

## 腹部臓器を対象とした深層学習に基づく 2D/3D 可変形画像位置合わせ

三浦 龍人<sup>†</sup> 中尾 恵<sup>†</sup> 中村 光宏<sup>††</sup> 松田 哲也<sup>†</sup>

<sup>†</sup> 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  
<sup>††</sup> 京都大学大学院医学研究科 〒606-8507 京都市左京区聖護院川原町 54  
E-mail: [†r-miura@sys.i.kyoto-u.ac.jp](mailto:†r-miura@sys.i.kyoto-u.ac.jp)

**あらまし** 2D/3D 画像位置合わせは治療時に撮像可能な二次元投影像に合わせて、治療前に取得済みの三次元画像の変形や配置を求める問題であり、治療支援や生体解析などへの応用が期待されている。これまでに骨格系を対象に最適化ベースの方法が広く研究されてきたが、反復計算のコストが大きく、局所解に陥りやすい点が課題であった。特に腹部臓器は変形が大きく、X-ray 画像上で輪郭が視認できないため、単一二次元投影像からの画像再構成は試みられていない。本研究では、単一視点の二次元投影像に対する三次元画像の 2D/3D 可変形画像位置合わせを達成する教師あり深層学習の枠組みを提案する。本枠組みでは、二次元投影像と三次元画像から 3D U-Net によって三次元変位場への変換が学習される。腹部 4D-CT から生成した疑似 X 線画像に対して三次元 CT 画像の可変形位置合わせを行い、患者の呼吸に伴う臓器変形を反映した CT 画像を再構成可能であることを確認した。

**キーワード** 2D/3D 位置合わせ, 可変形画像位置合わせ, 変位場, 畳み込みニューラルネットワーク

## Deep Learning based 2D/3D Deformable Image Registration for Abdominal Organs

Ryuto MIURA<sup>†</sup>, Megumi NAKAO<sup>†</sup>, Mitsuhiro NAKAMURA<sup>††</sup>, and Tetsuya MATSUDA<sup>†</sup>

<sup>†</sup> Graduate School of informatics, Kyoto University  
Yoshida Honmachi, Sakyo-ku, Kyoto, 606-8501, Japan

<sup>††</sup> Graduate School of Medicine, Kyoto University  
54 Kawahara-chou, Shougoin, Sakyo-ku, Kyoto, 606-8507, Japan  
E-mail: [†r-miura@sys.i.kyoto-u.ac.jp](mailto:†r-miura@sys.i.kyoto-u.ac.jp)

**Abstract** 2D/3D image registration is a problem that solves the deformation and alignment of a pre-treatment 3D image to a 2D projection image, which is available for treatment support and biomedical analysis. Conventional optimization-based methods widely studied for skeletal structures have problems due to calculation cost and unstable convergence characteristics. Specifically, as the abdominal organs are greatly deformed, and the contours are not detected on X-ray images, no studies have reported 3D image reconstruction from a single 2D projected image. In this study, we propose a supervised deep learning framework that achieves 2D/3D deformable image registration between the 3D image and a single viewpoint 2D projected image. The proposed method learns the translation from the target 2D projection images and the initial 3D image to 3D displacement fields by 3D U-Net. We registered 3D-CT images to the digitally reconstructed radiographs generated from abdominal 4D-CT images and confirmed that the CT images reflecting the respiratory organ motion were reconstructed.

**Key words** 2D/3D registration, deformable image registration, displacement field, Convolutional Neural Network

### 1. はじめに

コンピュータ断層撮影 (Computed Tomography: CT) や磁

気共鳴画像 (Magnetic Resonance Imaging: MRI) などの三次元医用画像は、臓器や腫瘍の位置や形状など患者固有の形態的情報を画像化できるため、診断および手術計画、治療計画な

