

Cone-beam CT 画像の画質改善を目的とした3次元敵対的生成ネットワークの提案

羽瀬 拓視[†] 中尾 恵[†] 今西 勁峰^{††} 中村 光宏^{†††} 松田 哲也[†]

[†] 京都大学大学院情報学研究科 〒606-8501 京都市左京区吉田本町
^{††} イーグロース株式会社 〒604-8006 京都市中京区下丸屋町 403
^{†††} 京都大学大学院医学研究科 〒606-8501 京都市左京区吉田近衛町
E-mail: †thase@sys.i.kyoto-u.ac.jp

あらまし Cone-beam CT(CBCT) 画像に含まれるアーチファクトや欠損は、放射線治療や手術支援において問題となっている。教師なし学習による画像変換を用いた従来研究によって金属アーチファクトの低減や頭頸部 CBCT 画像の画質改善は達成されているが、姿勢や呼吸による臓器変形の影響が大きい胸腹部の CBCT 画像の画質改善については報告例がない。本研究では腹部 CBCT 画像の画質改善を目的として、同一症例の CBCT 画像と CT 画像間の3次元的特徴を考慮した敵対的訓練により、解剖学的構造を保持しながら統計的に組織が元来有する CT 値に変換する方法を提案する。CT-CBCT データセット 70 例から学習した変換モデルを 8 例のテストデータに適用し、提案手法が CBCT 画像の画質を改善するため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

Proposal of 3D Generative Adversarial Network for Improving Image Quality of Cone-beam CT Images

Takumi HASE[†], Megumi NAKAO[†], Keiho IMANISHI^{††}, Mitsuhiro NAKAMURA^{†††}, and Tetsuya MATSUDA[†]

[†] Graduate School of Informatics, Kyoto University.
Yoshida Honmachi, Sakyo-ku, Kyoto, 606-8501 Japan
^{††} e-Growth Co., Ltd.
403, Shimo-Maruya-cho, Nakagyo-ku, Kyoto, 604-8006 Japan
^{†††} Graduate School of Medicine, Kyoto University.
Yoshida Konoemachi, Sakyo-ku, Kyoto, 606-8501 Japan
E-mail: †thase@sys.i.kyoto-u.ac.jp

Abstract Artifacts and defects included in Cone-beam CT (CBCT) images have become an obstacle in radiation therapy and surgery support. In conventional research, reduction of metal artifacts and improvement of image quality of head and neck CBCT images have been achieved by using image transformation by unsupervised learning, but there is no report on improvement of image quality of chest and abdomen CBCT images which are greatly affected by organ deformation due to posture or breathing. In this study, we aim to improve image quality of abdomen CBCT images based on unsupervised learning. We propose a method to statistically translate CT values to ones that the tissue originally has while keeping the anatomical structure by adversarial training considering the three-dimensional features between CBCT images and CT images of the same case. We applied the transformation model learned from 70 cases of CT-CBCT dataset to the test data of 8 cases, and it was confirmed that the proposed method was effective for improving the image quality of CBCT images.

Key words Unsupervised learning, adversarial generative network, Cone-beam CT, artifact reduction

1. はじめに

Cone-beam Computed Tomography(CBCT)はCTよりも小型で治療用ベッドに対して固定して設置できるため、治療中や手術中に患者の解剖学的構造を画像化することができる[1][2]。また一定の撮像領域に対し、CTと比較して被ばく量を抑えた撮像が可能である。しかし撮像時にはビームハードニング効果や機器の回転角制限等の要因により再構成後のCBCT画像にアーチファクトや欠損が生じて不正確なCT値を示すことがあり、放射線治療や手術計画において問題となっている[3]。

近年では、医用画像に対する深層学習を用いた画像処理についての研究[4]が数多くなされている。CBCT画像においても散乱補正等によって画質を改善する試み[5][6]は行われているが、これらの手法の多くは教師あり学習であり、CBCT画像と解剖学的構造が完全に一致するCT画像を用意する必要がある。しかし、医療現場においては完全に構造が一致したペア画像を用意することは困難である。

