

CycleGAN を用いた CT 画像における金属アーチファクト低減法

中尾 恵[†] 今西 効峰^{††} 上田 順宏^{†††} 今井裕一郎^{††††} 桐田 忠昭^{†††}
松田 哲也[†]

† 京都大学情報学研究科 〒606-8501 京都市左京区吉田本町

†† イーグロース株式会社 〒607-8062 京都市中京区下丸屋町 403

††† 奈良県立医科大学口腔外科学講座 〒634-8521 奈良県橿原市四条町 840

†††† 洛和会音羽病院口腔外科 〒607-8062 京都府京都市山科区音羽珍事町 2

E-mail: †megumi@i.kyoto-u.ac.jp

あらまし 本研究では、実 CT 画像を対象とした教師なし画像変換に基づく金属アーチファクト低減法を提案する。既存アルゴリズムで事前にアーチファクトを低減した教師データや、アーチファクトのシミュレーション画像の存在を前提とせず、歯科金属を有する症例と有しない症例の CT 画像群間のドメイン変換を得る問題を扱う。CycleGAN の考え方に基づいて、解剖学的構造と CT 値を保持しつつアーチファクト低減を実現する損失関数を設計し、顎骨や歯の 3 次元構造と金属アーチファクトの 3 次元分布を考慮した敵対的トレーニングの枠組みを構築した。96 症例の 3 次元 CT 画像から学習したドメイン変換によって効果的に金属アーチファクト低減が達成されることを確認した。

キーワード 教師なし学習、金属アーチファクト低減、敵対的生成ネットワーク、CT 画像

Metal artifact reduction using CycleGAN for CT images

Megumi NAKAO[†], Keiho IMANISHI^{††}, Nobuhiro UEDA^{†††}, Yuichiro IMAI^{††††}, Tadaaki KIRITA^{†††}, 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

††† Department of Oral and Maxillofacial Surgery, Nara Medical University

Shijocho 840, Kashihara-shi, Nara, 634-8521, Japan

†††† Department of Oral and Maxillofacial Surgery, Rakuwakai Otowa Hospital

Otowachinjicho 2, Yamashina-ku, Kyoto, 607-8062, Japan

E-mail: †megumi@i.kyoto-u.ac.jp

Abstract In this study, we propose a method for metal artifact reduction in real CT images based on unsupervised image transfer. We do not suppose the existence of training data with reduced artifacts or synthesized images of metal artifacts, and focus on a problem to obtain domain transfer between clinical CT images with and without dental metals. Based on the concept of CycleGAN, a novel loss function that reduces metal artifacts while preserving their CT values was designed. A adversarial training framework considering three-dimensional (3D) anatomical structures and 3D distribution of metal artifact was developed. This presentation reports the preliminary results of metal artifact reduction effectively performed by domain transfer learnt from 96 3D-CT images.

Key words Unsupervised learning, metal artifact reduction, adversarial generative network, CT images

1. はじめに

Computed Tomography(CT) では、撮像対象物に X 線の高 吸収体が含まれている場合、画像再構築における正確な CT 値の算出が阻害され、結果として画像内にアーチファクトが生まれる。特に金属アーチファクトは歯科や口腔外科における歯科

金属、胸腹部や大腿骨へ治療目的で用いられる金属用具等の影響により、様々な部位の CT 画像に生じうる。本アーチファクトは 3 次元的に画像領域の広範囲に影響を与えるため、CT 画像を用いた診断や手術計画 [1]、放射線治療における照射計画 [2] 等、CT 値に基づく演算における計算誤差の要因となる。我々はこれまでに手術計画の自動化 [3] [4] や放射線治療計画を支援する統計モデルの構築 [5] 等を目指してきたが、アーチファクトを有する症例に適用できないことが課題となってきた。臨床現場では医師が手動で除去するなどの対応がなされているが、処理に労力と時間を要することに加え、除去処理のみでは画像に欠損領域が生じるため、当該領域の組織から元来得られるべき CT 値の再構成を同時に行う必要がある。