どに広く用いられている。しかし三次元 CT 撮影では形態的情報を正確に得るために数百枚ものスライス画像の撮影を必要とし、高い放射線被ばくが生じる。また三次元医用画像の撮像には時間を要し、計測場所も制限されるため、外科手術や放射線治療の開始後は CT や MRI の機器を用いた撮像は難しい。そのため、取得可能な内視鏡画像や X-ray 画像などの低次元かつ局所的な二次元画像のみに基づいて治療が行われる。特に放射線治療においては、患者の治療期間の体重変化や治療前と治療時の姿勢の違い、治療時の呼吸に起因する腫瘍位置変動に対応する必要があり、照射精度が保障されない場合、隣接臓器に副作用を及ぼす危険が生じる。

この問題を解決するために、治療時に撮像可能な二次元画像に合わせて、治療前に取得済みの三次元画像の変形や配置を求めることが考えられる。これは 2D/3D 位置合わせと呼ばれ、内視鏡画像や X-ray 画像などの二次元画像から三次元の形態的情報を得ることを目的に研究が進んでいる。特に、変形が微小な骨格系などの剛体を対象とした 2D/3D 位置合わせは広く研究が行われている。従来の 2D/3D 位置合わせ手法では、三次元画像からシミュレートされた投影画像と X 線画像との間で、輪郭情報や画素値情報に基づいて画像間の類似度が最大となるように変換パラメータを最適化することで位置合わせが達成される [1], [2]。例えば、Gendrin らは X 線画像と投影画像から画素値情報に基づいた反復最適化を行い、腫瘍の剛体運動を推定した [1]。しかし、このような最適化ベースの位置合わせ手法は計算量が多く、位置合わせに時間を要するという問題がある。

高速な 2D/3D 位置合わせを達成するために、畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) を用いた学習により変換パラメータ推定する手法が提案されている [3]~[5]。Miao らは CNN を用いて投影画像から 6 自由度の剛体変換パラメータを階層的に直接推定することで、高速かつ高精度での位置合わせが可能であることを示した [3]。しかし、これらの 2D/3D 剛体位置合わせ手法では推定対象の幾何学的形状を既知としているため、変形しやすい柔軟臓器などの非剛体を対象とした 2D/3D 可変形位置合わせには対応できない。また、骨格系と比較して腹部領域は低コントラストであるため、臓器の輪郭情報を得ることは困難である。近年、Wu [6] らは深層学習に基づいて虚脱肺の投影画像から三次元形状を復元する方法を提案した。また、Nakao らはグラフ畳み込みネットワークを用いて腹部臓器の平均形状からの変形を学習し、単一 X-ray 画像から臓器形状メッシュを再構成する枠組みを提案した [7], [8]。しかし、これら研究では画像の再構成は行われておらず、線量計算が必要となる放射線治療計画における活用には課題が残っている。このように、柔軟臓器を対象とした画像ベースでの 2D/3D 可変形位置合わせの研究例は限られている。

本研究は、臓器変位の学習に基づく患者個人の腹部領域の 2D/3D 可変形位置合わせにより、単一視点の二次元 X-ray 画像から三次元 CT 画像を再構成することを目的とする。脳 MRI の 3D/3D 位置合わせの枠組みとして提案された VoxelMorph

[9] を拡張し、より不確実性の高い問題である 2D/3D 位置合わせを実現する新しい深層学習の枠組みを提案する。また、本研究は呼吸に伴って移動、変形する腹部領域を対象とする。腹部臓器は大きく変形し、かつ X-ray 画像における臓器のコントラストは低く輪郭も不鮮明であるため三次元情報の再構成は困難な課題である。

位置合わせ性能の評価には治療計画を目的に計測された膀胱がん患者の 1 呼吸分の時系列三次元 CT 画像を用いる。投影計算によって生成可能な二次元の時系列疑似 X-ray 画像 (Digitally reconstructed radiograph, DRR) に対して三次元 CT 画像を位置合わせし、CT 値の再構成誤差を算出することとした。提案手法によって、例えば放射線治療において治療中に撮影した X-ray 画像からリアルタイムに三次元の形態的情報を取得でき、照射対象の臓器や腫瘍位置、リスク臓器を含む画像再構成が期待される。

