

識別器からのフィードバック機構を備えた敵対的学習 による Cone-beam CT 画像の画質改善

羽瀬 拓視¹ 中尾 恵¹ 今西 勁峰² 中村 光宏³ 松田 哲也¹

概要: Cone-beam CT (CBCT) は治療中の体位で撮像できるため放射線治療や手術支援に利用されているが、再構成によって得られる画素が不正確で一部にアーチファクトや欠損が発生する。近年では Generative Adversarial Network (GAN) による画像変換を用いて医用画像の画質向上を目指した研究が試みられているが、従来 GAN における識別器の大局的な評価値に基づく敵対的学習では、局所的に異なる画像特徴に対して十分な変換性能が得られない点が課題となっている。本研究では CBCT 画像の画質改善を目的に、識別器から生成器へのフィードバック機構を備えた敵対的学習を提案する。本方法では、識別器に入力画像に対する局所的な識別結果を出力するチャンネルを追加し、その出力と入力画像を結合して生成器へ入力する。78 例の対応する CT-CBCT 画像を用いて敵対的学習とテストを行った結果、提案手法が従来 GAN より多様な画像特徴に対応した変換を実現し、CBCT 画像の画質改善に有効であることを確認した。

キーワード: 教師なし学習, 敵対的生成ネットワーク, Cone-beam CT, アーチファクト低減

Improving Cone-beam CT Image Quality by Adversarial Learning with a Feedback Mechanism from Discriminator

TAKUMI HASE¹ MEGUMI NAKAO¹ KEIHO IMANISHI² MITSUHIRO NAKAMURA³ TETSUYA MATSUDA¹

Abstract: Cone-beam CT (CBCT) is used for radiotherapy and surgical support because it can be used to image the patient in the position during treatment, but the pixels obtained by reconstruction are inaccurate and some artifacts and defects occur. In recent years, research has been conducted to improve the image quality of medical images using image transformation based on Generative Adversarial Network (GAN). However, adversarial learning based on the global evaluation of the discriminator in GANs does not provide sufficient transformation performance for locally different image features. In this study, we aim to improve the image quality of CBCT images. We propose an adversarial learning method with a feedback mechanism from the discriminator to the generator. As a result of adversarial learning and testing on 78 corresponding CT-CBCT images, we found that the proposed method achieves better transformation for various image features than the conventional GAN, and improves the image quality of CBCT images.

Keywords: Unsupervised learning, Generative adversarial network, Cone-beam CT, Artifact reduction

1. はじめに

近年、臨床医学における 3 次元イメージングにおいて、

¹ 京都大学大学院情報学研究科
Graduate School of Informatics, Kyoto University

² イーグロース株式会社
e-Growth Co., Ltd.

³ 京都大学大学院医学研究科
Graduate School of Medicine, Kyoto University.

Computed Tomography (CT) に加えて、Cone-beam Computed Tomography (CBCT) の利用機会が増加している。CBCT は小型かつ可動型のイメージング装置であり、治療用のベッドに固定できるため、外科手術や放射線治療において治療直前や治療中の姿勢で患者の 3 次元画像を取得することができる。一方で信号特性の違いから、再構成後の画像内に広範囲かつ多様なアーチファクトが生じる [1]。こ

のアーチファクトの影響により、CBCT 画像における画素値は CT 画像と比較して不正確であり、医用画像解析における精度低下の要因となっている。CT 画像に内在する生体組織と画素間の関係性、統計的知識を活用して、CBCT 画像の画質を改善することができれば、手術支援や放射線治療における利用拡大を見込むことができ、新たな診断、治療プロセスの創出に繋がるのが期待できる [2][3]。

医用画像の画質改善を目的とした深層学習の枠組みは多くの研究例が存在する [4]。医療現場においては同一患者を対象に完全に構造が一致した画像群を得ることは容易ではないため、近年では 1 対 1 に対応が取られた目標画像を前提としない教師なし学習が広く研究されており、特に敵対的生成ネットワーク (Generative Adversarial Network, GAN) [5] やその拡張である CycleGAN[6] の応用が試みられている。これまでに CT 画像に含まれる歯科金属アーチファクトや頭頸部 CBCT 画像のアーチファクト低減に CycleGAN の枠組みが有効であることが報告されている [7][8][9]。一方、CBCT 画像におけるアーチファクトは、複数の発生要因から生じるために多様な画像特徴を示し、また画像内の広範囲に渡って存在する。このため、従来研究で提案された学習の枠組みや損失関数の正則化 [10][11] によっても十分な画質改善が達成されない場合が存在する。この画像変換性能の限界の一要因として、従来の GAN や CycleGAN における識別器が目標画像か否かを大域的な評価値によってのみ評価している点が挙げられる。大域的な評価では局所的に異なる特徴を有する画像特徴に対して十分な変換性能が得られないことが報告されている [12]。局所的に異なる画像特徴を捉えつつ、多様な画像生成を実現する敵対的学習、画像変換の達成は依然課題である。