CT 画像再構成時におけるサイノグラムに対する補正処理 [6] は広く知られており、これまでに多くの CT 装置に導入されているが、金属の種類や配置によっては十分なアーチファクト低減に至らなかったり、元画像のコントラストが失われる点が課題とされてきた。近年では、医用画像に対する深層学習の応用に関する研究が盛んであるが、アーチファクト低減を目的とした教師あり学習では、アーチファクトを有する画像に対応するアーチファクトを有しない画像が必要となり、臨床においてそのような対応する画像対を取得することは容易ではない。既存のサイノグラム補正処理の結果を深層学習の教師データとして活用する方法 [7] [8] や、金属アーチファクトを生成したシミュレーション画像を教師とした学習 [9] [10] 等が試みられている。特に後者は高品質な画像復元が可能であることが報告されているが、学習が金属の 3 次元形状と配置が既知であることを仮定しており、シミュレートされたアーチファクトと実 CT 画像に含まれるアーチファクトのバリエーションとの差異への対応に課題が残る。

さらに近年では、教師なし学習の枠組みとして敵対的生成ネットワーク (Generative Adversarial Network, GAN) [11] とその応用手法 [12] が広く研究されている。学習データの変換元と変換先の対応付けが必要なく、各ドメインの画像特徴量の変換と識別を、生成器と識別器に敵対的に学習させることで、各ドメインの画像を相互に変換するモデルを得る。例えば、高線量 CT 画像群と低線量 CT 画像群間の変換を生成器が獲得できるように学習することによって低線量 CT 画像のノイズ軽減を目指した例 [13] 等が報告されている。教師なし画像変換は対応する教師データやシミュレーションの必要なしに医療機関に蓄積された実 CT 画像のみからアーチファクト低減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応用が期待できる。

本研究では、実 CT 画像間の教師なしドメイン変換に基づく金属アーチファクト低減法を提案する。アーチファクト低減後の教師データやアーチファクトのシミュレーション画像の存在を前提とせず、実 CT 画像のみを用いた学習によって、頸骨や歯等の構造的特徴を保存しつつ、アーチファクトを有する画像群からアーチファクトを有しない画像群への変換を求める問題を考える。この課題に対して、CycleGAN [12] の枠組みを応用し、歯科金属を有する画像群と有しない画像群間の解剖学的構




図 1 生成型ネットワークによる CT 画像群間の変換、 X :アーチファクトを有する画像群、 Y :アーチファクトを有しない画像群

造と CT 値を保持したドメイン変換を求める損失関数を新たに設計した。また、頸骨や歯列の 3 次元構造と金属アーチファクトの 3 次元分布を考慮した学習の枠組みを構築した。口腔外科において撮像された 96 例の頭頸部 CT 画像を対象に、金属アーチファクトを有する画像群と金属アーチファクトを有しない画像群間の変換を求め、頸骨や歯の解剖学的構造を保持しつつ金属アーチファクトを効果的に低減できることを確認したので報告する。

2. 提案アーチファクト低減法

本稿では、アーチファクトを有する実 CT 画像の集合を $X = \{x_i\} (i = 1, 2, \dots, N)$ 、アーチファクトを有しない実 CT 画像の集合を $Y = \{y_i\} (i = 1, 2, \dots, M)$ として、アーチファクトの有無において対となる同一患者の画像、すなわち、事前に別の方法でアーチファクトを低減した教師画像や、アーチファクトを人工的に付加したシミュレーション画像の存在を前提とせずに X から Y への画像変換を求める問題を扱う。ここで、望ましい画像変換として、入力画像における症例固有の 1) CT 値及び解剖学的構造を保存しつつ、2) 金属アーチファクトをできるだけ低減するような変換を考え、この変換を教師なし学習によって獲得するために CycleGAN の考え方を応用する。

2.1 CycleGAN

GAN [11] の枠組みでは X と Y を入力として、以下の二つの生成器と識別器の対 $(G_X, D_X), (G_Y, D_Y)$ をそれぞれ敵対的に訓練する。

- $Y \rightarrow X$ の変換を行う生成器 G_X
- $X \rightarrow Y$ の変換を行う生成器 G_Y
- 変換後の $G_X(Y)$ と X を識別する識別器 D_X
- 変換後の $G_Y(X)$ と Y を識別する識別器 D_Y