## 2. 提案手法

### 2.1 問題設定

本研究が対象とする問題は、患者内の呼吸変形において異なる時相に得られた腹部領域の二次元 DRR 画像と三次元 CT 画像の間の局所対応を求めることである。具体的には CT 画像をソース、DRR 画像をターゲットとして、画素値情報に基づいて CT 画像のボクセル単位での三次元変位場を得ることで、ソースからターゲットへの 2D/3D 位置合わせを行う。本研究で用いるデータの特徴として、臓器変形が大きいこと、DRR 画像は低コントラストで各臓器の輪郭は不鮮明であることが挙げられる。そのため、画像位置合わせを対象とした従来研究 [9], [10] においても位置合わせの性能は明らかになっていない。

提案手法は、過去の研究 [13] において集積された患者の 1 呼吸分の 10 時相からなる時系列三次元 CT データを用いて、異なる時相における DRR 画像と三次元 CT 画像の間で 2D/3D 位置合わせを行い、腹部臓器を対象に 2D/3D 位置合わせの性能を評価する。図 1 に提案手法の枠組みを示す。同一患者内のある呼吸時相 (Phase A) における三次元 CT 画像 ( $V_s$ ) と同一時相の DRR 画像 ( $I_s$ )、ターゲットとなる別時相 (phase B) の DRR 画像 ( $I_t$ ) を連結してネットワークに入力し、CNN に基づく三次元変位場生成部によって解剖学的構造の変位を学習する。出力される各ボクセルの変位ベクトルを用いて、 $V_s$  を空間変換する。再構成された三次元 CT 画像 ( $V_{def}$ ) を出力として、正解画像である phase B の三次元 CT 画像 ( $V_{gt}$ ) と比較し、ネットワークの重みを最適化する。提案する枠組みの各モジュールについて、2.2 節で詳細に説明する。

### 2.2 提案フレームワーク

#### 2.2.1 三次元変位場の生成

ここでは、二次元 DRR 画像と三次元 CT 画像を入力として三次元変位場を得ることを目的とする。ターゲットである DRR 画像について、画像間の画素値の違いから変位特徴を抽出するために、 $I_t$  に加えて  $I_s$  も入力情報として与える。そこに、三次元情報を持つ CT 画像  $V_s$  を連結した 2 チャンネルの画像を入力とする。三次元変位場生成部によって変位ベクトル  $u$

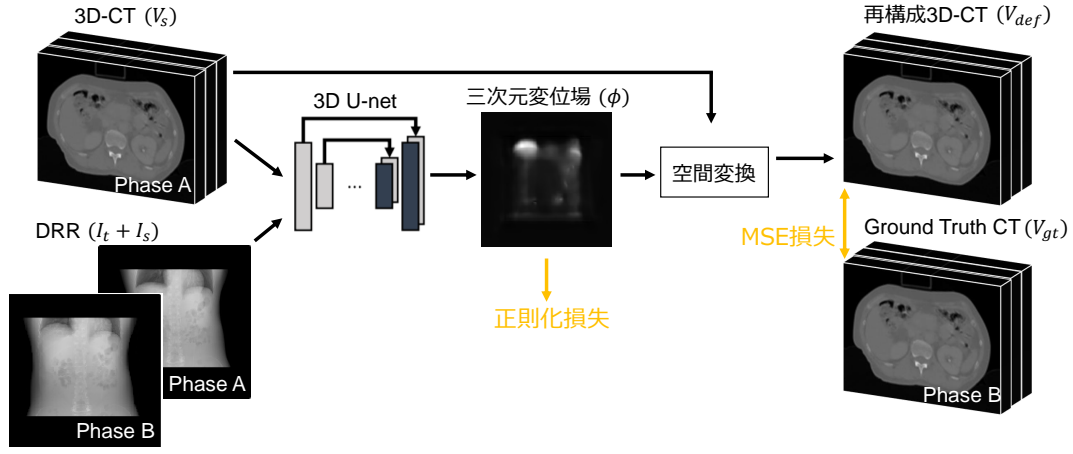


図1 提案するフレームワークの概要.




