


2023年度 修士論文概要

主査	舟橋健司	副査	本谷秀堅	研究室	舟橋研究室
入学年度	2022年度	学籍番号	34414060	氏名	鈴木康介

論文題目 生成モデルによるリンパ節転移有無の分類精度向上手法 (Improvement Method for Classification of Lymph Node Metastasis using Generative Model)

1 はじめに

CT画像による直腸がんの病期診断においては、リンパ節へのがん転移有無が重要視されている。しかし、画像診断は医師の負担が大きく、専門性が高いため医師の経験量によって診断にばらつきが生じるという問題がある。そのため機械学習による診断支援が望まれている。機械学習によるCT画像からのリンパ節分類の先行研究として文献[1]などがある。そのような研究において課題となるのが、データセットの入手である。CT画像を機械学習に用いるためには専門の医師によるアノテーションが必要となるため、大量のデータセットを構築するのは困難である。しかし、少量のデータセットでは複雑なモデルの学習を十分に行うことができない。そこで本研究では近年発展している生成モデルを活用することでデータセットの少なさを補う手法として、ESRGAN[2]による超解像手法と、Diffusionモデル[3]による画像生成手法を提案する。



(a) 入力 (b) SRCNN (c) ESRGAN

図 1: 超解像の例

の良い超解像手法を用いるほど Recall と F 値が向上していることが確認できた。超解像によって、G3 (転移あり) の正しい分類に必要な情報が復元できることが確認できた。一方で、Accuracy と Precision は単に拡大した場合の方が高いため、超解像が G1 (転移なし) の分類においてはノイズとなる可能性が示唆された。実際の診断においては F 値と Recall がより重要であり、ESRGAN を用いた場合の F 値は 85.57% で、文献[1]と比較すると専門医師の 85% に匹敵する性能であった。

表 1: 分類結果

超解像手法	Accuracy	Precision	Recall	F 値
なし	0.8000	0.9567	0.6333	0.7551
単に拡大	0.8715	1.000	0.7299	0.8391
SRCNN	0.8538	0.9215	0.7824	0.8444
ESRGAN	0.8688	0.9180	0.8018	0.8557

2 超解像処理

現在普及している CT スキャナの解像度は 512×512 である。その制約により失われた詳細な形状の情報を復元することで分類精度を向上させられると考え、リンパ節画像を分類用モデルに入力する前に超解像する手法を提案する。超解像モデルは CNN ベースの SRCNN と GAN ベースの ESRGAN を用いて比較した。超解像モデルの作成は、使用できるデータセットの解像度を考慮し、次の手順で行った。

- 512×512 ピクセルの CT 画像から、64×64 ピクセルまたは 128×128 ピクセルでクロップする。
- クロップした画像を縦横それぞれ 4 分の 1 に低解像度化する。
- 2 の画像を入力データ、1 の画像を正解データとして学習を行う。

学習の結果、図 1 のような超解像が可能となり、ESRGAN の方が高精度で CT 画像の超解像を行えることが確認できた。

次に、超解像したリンパ節周辺画像で 3DCNN の学習・推論を行うことで、超解像のリンパ節分類への影響について実験した。結果は表 1 のようになり、より精度

3 画像生成によるデータ拡張

Diffusion モデルで生成した画像をデータ拡張に使用することでデータセットの少なさを補うため、少量のデータセットからリンパ節分類のデータ拡張に使用可能な Diffusion モデルを作成する手法を提案する。G3 の生成用モデルは次の手順で学習を行った。

- G1 と G3 両方のデータを訓練データとして 100 エポック学習する。
- G3 のデータのみを訓練データとして 50 エポック追加学習する。

生成結果は図 2, 3 のようになった。G1 と G3 の両方で学習を行うことで、多様なリンパ節のような形状が中心に存在する画像が生成できた。さらに G3 のみで追加学習を行うことで、大きさなどが G3 の特徴を満たすリンパ節のような形状が存在する画像が生成できた。し

たがって、Diffusion モデルによって任意のがん転移状態のリンパ節画像を生成できることが確認できた。




図 2: 手順 1 完了時点での生成例




図 3: 手順 2 完了時点での生成例

次に、生成した G3 画像をデータ拡張に使用して CNN の学習を行い、データ拡張としての有効性を実験した。結果は表 2 のようになり、生成データ拡張によって Recall が向上しており、G3 の誤分類が減少したことがわかった。Diffusion モデルでの生成によって、単純なデータ拡張よりも多様性のあるデータの学習が可能となり、より多くの G3 を正しく分類できるようになったことが示された。一方で、生成データ拡張では G1 の誤分類が増えて Precision が低下しており、G3 の生成モデルが G1 と分類すべき画像を生成してしまうことによる悪影響が示唆された。

表 2: 分類結果

手法	Accuracy	Precision	Recall	F 値
単純データ拡張	0.8417	0.9372	0.7333	0.8218
生成データ拡張	0.8511	0.9064	0.7865	0.8416

生成データ拡張がより複雑なネットワークの学習にも有効かを確認するため、生成した G1 と G3 の画像を使用して、Vision Transformer (ViT) の学習を行なった。結果は表 3 のようになり、単純なデータ拡張を行った場合には Recall が極端に低く、学習が十分に進まずに G1 に偏った出力をするモデルになってしまうが、生成データ拡張は多様性のあるデータ拡張が可能であるため、少ない枚数でも効果があり、枚数を増やすほど性能が向上することが確認できた。各クラス 2000 枚の生成データ拡張を行った場合の F 値は 88.89% であり、文献 [1] において多量のデータセットで CNN を学習させた場合に匹敵する性能であった。一方で、2000 枚以上では生成データを増やしても精度が向上しておらず、生成モデルの出力の多様性に限界があることが示された。




図 4: G1 の生成例

表 3: ViT の分類結果

手法	Accuracy	Precision	Recall	F 値
1,000 枚 単純データ拡張	0.7000	1.000	0.4000	0.5714
500 枚 生成データ拡張	0.8333	1.000	0.6667	0.8000
1,000 枚 生成データ拡張	0.8333	1.000	0.6667	0.8000
2,000 枚 生成データ拡張	0.9000	1.000	0.8000	0.8889
4,000 枚 生成データ拡張	0.9000	1.000	0.8000	0.8889

4 むすび

本論文では、分類モデルの学習に使用できるデータセットが少ない場合における生成モデルの活用方法を 2 つ提案した。ESRGAN による CT 画像の超解像手法では、分類用モデルに入力する前処理として超解像処理をすることで、G3 の分類精度が向上することを示した。Diffusion モデルによる特定のクラスのリンパ節画像生成手法では、生成画像をデータ拡張として用いることで分類精度が向上することを示した。どちらの手法においても、少量のデータセットのみを使用して、先行研究における医師や大量のデータで学習した CNN に匹敵する分類精度のモデルが作成できることが確認できた。今後の展望として、超解像の学習に生成した画像を用いるなど、提案手法を組み合わせることによるさらなる分類精度の向上が挙げられる。

参考文献

- [1] A. Hartenstein, et al., “Prostate cancer nodal staging: using deep learning to predict 68Ga-PSMA-positivity from CT imaging alone,” Scientific reports, vol.10, no.1, p.3398, 2020.
- [2] X. Wang, et al., “ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks,” Proceedings of the European Conference on Computer Vision (ECCV) Workshops, Sept. 2018.
- [3] J. Ho, et al., “Denoising diffusion probabilistic models,” Advances in neural information processing systems, vol.33, pp.6840–6851, 2020.