

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

中尾 恵[†] 今西 勁峰^{††} 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 本研究では歯科金属アーチファクト低減を実現する3次元敵対的生成ネットワークを構築した。915の実患者3次元CT画像を歯科金属の有無に基づいて分類した金属アーチファクトデータベースを構築し、設計した正規化付き損失関数に基づいて敵対的トレーニングを行った。複数の歯科金属から生成される広範囲な画素欠損を伴うアーチファクトを対象に、アーチファクト低減及びCT値復元性能の評価を試みたので報告する。

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

Evaluation of 3D adversarial networks for metallic dental artifact reduction

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. An 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

近年の治療技術の向上に伴い、歯科や口腔外科における金属充填物、脊椎や大腿骨へ治療目的で用いられる金属用具等

の体内留置金属は増加傾向にある。これら金属はComputed Tomography(CT)撮像時においてX線パス上のフォトン不足、ビームハードニング等の要因となり、正確なCT値の再構成を阻害する[1]。結果としてCT画像内に生じた金属アーチファ

クトは診断や手術計画, 放射線治療等, 多くの臨床分野において問題となっている. アーチファクトを有する画像を補正するためには, アーチファクトを除去すると同時に当該領域の組織から元来得られるべき CT 値の復元を同時に達成する必要がある. アーチファクトに関する事前知識の活用 [1], サイノグラムに対する補正処理 [2] は広く研究されており, これまでに多くの CT 装置に導入されているが, 複数の金属から生じる複雑なアーチファクトには十分な低減効果が得られない場合が多い [3]. 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しているのが現状である.

最近では, 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る. 特に一度設置した歯科金属を除去する機会が少ない臨床において, そのようなペア画像を取得することは容易ではない. これまでに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 [4] が試みられている. 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 画像に含まれる複雑な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.

敵対的生成ネットワーク (Generative Adversarial Nets, GANs) のアーチファクト低減への応用は比較的新しい研究領域である. Liao ら [5] は, CycleGAN [6] を拡張したアーチファクト低減向けネットワークを提案し, アーチファクト合成画像を利用して教師あり学習と教師なし学習による低減性能を比較した. 一方, 複数の歯科金属から生成される複雑なアーチファクトを有する実患者 CT 画像を学習した際のアーチファクト低減性能については未だ明らかになっていない. 金属アーチファクト低減に求められる画像補正は, アーチファクトの影響を受けた領域に存在する元来の構造物特徴を復元する一方で, それ以外の領域においては患者の本来の解剖学的構造が保持される必要がある. これらの課題に対して, 本稿では臨床において得られる複雑なアーチファクトを有する低品質画像の敵対的トレーニングと, CT ボリュームに内在する 3 次元特徴を学習することの重要性に着目している.

本研究では, 教師なし学習に基づく歯科金属アーチファクト低減の実現を目指し, 3 次元敵対的生成ネットワーク [7] [8] を構築した. 915 の実患者 3 次元 CT 画像を歯科金属の有無に基づいて分類した金属アーチファクトデータベースを構築し, 設計した正則化付き損失関数に基づいて敵対的トレーニングを行った. 複数の歯科金属から生成される広範囲な画素欠損を伴うアーチファクトを対象に, 教師なし学習の枠組みにおける手法比較, 3 次元特性の分析, 専門医による主観評価を試みたので報告する.

2. 手 法

本稿で扱う教師なしアーチファクト低減法の目標は, 金属アーチファクトを有する実 CT 画像の集合 $X = \{x_i\}(i =$

$1, 2, \dots, n_p)$ 及び金属アーチファクトを有しない実 CT 画像の集合を $Y = \{y_i\}(i = 1, 2, \dots, n_q)$ としてアーチファクトの有無においてペア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 X から Y への画像変換を求めることである.

2.1 3 次元 CT 画像データベース

金属アーチファクト低減を目指した従来の深層学習や敵対的生成ネットワークによるアプローチでは主に 2 次元スライス画像を 1 単位とした学習が試みられてきた. 複雑な金属アーチファクトのバリエーションを有する 3 次元 CT 画像データベースは知られていなかったため, Cancer Image Archive (TCIA) [9] 及び 奈良県立医科大学 口腔外科において過去に治療を受けた患者の臨床データ [10] [11] から 915 の頭頸部 CT ボリュームを収集し, 歯科金属アーチファクトを有する群 X と有しない群 Y からなる 3 次元 CT 画像データベースを新たに構築した. 口腔外科における CT 画像は, Siemens SOMATOM Definition AS CT スキャナ (120 kV, 200 mA) で撮像された. 本研究は, 奈良県立医科大学の倫理委員会の承認 (承認番号: 2296) の下実施された.

