

三次元医療データ超解像への 3D-SRCGANの応用

宮崎大学大学院 工学研究科 工学専攻
機械・情報系コース 情報システム工学分野

指導教員 椋木雅之

T2303219 倉永将宏

2025/01/30

背景


X線CT画像、MRI画像：医師が読影に使用

高解像度データ


利点：読影しやすい

問題点：放射線被爆やコスト

→低解像度データを高解像にする超解像の研究が盛ん



CT画像



MRI画像 2

超解像 (みやだいもうくんのLINEスタンプ)



低解像度画像





超解像画像

https://www.miyazaki-u.ac.jp/new_srelease/topics-info/32-line.html

三次元ボリュームデータの超解像

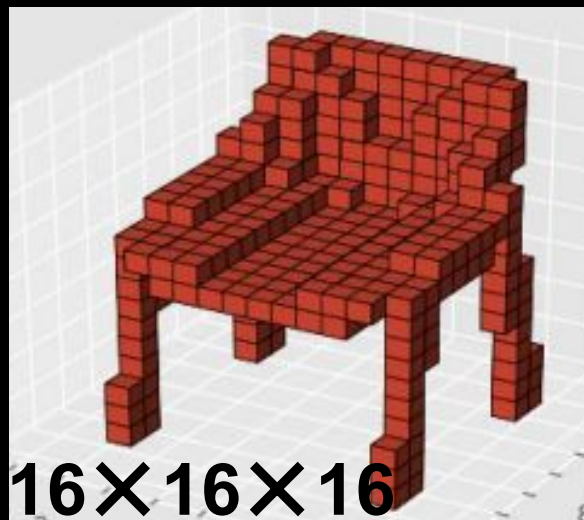
- ・CTやMRIの医療データは、三次元ボリュームデータである
- ・ボリュームデータは、濃度を多値で表現する



三次元ボクセルデータの超解像

三次元ボクセルデータの超解像の手法に3D-SRCGAN[1]がある

3D-SRCGANは、ボクセル超解像で非常に良い結果を残したので採用



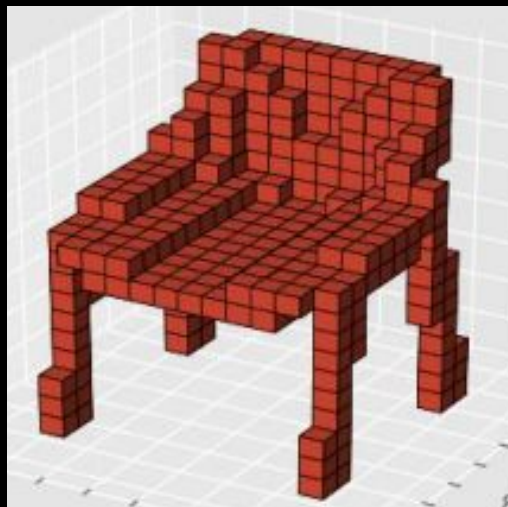
3D-SRCGAN



目的


3D-SRCGANを、医療データの超解像に応用

ボクセルとボリュームの性質の違いを 3つのポイントで実験、評価する



三次元ボクセルデータ

3D-SRCGANを
医療データへ応用



医療データ
(三次元ボリュームデータ)

1つ目のポイント: 損失関数 (Loss関数)

