。提案手法は、点群特徴量のみを用いる手法 と、点群特徴量と他の特徴量を用いる手法の二種類あ り、それぞれランダムフォレスト分類器とk近傍法を 用いて生存期間予測を行う。実験により、提案手法が 従来の手法よりも精度が高くなることを示す。

1. 研究の目的

近年、MRIやCT画像などの高次元データから画像特 徴量を抽出する Radiomics 研究への関心が高まってお り、これまでに、外科、放射線治療、化学療法などに 応用すべく様々な研究が行われている。その中で、脳 腫瘍は、腫瘍の種類によって治療方法や予後が大きく 異なるため、手術・放射線治療・化学療法などを適宜 組み合わせた総合的な治療が必要となる。この治療方 針の決定に役立つ、生存期間予測などの多くの用途に Radiomics が活用されている。そこで本研究は、脳腫 瘍患者の術後生存期間予測の精度を向上させるための 一手法を提案する。

2. 研究の背景

関連研究では、腫瘍の位置や形状に関する特徴が生存期間予測に有効であることを示した Solitaniら[1] をはじめ、算出した形状や位置の特徴に基づき生存予 測を行う方法が多く提案されている。これらの従来手 法では、位置特徴として 2 次元スライス画像から得ら れる特徴を、形状特徴として体積や表面積などの特徴 を用いることが多い。また、ディープラーニングを用 いた手法では、スライス画像から腫瘍部をよく表現す る特徴を抽出することが多い。しかし、これら従来の 手法はいずれも、3 次元空間における腫瘍の位置や形 状をうまく利用できていない可能性がある。そこで、 本研究では、ディープラーニングを用いた3 次元点群 処理と Radiomics の特徴を組み合わせることで、脳腫 瘍患者の術後生存予測の精度を向上させることを目的 とする。

3. 提案手法

図 1に比較対象とするベースライン手法、図 2 に 3 次元点群処理を用いた生存期間予測の提案手法の概 要図を示す。 各手法は以下の特徴量を用いる。



3-1 ベースライン手法

Soltaniら[1]が提案した位置特徴と修正位置特徴を 用いた方法をベースラインとして使用する。参考文献 [1]で提案された位置特徴は、axial断面で最も腫瘍径 が大きいスライスから抽出される。改良された位置特 徴を以下に示す。

- 最大径のスライスにおける腫瘍領域の中心座 標と、脳中心から腫瘍までの距離
- 文献[1]で提案された位置特徴と、腫瘍が画像 上に現れたスライス、および腫瘍が画像上に 現れなくなる前のスライスから得られる腫瘍 部分の中心座標
- axial断面とは異なる断面(coronal断面、 segittal断面)から得られる、[1]で提案され た位置特徴量

さらにRadiomics 特徴量として、First Order

Statistics, Shape-based (2D, 3D), Gray Level Cooccurrence Matrix, Gray Level Run Length Matrix, Gray Level Size Zone Matrix, Neighboring Gray Tone Difference Matrix, Gray Level Dependence Matrix等を採

用した。

機械学習モデルは、ランダムフォレスト分類器(以降、RFC)と k 近傍法(以降、kNN)を用いる。

3-2 提案手法

提案手法の3次元点群処理モデルは、Point Transformer [3]、Point MLP [4]を使用し、比較する。 それらのモデルは、3次元形状を分類する点群データ セットであるModelNet [5]を用いて、事前学習を行う。 ここでは、3次元点群処理を用いた2種類の方法を比 較検討する。以下にそれぞれについて詳細を示す。

<u>手法1</u>:点群特徴量のみを用いる手法

一つ目は、点群による特徴量のみを用いる手法であ る。3次元点群処理モデルから得られた特徴量を入力 として、全結合層、バッチ正規化、活性化関数(ReLU 関数)、ドロップアウトのシーケンスを2回繰り返し、 最後に全結合層を用いて生存期間予測を行う。