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, X と Y の 2 群に分類した. 具体的には, 金属アーチファクトを部分的に含む CT ボリュームは, まずアーチファクト有りサブボリュームとアーチファクト無しサブボリュームに分割後, 前者を Y に, 後者を X にそれぞれ分類した. 歯科金属を有しない臨床データは相対的に少なく, 患者単位の分類では 2 群のデータ数に偏りが生じやすいが, サブボリューム単位で分類することによって, より多くの患者からアーチファクト無しボリュームを収集することとした.

次に, 16 のアーチファクト無し CT ボリュームと 40 の金属アーチファクト有り CT ボリュームを無作為に抽出し, 評価用データとして学習対象のデータから除外した. 学習にはそれ以外の 539 のアーチファクト無し 3 次元ボリューム (計 10491 スライス) と様々な金属アーチファクトパターンを有する 320 のボリューム (計 5655 スライス) を用いた. 各ボリュームは, 512×512 pixel, 5–43 スライスからなり, 両方の画像ドメインには同一患者の同一の 3D 領域を示すペアデータは存在しない. 軟部組織および骨に現れる広範囲のアーチファクトを対象とするため, $[-1000\text{HU}, 1000\text{HU}]$ を $[-1, 1]$ に正規化した.

2.2 3 次元敵対的生成ネットワーク

提案する 3 次元敵対的生成ネットワークは CycleGAN における画像-画像間変換 [6] の枠組みの拡張として設計された. 従来の 2 次元の枠組みでは, 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. 本研究では, 局所的な 3 次元ボリュームデータを最小単位とした敵対的トレーニングがアーチファクト低減に有効か否かを議論することを主眼においている. なお, 本稿ではページ数の制約のため, 手法の詳細については [7] [8] も参照して頂きたい.

提案するボリューム変換モデルは図 1 に示す二つのマッピング




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

関数 $G_Y : X \rightarrow Y$ 及び $G_X : Y \rightarrow X$ から構成される。識別器 D_X は元画像 x と生成画像 $G_X(y)$ の識別を、 D_Y は同様に y と $G_Y(x)$ の識別を目指して学習が行われる。ここで、学習サンプル x, y は異なる患者のボリュームであり、連続する N 枚のスライスから構成されるものとする。図2は連続する2枚から構成されるボリュームを1学習単位とした敵対的トレーニング ($N=2$) の際の100epoch 時点の生成画像を例示している。左側の4枚の画像群は $X \rightarrow Y$ 変換を、右側の画像群は $Y \rightarrow X$ 変換の例である。各ボリュームは空間的に連続した金属アーチファクトの分布を有しており、 x に含まれていた金属アーチファクトが変換後のボリューム $G_Y(x)$ では低減されている。一方、アーチファクト無しボリューム y から変換された $G_X(y)$ には生成器 G_X によって表現されたアーチファクトが合成されている。

学習モデル構築後、新たなボリュームに対するアーチファクト低減の際には、上部（あるいは下部）の N スライス分の局所ボリュームを処理対象として変換を始め、変換対象の全体ボリュームを N スライスごとに順次更新する [7]。ここで、 N の値が全体ボリュームのスライス数よりも十分に小さく、最初の局所ボリュームに歯列の3次元構造全体が含まれないとすると、歯科金属も端の一部が含まれるのみとなり、金属アーチファクトの影響を受ける領域は局所ボリュームの体積と比べて小さい状況、つまり弱いアーチファクトを有する局所ボリュームであることを仮定できる。さらに変換後の局所ボリュームの一部は、スライスを進めた次の局所ボリュームにおいて再利用する。この手続きによって、局所ボリュームが強いアーチファクトを有する低品質なスライス画像のみで構成される可能性が減じられ、変換後のボリュームの画質改善に繋がる効果が期待できる。評価実験においてこのボリューム間変換モデルの有効性を定量的に分析する。

2.3 アーチファクト低減のための正則化付き目的関数

入力されたボリュームをターゲットドメインに変換するマッピング G は無限に存在するため、金属アーチファクト低減の目的に合わせた損失関数が必要となる。CycleGAN の損失関数ではアーチファクトは効果的に低減されても、顎骨や歯等の構造を変形させたり、新たに生み出す可能性があり [7]、臨床における利用には課題となる。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