敵対的生成ネットワーク(Generative Adversarial Network, GAN)[7]やその応用手法であるCycleGAN[8]は比較的新しい教師なし学習の枠組みであり、広く研究されている。特にCycleGANは教師なし学習に基づく画像変換を目的に提案されており、ペア画像を用意することが困難な医用画像分野では非常に有効な手法となりうるため、画質改善を始めとして様々な用途で研究が行われている[4]。アーチファクトの低減への応用例として、Nakaoらによる3次元敵対的生成ネットワークを用いた歯科金属アーチファクトの低減の試み[9][10]がある。解剖学的構造を保ちながらアーチファクトを低減することを目的として研究が行われており、変換前と変換後の画素の差がスパースであることを利用し、その差に対してペナルティを与える正則化項を損失関数に加えて学習が行われている。

Liangらは頭頸部のCBCT画像の画質改善[11]の研究を行った。画像変換にはCycleGANを基盤に損失関数を加えた手法を用いており、頭頸部のCBCT画像の解剖学的構造を保ちながら、CT画像に近い画素値への変換を達成した。しかし、頭頸部のような日々の解剖学的構造の変化があまり大きくないような部位を対象としているため、同じ手法が他の部位へ利用可能か否かは自明ではない。例えば姿勢や呼吸による臓器変形等の影響が大きい胸部や腹部などの部位では、撮像日時が異なるCBCT画像とCT画像間での差異が多く生じている。それが原因となって解剖学的構造を変形させたり新たに生み出すような変換を学習してしまう場合、CBCT画像が有している治療当日の解剖学的構造という情報が変換によって失われてしまうという問題がある。

本研究では、前立腺がんの放射線治療において撮像された腹部CBCT画像の画質改善を目的として、CycleGANの枠組みを応用しCBCT画像群とCT画像群間を変換する敵対的生成ネットワークを構築した。解剖学的構造を保持したまま画像変換をするという課題を解決するために変換がスパースであることおよびCBCT画像が3次元的特徴を持っていることの2つを考慮した学習を行った。そして得られた変換後画像に対




図1: 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, (a) CT画像, (b) CBCT画像と欠損

して、その変換性能をCT値変換と解剖学的構造保持の2つの観点から評価した。また教師なし学習に基づく画像変換の枠組みにおける他の手法との比較や、変換の3次元特性の分析を行ったので報告する。

2. 提案手法

2.1 データ

本研究では、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78名のCT画像(512×512 pixel, 134–226 slices)およびCBCT画像(512×512 pixel, 48–93 slices)を用いる。データセット78名のうち、無作為に選択した8名分のデータをテストデータとし、残りの70名分のデータを訓練データとした。図1の(a)は治療計画用に撮像されたCT画像であり、(b)は治療当日に撮像されたCBCT画像である。黄矢印で示した部分を比較すると、CBCT画像にはアーチファクトや欠損が含まれていることが確認できる。またCBCT画像はCT画像に比べて撮像視野が狭く、体軸横断面では前立腺を中心に直径25cmまたは直径26cmの円形領域のみを映している。体軸方向についてもCBCT画像は前立腺を中心に±7cm程度のみの撮像領域となっている。一方でCT画像はCBCT画像よりも広い撮像視野と撮像領域を持っている。このような撮像領域の違いを踏まえて、前処理としてスケーリング処理と領域クリッピング処理を行い、CBCT画像とCT画像間の相違点を減らすことを目指した。

まずスケーリング処理について、概要を図2に示す。図2の(a)と(c)に示すように、初期状態では512×512pixelのスライス画像におけるCT画像の1pixelあたりのサイズはCBCT画像の1pixelあたりのサイズの約2倍である。そこで以下の手順でスケーリングを行い、撮像視野を揃えた。

STEP 1 訓練データの CT スライス画像の、中心部分 256×256pixel の領域を切り取る

STEP 2 切り取った領域の 1pixel のサイズが元の 0.5 倍になるようにリサイズする

処理後は、スライス画像が 512×512pixel であり、1pixel のサイズが CBCT 画像に近い CT 画像が得られる。以上により、訓練データの CBCT 画像と CT 画像の撮像視野を揃え、画像群間での相違点を減らせた。