本研究では、CBCT 画像の画質改善を目的とした新たな教師なし学習の枠組みとして、識別器からのフィードバック機構を備えた敵対的学習を提案する。従来の GAN では、識別器が出力する大域的な識別結果に基づいて敵対的学習が行われてきたが、提案方法では局所識別マップを出力する識別器へと拡張して用いる。ここで、局所識別マップとは、画素単位で入力画像が目標画像である確率を算出して格納した画像であり、生成画像と目標画像間に見られる画像特徴の差に関する局所的な評価を得ることを目的としている。また従来の GAN では、識別器による識別結果は損失関数における評価にのみ用いられてきた。提案する敵対的学習の枠組みでは、識別器が出力する局所識別マップを生成器へ追加的に入力するフィードバック機構を導入する。生成器に注目すべき画像特徴や局所領域に関する情報を与えることで、より多様な画像特徴の生成能力の獲得を促し、画像変換性能の向上を目指す。

提案方法による CBCT 画像の画質改善への有効性を確認するために、前立腺がんに対する放射線治療を受けた 76 例を対象に、治療前に撮像された CT 画像と治療当日に撮

像された CBCT 画像を用いて敵対的学習を行った。従来の CycleGAN による画像変換を比較対象として、CBCT 画像から変換された画像と対応する CT 画像間で、前立腺周辺の関心領域における画素値の定量評価を行った。また、複数の変換結果を対象に CBCT 画像に見られるアーチファクトの低減や欠損領域の復元結果を視覚的に確認し、提案する敵対的学習による画像変換性能と有効性を調査した。

2. 提案手法

本研究の目標は、CBCT 画像群 $X = \{x_{r,1}, x_{r,2}, \dots, x_{r,n}\}$ 及び CT 画像群 $Y = \{y_{r,1}, y_{r,2}, \dots, y_{r,n}\}$ を対象に、 X から Y への画像変換を求める新たな敵対的学習の枠組みを構築し、CBCT 画像が有する多様なアーチファクトの低減、画質改善を達成することである。本研究では、 $x_{r,k}, y_{r,k}$ ($k = 1, 2, \dots, n$) はそれぞれ同一患者から取得された画像とするが、CBCT 画像、CT 画像は異なる日時に撮像されるため両者の解剖学的構造は厳密には一致していない。以降、対応する CBCT 画像、CT 画像をそれぞれ x_r, y_r と簡略化して表記する。また提案する敵対的学習の枠組みにおいて、 G_Y を $X \rightarrow Y$ の画像変換を行う生成器、 G_X を $Y \rightarrow X$ の画像変換を行う生成器とし、 D_X を入力画像が画像群 X に属する確率を出力する識別器、 D_Y を入力画像が画像群 Y に属する確率を出力する識別器とする。

2.1 フィードバック機構を備えた敵対的学習

従来の GAN では、生成画像に対して識別器による大域的な識別結果が 0 から 1 のスカラー値として算出され、損失関数における評価にのみ用いられてきた。しかし大域的な評価のみでは局所的に異なる特徴を有する画像に対して十分な変換性能は得られない [10][11]。提案手法では識別器 D_Y と生成器 G_Y をそれぞれ拡張し、敵対的学習の中で識別器 D_Y が蓄積してきた各画像群における注目領域、局所の画像特徴に関する情報を生成器 G_Y にフィードバックする構造を導入することで、局所的に異なる画像特徴に対する変換性能の向上を目指す。

2.1.1 識別器の構造

図 1 に示すとおり、提案手法では従来 GAN における識別器を拡張し、U-netGAN[12] を参考に本ネットワークに U-net[13] を採用する。この U-net 型識別器 D_Y は入力画像に対して従来通りの大域的な識別結果 d_y^G に加えて、新たに局所識別マップ d_y^L を出力する。ここで局所識別マップ d_y^L とは、画素単位で入力画像が目標画像である確率を算出して格納した画像であり、入力された画像と目標画像との間に見られる画像特徴の違いに関する局所的な評価を得ることを目的としている。

U-net 型識別器の学習時には、目標画像 y_r に加えて、生成器から出力される生成画像 y_f を入力する。このとき、目標画像 y_r が入力された場合はすべての画素が白の局所識