具体的には、 G_X, G_Y はそれぞれ変換先の X, Y に類似した画像を生成するように、すなわち、 D_X, D_Y による識別率が 50% に近くなるように学習を進める。一方、 D_X, D_Y はそれぞれ G_X, G_Y が生成した画像と元の X, Y を正しく識別できるように学習を進める。加えて、CycleGAN [7] では、 G_X と G_Y を順に適用することで実現される $X \rightarrow Y \rightarrow X$ や $Y \rightarrow X \rightarrow Y$ の変換によって変換前の元画像に戻ることが要請される。学習時に用いられる損失関数を式 (1) に示す。

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




図 2 3 次元訓練データの構成方法

$$+ \mathcal{L}_{adv}(G_X, D_X, Y, X) \\ + \lambda \mathcal{L}_{cyc}(G_X, G_Y),$$

ここで、 \mathcal{L}_{adv} は adversarial loss と呼ばれ、式(2)によって定義される。生成画像の $G_Y(X)$ と実画像の Y を D_Y が判別できるか否かの尺度となる。

$$\mathcal{L}_{adv}(G_Y, D_Y, X, Y) = \mathbb{E}_y[\log D_Y(y)] \\ + \mathbb{E}_x[\log(1 - D_Y(G_Y(x)))]. \quad (2)$$

また、 \mathcal{L}_{cyc} は cycle consistency loss と呼ばれ、式(3)によって定義される。

$$\mathcal{L}_{cyc}(G_X, G_Y) = \mathbb{E}_x[||G_X(G_Y(x)) - x||_1] \\ + \mathbb{E}_y[||G_Y(G_X(y)) - y||_1], \quad (3)$$

ここで、第一項は $X \rightarrow Y \rightarrow X$ の変換によって生成された画像 $G_X(G_Y(x))$ と元の入力画像 x 間の再構成誤差を定量する損失関数である。 λ は adversarial loss と cycle consistency loss の強弱を制御する重みである。 G_X, G_Y は式(1)の値を小さくなるように、逆に D_X, D_Y は大きくなるように学習が進められる。

式(1)は [7]において導入された損失関数であるが、adversarial loss は識別器 D による判別結果のみを尺度としており、cycle consistency loss は入力画像群の情報の保持のみを尺度としているため、生成画像 $G(x)$ において、想定する特徴が生成されないまま D の識別率を低下させる特定のパターンを生成するよう学習が進むモード崩壊が課題となっている。

2.2 アーチファクト低減向け目的関数

前節で述べた課題を踏まえ、本研究では元画像に含まれる患者固有の解剖学的構造や CT 値を保持する制約を導入したアーチファクト低減向けの目的関数を設計した。具体的には、式(1)に変換前後の画像間において特微量が保持されることを要請する feature loss、アーチファクト低減後の画像と元画像間において、大局的に CT 値が保持されることを要請する intensity loss を導入する。また、zero-centered gradient penalty [15] を導入し、学習の安定性の向上を目指した。

feature loss は式(4)に示すように、変換後の CT 画像と変換前の CT 画像の 3 通りの組み合わせにおける潜在特微量の差に対してペナルティを与える正則化項として定義する。アーチファクトの有無に起因する特微量の差はスパースであると仮定

し、正則化項には L1 ノルムを採用した。CT 画像から潜在特微量への変換には VGG16 [14] における特微量算出部を用いた。

$$\mathcal{L}_{fea} = \mathbb{E}_x[||f(G_Y(x)) - f(x)||_1] \\ + ||f(G_X(G_Y(x)) - f(G_Y(x))||_1 \\ + ||f(G_X(G_Y(x)) - f(x)||_1 \\ + \mathbb{E}_y[||f(G_X(y)) - f(y)||_1 \\ + ||f(G_Y(G_X(y)) - f(G_X(y))||_1 \\ + ||f(G_Y(G_X(y)) - f(y)||_1], \quad (4)$$

intensity loss は式(5)に示すように、生成画像と元画像の CT 値の差に対してペナルティを与える正則化項として定義する。画素すべてについて大局的に CT 値が近くなるような評価として log を採用した。

$$\mathcal{L}_{int} = \mathbb{E}_x[\log(|G_Y(x) - x| + 1.0)] \\ + \mathbb{E}_y[\log(|G_X(y) - y| + 1.0)], \quad (5)$$

zero-centered gradient penalty [15] は式(6)によって定義される。GAN の枠組みでは生成器と識別器の学習の進度が均衡することが望ましいが、識別器の方が最適化が進みやすいことが知られている。 D の勾配に損失を設けることで学習の安定性向上を図る。

$$\mathcal{L}_{gp} = \mathbb{E}_{\tilde{x}}[||\nabla D_{\tilde{x}}||^2] \quad (6)$$

