

条件付 GAN を用いた低線量 X 線画像の高周波成分復元による超解像化 Low dose X-ray Image Super-resolution by High Frequency Component Restoration Using conditional GAN

栗原 慧至[†] 濱上 知樹[†]
Satoshi Kurihara Tomoki Hamagami

1. はじめに

医療分野において放射線を用いた X 線画像等が多く利用されているが、同時に医療被ばくの増加による影響も懸念されている[1]. ここで、具体的に問題となるのが線量と画質のトレードオフの関係である. 一般に高線量で撮影した場合は高画質の画像が得られるが患者の被ばく量は増加し、低線量で撮影した場合は患者の被ばく量は減少するが量子ノイズの増加により画質は低下する. 被ばくによる患者の負担を考慮すると、低線量での撮影が望ましい.

従来より、低線量で撮影した X 線画像で発生するノイズを軽減する研究が行われており、近年では畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)を利用した超解像化やデノイズの手法が提案されている. しかし、これらの手法では学習時の損失関数として出力画像と正解画像の平均 2 乗誤差(Mean Squared Error: MSE)を利用しており、ネットワークの出力画像が正解画像に平均的に近くなるため、出力画像は高周波成分が失われたぼやけた画像となることが課題として挙げられる.

そこで、本稿では患者の被ばく量を抑えながらも鮮明な画像を得られるよう、画像の生成モデルを利用した超解像化技術によって低線量 X 線画像の画質向上を行う手法を提案する.

2. 提案手法

提案手法の概要は図1のように示され、処理は大きく2つの部分に分かれている. 1つ目が入力として与えられる低線量 X 線画像を高周波成分と低周波成分に分離する部分であり、2つ目が画像の生成モデルを用いて高周波成分を復元した画像を生成する部分である. 最後に入力画像の低周波成分と復元した高周波成分を加算することで、超解像化した画像を得る.

2.1 画像の生成モデルによる復元

提案手法では、低線量 X 線画像の周波成分のうち、ノイズの影響が大きい高周波成分から高線量 X 線画像の高周波成分に相当する画像を復元するために条件付 GAN (conditional Generative Adversarial Network) と呼ばれる画像の生成モデル[2]を利用する.

2.2 画像の周波数分離

Guo らの研究[3]では残差ネットワーク(ResNet)において輝度値が 0 である画素を含むスパース性のある学習データを用いると学習が容易になると指摘している. ResNet と条件付 GAN で用いられている U-Net はフィルタの係数を調整することで等価な構造を持つと考えられ、U-Net においても学習データでのスパース性の利点が活かされると期待で





図1 提案手法の概要



(a) ガウシアンフィルタによる分離 (b) 空間周波数領域上での分離
図2 提案手法における周波数分離

きる. このことから、提案手法では低線量 X 線画像からスパース性を抽出するため画像の周波数分離を導入している. 具体的な周波数分離方法として次の2つの方法を試みた.

- (a) ガウシアンフィルタを用いた周波数分離
- (b) 空間周波数領域上での周波数分離

図2に示すように、(a)は低線量 X 線画像にガウシアンフィルタを複数回適用することによって低周波成分を生成し、低線量 X 線画像と低周波成分の差分から高周波成分を抽出する方法である. (b)では低線量 X 線画像をフーリエ変換した際の空間周波数領域上でローパスフィルタを通過させて低周波成分を抽出し、低線量 X 線画像と低周波成分の差分から高周波成分を抽出する方法である.

3. 実験

3.1 実験設定

提案手法の超解像化の性能を比較する実験を行った. 比較を行う手法は次の4つである.

- (1) 提案手法
 - (a) ガウシアンフィルタを用いた周波数分離
 - (b) 空間周波数領域上での周波数分離
- (2) 条件付 GAN (入力画像の周波数分離なし)
- (3) CNN-1 (入力画像の周波数分離あり)
- (4) CNN-2 (入力画像の周波数分離なし)

手法(2)では提案手法と同じ条件付 GAN を用いるが周波数

[†] 横浜国立大学大学院理工学府

分離を行わず低線量X線画像から直接、高線量X線画像の復元を行う。また手法(3), (4)は損失関数としてMSEを用いている4層の畳み込み層を持つCNNである。学習データにおいては低線量画像と高線量画像のペアを訓練用として226組、テスト用として20組を用意している。