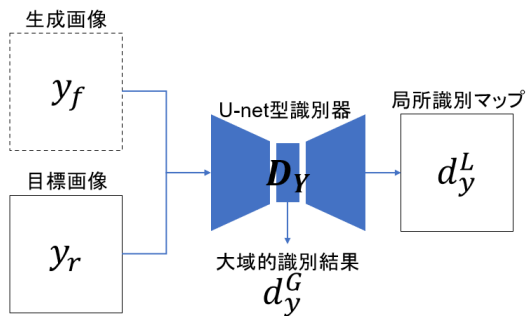


図 1 U-net 型識別器の構造

別マップを、生成画像 y_f が入力された場合はすべての画素が黒の局所識別マップを出力するように学習を進める。これにより、識別器は目標となる画像群 Y が有する画像特徴を学習し、生成画像 y_f 内に局所的に画像群 Y と異なる画像特徴が存在する場合に低い確率を与えるような局所識別マップ d_y^L を出力可能となる。

以上の U-net 型識別器 D_Y による出力に合わせて、学習時に用いる損失関数を従来から拡張する。大域的な識別だけでなく局所的な識別の精度も向上させるために、式 (1) と式 (2) を識別器に対する損失関数として定義する。

$$\mathcal{L}_{d_y^G} = E_y \|d_y^G(y_r) - 1\|_1 + E_y \|d_y^G(y_f) - 0\|_1 \quad (1)$$

$$\mathcal{L}_{d_y^L} = E_y \left[\sum_{i,j} [\|d_y^L(y_r) - 1\|_1]_{i,j} \right] + E_y \left[\sum_{i,j} [\|d_y^L(y_f) - 0\|_1]_{i,j} \right] \quad (2)$$

ここで、 i, j は画素の位置である。式 (1) は従来と同様、U-net 型識別器 D_Y による大域的な識別結果 d_y^G の精度を向上させるための損失関数であり、この損失を小さくするように学習が進むと、U-net 型識別器 D_Y は入力画像が目標画像であるか生成画像であるかを識別可能となる。式 (2) は新たに追加した損失関数であり、同時に局所識別マップ d_y^L の精度を向上させることを要請する。本損失を小さくするように学習が進むと、U-net 型識別器 D_Y は入力画像の各画素が目標画像か否かを局所的に識別可能となる。以上の 2 つの損失の線形結合によって、U-net 型識別器 D_Y に対する損失関数を式 (3) のように定義する。

$$\mathcal{L}_{D_Y} = \mathcal{L}_{d_y^G} + \mathcal{L}_{d_y^L} \quad (3)$$

ここで線形結合の際の重みについては、U-netGAN[12] を参考に 1.0 としている。

$X \rightarrow Y$ の画像変換において、元画像を識別器に入力した際に得られた局所識別マップと学習途中において生成画像及び目的画像を入力した際に得られた局所識別マップの例を図 2 に示す。上段は識別器 D_Y に入力した各画像、下段はそれぞれの局所識別マップであり、各局所領域が有す




図 2 局所識別マップ d_y^L の例、(a) 元画像 x_r と局所識別マップ、(b) 生成画像 y_f と局所識別マップ、(c) 目標画像 y_r と局所識別マップ

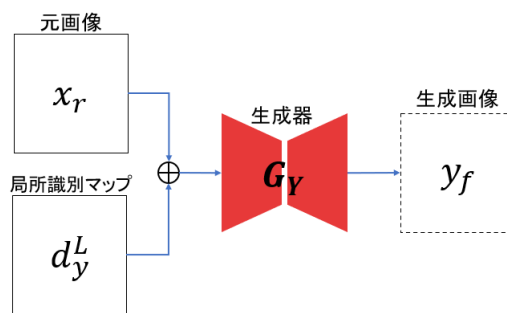


図 3 生成器の構造

る画像特徴が画像群 Y に属する確率が空間的に表現されている。(a) の局所識別マップは、画像の大部分が黒に近い灰色となっており、元画像 x_r 、すなわち入力された CBCT 画像は CT 画像と特徴が異なる領域が多いことが表現されている。一方、(c) の局所識別マップは白に近い画素が大部分を占めており、目標画像である CT 画像 y_r が入力された場合は、その画素単位で算出される局所領域の画像特徴についても画像群 Y に属する確率が高いことが表現されている。(b) は学習途中の生成画像 y_f が入力された場合の局所識別マップであり、(a) と比較して全体的に白に近い灰色の画素が多くなっているが、(c) と比較すると局所的には黒に近い画素が依然多く存在する。これは学習が進んだ識別器 D_Y が、生成画像において画像群 Y の有する特徴とは異なる領域に対して低い確率を与えた結果である。提案する画像変換ネットワークでは、このように U-net 型識別器から出力された局所識別マップ d_y^L を生成器 G_Y にフィードバックすることで生成器 G_Y の変換性能の向上を目指す。