図2 三次元変位場生成部の構造.

を求め、 $V_s$  の各ボクセルに変位ベクトルが格納された3チャンネルの三次元変位場  $\phi = Id + \mathbf{u}$  を出力する。ここで、 $\theta$  は生成部の最適化パラメータ、 $Id$  は  $V_s$  の同一変換を表す。提案手法では、3D U-Net [11] を用いて生成部の実装を行った。図2にその構造を示す。U-Net は医用画像のセマンティックセグメンテーションなどに広く用いられており、CNN に基づくエンコーダ-デコーダ構成のネットワークである。エンコーダ、デコーダの各層でカーネルサイズ3、ストライド2の畳み込みを行い、各畳み込み後の活性化関数にはパラメータ0.2のLeakyReLUを用いる。デコーダの各層の直後には画像を元の解像度に復元するためのアップサンプリング層が続く。また、3D U-Net ではエンコーダとデコーダの各階層で特徴マップを連結することで、高解像度な画像生成を達成する。

### 2.2.2 変位場に基づく三次元画像の変形

提案手法では、三次元変位場  $\phi$  を用いた  $V_s$  の空間変換によって、CT 値を保持したまま三次元 CT 画像  $V_{def}$  を再構成する。 $V_{def}$  と正解画像  $V_{gt}$  との間の差を最小化することで最適なパラメータを学習する。この際に標準的な勾配ベースの最適化手法を使用するために、微分可能な演算により  $V_{def}$  の各ボクセルの値を計算する [12]。

まず各ボクセル  $\mathbf{p}$  について、 $V_s$  内の位置  $\mathbf{p}' = \mathbf{p} + \mathbf{u}(\mathbf{p})$  を求める。このとき、画素値は  $V_s$  内の整数位置でのみ定義されるため、式(1)に示すように  $V_{def}(\mathbf{p})$  の値を  $\mathbf{p}'$  に隣接する8個のボクセルの値で線形補完する。

$$V_{def}(\mathbf{p}) = \sum_{\mathbf{q} \in \mathcal{Z}(\mathbf{p}')} V_s(\mathbf{q}) \prod_{d \in \{x, y, z\}} (1 - |\mathbf{p}'_d - \mathbf{q}_d|) \quad (1)$$

ここで、 $\mathcal{Z}(\mathbf{p}')$  は  $\mathbf{p}'$  に隣接するボクセルであり、 $\mathbf{p}'$  からの

距離で重み付けをしている。これによって勾配もしくは劣勾配を計算できるため、最適化において誤差逆伝搬が可能となる。

### 2.2.3 損失関数

提案手法では、 $V_{gt}$  との類似度が高く変形の滑らかな  $V_{def}$  を得るために、画素値の違いに制約を課す平均二乗誤差 (Mean Squared Error: MSE) 損失と、 $\phi$  の局所的な変位に制約を課す正則化損失を導入する。MSE 損失は  $V_{def}$  と  $V_{gt}$  の間で、対応するボクセルの画素値の誤差を評価する。MSE 損失を式(2)のように定義する。

$$\mathcal{L}_{MSE}(V_{gt}, V_{def}) = \frac{1}{|\Omega|} \sum_{\mathbf{p} \in \Omega} [V_{gt}(\mathbf{p}) - [V_{def}](\mathbf{p})]^2 \quad (2)$$

ここで、 $\Omega$  は CT 画像内の全ボクセルの集合を表す。MSE 損失は  $V_{def}$  の各ボクセルを対応する  $V_{gt}$  のボクセル位置に収束させる働きがある。

$\mathcal{L}_{MSE}$  を最小化すると  $V_{def}$  は  $V_{gt}$  に近づくが、物理的にありえないような滑らかでない  $\phi$  が生成される可能性がある。そのため変位場  $\mathbf{u}$  の勾配を正則化し、滑らかな  $\phi$  を生成するための正則化損失を、式(3)のように定義する。

$$\mathcal{L}_{smooth}(\phi) = \sum_{\mathbf{p} \in \Omega} \|\nabla \mathbf{u}(\mathbf{p})\|^2 \quad (3)$$