手法2:点群特徴量と他の特徴量を用いる手法

二つ目は、点群特徴量、ベースラインで用いる位置 特徴量、Radiomics 特徴量を用いる手法である。3 次 元点群処理モデルから得られる特徴量を入力として、 全結合層・バッチ正規化・活性化関数(ReLU 関数)・ド ロップアウトを適用した出力と、位置特徴量と Radiomics 特徴量を入力として、全結合層・バッチ正 規化・活性化関数・ドロップアウトを適用した出力を 結合する。その後、再度全結層・バッチ正規化・活性 化関数・ドロップアウト・全結合層から構成される分 類層に、結合した特徴量を入力し、生存期間予測を行 う。

3-3 データセット

本研究では、BraTS2019 データセットを用いる。本 研究では、その中で、生存期間が登録されており、切 除状態が全切除(以降、GTR)および未登録(以降、NA) であるデータを使用する。この条件を満たしたデータ は、GTR が 101 件、NA が 107 件となる。

また、そのデータセットから点群データセットを構 築する。3 次元 MRI を二つの手法で点群化する。一つ 目は、マーチングキューブ法を用いて、メッシュ化し、 メッシュの頂点からなる点の集合を点群とする。この 方法で点群化した場合、点群の数がそれぞれで異なる ため、Farthest Point Sampling(以降、FPS)[6]を 用いてダウンサンプリングを行い、点群数を統一する。 二つ目の手法では、一つ目と同様にメッシュ化した後 に、サンプリングを行い、点群を生成する。点群デー タセットの作成で用いるサンプリング手法は、Poisson Disk Sampling(以降、PDS)[7]である。FPS と PDS それぞれを用いて、点群数が 1024、4096 の点群デー タセットを作成する。

3-4 実験

生存期間が 450 日未満か 450 日以上かを予測する 二値分類問題を取り扱う。切除状態 GTR と NA をそ れぞれ独立して実験を行う。

改良した位置特徴量の実験結果(ベースライン)を

Radiomics 解析のための高次構造テンソルを用いた多次元信号復元

表1に、3次元点群処理を用いた実験結果(提案手法) を表2と表3に示す。ベースライン手法のうち[1]の 特徴量をそのまま用いる手法を「baseline」とし、

「baseline」に、2.1 章で説明した、改良した位置特徴 量を加えた方法を「improved baseline」とする。

表2 と表3 には、実験名の前に、点群のサンプリン グ手法を記載している。例えば、「FPS_手法1」とは、 点群のサンプリング手法 FPS で手法1 を行うことを 表す。

表 1: ベースラインと改良した位置特徴量の結果.

E-m onim ont	Madal	Accuracy		
Experiment	Model	GTR	NA	
h a calin a	RFC	0.594	0.718	
baseline	kNN	0.604	0.719	
improved baseline	RFC	0.613	0.728	
improved baseline	kNN	0.623	0.729	

表 2:3 次元点群処理を用いた実験結果(GTR)

Number of Point Cloud	Model	Accuracy			
		FPS_手法1	FPS_手法 2	PDS_手法1	PDS_手法 2
1024	Point Transformer	0.6929	0.7319	0.6933	0.7619
	Point MLP	0.7633	0.7629	0.7629	0.7424
4096	Point Transformer	0.6838	0.7619	0.6833	0.7419
	Point MLP	0.7814	0.7619	0.7319	0.7619

表 3:3 次元点群処理を用いた実験結果(NA).