2.1.2 生成器の構造

提案手法では識別器 D_Y から出力される局所識別マップ d_y^L を画像変換に活用するために、識別器 D_Y から生成器 G_Y へのフィードバック機構を導入する。図 3 に示す通り、生成器 G_Y の入力チャンネルを変更し、元画像 x_r と局所識

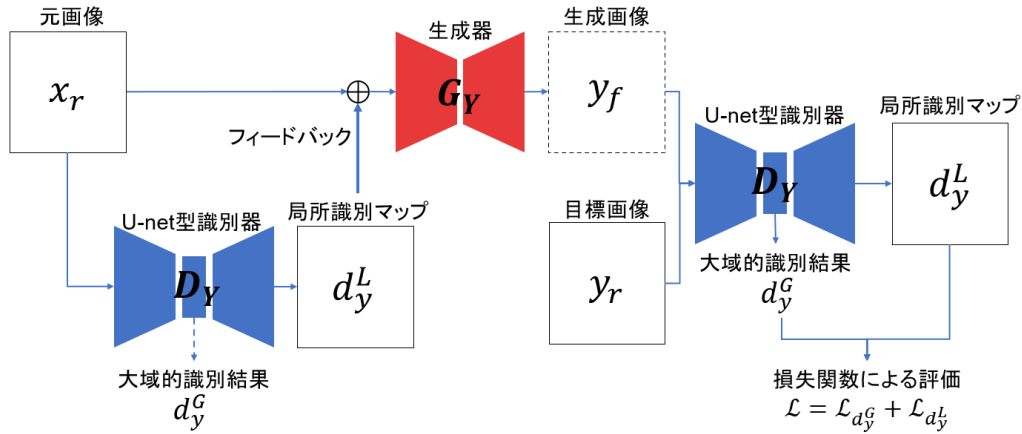


図 4 フィードバック機構を備えた敵対的学習

別マップ d_y^L を結合して入力可能なネットワークとする。出力は従来と変わらず、生成画像 y_f のみを出力する。

この生成器 G_Y には、事前に識別器 D_Y へ元画像 x_r が入力されることによって得られる局所識別マップ $d_y^L(x_r)$ が追加的に入力される。このとき図 2(a) に示したように、学習が進んだ識別器 D_Y から出力される局所識別マップには画像群 Y が有する特徴と異なる領域に対して低い確率、すなわち、黒に近い画素が与えられる。この局所識別マップ d_y^L をフィードバックすることで生成器 G_Y は識別器が注目する局所領域や画像特徴を直接的に受け取ることが可能になり、より多様な画像特徴の生成能力を獲得し、敵対的学習による画像変換性能が向上することが期待される。

敵対的学習において、生成器 G_Y の画像変換に局所識別マップ d_y^L を活用し、より多様な画像特徴の生成能力の獲得を促すために、以下の式 (4) を生成器 G_Y に対する損失関数として定義する。

$$\begin{aligned} \mathcal{L}_{G_Y} = & E_y \|d_y^G(y_f) - 1\|_1 \\ & + E_y \left[\sum_{i,j} [\|d_y^L(y_f) - 1\|_1]_{i,j} \right] \end{aligned} \quad (4)$$

第 1 項は従来と同様、識別器 D_Y に生成画像 y_f を入力した際の大域的識別結果に対する評価であり、生成画像が識別器 D_Y によって目的画像群 Y に属する評価を得ることを目指すための損失となっている。第 2 項は新たに追加した項であり、識別器 D_Y に生成画像 y_f を入力した際の局所識別マップに対する評価である。この項により生成画像が局所的にも画像群 Y に属する評価を得ることを目指すための損失として設計した。本損失関数によってネットワークの重みパラメータを更新することで、生成器 G_Y に局所識別マップ d_y^L を効果的に活用した画像変換の学習を促す。