正則化損失によって滑らかな変形を表現しつつ、より  $V_{gt}$  に近い  $V_{def}$  を得るように学習を行うことができる。

全体の損失は重みパラメータ  $\lambda$  を用いて式(4)で表される。

$$\mathcal{L}_{total}(I_{tar}, V_{sou}, \phi) = \mathcal{L}_{MSE}(V_{gt}, V_{def}) + \lambda \mathcal{L}_{smooth}(\phi) \quad (4)$$

提案手法では、重みパラメータ  $\lambda$  について VoxelMorph で推奨されている  $\lambda = 0.05$  を用いた。

## 3. 実験

本実験の目的は、患者内で異なる時相に得られた低コントラストな DRR 画像と CT 画像の間で 2D/3D 位置合わせを行い、提案手法による患者の呼吸に伴う臓器変形を反映した CT 画像の再構成性能を確認することである。

### 3.1 データセットおよび前処理

本実験では、京都大学医学部附属病院放射線治療科におい

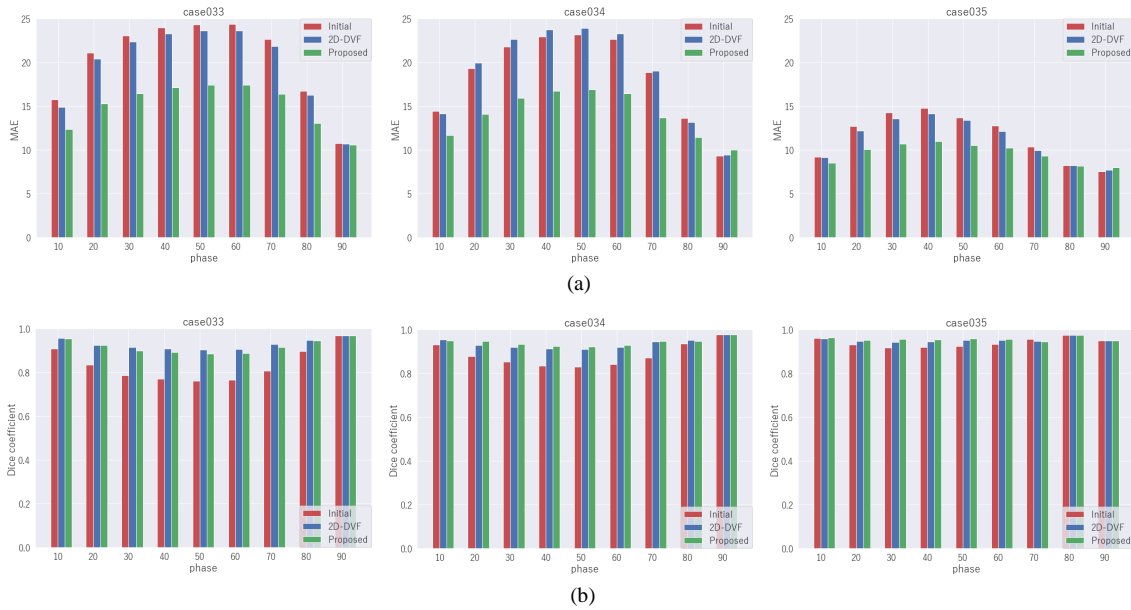


図3 提案手法の定量評価. (a) MAE, (b) 肝臓領域に関する Dice 係数.