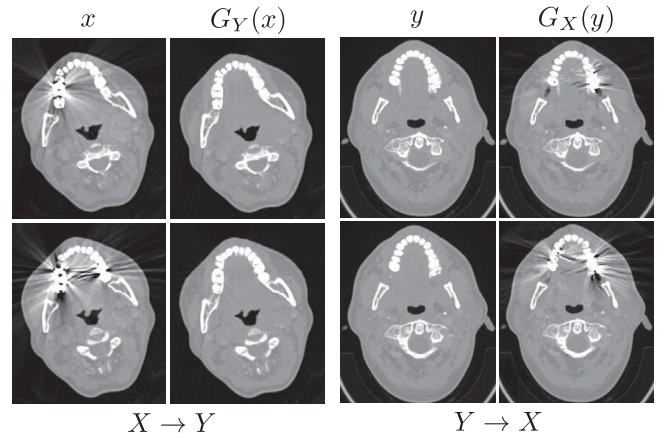


図2 3次元敵対的トレーニングの例。異なる患者の局所ボリューム (x, y) を他方の群 (Y, X) へそれぞれ変換する場合

ファクト低減向けの目的関数を設計した。具体的には次に示す二つの損失関数を定義する。

Intensity Loss

図2の元画像 x が示すように、歯科金属によるアーチファクトの影響が見られる画素は全画素に対して一部であり、またその分布はスパースとなる傾向がある。強いアーチファクトは広範囲の画素に影響を与える可能性があるが、歯科金属の形状から3次元元画像空間においては密な分布とならない。提案方法では、これらの特性を考慮し、元画像と生成画像のCT値の差に対してペナルティを与える正則化項として式(1)に示す intensity loss を導入する。ノルムにはスパース性を考慮して L1 ノルムを採用した。

$$\mathcal{L}_{int} = \mathbb{E}_x \|G_Y(x) - x\|_1 + \mathbb{E}_y \|G_X(y) - y\|_1. \quad (1)$$

Feature Loss

生成器 G_X は、アーチファクト有り画像から金属アーチファクト由来の特徴を減じる必要がある一方で、生成器 G_Y はアーチファクト無し画像に同様の特徴を付加することが望まれる。提案方法では、このような特徴付加、低減の対称性を考慮した学習を促すために、変換前後の画像の差分に関する潜在特徴量の差に対してペナルティを与える正則化項として、式(2)に示す Feature Loss を導入する。

$$\mathcal{L}_{fea} = \mathbb{E}_{x,y} \|f(x - G_Y(x)) - f(G_X(y) - y)\|_2 + \mathbb{E}_{x,y} \|f(x' - G_X(y)) - f(G_X(y) - y')\|_2. \quad (2)$$

f は潜在特徴量への変換関数であり、本研究では VGG16 [12] の特徴量算出部を利用する。

Full objective

最終的な目的関数 \mathcal{L} は式(3)のように CycleGAN の損失関数 \mathcal{L}_{cgan} に式(1), (2)を加えた関数とした。 λ_{fea} , λ_{int} はそれぞれの正則化の強弱を制御する重みであり、幾つかのパラメータセットを試行後、 $\lambda_{fea} = 1.0$, and $\lambda_{int} = 25.0$ を用いること

とした。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 (4) によって得られる。

$$\mathcal{L} = \mathcal{L}_{gan} + \lambda_{int}\mathcal{L}_{int} + \lambda_{fea}\mathcal{L}_{fea}, \quad (3)$$

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

3. 評価実験

提案する 3 次元敵対的ネットワークによるアーチファクト低減性能を検証するために、アーチファクト合成画像を用いた手法比較、3 次元特性の分析、専門医による主観評価の三つの評価実験を実施した。