損失関数: 学習時に正解と出力の誤差を減らすために使用

ボクセル超解像[1]では、MSE Lossで十分であった

しかし、ボリューム超解像では構造が重要と考え以下の損失関数を使用

MSE Loss: 個々のデータの値の誤差を減らす

SSIM Loss: 構造的な類似度を近づける

MSE Loss + SSIM Loss: 上2つを組み合わせて同時に最適化


2つ目のポイント:パッチング

パッチング:データを小領域に分割し、領域ごとに学習する手法

- ・ボクセル超解像では、パッチングが有効ではない[2]
- ・二次元画像では、パッチングが有効

↑
↓
性質が近い
ボリュームデータ

パッチングの有効性を調査

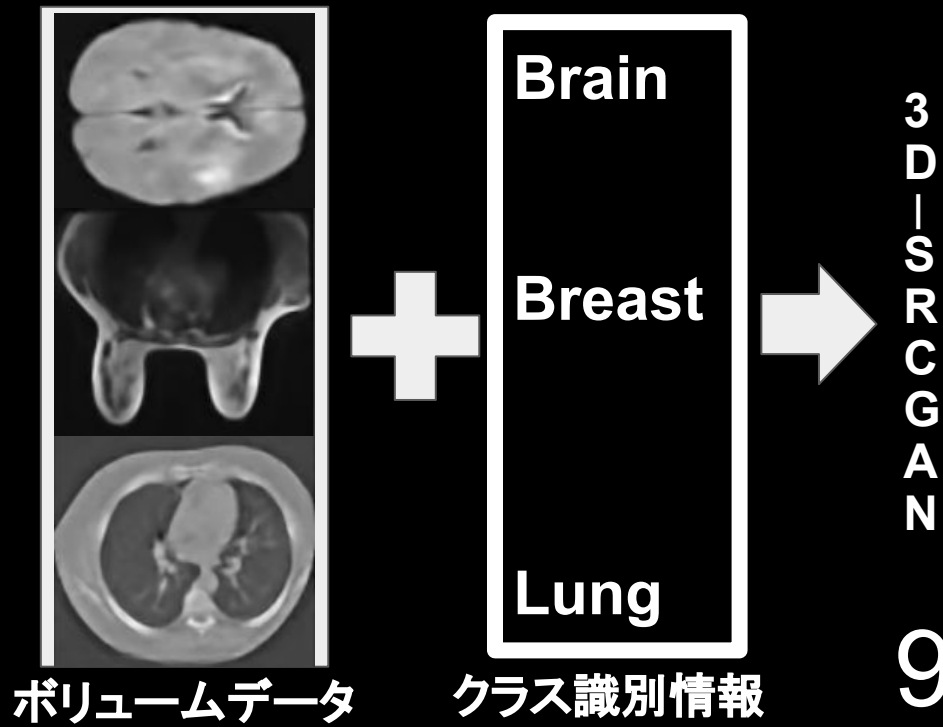


3つ目のポイント: クラス識別情報

クラス識別情報: データを特定のクラスに分類するために使用

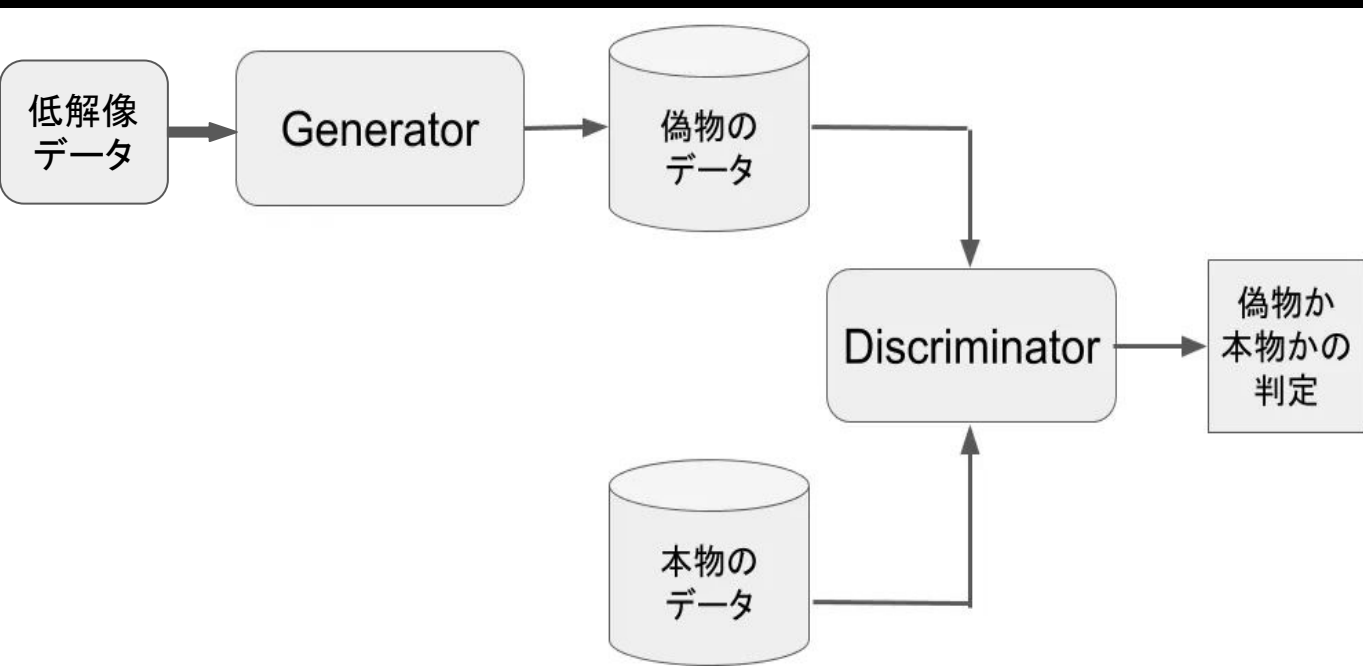
- ・二次元画像では有効ではない
- ・ボクセルデータでは有効[1]