て、肺がんの放射線治療を受けた 35 名の患者の 1 呼吸分の 10 時相からなる腹部 4D-CT データを用いる。また、データの時相を phase00, 10, ..., 90 で表すこととする。このとき phase00 および 90 は患者の最大吸気時相を表し、phase40 および 50 付近が最大呼気時相となる。各 3D-CT ボリュームは  $512 \times 512$  pixel からなる 88-152 枚の 2 次元断層画像 (1voxel:  $1.0 \text{ mm} \times 1.0 \text{ mm} \times 2.5 \text{ mm}$ ) から構成されている。CT ボリュームを背腹方向に投影計算することで、X-ray 画像を疑似的に表現した DRR 画像を生成し、CT 画像及び DRR 画像の画素はそれぞれ等方化後、画像サイズを  $128 \times 128$  pixel にリサンプリングした。

次に、提案手法ではターゲット画像とソース画像を連結し、 $128 \times 128 \times 128 \times 2$  channel の 3D ボリュームとして三次元変位場生成部に入力する。このとき、1channel 目には 3D-CT を与え、2channel 目には全ボクセルの画素値を 0 に初期化後、2 枚の DRR 画像の画素情報のみを与えて入力とした。また、本実験では呼吸による臓器変形と位置合わせ性能の関係を確認するために、3D-CT の時相を phase00 に固定し、ターゲットとなる DRR 画像の時相を phase10 から 90 へ変化させた。前処理後の 35 症例 10 時相からなる全 350 データのうち、32 症例から得られた 320 データをトレーニングデータとし、残りの 3 症例から得られた 30 データをテストデータとした。

### 3.2 誤差指標

本実験では、再構成画像と正解画像との画像全体での差を評価するために、平均絶対誤差 (Mean Absolute Error: MAE) を導入する。MAE は二つの画像間に対応するボクセルの画素値の差を計算し、その平均値を取ったものである。これにより画像間の平均的な CT 値の差を確認することができる。MAE を式 (5) のように定義する。

$$MAE(V_{gt}, V_{def}) = \frac{1}{|\Omega|} \sum_{p \in \Omega} |V_{gt}(p) - V_{def}(p)| \quad (5)$$




図4 入力 DRR 画像. (a) 最大吸気時相 (phase00), (b) 最大呼気時相 (phase40).

次に、Dice 係数を用いて肝臓形状の再構成性能を評価する。対象となる肝臓領域には、各時相の三次元 CT 画像に対して事前に放射線技師によって手動で定義された輪郭データ [13] を用いる。Dice 係数を式 (6) のように定義する [14]。

$$Dice(L_{gt}, L_{def}) = 2 \frac{|L_{gt} \cap L_{def}|}{|L_{gt}| + |L_{def}|} \quad (6)$$

ここで、 $L_{gt}$ ,  $L_{def}$  はそれぞれ肝臓形状の真値、再構成された肝臓形状を表す。

これらの評価関数に加えて、再構成画像および変位場を可視化することにより、再構成性能を確認することとした。

### 3.3 比較対象

提案手法では入力画像から三次元変位場を学習するが、このとき二次元投影像のみからは推定が困難な背腹方向の変位推定による三次元画像再構成性能を検証するために、背腹方向を除く二次元変位場のみを用いて三次元画像再構成を行い、提案手法と比較する。比較手法に用いる二次元変位場は、提案手法においてソース画像を phase A の DRR 画像、ターゲット画像および正解画像を phase B の DRR 画像に置き換えて、投影像間の 2D/2D 位置合わせを行うことで得られる。得られた二次元変位場を用いて 3D-CT のすべての冠状面スライス空間変換することで、疑似的に CT 画像を再構成する。これは、二次元投影像内で類似度を評価し 2D/3D 位置合わせを行




図5 提案手法の視覚的評価 (case033). 上段は冠状面 (Coronal), 中段は矢状面 (Sagittal), 下段は横断面 (Axial) のスライス.




図6 再構成 CT 画像と変位場. (a) 肝臓周辺の横断面スライス, (b) 中央の横断面スライス.




図7 横断面における肝臓領域の可視化. 紫: 推定された領域, 緑: 真値, 白: 重複領域. (a) 2D-DVF, (b) 提案手法.

う従来の発想に基づいた手法である [3],[9]. 以降, この比較手法を 2D-DVF と呼ぶ.