2.1.3 局所識別マップを活用した敵対的学習

以上の識別器 D_Y と生成器 G_Y を組み合わせることで、 $X \rightarrow Y$ の画像変換において局所識別マップをフィード

バックとして活用した敵対的学習を実現する。そのネットワーク構造と学習時における入出力を図 4 に示す。またこのとき、全体の損失関数は式 (3) と式 (4) の線形和である式 (5) として定義される。

$$\mathcal{L} = \mathcal{L}_{D_Y} + \mathcal{L}_{G_Y} \quad (5)$$

2.2 双方向画像変換への拡張

本研究で変換対象としている CBCT 画像群 X と CT 画像群 Y には、アーチファクトの差違や画素値が不正確であるという差違は存在するが、一方で解剖学的構造などにおいて共通の特徴を多く備えている。そのため従来の CycleGAN に用いられていたサイクル一貫性損失を考慮した敵対的学習が、本研究の目的を達成するためにも有効であると考えられる。 $X \rightarrow Y$ の画像変換と $Y \rightarrow X$ の画像変換とでサイクルを構築したネットワークを図 5 に示す。

また、 $X \rightarrow Y$ の画像変換と同様の損失関数を用いて $Y \rightarrow X$ の画像変換についても学習を進める。式 (6) を識別器 D_X に対する損失関数として定義する。

$$\mathcal{L}_{D_X} = \mathcal{L}_{d_x^G} + \mathcal{L}_{d_x^L} \quad (6)$$

$$\mathcal{L}_{d_x^G} = E_x \|d_x^G(x_r) - 1\|_1 + E_x \|d_x^G(x_f) - 0\|_1 \quad (7)$$

$$\begin{aligned} \mathcal{L}_{d_x^L} = & E_x \left[\sum_{i,j} [\|d_x^L(x_r) - 1\|_1]_{i,j} \right] \\ & + E_x \left[\sum_{i,j} [\|d_x^L(x_f) - 0\|_1]_{i,j} \right] \end{aligned} \quad (8)$$

そして生成器 G_X に対しても以下の式 (9) を損失関数として定義する。

$$\begin{aligned} \mathcal{L}_{G_X} = & E_x \|d_x^G(x_f) - 1\|_1 \\ & + E_x \left[\sum_{i,j} [\|d_x^L(x_f) - 1\|_1]_{i,j} \right] \end{aligned} \quad (9)$$

さらに従来の CycleGAN に対する損失関数に含まれてい




図 5 フィードバック機構を備えた敵対的学習の全体像

たサイクル一貫性損失を加えて、目的関数は

$$\mathcal{L} = \mathcal{L}_{D_Y} + \mathcal{L}_{G_Y} + \mathcal{L}_{D_X} + \mathcal{L}_{G_X} + \lambda_{cycle} \mathcal{L}_{cycle} \quad (10)$$

となる。そして下式 (11) の最適化問題を解くことが提案するフィードバック機構を備えた敵対的学習の目的である。

$$G_Y^*, G_X^* = \arg \min_{G_Y, G_X} \max_{D_Y, D_X} \mathcal{L} \quad (11)$$

学習時の識別器 D と生成器 G の学習速度について、一般的に敵対的学習においては識別器 D の学習の方が早く進むことが知られており [5], 本手法の場合でも同様であると考えられる。識別器 D の学習が進んでいない序盤において、生成器 G はフィードバック情報としては振幅が大きな局所識別マップを受け取ることになる。その場合、生成器 G は様々な変換を試みると考えられる。識別器 D の学習が十分に進むと、局所識別マップが定常状態に近づくと考えられるため、その情報を受け取った生成器 G の学習が急速に進むと予想される。

そして学習終盤では、目標画像が有する特徴とは異なる特徴を示す局所領域に対して黒に近い画素を与えられた局所識別マップが出力されると考えられる。逆にその他の領域は識別器 D には目標画像が否かの識別が不可能となっているため、局所識別マップは全体的に灰色に近い画素が多くなる。このように目標画像群が有する特徴と異なる部分、つまりアーチファクト領域に対して黒い画素が与えられた局所識別マップが出力されるように学習を進めることができれば、アーチファクト低減に有効な画像変換性能を生成器 G が獲得すると期待できる。

3. 評価実験

提案する画像変換の枠組みによる CBCT 画像の画質改善の有効性を検証するために評価実験を行った。最初に、訓練データに対して提案手法による学習を行い、学習済み

モデルを得た。次に学習済みモデルを用いてテストデータの画像変換を行って生成画像を得た。生成画像と対応する目的画像間の誤差を算出し、以下の手法間で変換性能を検証した。

- CycleGAN[6]
- U-netGAN[12]
- 提案手法

3.1 データセット

京都大学医学部附属病院において放射線治療を受けた前立腺がん患者 76 名の CT 画像 (512 × 512 pixel, 134-226 slices) および CBCT 画像 (512 × 512 pixel, 48-93 slices) を用いた。ある患者について治療計画用に撮像された CT 画像と、治療当日に撮像された CBCT 画像がセットになっている。また図 6 に示すように、それぞれ撮像された日時や患者の姿勢・状態などの撮像条件が異なるため、2 つの画像間でスケールに関するいくつかの相違点が存在する。