ボリュームデータでの有効性を調査




3D-SRGAN

GAN: 本研究で使用する3D-SRGANの核の部分

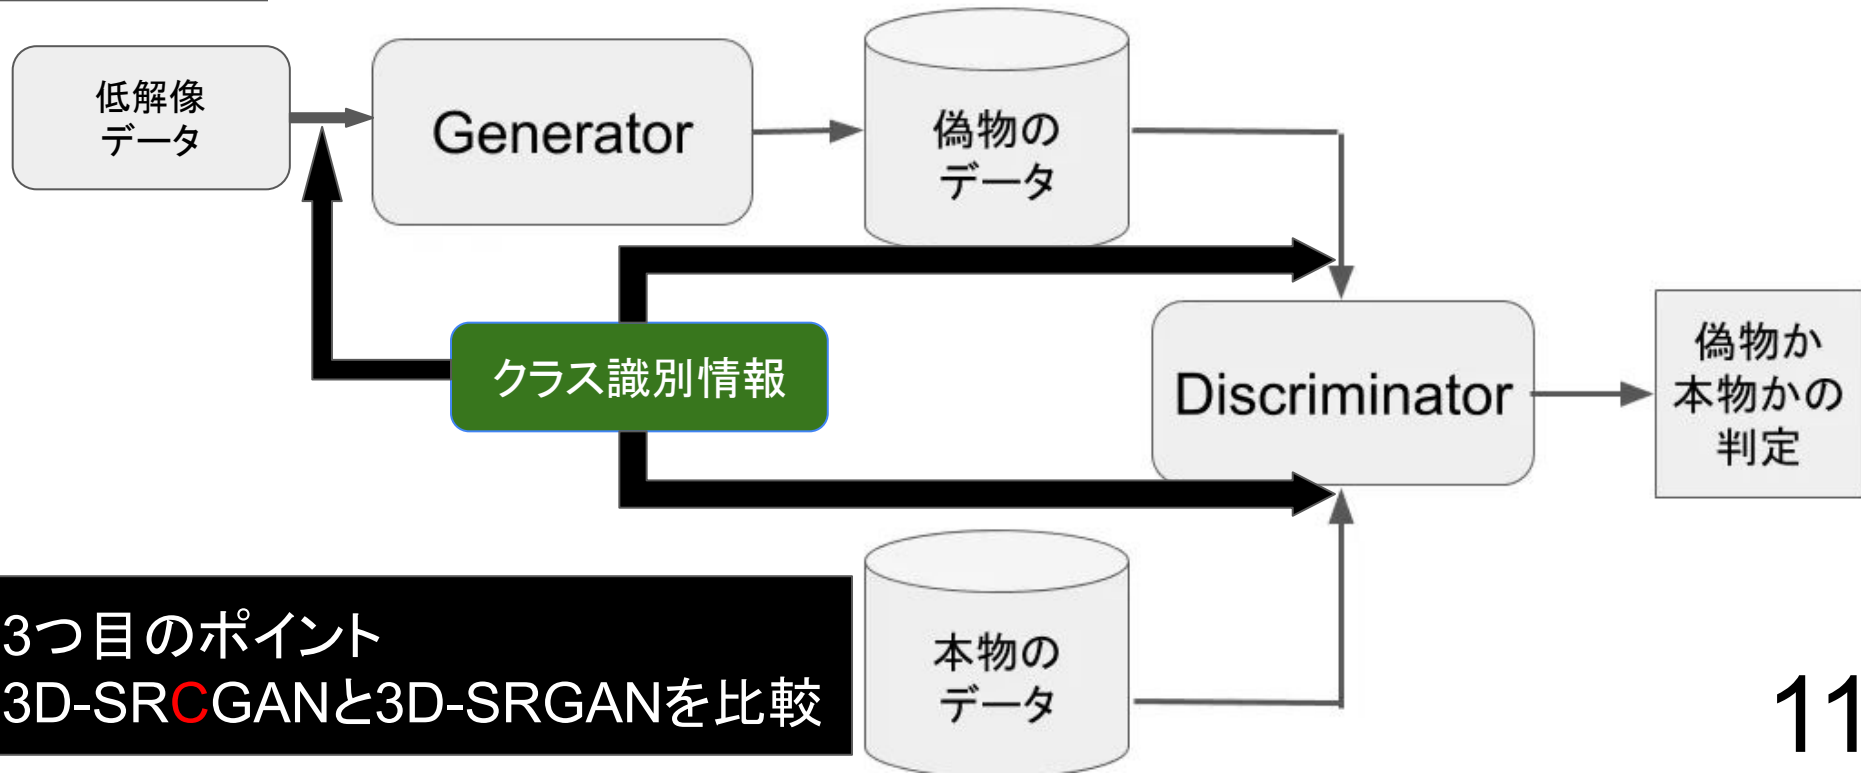


GANのネットワーク構造



3D-SRCGAN

C: クラス識別情報。それを付与することで各クラスの特徴が混ざらない



3つ目のポイント
3D-SRCGANと3D-SRGANを比較

実験

実験1 損失関数(SSIM)による精度向上の評価

実験2 パッチングによる精度向上の評価

実験3 クラス識別情報による精度向上の評価

評価方法

数値評価

・MSE : 正解との各画素値の誤差

$$\frac{1}{r^3 WHD} \sum_{x=1}^{rW} \sum_{y=1}^{rH} \sum_{z=1}^{rD} (l_{x,y,z}^{HR} - G(l^{LR})_{x,y,z})^2$$

・SSIM : 正解との構造の類似度

$$\frac{((2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2))}{((\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2))}$$

・PSNR : 正解とのノイズの比率


$$10 \log_{10} \left(\frac{L^2}{MSE} \right)$$

視覚評価

濃淡、ぼやけ、細かさ

実験データ


	数	形式	ソース
Brain	484	MRI	Medical Decathlon[3]
Breast	1510	MRI	Medical Decathlon[3]
Lung	553	CT	Cancer Imaging Archive[4]



Brain



Breast



Lung




実験1 - SSIMを損失関数としたときの精度向上の定量評価

		MSE Loss	SSIM Loss	MSE Loss + SSIM Loss
Brain	MSE↓	0.0003482	0.0004301	0.0003778
	SSIM↑	0.9700	0.9711	0.9716
Breast	MSE↓	0.002140	0.003357	0.002024
	SSIM↑	0.8703	0.8691	0.8836
Lung	MSE↓	0.07750	0.07773	0.07613
	SSIM↑	0.5994	0.6027	0.6626


MSE LossにSSIM Lossを加えたほうが優れていた

⇒ SSIMを損失関数として導入したほうが良い

実験1 - 視覚評価



低解像度画像



高解像度画像 16

実験2 - パッチングによる精度向上の定量評価




左: パッチングあり / 右: パッチングなし

		MSE Loss	SSIM Loss	MSE Loss + SSIM Loss