### 3.4 実験および結果

提案フレームワークは Tensorflow-GPU により実装し, 学習率  $1 \times 10^{-4}$  の Adam optimizer を使用してトレーニングを行った. バッチサイズは 4, エポック数は 200 とし, 学習には 316 分を要した. 2D-DVF はトレーニング時にバッチサイズ 32 とし, その他の条件は提案手法と同様とした.

テストデータとして用いた case033, 034, 035 の 3 症例ついで,

$I_{tar}$  を phase10 から 90 の各時相として提案手法および 2D-DVF による位置合わせを行い, MAE と Dice 係数を用いた評価を比較した. 図 3 に結果を示す. また, 評価の比較対象として位置合わせを行う前の入力 CT 画像と正解画像との間で各値を算出し, 図 3 中に Initial として示す. 各症例において, 呼吸に伴う臓器変位の大きな phase30-60 で MAE が高く, 肝臓形状の Dice 係数は低いことがわかる. MAE については, 図 3(a) に示すように大部分で提案手法による MAE が 2D-DVF を下回っており,  $t$  検定において  $p$  値は  $6.0 \times 10^{-3}$  であり有意差が確認された. これにより, 三次元変位場の推定によって CT 画像の再構成性能は向上することが確認された. 一方で, ダイス係数については図 5(b) に示すように case034, 035 の大部分で提案手法は 2D-DVF をわずかに上回っているが, 横隔膜周辺の変位が相対的に大きな case033 ではすべての phase で 2D-DVF による再構成性能を下回っていることが確認できた.  $t$  検定において  $p$  値は  $9.3 \times 10^{-1}$  であり, 両者に有意差は確認できなかった.

1 例として, 図 4 に case033 の最大吸気時相 (phase00) および最大呼気時相 (phase40) における DRR 画像を示す. また, この二枚の DRR 画像をターゲット画像としたときのテスト結果について, 右横隔膜をキャプチャ範囲に含んでいる冠状面 (Coronal), 矢状面 (Sagittal), 横断面 (Axial) の各スライスを図 5 に示す. 各スライスから, 入力 CT 画像では右横隔膜が下がっているのに対し, 提案手法および 2D-DVF により再構成された再構成 CT 画像では呼吸に伴って同部分が上部に移動していることが確認できる. また, 矢状面のスライスについて黄色の矢印で示した部分に着目すると, 2D-DVF により再構成された CT 画像は入力 CT 画像の同一部分の形状を保持したまま上部に移動しているのに対して, 提案手法による再構成 CT 画像はより真値に近い見た目となっており, ボクセ

ルごとの変位が見て取れる。図5で示した提案手法による再構成CT画像の横断面のスライスに、同一平面内の変位場を重ねた結果を図6(a)に示す。変位ベクトルの向きから、背腹方向の臓器変位を推定できていることが確認できる。図6(b)は再構成CT画像中央の横断面スライスに上と同様の処理を加えたものであり、同様の結果が確認できる。

2D-DVFと提案手法では再構成結果のMAEに差が見られたのに対して、肝臓形状のDice係数では差が確認されなかった。図7は、図6(a)のスライスにおいて変形後の肝臓領域を紫、真値を緑で示しており、重複領域は白となる。図7(a)は2D-DVF、図7(b)は提案手法による再構成結果を示しており、図7(b)では図6(a)に示した変位場によって肝臓が図下方向に変位している様子が確認できる。一方で、図7内に黄色の矢印で示す部分に着目すると、図7(b)で紫色で示す形状に凹みが確認でき、変形後の肝臓上部を捉えていることがわかる。このことから、提案手法では呼吸に伴う体軸方向の臓器変位が十分でない部分があることが確認できた。

#### 4. おわりに

本研究では、低コントラストな腹部領域の二次元DRR画像に対して、三次元CT画像の可変形位置合わせを達成する深層学習の枠組みを提案した。10時相の腹部4D-CTデータから得られた二次元DRR画像と三次元CT画像を用いた実験を行い、患者の呼吸に伴う臓器変形を反映したCT画像の再構成が可能であることを確認した。二次元変位場のみを用いて三次元画像再構成を行う手法との比較により、投影画像からは推定困難な背腹方向の変位を含む三次元変位場の推定によってCT画像の再構成性能が向上することを確認した。今後の研究では、新たな損失関数の導入などによりフレームワークを改良し、高性能な三次元画像再構成を目指す。