最終的な目的関数 \mathcal{L}_{MA} は式(7)となる。 $\lambda_{fea}, \lambda_{int}, \lambda_{gp}$ はそれぞれの正則化の強弱を制御する重みである。アーチファクト低減を実現する学習済み画像変換モデル G_Y^* は式(8)によって得られる。

$$\mathcal{L}_{MA} = \mathcal{L}_{cgan} + \lambda_{fea}\mathcal{L}_{fea} + \lambda_{int}\mathcal{L}_{int} - \lambda_{gp}\mathcal{L}_{gp} \quad (7)$$

$$G_X^*, G_Y^* = \arg \min_{G_X, G_Y} \max_{D_X, D_Y} \mathcal{L}_{MA}(G_X, G_Y, D_X, D_Y) \quad (8)$$

2.3 3 次元訓練データの構成方法

本節では CycleGAN の枠組みに適用する各訓練データ x, y の構成方法について説明する。従来研究では 2 次元スライス画像を 1 単位として学習が行われているが、解剖学的構造やアーチファクトの 3 次元情報は十分に学習されない可能性がある。提案する学習の枠組みでは、顎骨や歯などの生体の体軸方向の構造的特徴やアーチファクトの空間的な広がりを反映した画像

誤 : -
正 : +




図 3 異なる損失関数を用いた場合の画像変換結果 (a) 元画像, (b) CycleGAN の損失関数 (c)
feature loss の導入結果, (d) intensity loss の導入結果, (e) gradient penalty の導入結果

変換モデルを獲得するために、局所的な 3 次元ボリュームデータを最小単位として敵対的トレーニングを行う。具体的には、図 2 に示すように、各症例の 3 次元 CT ボリュームにおいて、歯列が存在する範囲にランダムに定められた体軸 (z 軸) 方向の位置 z を基準として、幅 s の範囲で局所ボリューム領域を定義する。局所ボリューム領域から T 枚のスライス画像を選定して得られる T チャネルの画像を学習単位としてネットワークへ与える。 T の値を大きくするとより多くの 3 次元構造が 1 データとして扱われることになるが、ネットワークの最適化時に要するメモリと計算時間が増大するため、対象とする部位やアーチファクトの性質、Graphic Processing Unit (GPU) 等のハードウェア環境に合わせて設定する必要がある。

3 次元情報を学習に取り入れた本枠組みの別の観点として、各症例単位ではなく、局所ボリューム領域単位で X と Y に分類し、学習を行う点がある。位置 z のスライス画像がアーチファクトを有する場合は X に、アーチファクトを有しない場合は Y に分類される。歯列が含まれるスライス画像で、かつ、アーチファクトの影響を受ける領域が一部である場合には、アーチファクトを有する症例の 3 次元ボリュームから x と y の両方の訓練データが得られる。成人は過去の歯科治療によって歯科金属を有している場合が多く、医療機関に蓄積されるデータにはアーチファクトを有する症例の方が多い傾向があるが、提案する枠組みではアーチファクトを有しない局所ボリュームデータは Y に分類されるため、学習データ数の均衡に繋がることが期待される。

3. 実験

奈良県立医科大学 口腔外科において撮像された 3 次元 CT 画像 96 例 (512×512 pixel, 157-515 slices) を用いて、提案方法が元画像に含まれる頸骨や歯の解剖学的特徴を保持しつつ、対象となる金属アーチファクトの軽減が可能か否かを確認する実験を行った。アーチファクトを有する症例は 76 例、アーチファクトを有しない症例は 20 例で、それぞれ異なる患者であ