- 撮像範囲が異なり、CT 画像の方が撮像範囲が広い
- スライス画像の画素数は共通 (512 × 512 pixel) だが、解像度が異なる
- 画像内の患者の姿勢が異なる場合がある
- 撮像日の違いにより、臓器の位置や形状が異なる

以上の違いを踏まえ、図 7 に示すような画像データの前処理を行った。具体的には CT 画像を source, CBCT 画像を target とした剛体レジストレーションによる位置合わせにより、CT 画像の画素数やスライス枚数、解像度などのスケールを CBCT 画像のスケールに揃えた。

前処理により、画像間のスケールの違いを解消し 3 次元的に構造が一致している CT 画像と CBCT 画像のペア (512 × 512 pixel, 48-93 slices) を 76 名分得ることができた。このうち無作為に 68 名分の CBCT-CT 画像ペアを抽出して訓練データとし、残りの 8 名分の CBCT-CT 画像ペア




図 6 CT 画像と CBCT 画像との撮像条件の違い, (a)CT 画像, (b)CBCT 画像

アをテストデータとした。

3.2 評価方法

本評価実験の手順について説明する。テストデータの CBCT 画像を元画像とし、学習済みモデルを用いて元画像を変換した画像を生成画像とする。またテストデータの CT 画像を参照画像とする。CBCT 画像においてアーチファクトが発生しているのは主に前立腺周辺であり、変換によって十分にアーチファクトを低減できたかを評価するために、図 8 に示すように評価の範囲を前立腺周辺に限定した。具体的には画像の中央 256×256 pixels, 20slices をトリミングした。また前立腺周辺の細かな CT 値の違いに着目した評価が行えるよう、CT 値のレンジを $[-300, 150]$ に決定し、CT 値が -300 を下回るものは -300 に、 150 を上回るものは 150 に値を丸めた。

定量評価の指標として、評価範囲内の CT 値を統計的に調べるために平均値と標準偏差を採用した。そして評価範囲内の CT 値のヒストグラムを作成し、その形状を比較した。具体的には参照画像のヒストグラムとの相関係数を計算し、参照画像の CT 値分布にどれだけ近づいたかを評価した。

3.3 定量評価結果

従来手法と提案手法とで敵対的学習を行い、テストデータを用いて変換性能の比較評価を行った結果を表 1 に示す。まず CT 値の平均値と標準偏差について、従来手法と比較して提案手法の方が参照画像に近い値となった。従来 CycleGAN のような大域的な特徴を捉えるだけの敵対的学習では達成できなかった数字を、提案手法では達成することができた。次にヒストグラムの相関係数についても従来手法よりも提案手法を用いた方が、画像変換によって参照画像に近い CT 値の分布が得られた。以上の統計的指標を




図 7 前処理として行った剛体レジストレーションによる位置合わせ結果, (a)CT 画像 (source), (b) 位置合わせ後の CT 画像, (c)CBCT 画像 (target)




図 8 評価範囲の限定

用いた定量評価から、従来手法よりも提案手法の方がより CBCT 画像の画質改善に有効であると考えられる。

3.4 ヒストグラムの比較

提案手法による生成画像と従来手法による生成画像とで、評価範囲における CT 値分布を調べるために、ヒストグラムを作成した。テストデータとして用いた 8 症例のうち 1 症例のヒストグラムを図 10 に示す。黒の実線が変換前の CBCT 画像で、黒の破線が参照 CT 画像のヒストグラムである。CT 値分布が黒の破線に近づくように、提案手法と従来手法を用いて変換した結果がそれぞれ赤、青、緑の実線である。図が示すように、提案手法である赤い実線の方がより黒の破線の形状に近づいていることが確認できた。つまり従来手法よりも提案手法の方が、CT 値の分布が参照画像に近くなるような画像変換を行うことができた。

3.5 生成画像の比較

変換後の画像を視覚的に確認し、従来と比べて変換性能が向上したと考えられる症例を 2 例、また変換性能が不十分であったと考えられる症例を 1 例、計 3 例を図 9 に示す。まず 1 つ目の症例 A について、画像内の矢印部分で示すように、CycleGAN による画像変換では身体の外形を変形させていた症例に対して、提案手法を用いることで身体