Number of Point Cloud	Model	Accuracy			
		FPS_手法1	FPS_手法 2	PDS_手法1	PDS_手法2
1024	Point Transformer	0.7476	0.7939	0.7848	0.7749
	Point MLP	0.8035	0.7848	0.8312	0.8035
4096	Point Transformer	0.7753	0.7753	0.8030	0.7848
	Point MLP	0.8039	0.8130	0.8225	0.7944

改善された位置特徴量と3次元点群を用いる方法の 両方が、baselineの精度を上回る結果となった。また、 提案手法は、baselineと improved baselineの精度を 上回ることができ、提案手法の有効性が示された。腫 瘍の位置や形状をよりよく表現できたため、精度が向 上したものと考えられる。

GTR と NA の両方で概ね Point MLP が Point Transformer の精度を上回り、Point MLP の構造が Point Transformer よりも位置・形状特徴を捉えやす いことが示唆された。また、Radiomics 特徴量と位置 特徴量の追加により、多くのケースで精度が低下した。 これは、学習データの少なさによるオーバーフィッテ ィングが原因と考えられる。

GTR では、FPS と PDS を使った精度を比較すると、 FPS を使った方が PDS を使った場合よりも精度が高 くなることが多い。一方、NA では、PDS を使用した 方が精度が高くなることが多い。また、サンプリング 方法によっても精度が異なるため、サンプリング方法 の選択も重要視されている。

点群数による精度の比較では、精度が上がるケースと 下がるケースがあった。1024 点群と4096 点群の実験 だけでは、精度と点群数の関係を正確に判断すること ができない。したがって、より多くの点群数を用いた 実験が必要である。

おわりに

本研究では、脳腫瘍患者術後生存期間予測の精度向 上のための位置特徴量の改良や3次元点群処理モデ ルを用いる手法を提案した。全ての実験において、ベ ースラインと比較して、高い数値が得られ、有効性を 示すことができた。

今後の展開としては、二つある。一つ目は、点群の データ拡張である。医用画像はデータ数が少なく、十 分に学習できない。データ拡張することができたら、 より精度向上できる可能性があると考えられる。二つ 目は、アンサンブル学習である。モデルによって捉え ている特徴が違うため、複数モデルを用いてアンサン ブル学習をすることで、より精度向上できる可能性が あると考えられる。

参考文献

- Soltani, M., Bonakdar, A., Shakourifar, N., Babaei, R. and Raahemifar, K.:Efficacy of Location-Based Features for Survival Prediction of Patients With Glioblastoma Depending on Resection Status, Frontiers in Oncology, Vol. 11 (2021).
- [2] van Griethuysen, J. J., Fedorov, A., Parmar, C., Hosny, A., Aucoin, N., Narayan, V., Beets-Tan, R.

G., Fillion-Robin, J.-C., Pieper, S. and Aerts, H. J.: Computational Radiomics System to Decode the Radiographic Phenotype, Cancer Research, Vol. 77, No. 21, pp. e104-e107 (2017).

- [3] Guo, M.-H., Cai, J.-X., Liu, Z.-N., Mu, T.-J., Martin, R. R. and Hu, S.-M.:PCT: Point cloud transformer, Computational Visual Media, Vol. 7, No. 2, pp. 187–199 (2021).
- [4] Ma, X., Qin, C., You, H., Ran, H. and Fu, Y.: Rethinking Network Design and Local Geometry in Point Cloud: A Simple Residual MLP Framework, International Conference on Learning Representations (2022).
- [5] Wu, Z., Song, S., Khosla, A., Yu, F., Zhang, L., Tang, X. and Xiao, J.:3d shapenets: A deep representation for volumetric shapes, Proceedings of the IEEE conference on computer vision and pattern recognition, pp.1912–1920 (2015).
- [6] Eldar, Y., Lindenbaum, M., Porat, M. and Zeevi, Y. Y.: The farthest point strategy for progressive image sampling, IEEE Transactions on Image Processing, Vol. 6, No. 9, pp. 1305–1315 (1997).
- [7] Bridson, R.: Fast Poisson disk sampling in arbitrary dimensions., SIGGRAPH sketches, Vol. 10, No. 1, p. 1 (2007).

この研究は、令和元年度SCAT研究助成の対象とし て採用され、令和元年~3年度に実施されたものです。 また、本報告は山崎仁氏が本学に在籍中に実施した研 究成果をまとめたものである。