る。前者の方が症例数が大幅に多いが、前節で述べたように提案する学習の枠組みでは、症例単位ではなく局所ボリューム単位で訓練データが生成される。

訓練データ準備時の前処理として、最初に全症例のスライス画像集合を目視で確認し、体軸方向における歯列を含む範囲を特定後、歯科金属によるアーチファクトを有する画像ドメイン X とアーチファクトを有しない画像ドメイン Y の 2 群に分類した。アーチファクトの有無の判定が難しいスライスに関しては両方の群に含めることとし、結果的にアーチファクトを有する訓練データ数は 1860、アーチファクトを有しない訓練データ数は 1662 となった。各画像の CT 値は軟組織におけるアーチファクトも除去対象とするために [-1000HU, 1000HU] を [-1, 1] に正規化した。学習単位となる局所ボリュームの厚みは $T = 5$ を採用し、ランダムシャッフルされた画像ドメインの訓練データは 1epoch ごとにそれぞれ 5 チャンネルの画像として CycleGAN の枠組みへ適用し、 (G_X, D_X) 及び (G_Y, D_Y) を敵対的にトレーニングした。生成器及び識別器にはそれぞれ U-net [16], VGG16 [14] を用いた。学習と推定には CPU: Intel Core i7-7900X, Memory: 32.0 GB, GPU: GeForce RTX 2080, OS: Windows 10 を搭載した計算機を用いた。

3.1 手法比較

本実験では、提案する目的関数の有効性を検証するために、Cycle GAN の目的関数と以下の 3 通りの提案目的関数による生成画像の違いについて定性的な比較を行った。

Model A CycleGAN の目的関数 \mathcal{L}_{cgan}

Model B $\mathcal{L}_{MA} (\lambda_{fea} = 1.0, \lambda_{int} = 0.0, \lambda_{gp} = 0.0)$

Model C $\mathcal{L}_{MA} (\lambda_{fea} = 1.0, \lambda_{int} = 50.0, \lambda_{gp} = 0.0)$

Model D $\mathcal{L}_{MA} (\lambda_{fea} = 1.0, \lambda_{int} = 50.0, \lambda_{gp} = 0.0001)$

Model B は feature loss のみの場合、Model C は feature loss と intensity loss の両方を損失に加えた場合、Model D は Model C に gradient penalty を加えた場合であり、それぞれの重みは数通りのパラメータを試行して経験的に定めた。図

3の上段に、各モデルによる画像変換結果の典型例を、下段に変換前後のCT値の差の絶対値を画素とした差分画像を示す。(b)(c)(d)ではアーチファクトは良好に低減されているが、差分画像からアーチファクト以外の領域においても差異が生じており、解剖学的構造の保持に課題が残っている。特に(b)(c)では軟組織や頸骨、歯の形状に変形が生じており、(d)では主に軟組織について改善が見られるが、依然歯や骨の形状が変化している。これに対して、(e)ではアーチファクトの低減効果は他よりも若干低いが、学習が安定に進み解剖学的構造が保持されたアーチファクト低減が実現されている。

3.2 金属アーチファクト低減例

テストデータに異なる金属アーチファクトを有する3症例を用いた場合の、Model Dによるアーチファクト低減結果を図4及び図5に示す。形成外科や口腔外科における手術計画では、特に頸骨や歯の3次元形状や位置関係の把握が重要であるが、特に(a)(b)では良好にアーチファクトが低減されており、強いアーチファクトを有する(c)においても、軟組織や歯の構造を保持したアーチファクト低減が達成されている。口腔外科医2名および歯科技工士1名によるコメントとして、一部歯の形状に変形が見られる症例があるが、臨床における実利用が可能なレベルであるとの意見が得られている。GANを画像補正の目的で用いる場合において、元画像に含まれない構造が新たに生成されたり、元画像に含まれる構造が崩れるなどの特性は課題であったが、本結果は損失関数への制約の導入と3次元構造の考慮によって、教師なし画像変換に基づくアーチファクト低減と臨床における実利用の可能性を示唆している。

4. おわりに

本研究では、実CT画像間の教師なしドメイン変換に基づく金属アーチファクト低減法を提案した。96症例による画像変換モデルの学習によって解剖学的構造を保持した金属アーチファクト低減が達成されることを定性的に確認した。より強いアーチファクトを有する症例に対しても有効な損失関数の設計に加え、生成画像におけるCT値復元とアーチファクト低減効果の両方の観点を踏まえた定量評価が課題である。今後はシミュレーション画像や同一患者の対応する画像を用いた定量評価を予定している。

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: 19H04484) 及び 挑戦的研究(萌芽) (課題番号: 18K19918) の助成による。