Brain	MSE↓	0.0003482 / 0.0003261	0.0004301 / 0.0003701	0.0003778 / 0.0003648
	SSIM↑	0.9700 / 0.9685	0.9711 / 0.9711	0.9716 / 0.9707
Breast	MSE↓	0.002140 / 0.002229	0.003357 / 0.002605	0.002024 / 0.002139
	SSIM↑	0.8703 / 0.8561	0.8691 / 0.8620	0.8836 / 0.8633
Lung	MSE↓	0.07750 / 0.08744	0.07773 / 0.07857	0.07613 / 0.07683
	SSIM↑	0.5994 / 0.4545	0.6027 / 0.5812	0.6626 / 0.6288



全体的にパッチングありのほうが優れていた

実験2 - 視覚評価

パッチングあり



パッチングなし




MSE Loss + SSIM Loss
18

実験3 - クラス識別情報 による精度向上の定量評価


		3D-SR C GAN	3D-SR G GAN
Brain	MSE↓	0.0004301	0.0004341
	SSIM↑	0.9711	0.9709
Breast	MSE↓	0.003357	0.003094
	SSIM↑	0.8691	0.8719
Lung	MSE↓	0.07773	0.07627
	SSIM↑	0.6027	0.6597

クラス識別情報の有効性は示されなかった

実験3 - 視覚評価



3D-SRcGAN



3D-SRGAN

クラス識別情報は、影響を与えない

まとめ

ボクセルデータ超解像のための 3D-SRCGANを、医療データ (ボリュームデータ) に応用し、3つのポイントから実験、検証した。

- ・ボリュームでは、SSIMを損失関数として使用する有効性が示された
- ・ボリュームでは、パッチングの有効性が示された
- ・ボリュームでは、クラス識別情報は有効性が示されなかった

今後の課題

- ・医師の協働のもと超解像結果を確認してもらう
- ・CT データを1分に収集し、超解像精度の向上を図る

参考文献

- [1] 野村淳也, 椋雅之, “クラス識別を導いた 3D-SRGAN によるボクセル超解像”, 令和 5 年度宮崎学学院学研究科 修論 (2024)
- [2] 岡和寿, 椋雅之, “SRGAN の 3 次元ボクセルモデル超解像への適用”, 画像電学会論誌, vol. 48, no. 4, pp. 448-496 (2019)
- [3] Medical Decathlon, <http://medicaldecathlon.com/dataaws/>
- [4] Cancer Imaging Archive, <https://www.cancerimagingarchive.net/>