3.2 実験結果

3.2.1 視覚的評価

図3に各手法で得られた出力の画像を示す。提案手法(a)の出力は高周波成分の復元が他手法よりも顕著に行われていることが確認できるが、肋骨の形状がもとの形から変形していることが確認できる。

3.2.2 定量的評価

各手法の出力と高線量X線画像との画質の比較を画像の構造的類似度を評価するSSIM(Structural Similarity)と平均的な誤差を評価するPSNR(Peak Signal-to-Noise Ratio)によって行った。いずれの評価値においても低線量X線画像より高いスコアが得られた。SSIMでは提案手法(a)が最も良い評価であったが、PSNRでは提案手法は比較的低いスコアとなった。

3.2.3 学習曲線の変化

条件付GANを用いた手法において各生成器のイテレーションごとの損失の推移をみると、ガウシアンフィルタを用いた提案手法において損失が低く、安定していることが分かった。このことから、スパース性の利点が活かされていると考えられる。

4. 提案手法における改善

ガウシアンフィルタを用いた提案手法の実験結果において、視覚的評価では肋骨の変形が見られ、定量的評価ではPSNRの低下が確認された。以下ではそれらに対して行った改善について述べる。

4.1 肋骨の変形の改善

図4(a)に示すように出力画像を64分割し、各部分のSSIMを測定すると肋骨が存在する領域が他の部分より比較的低いことが分かった。そこで、肋骨部分の変形の抑制を目的として枠線で囲まれた領域のSSIMが向上するよう損失関数に対して(1)式のように各領域のSSIMの値である $SSIM_i$ をペナルティとして加えて生成器の学習を行った。SSIMは最大値が1であるので、SSIMが低いほど損失が大きくなるように1から $SSIM_i$ を減算している。また、 t は判別器の入力が本物であることを表すラベルであり、 x および y はそれぞれ低線量および高線量X線画像を表す。 $G(x), D(x, G(x))$ はそれぞれ生成器の出力およびそれが入力されたときの判別器の出力であり、 λ は定数である。

$$\mathcal{L} = \text{CrossEntropy}(t, D(x, G(x))) + \lambda \|y - G(x)\|_1 + \lambda \sum_i (1 - SSIM_i) \quad (1)$$

損失関数の変更にて得られた出力の評価結果は図4(b)のようであり、肋骨の部分のSSIMが向上し、視覚的にも変形が抑えられている部分が存在するが、反対にそれ以外の部分では値が低下している。このことから、CNNでは画像中の全画素とフィルタの係数は共有しているため、構造や周波数成分が異なる肋骨や臓器が混在しているX線画像を一つのネットワークで学習する場合、ある部分の画質が向上しても性質の異なる他の部分では画質の低下が起きるようなトレードオフの関係が存在すると考えられる。




図3 各手法の出力結果




図4 提案手法の概要

4.2 PSNR 低下の改善

PSNRは平均2乗誤差によって定まるので、比較対象の画像の輝度値が全体的に低下すると、その分誤差は増加しPSNRも低下する。よって、提案手法の出力のPSNRが低いことは、低線量画像の低周波成分におけるノイズの存在により輝度値が全体的に下がっていることに起因すると考えられる。そこで、低周波成分に対しても高線量画像の低周波成分に近づくような超解像化を行ったところ、SSIMの値は維持しつつPSNRは大幅に向上した。

5. おわりに

本稿では、低線量X線画像を低周波成分と高周波成分に分離し、条件付GANを用いてその高周波成分を復元する超解像化を行った。実験結果より、提案手法の有効性が示されスパース性の利点も利用できていることが分かった。また、1つのネットワークで画像全体を学習することでそれぞれ性質が異なる肋骨部分とそれ以外の部分でトレードオフの関係が存在する示唆も得られた。今後の課題として、X線画像において部位ごとに認識を行い、超解像化を行う手法の構築が求められる。

参考文献

- [1] 遠藤 啓吾: 暮らしの中の放射線ばくばく — 医療被ばくの現状 —, https://www.kantei.go.jp/saigai/senmonka_g65.html
- [2] P. Isola and J. Y. Zhu and T. Zhou and A. A. Efros, "Image-to-Image Translation with Conditional Adversarial Networks", IEEE Conference on Computer Vision and Pattern Recognition, (2017).
- [3] T. Guo, H. S. Mousavi, T. H. Vu and V. Monga, "Deep wavelet prediction for image super-resolution", The IEEE Conference on Computer Vision and Pattern Recognition Workshops, (2017).