次に体軸方向の撮像領域の処理について、概要を図 3 に示す。初期状態では CT 画像の体軸方向の撮像領域が CBCT 画像と比較して大きいため、個々のスライスに含まれる構造が大きく異なるような部位が混在しており、学習の大きな妨げになることが予想される。訓練データの CT ボリューム画像に含まれる部位をできるだけ下腹部領域に限定することにより、構造の大きく異なる部位の混在を防ぐ。放射線科医師によると CT 画像を用いた線量計算には、その画像内に骨盤領域と骨盤から足側に 2~3cm の範囲が含まれてることが十分条件である。したがって本研究においても、訓練データの CT 画像における体軸方向の撮像領域を線量計算に十分である範囲に限定し、クリッピングした。このようにして各画像群の訓練データ間のばらつきを抑えることで、画像群間での相違点を減らせた。

2.2 問題設定

本研究では、教師なし学習の枠組みに基づいて CBCT 画像の画質を改善することが目的である。ペア画像データの存在を仮定しないことによって、医療機関に蓄積された CBCT 画像と CT 画像を用いて CBCT 画像の画質改善モデルを構築できる可能性があり、治療計画支援への直接的な貢献が期待される。CBCT 画像の集合を $X = \{x_i\} (i = 1, 2, \dots, N)$ 、CT 画像の集合を $Y = \{y_j\} (j = 1, 2, \dots, M)$ として、同一患者における CBCT 画像と CT 画像間の対応付けをせずに画像群 X から画像群 Y への画像変換を求める問題を扱うため、CycleGAN の枠組みを応用することとする。次の 2 点を画像変換において達成すべき課題とする。

- (1) CBCT 画像に含まれるアーチファクトを低減し、撮像対象の組織が示す正しい CT 値へと変換する
- (2) 変換の際には、CBCT 画像の解剖学的構造は保持する

(1) については CycleGAN の生成器 G に CT 画像と CBCT 画像の 3 次元特徴を学習させることが有効であると考えられるため、3 次元敵対的生成ネットワーク [9][10] を応用し 3 次元ボリュームデータを入力とする学習を行った。(2) については画像変換時に CT 値の大きな変化を抑制することが解剖学的構造の保持に有効であると考えられるため、損失関数に正則化項を加えたものを目的関数とした。

2.3 正則化付き目的関数

本研究ではペアデータを必要としない画像群間の変換を行うため、CycleGAN の枠組みを用いている。まず CycleGAN で用いられる損失関数を式 (1) に示す。




図 2: スケーリング処理, (a) CT スライス画像, (b) 撮像視野を揃えた CT 画像, (c) CBCT スライス画像




図 3: 領域クリッピングによる体軸方向の領域範囲の限定

$$\mathcal{L}_{cgan} = \mathcal{L}_{adv}(G_Y, D_Y, X, Y) + \mathcal{L}_{adv}(G_X, D_X, X, Y) + \lambda_{cyc} \mathcal{L}_{cyc}(G_Y, G_X) \quad (1)$$

λ_{cyc} は重み係数である。ここで本研究の課題の一つである、解剖学的構造の保持を達成するために、次の式 (2) で定義される Intensity Loss [10] を加えた。

$$\mathcal{L}_{int} = \mathbb{E}_x \|G_Y(x) - x\|_1 + \mathbb{E}_y \|G_X(y) - y\|_1 \quad (2)$$

式 (2) の第 1 項は、生成器 G_Y の前後での誤差、つまり元 CBCT 画像 x と変換 CT 画像 $G_Y(x)$ との差に対してペナルティを与えるような正則化項としての役割を持つ損失関数である。これによって、変換の前後で画像全体の CT 値が大きく変化することを抑制し、結果的に解剖学的構造の保持に有効であると考えられる。

以上の式 (1) と式 (2) をまとめたものを、本研究の最終的な目的関数として式 (3) で定義する。これを提案目的関数とする。

$$\mathcal{L} = \mathcal{L}_{cgan} + \lambda_{int} \mathcal{L}_{int} \quad (3)$$

λ_{int} は正則化項の強弱を制御する重みである。そして次の式 (4) により求める学習済みモデル G_Y^* が得られる。

$$G_Y^*, G_X^* = \arg \min_{G_Y, G_X} \max_{D_Y, D_X} \mathcal{L} \quad (4)$$

2.4 3次元ボリュームデータの入力

本研究では、入力となる CT 画像や CBCT 画像内の骨、体表、臓器や、CBCT 画像内のアーチファクトが 3 次元特徴を持っていることを考慮し、3 次元ボリュームデータを入力とする学習を行った。以下にその手順を示す。