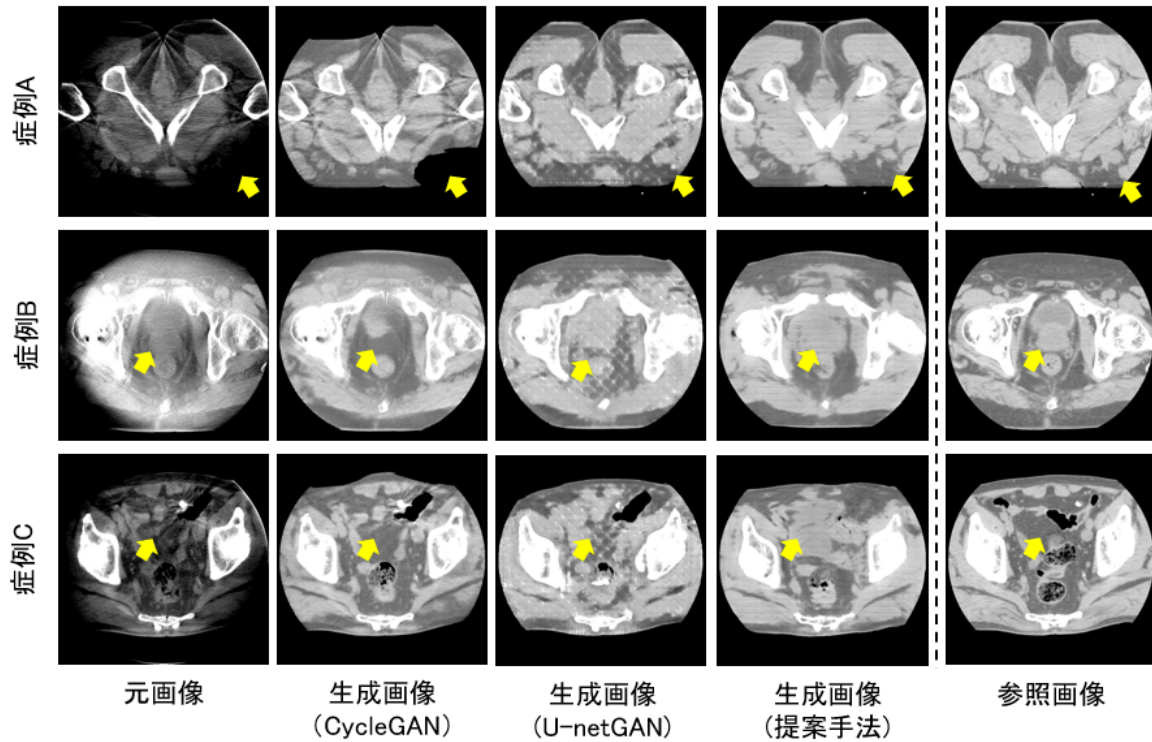


図 9 提案手法と従来手法による生成画像の比較

表 1 定量評価の結果

	Original	CycleGAN	U-netGAN	提案手法	参照画像
Mean±SD [HU]	-67.2±99.9	-1.19±82.3	14.7±77.8	12.6±76.6	9.07±80.1
相関係数	0.185	0.859	0.890	0.930	1.00

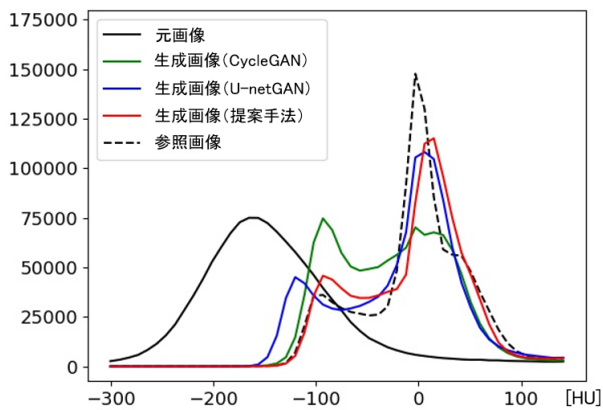


図 10 生成画像における CT 値のヒストグラム

の外形を保持したまま画像変換を行うことができた。また元々 CBCT 画像は CT 画像に比べて全体的に低い CT 値を示しており画像全体が暗く写っているが、提案手法による変換により、視覚的には参照 CT 画像とほぼ変わらない明るさに改善できた。この症例から、提案手法は CT 値の改善と身体の外見保持の両方に対して比較的有効であると考えられる。次に 2 つ目の症例 B について、画像内の矢印部分が示しているのは、CBCT 画像に強いアーチファクトが含まれている領域である。CycleGAN ではその領域の変