文 献

- [1] J. I. Efanov, A. Roy, K. N. Huang, D. E. Borsuk, Virtual Surgical Planning: The Pearls and Pitfalls, *Plast Reconstr Surg Glob Open.*, 6(1):e1443, 2018.
- [2] B. Rigaud, A. Simon et al., Statistical Shape Model to Generate a Planning Library for Cervical Adaptive Radiotherapy. *IEEE Trans Med Imaging*, 38(2), pp.406-416, 2019.
- [3] M. Nakao, M. Hosokawa, Y. Imai, N. Ueda, T. Hatanaka, T. Kirita and T. Matsuda, Volumetric fibular transfer planning with shape-based indicators in mandibular reconstruction, *IEEE Journal of Biomedical and Health Informatics*, 19(2), pp.581-589, 2015.
- [4] M. Nakao, S. Aso, Y. Imai, N. Ueda, T. Hatanaka, M. Shiba, T. Kirita and T. Matsuda, Automated planning with multivariate shape descriptors for fibular transfer in mandibular reconstruction, *IEEE Trans. on Biomedical Engineering*, 64(8), pp.1772-1785, 2017.
- [5] M. Nakamura, M. Nakao, H. Hirashima, H. Iramina, T. Mizowaki, Performance evaluation of a newly developed three-dimensional model-based global-to-local registration in prostate cancer, *Journal of Radiation Research*, rzz031, 2019.
- [6] E. Meyer, R. Raupach, M. Lell, B. Schmidt, M. Kachelriess, Normalized metal artifact reduction (NMAR) in computed tomography. *Med Phys*, 37(10), pp. 5482-93, 2010.
- [7] L. Gjesteby, Q. Yang, Y. Xi, Y. Zhou, J. Zhang, G. Wang, Deep learning methods to guide CT image reconstruction and reduce metal artifacts, *SPIE Medical Imaging*. Vol. 10132. 2017.
- [8] 小名木佑来, 橋本拓磨, 黒澤隆那, 村田泰輔, 古山良延, 太田丞二, 高岡浩之, 横田元, 森康久仁, 小林欣夫, 須鎗弘樹, 深層学習を用いたメタリックアーチファクトの低減手法, 医療情報学会人工知能学会 AIM 合同研究会資料, 6(7), SIG-AIMED-006-07, 2018.
- [9] Y. Zhang and H. Yu, Convolutional neural network based metal artifact reduction in X-ray computed tomography. *IEEE Transactions on Medical Imaging*, 37(6), pp.1370-1381, 2018.
- [10] M. Sakamoto, Y. Hiasa, Y. Otake, M. Takao, Y. Suzuki, N. Sugano, Y. Sato, Automated Segmentation of Hip and Thigh Muscles in Metal Artifact-Contaminated CT using Convolutional Neural Network-Enhanced Normalized Metal Artifact Reduction, *arXiv:1906.11484*, 2019.
- [11] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio. Generative adversarial nets, In *NIPS*, 2014.
- [12] J. Zhu, T. Park, P. Isola, A. A. Efros. Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks, in *IEEE International Conference on Computer Vision (ICCV)*, 2017.
- [13] Q. Yang, P. Yan, Y. Zhang, H. Yu, Y. Shi, X. Mou, M. K. Kalra, Y. Zhang, L. Sun, G. Wang, Low-Dose CT Image Denoising Using a Generative Adversarial Network With Wasserstein Distance and Perceptual Loss. *IEEE Transactions on Medical Imaging*, 37(6), pp.1348-1357, 2018.
- [14] K. Simonyan, A. Zisserman, Very Deep Convolutional Networks for Large-Scale Image Recognition, *ICLR*, 2014.
- [15] H. Thanh-Tung, T. Tran, S. Venkatesh, Improving Generalization and Stability of Generative Adversarial Networks, *ICLR*, 2019.
- [16] O. Ronneberger, P. Fischer, T. Brox, U-Net: Convolutional Networks for Biomedical Image Segmentation, *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, pp. 234-241, 2015.




図 4 変換前後の CT スライス画像例 (a)(b)(c) 変換前, (d)(e)(f) 変換後




図 5 変換前後の 3 次元 CT 画像例 (a)(b)(c) 変換前, (d)(e)(f) 変換後