- STEP 1 CBCT 画像と CT 画像の体軸方向のある位置 z を基準として、連続した N 枚のスライス画像を選択する
- STEP 2 その N チャンネルの画像を学習単位として入力する
- STEP 3 位置 z の上下のスライス画像の情報も利用して変換がなされ、位置 z における変換スライス画像 1 枚が出力として得られる
- STEP 4 提案目的関数を用いた敵対的学習を繰り返し、学習済みモデルを得る。

単一スライス画像を入力する場合では判断が困難な特徴に基づいて誤った変換につながる可能性があるが、複数スライス画像の入力によって生成器 G が CT 画像と CBCT 画像の 3 次元の特徴を学習できる。つまり、入力するボリュームデータの各スライスについて、変換先の画像群に存在する同じスライス部分との対応付けが可能となり、CT 値の適切な変換が達成されると期待される。

以上の正則化付き目的関数と 3 次元ボリュームデータの入力を組み合わせた 3 次元敵対的生成ネットワークを本研究の提案手法とする。

3. 実 験

本研究では、70 名分の訓練データを CBCT 画像群と CT 画像群に分け、提案手法による 3 次元敵対的学習を行った。なお、提案目的関数内の各損失関数に対する重みについては予備調査で幾つかの値を調べ、最も性能が良いと考えられた $\lambda_{cyc} = 10.0$, $\lambda_{int} = 10.0$ を用いた。また学習時にはデータ数を増加させるために、10 度までの回転を加えた画像や、ランダムに上下左右反転させた画像を入力する。

3.1 評価方法

学習済みモデルを用いてテストデータを変換し、変換画像を確認の上、その変換性能に関して定量的な評価を行うこととする。定量的に評価するためには、Ground Truth となる参照画像を用意しその誤差を調べる必要があるため、CBCT 画像に対してサイズや解像度を一致させた位置合わせ済みの CT 画像を用意した。以下に参照画像の作成手順を述べる。

- STEP 1 テストデータとして用いる Case1-8 の 8 名の CT 画像と CBCT 画像について、CBCT 画像をリサイズして CT 画像の解像度に揃える
- STEP 2 CT 画像から、CBCT 画像と同じボリュームの領域を切り取り、その領域と CBCT 画像との二乗平均平方根誤差 (Root mean square error, RMSE) を算出する
RMSE は以下の式 (5) で定義される

$$RMSE(I, I_o) = \sqrt{\frac{1}{n} \sum_i (I(x, y, z) - I_o(x, y, z))^2} \quad (5)$$

ここで $I(x, y, z)$ は位置 (x, y, z) における画素値である

- STEP 3 切り取る領域を 1 voxel ずつ移動させ、テンプレート




図 4: テンプレートマッチングによる参照画像の作成, (a) CT 画像, (b) 参照画像, (c) CBCT 画像

マッチングの要領で、RMSE が小さくなる領域を探索する

- STEP 4 RMSE が最小の領域を参照画像とする

図 4 に参照画像作成の例を示す。このようにして得られた参照画像は、解剖学的構造が CBCT 画像とほとんど等しいと仮定し、評価に用いた。

本研究では評価指標として、RMSE および構造的類似指標 (Structural Similarity, SSIM) [12] を用いた。SSIM は画像構造の類似度が、人間の画質劣化の知覚に寄与するとの仮説に基づいて定義されている。構造の類似度を測る目的で、従来研究 [9][11] においても用いられている。0 から 1 の範囲で値をとり、1 に近いほど比較する 2 つの画像の類似度が高い。

評価実験において変換性能の評価範囲は、CBCT 画像のスライスと同じく直径 25cm または直径 26cm の円形領域の内部のみとすることにより、前立腺付近の局所領域に限定した評価を行った。またより細かな CT 値の差を評価できるように CT 値のレンジを小さく設定した。以下に詳しい手順を述べる。