3.1 アーチファクト合成画像

実患者の頭頸部 CT 画像を対象にアーチファクト低減性能を定量的に評価するためには、アーチファクトの有無のみが異なる同一患者の 3 次元 CT 画像が必要となる。臨床において、一度設置された歯科金属を除去する機会は少なく、真値として利用可能な同一患者内のペア画像の取得は容易ではない。本研究では、歯科金属を有しない 3 次元 CT 画像に対して金属アーチファクトをシミュレートしたアーチファクト合成画像を作成し、定量評価を試みた。複数の歯科金属から生成される複雑なアーチファクトパターンをシミュレートするために、CT ボリュームから 8 本の歯の 3 次元領域を抽出することにより、2 値ボリュームラベルを作成した。1, 2 番目は奥歯からランダムに選択し、3, 4 番目は、1, 2 番目の歯に近い奥歯から選択した。このような歯科金属の配置は実際の患者データに良く見られ、特に二つ以上の隣接する歯科金属からは広範な領域の画像欠損を伴うアーチファクトが生成される。5 番目と 6 番目は前側の歯から選択し、7, 8 番目は残りの歯からランダムに選択した。各領域の和集合によって、配置バリエーションが異なる 1 から 8 個の歯科金属を表現したボリュームラベルを作成した。

金属アーチファクトは従来の深層学習を用いたアーチファクト低減の研究 [4] で使用されたサイノグラム逆投影の手続き、及び、同じパラメータを用いてシミュレートし、アーチファクト合成ボリュームを生成した。異なる点は、多数の歯科金属の存在を想定した強いアーチファクトを含むより低品質の画像群を対象としていることが挙げられる。図 3 左は、8 個のバーチャル歯科金属のボリュームラベルから生成された金属アーチファクトを含む合成画像の例を示している。

3.2 アーチファクト合成画像を用いた手法比較

提案方法と従来方法の定量比較には、4 例のアーチファクト無し実患者 3 次元画像を参照画像 (Reference) とし、歯科金属を m 個 ($m = 1, 2, \dots, 8$) を含む歯列をシミュレートした計 32 のアーチファクト合成画像を処理対象の画像 (Original) として使用した。教師あり学習と教師なし学習の定量的な比較については従来研究 [5] において詳細な報告がなされているため、本研究では教師なし学習の枠組みにおいて、提案方法と CycleGAN (CGAN) [6]、その拡張である Artifact disentangle network (ADN) [5] との比較を行った。提案方法は 3DGAN と




図 3 アーチファクト合成画像に対するボリューム変換例。左：シミュレートされた金属アーチファクトを有する 3 次元 CT 画像 (Original), 中央：アーチファクト低減結果 (Result), 右：参照画像 (Reference)

表 1 元画像と変換後画像の RSME 及び SSIM の中央値

$m = 1$	Original	CGAN	ADN	3DGAN1	3DGAN5
RSME	32.6	33.2	35.8	28.1	28.6
SSIM	0.882	0.872	0.844	0.890	0.914
$m = 4$	Original	CGAN	ADN	3DGAN1	3DGAN5
RSME	46.3	39.5	38.1	36.5	35.3
SSIM	0.755	0.811	0.795	0.841	0.873
$m = 7$	Original	CGAN	ADN	3DGAN1	3DGAN5
RSME	50.0	43.9	38.1	39.1	38.3
SSIM	0.649	0.739	0.761	0.773	0.816

記載し、学習単位の局所ボリュームを構成するスライス枚数を接尾辞として付記する。例えば、3DGAN5 は、5 枚のスライスからなる局所ボリュームを学習単位とした変換モデルを意味する。3DGAN1 はスライス単位の変換を意味し、式 (3) の目的関数を用いている点のみが従来方法と異なる。

図 3 中央は 提案方法による画像変換結果の例であり、右はアーチファクトを合成する前の参照画像である。この両者の CT 値が類似していれば、解剖学的構造の維持、復元がなされた金属アーチファクト低減が達成されたとみなす。定量評価指標には、参照画像と変換後画像間の二乗平均平方根誤差 (RMSE) 及び 構造的類似指標 (Structural Similarity, SSIM) [13] を用いる。SSIM は形態的な類似度の評価を目的に従来研究 [4] [5] においても採用されており、0 から 1 の値を取り、値が大きい程 類似度が高いことを示す。

表 1 に、参照画像と元画像、変換後の画像間の RMSE 及び SSIM の中央値を示す。3DGAN1 は特に SSIM について CGAN, ADN よりも優れた性能を示しており、提案損失関数の有効性が確認された。3DGAN5 はさらに高いアーチファクト低減性能を示し、また 3DGAN1 と 3DGAN5 の結果には比較的大きな評価値の改善が見られた。スライス画像の変換よりも、ボリュームを 1 単位とした学習がアーチファクトの 3 次元分布の学習に有効であったことが示唆される。