換に失敗しており、本来存在している臓器の一部を消去していた。これに対して提案手法では臓器形状を変えずに変換に成功した。この症例から、提案手法は強いアーチファクトが発生している部分の変換時であっても、身体内部の臓器の形状を保持することに有効であると考えられる。最後に 3 つ目の症例 C について、矢印部分を確認すると、提案手法の画像変換において本来とは異なる形状の臓器を創り出していた。この症例については元の CBCT 画像において強いアーチファクトが発生しているために、本来の臓器の形状が明確に写っていないことが原因として考えられる。

4. おわりに

本研究では CBCT 画像の画質改善を目的とした新たな教師なし学習の枠組みとして、識別器からのフィードバック機構を備えた敵対的学習を提案した。CBCT 画像の画質改善に対して提案手法の有効性を検証するために、前立腺がん患者 76 名の CBCT-CT 画像を用いて実験を行った。テストデータを用いて学習済みモデルによる定量評価を行ったところ、生成画像の CT 値平均が 12.6 ± 76.6 、参照画像の CT 値分布との相関係数が 0.930 という結果が得られ、従来手法より参照画像の画像特徴を踏まえた画像変換

を達成した。

謝辞 本研究は、日本学術振興会 科学研究費補助金 基盤研究 (B) (課題番号: 18H02766) 及び 挑戦的研究 (萌芽) (課題番号: 18K19918) の助成による。

参考文献

- [1] Rabelo Katharina Alves, C. Y. W.: Quantitative assessment of image artifacts from root filling materials on CBCT scans made using several exposure parameters, *isd*, Vol. 47, No. 3, pp. 189–197 (2017).
- [2] Scarfe, W. C. and Farman, A. G.: What is Cone-Beam CT and How Does it Work?, *Dental Clinics of North America*, Vol. 52, No. 4, pp. 707–730 (2008).
- [3] Maekawa, H., Nakao, M., Mineura, K., Chen-Yoshikawa, T. F. and Matsuda, T.: Model-based registration for pneumothorax deformation analysis using intraoperative cone-beam CT images, *2020 42nd Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC)*, pp. 5818–5821 (2020).
- [4] Yi, X., Walia, E. and Babyn, P.: Generative adversarial network in medical imaging: A review, *Medical Image Analysis*, Vol. 58, p. 101552 (2019).
- [5] Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. C. and Bengio, Y.: Generative Adversarial Nets, *NIPS*, pp. 2672–2680 (2014).
- [6] Zhu, J.-Y., Park, T., Isola, P. and Efros, A. A.: Unpaired Image-To-Image Translation Using Cycle-Consistent Adversarial Networks, *Proceedings of the IEEE International Conference on Computer Vision (ICCV)* (2017).
- [7] Nakao, M., Imanishi, K., Ueda, N., Imai, Y., Kirita, T. and Matsuda, T.: Regularized Three-Dimensional Generative Adversarial Nets for Unsupervised Metal Artifact Reduction in Head and Neck CT Images, *IEEE Access*, Vol. 8, pp. 109453–109465 (2020).
- [8] Nakamura, M., Nakao, M., Imanishi, K., Hirashima, H. and Tsuruta, Y.: Geometric and dosimetric impact of 3D generative adversarial network-based metal artifact reduction algorithm on VMAT and IMPT for the head and neck region, *Radiation Oncology*, Vol. 16, No. 96 (2021).
- [9] Liang, X., Chen, L., Nguyen, D., Zhou, Z., Gu, X., Yang, M., Wang, J. and Jiang, S.: Generating synthesized computed tomography (CT) from cone-beam computed tomography (CBCT) using CycleGAN for adaptive radiation therapy, *Physics in Medicine & Biology*, Vol. 64, No. 12, p. 125002 (2019).
- [10] Kida, S., Kaji, S., Nawa, K., Imae, T., Nakamoto, T., Ozaki, S., Ohta, T., Nozawa, Y. and Nakagawa, K.: Visual enhancement of Cone-beam CT by use of CycleGAN, *Medical Physics*, Vol. 47, No. 3, pp. 998–1010 (2020).
- [11] Hase, T., Nakao, M., Imanishi, K., Nakamura, M. and Matsuda, T.: Improvement of Image Quality of Cone-beam CT Images by Three-dimensional Generative Adversarial Network, *2021 43rd Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC)*, pp. 2843–2846 (2021).
- [12] Schonfeld, E., Schiele, B. and Khoreva, A.: A U-Net Based Discriminator for Generative Adversarial Networks, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*

- (2020).
- [13] Ronneberger, O., Fischer, P. and Brox, T.: U-Net: Convolutional Networks for Biomedical Image Segmentation, *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, pp. 234–241 (2015).