- STEP 1 学習済みモデルを用いて、テストデータの CBCT 画像を変換し、変換後画像を得る
- STEP 2 得られた変換後画像を、リサイズによって参照画像の解像度に揃える
- STEP 3 変換後画像と参照画像に対して、スライス画像の中心から直径 25cm または直径 26cm の円形領域を切り取り、その外側の領域の CT 値を -1000 に置換する
- STEP 4 変換後画像および参照画像において、CT 値が -300 以下のものを -300 に、150 以上のものを 150 に値を丸め、CT 値のレンジを [-300,150] とする
- STEP 5 変換後画像と参照画像との RMSE と SSIM を算出する

3.2 提案目的関数の評価

本実験では、提案手法の目的関数の有効性を検証するために、従来手法 [8][11] で用いられた目的関数との比較を行った。入力データはすべて 2 次元スライス画像とする。提案手法を




図 5: 提案手法と従来手法による CBCT 画像 2 例の変換結果

含む以下の 3 手法で RMSE と SSIM を算出し、比較する。

- ・ 従来手法 I: CycleGAN [8]
- ・ 従来手法 II: CycleGAN + Identity Loss [11]
- ・ 提案手法: CycleGAN + Intensity Loss [10]

まず変換結果例を図 5 に示す。症例 A において黄矢印部分と比較すると、提案手法によってアーチファクトの低減に成功していることが確認される。また元画像の解剖学的構造を保持できていることも確認される。さらに緑矢印部分を比較すると、提案手法のほうが身体内部の臓器形状を保持できている。症例 B においては緑矢印部分を見ると臀部のようなくびれを生成しており、元画像が腹臥位であったのに対して逆の仰臥位へと変換されていることが確認される。これは訓練データを増加させるために入力画像を上下反転させていたことが原因ではないかと考えられる。

次にそれぞれの手法の評価結果を表 1 に示す。RMSE の平均値は提案手法で最も小さくなった。SSIM に関しては従来手法 I が提案手法を若干上回ったが、有意差は認められなかった。

3.3 変換の 3 次元特性の検証

本実験では、提案手法における変換結果の 3 次元特性と入力スライス枚数 N の関係を調べるため、以下の 3 通りの入力スライス枚数 N での変換結果を比較し定量的評価を行った。

- ・ スライス 1 枚 ($N=1$)
- ・ スライス 3 枚 ($N=3$)
- ・ スライス 5 枚 ($N=5$)

まず変換結果例を図 6 に示す。症例 A において、結果 ($N=1$) と結果 ($N=3$) の黄矢印部分が示すように新たに骨を生成するような変換を行っていた。しかし結果 ($N=5$) では骨を新たに生成する変換は行っておらず、 $N=1$ や $N=3$ の場合と比較して骨の 3 次元特徴を学習できていると考えられる。症例 B においてはどの結果も緑矢印部分を見ると、アーチファクトを低減できていることが確認される。

表 1: 提案手法と従来手法の変換結果の評価 (元画像, 変換後画像の RMSE および SSIM の平均値)

	Original	従来手法 I	従来手法 II	提案手法
RMSE 平均	130.4	77.15	87.81	75.77
SSIM 平均	0.4964	0.5098	0.4263	0.5090

表 2: 3 次元入力時の変換結果の評価 (元画像, 変換後画像の RMSE および SSIM の平均値)

	Original	N=1	N=3	N=5
RMSE 平均	130.4	75.77	73.20	70.67
SSIM 平均	0.4964	0.5090	0.5139	0.5355

次にそれぞれのスライス枚数の評価結果を表 2 に示す。スライス枚数を増やすほど、RMSE 平均は小さくなり、SSIM 平均は大きくなった。このことから、スライス枚数が多い方が変換性能は向上すると考えられる。特に $N=5$ の時には、3 つの中で最もよい評価値を得た。しかし Nakao らの研究 [9] ではスライス枚数を増やしすぎると逆に変換性能は下がっており、多くのスライス枚数を 1 単位とすることにより学習に利用可能な全体データ数が減少する可能性を示唆していることを考えると、このまま単純にスライス枚数を増やしていくことが、変換性能の向上につながるとは限らないと予想される。したがって変換性能が最も高くなる最適な値を今後調べる必要がある。