異なる患者、異なる個数の歯科金属から生成されたアーチファクト合成画像に対して 3DGAN5 によって変換を行った結果を図 4 に例示する。視覚的にアーチファクト低減及び画素の復元がなされていることが確認される。強い金属アーチファクトの影響によって歯自体に CT 値の欠損が生じている $m = 7, 8$ の場合には復元された歯列に誤差が生じているが、それ以外の顎骨や軟組織の解剖学的構造は良好に維持されていることが確認された。




図4 異なる患者の3次元画像に対して生成されたアーチファクト合成画像の変換結果。m: アーチファクト生成に用いた歯科金属の個数

3.3 3次元特性

次に提案するボリューム変換の3次元特性について、アーチファクト合成ボリューム及び実患者CTデータの両方を対象に実験を行った。学習対象とする局所ボリュームのスライス枚数を変化した学習済みモデルを複数準備し、それぞれのアーチファクト低減性能を比較することによって確認した。GPUメモリの制限により、学習時の入力ボリュームのスライス枚数 N が 1, 3, 5, 7, 9, 13 の場合について調査することとした。

図5(a)に16のアーチファクト合成ボリュームに対し、異なる N を用いて学習したモデルによって得られた処理結果についてSSIMを算出した結果を示す。SSIMの中央値は $N=9$ まで増加傾向を示し、3DGAN9が最も良い評価値を示した。図5(b)は実患者CTボリュームに対する3DGAN1及び3DGAN9によって得られた結果を示している。3DGAN1は画像単位で変換を学習するため、葉や舌、下顎周辺において黄色矢印に示すような不自然な修正結果を生成する傾向がある。一方、3DGAN9では緑矢印の対応箇所において、解剖学的構造を反映した視覚的に自然な変換が達成されている。3DGAN11や3DGAN13では評価値が逆に減少傾向を示した。これは学習時のボリュームが歯列周辺の5-43枚で構成されているため、多くのスライス枚数を1単位とした際に、学習に利用可能なデータが減少することが影響した可能性がある。

3.4 臨床データの変換結果に対する医師の主観評価

15, 26, 36年の経験を持つ3名の口腔外科医(日本口腔外科学会専門医)の実験参加への同意の下、選出された4例の実患者CT画像を対象として、提案方法によって変換された画像に対する主観評価を実施した。下顎骨再建術の手術計画[11][14]における利用を想定し、20年以上の経験を有する歯科技工士による手動修正と提案方法(3DGAN5)による変換結果を比較した。手動修正は、現行の市販のCTに付属のアーチファクト低減機能では修正が難しい、ピクセルの欠損を含む強いアーチファクトに対して臨床で広く用いられている。

本研究では、臨床への適用可能性を評価するために、Quality of artifact reduction (QOAR), structural accuracy (SA) 及び修正に要した所要時間の三つの評価指標を定義した。QOAR

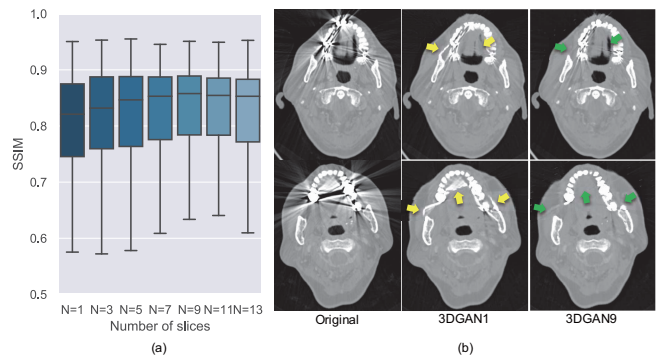


図5 3次元敵対的トレーニングの特性, (a) 学習時の入力ボリュームのスライス枚数とSSIMの関係, (b) 実患者CTボリュームに対する2次元変換と3次元変換による差異

はアーチファクトが適切に低減できるか否か、SAは歯列や下顎の解剖学的構造が正確か否かを参加者の臨床経験に基づいてExcellent: 4, Good: 3, Fair: 2, Poor: 1の4段階で評価する。Goodは臨床において十分に利用可能な水準、Fairは若干の問題はあるが、Acceptableな水準とすることを参加者に伝えた。各参加者はランダムに提示される手動及び提案方法による修正結果について、正面、側面、底面のボリュームレンダリング像を観察し、QOARとSAを回答した。