#### 謝辞

本研究は日本学術振興会 科研費補助金 基盤研究(B) 18H02766 及び 19H04484 の支援による。

#### 文 献

- [1] C. Gendrin, H. Furtado, C. Weber, C. Bloch, M. Figl, S.A. Pawiro, H. Bergmann, M. Stock, G. Fichtinger, D. Georg, W. Birkfellner, "Monitoring tumor motion by real time 2D/3D registration during radiotherapy," *Radiotherapy and oncology*, vol.102, no.2, pp.274-280, 2012.
- [2] C.J.F. Reyneke, M. Lüthi, V. Burdin, S.T. Douglas, T. Vetter, T.E. Mutsvangwa, "Review of 2-D/3-D reconstruction using statistical shape and intensity models and X-ray image synthesis: Toward a unified framework," *IEEE reviews in biomedical engineering*, vol.12, pp.269-286, 2018.
- [3] S. Miao, Z.J. Wang, R. Liao, "A CNN regression approach for real-time 2D/3D registration," *IEEE trans. medical imaging*, vol.35, no.5, pp.1352-1363, 2016.
- [4] J. Zheng, S. Miao, R. Liao, "Learning CNNs with pairwise domain adaptation for real-time 6dof ultrasound transducer detection and tracking from x-ray images," In *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, pp.646-654, 2017.
- [5] A. Presenti, Z. Liang, L.F.A. Pereira, J. Sijbers, J. De Beenhouwer, "CNN-based Pose Estimation of Manufactured Ob-

- jects During Inline X-ray Inspection," In *2021 IEEE 6th International Forum on Research and Technology for Society and Industry (RTSI)*, pp.388-393, 2021.
- [6] S. Wu, M. Nakao, J. Tokuno, T. Chen-Yoshikawa, and T. Matsuda, "Reconstructing 3D lung shape from a single 2D image during the deaeration deformation process using model-based data augmentation," *IEEE International Conference on Biomedical and Health Informatics (BHI)*, pp.1-4, 2019.
- [7] F. Tong, M. Nakao, S. Wu, M. Nakamura and T. Matsuda, "X-ray2Shape: Reconstruction of 3D Liver Shape from a Single 2D Projection Image", *IEEE Engineering in Medicine and Biology Society (EMBC)*, pp.1608-1611, 2020.
- [8] M. Nakao, M. Nakamura, T. Matsuda, "Image-to-Graph Convolutional Network for Deformable Shape Reconstruction from a Single Projection Image," *International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI)*, pp.259-268, 2021.
- [9] G. Balakrishnan, A. Zhao, M.R. Sabuncu, J. Guttag, A.V. Dalca, "Voxelmorph: a learning framework for deformable medical image registration," *IEEE trans medical imaging*, vol.38, no.8, pp.1788-1800, 2019.
- [10] G. Haskins, U. Kruger, P. Yan, "Deep learning in medical image registration: a survey," *Machine Vision and Applications*, vol.31, no.1, pp.1-18, 2020.
- [11] O. Ronneberger, P. Fischer, T. Brox, "U-net: Convolutional networks for biomedical image segmentation," In *International Conference on Medical image computing and computer-assisted intervention (MICCAI)*, pp.234-241, 2015.
- [12] R. Bajcsy, S. Kovačič, "Multiresolution elastic matching," *Computer vision, graphics, and image processing*, vol.46, no.1, pp.1-21, 1989.
- [13] M. Nakao, M. Nakamura, T. Mizowaki, T. Matsuda, "Statistical deformation reconstruction using multi-organ shape features for pancreatic cancer localization," *Medical Image Analysis*, Vol.67, 101829, 2021.
- [14] L.R. Dice. "Measures of the amount of ecologic association between species," *Ecology*, vol.26, no.3, pp.297-302, 1945.