4. おわりに

本研究では、教師なし学習の枠組みに基づいた CBCT 画像の画質改善を目的として、アーチファクトを除去し CT 値を適切な値へと変換すること、解剖学的構造を保持することの 2 点を解決できるような手法の提案を試みた。提案手法には CycleGAN の応用として、正則化付きの目的関数と 3 次元ボリュームデータの導入した 3 次元敵対的生成ネットワーク




図 6: 入力スライス枚数 N を変えた時の CBCT 画像 2 例の変換結果

クを用いた。提案手法を用いて得られた学習済みモデルの変換性能を評価した結果、提案手法がアーチファクトの除去や CT 値の変換に対して有効であることを確認した。現状の課題として、提案手法を用いても身体の外形を変える変換をしたり身体内部の臓器形状を変える変換をしてしまうなどの解剖学的構造の保持が不十分である点が挙げられる。これらの課題を解決するために学習の枠組みやデータセットの構成方法の改善に取り組む予定である。

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。

文 献

[1] C. William, G. Allan, What is Cone-Beam CT and How Dose it Work?, The Dental Clinics of North America, No. 52, pp. 707–730, 2008.

[2] 前川日南子, 中尾 恵, 峯浦 一貴, 荒川 豊史, 松田 哲也, 術中 CBCT を用いた虚脱肺の変形解析の試み, 電子情報通信学会技術報告 (MI), 119(399), pp. 31–36, 2020.

[3] M. Nakao, M. Maekawa, T. Mizowaki, T. Matsuda, Statistical deformation reconstruction using multi-organ shape features for pancreatic cancer localization, arXiv preprint, Art. No. 1911.05439, 2019.

[4] Y. Xin, W. Ekta, B. Paul, Generative adversarial network in medical imaging: A review, Medical Image Analysis, Vol. 58, Issue 101576, 2019.

[5] K. Tateoka, Y. Saito, T. Nakazawa, M. Yano, K. Nakata, M. Someya, M. Hori, K. Sakata, Method for Converting Cone-Beam CT Values into Hounsfield Units for Radiation Treatment Planning, International Journal of Medical Physics, Clinical Engineering and Radiation Oncology, No. 6, p. 361, 2017.

[6] C. Zöllner, S. Rit, C. Kurz, G. Vilches-Freixas, et al., Decomposing a prior-CT-based cone-beam CT projection correction algorithm into scatter and beam hardening components, Physics and Imaging in Radiation Oncology, No. 3, pp. 49–52, 2017.

[7] I. Goodfellow, J. Pouget, M. Mirza, B. Xu, D. Warde, S. Ozair, A. Courville, Y. Bengio, Generative Adversarial Nets, Advances in Neural Information Processing Systems 27, pp. 2672–2680, 2014.

[8] J. Zhu, T. Park, P. Isola, A. Efros, Unpaired Image-To-Image Translation Using Cycle-Consistent Adversarial Networks, The IEEE International Conference on Computer Vision (ICCV), pp. 2223–2232,

2017.

[9] 中尾 恵, 今西 勤峰, 上田 順宏, 今井 裕一郎, 桐田 忠昭, 松田 哲也, 歯科金属アーチファクト低減向け 3 次元敵対的生成ネットワークの性能評価, 電子情報通信学会技術報告 (MI), 119(399), pp. 159–164, 2020.

[10] M. Nakao, K. Imanishi, N. Ueda, Y. Imai, T. Kirita, T. Matsuda, 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.

[11] L. Xiao, C. Liyuan, N. Dan, Z. Zhiguo, G. Xuejun, Y. Ming, W. Jing, J. Steve, Generating synthesized computed tomography (CT) from cone-beam computed tomography (CBCT) using CycleGAN for adaptive radiation therapy, arXiv, 2019.

[12] W. Zhou and A.C. Bovik and H.R. Sheikh and E.P. Simoncelli, Image quality assessment: from error visibility to structural similarity, IEEE Transactions on Image Processing, Vol. 13, No. 4, pp. 600–612, 2004.