歯科技工士による手動修正と提案方法による変換結果のボリュームレンダリング像の例(MA3)を図6に、3名の外科医から得た評価値と所要時間を表2に示す。すべてのデータに対して提案手法によるQOAR, SAは高い値を示しており、平均3.5となった。MA3は複数のdark bandやscattering noiseを含む強いアーチファクトを有するデータである。歯科技工士による手動修正では歯の表面に凹凸のある不規則なノイズが残存しているが、提案方法では臨床において利用可能なアーチファクト低減を達成し、かつ、相対的に滑らかな歯の構造を復元することが確認された。手動修正及び提案方法による処理時間はそれぞれ平均33分, 11.9秒であった。これらの結果は強いアーチファクトを有する3次元CT画像に対し、臨床利用が可能な水準の修正結果を提供できることを示しており、術前計




図6 歯科技工士による手動修正と提案方法による変換結果のポリウム可視化例

画や放射線治療計画における生産性向上に寄与することが期待される。

表2 医師による主観評価結果と処理時間。

	QOAR		SA		処理時間	
	手動	提案	手動	提案	手動(分)	提案(秒)
MA1	3.3	4.0	3.3	4.0	12	6.6
MA2	2.0	3.0	2.0	3.0	50	11.9
MA3	2.0	3.0	2.3	2.7	52	13.2
MA4	3.7	4.0	3.3	4.0	18	15.8

4. おわりに

本稿では、歯科金属アーチファクトの低減向け3次元敵対的生成ネットワークの枠組みを紹介し、その性能評価結果について報告した。915の局所ポリウムを歯科金属の有無に基づいて分類した3次元CT画像データベースを構築し、設計した正規化付き損失関数に基づいて敵対的トレーニングを行った。

アーチファクト合成画像を用いた定量評価では、従来損失関数を用いた場合よりもRSME, SSIMが改善され、スライス画像を1単位とする学習と比較して局所ポリウムを1単位とした学習が効果的であることが確認された。口腔外科医による主観評価の結果、臨床において現在実用されている歯科技工士による手動修正結果よりも高い評価値が得られ、提案方法は臨床に利用可能なアーチファクト低減を達成することが確認された。

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

文 献

[1] L. Gjesteb, B. D. Man, Y. Jin, H. Paganetti, J. Verburg, D.

Giantsoudi et al., "Metal artifact reduction in CT: Where are we after four decades?," IEEE Access, vol. 4, pp. 5826–5849, 2016.

[2] 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.

[3] J. Y. Huang, J. R. Kerns, J. L. Nute, X. Liu, P. A. Balter, F. C. Stingo et al., "An evaluation of three commercially available metal artifact reduction methods for CT imaging," Phys. Med. Biol., vol. 60, no. 3, pp. 1047–67, 2015.

[4] 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.

[5] H. Liao, W. Lin, S. K. Zhou and J. Luo, "ADN: Artifact Disentanglement Network for Unsupervised Metal Artifact Reduction," IEEE Transaction on Medical Imaging, 2019. (Published online)

[6] J. Zhu, T. Park, P. Isola, A. A. Efros, "Unpaired image-to-image translation using Cycle-consistent adversarial networks," IEEE Int. Conf. Computer Vision (ICCV), 2017.

[7] 中尾 恵, 今西 勁峰, 上田 順宏, 今井 裕一郎, 桐田 忠昭, 松田 哲也, CycleGAN を用いた CT 画像における金属アーチファクト低減法, 電子情報通信学会技術報告 (MI), 119(193), pp. 63–68, 2019.

[8] M. Nakao, K. Imanishi, N. Ueda, Y. Imai, T. Kirita, T. Matsuda, Three-dimensional generative adversarial nets for unsupervised metal artifact reduction, arXiv preprint arXiv:1911.08105, 2019.

[9] K. Clark, B. Vendt, K. Smith, J. Freymann, J. Kirby, P. Koppel et al., "The Cancer Imaging Archive (TCIA): maintaining and operating a public information repository," Journal of digital imaging, vol. 26, no. 6, pp. 1045–1057, 2013.

[10] 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.

[11] 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.

[12] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv, Art no. 1409.1556, 2014.

[13] W. Zhou, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: from error visibility to structural similarity," IEEE Trans. Image Processing, vol. 13, no. 4, pp.600–612, 2004.

[14] R. Kawasaki, M. Nakao, Y. Imai, N. Ueda, T. Hatanaka, M. Shiba, T. Kirita, T. Matsuda, "Sparse shape model for fibular transfer planning in mandibular reconstruction", International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp.2508-2511, 2016.