

X-ray2Shape: グラフ畳み込みネットワークを用いた 単一 X-ray 画像からの臓器形状再構成

Fei Tong^{1,a)} 中尾 恵¹ 武 淑瓊² 中村 光宏³ 松田 哲也¹

概要: CT や MRI により生体の高分解能の 3 次元画像が計測可能となったが、手術時や放射線治療中には内視鏡画像や X-ray 画像などの低次元かつ局所的な単視点画像しか得られないことが多い。また、呼吸によって臓器は変形しつつ移動するため、治療時における臓器形状の再構成は難しい課題である。本研究では、グラフ畳み込みネットワーク (GCN) を用いて単一 X-ray 画像から臓器形状を再構成する X-ray2Shape の枠組みを提案する。臓器形状メッシュの再構成に有効な損失関数を新たに導入し、患者個人の 3D-CT データから生成可能な最大吸気時の臓器形状を初期テンプレートとして、呼気時相の X-ray 画像特徴量と臓器形状間の関係を学習する。35 症例 10 時相からなる 4D-CT データを用いて、腹部領域の疑似 X 線画像から肝臓の 3 次元形状を再構成する実験を行い、提案法の性能を確認したので報告する。

キーワード: 三次元形状推定, グラフ畳み込みネットワーク, X-ray 画像

X-ray2Shape: Reconstruction of Organ Shape from a Single X-ray Image using Graph Convolution Network

Abstract: High resolution 3D images can be measured by computed tomography and magnetic resonance imaging. However, during surgery or radiotherapy, only low-dimensional and local single-viewpoint 2D images may be obtained, and organs move while deforming due to breathing. Therefore, shape reconstruction from a single-viewpoint 2D image such as an endoscopic image or an X-ray image remains a challenge. In this study, we proposed an X-ray2Shape framework which can reconstruct the 3D organ shape from a single-viewpoint X-ray image using a graph convolution network. The proposed method learns the mesh deformation from organ shape during inspiration and deep features computed from the individual X-ray images. Experiments with organ meshes and digitally reconstructed radiograph images of abdominal regions were performed to confirm the estimation performance of our proposed method.

Keywords: 3D shape reconstruction, Graph Convolution Network, X-ray image

1. はじめに

コンピュータ断層撮影 (CT) や磁気共鳴画像 (MRI) などの 3 次元医用イメージングは人体の内部情報を画像化できるため、診断や手術計画、術中ナビゲーション等に広く用

いられている。しかし、3 次元 CT から正確な臓器の形状や腫瘍の位置を得るためには数百以上のスライス画像の撮影が必要であり、患者にとって望ましくない高い放射線被曝が生じる [1][2]。また、正確に 3 次元臓器形状を抽出するプロセスも必要となる。計測枚数を減らしたり、画像の解像度を落とすことによって計測時間と放射線量を減少させることができるが、それに応じて画像の品質は低下する。特に外科手術や日々の放射線治療の開始後は、物理的に離れた場所にある CT や MRI の機器を用いた撮像は難しい。高解像度の 3 次元画像は得られず、内視鏡画像や X-ray 画像等の低次元かつ局所的な 2 次元画像のみに基づいて治療が進められる。

この問題を解決するために、内視鏡画像や X-ray 画像な

¹ 京都大学大学院情報学研究科
Graduate School of Informatics, Kyoto University, Yoshida Honmachi, Sakyo-ku, Kyoto, 606-8501, Japan

² 大阪大学産業科学研究科
The Institute of Scientific and Industrial Research, Osaka University, 8-1 Mihogaoka, Ibaraki, Osaka, 567-0047, Japan

³ 京都大学大学院医学研究科
Graduate School of Medicine, Kyoto University, 53 Syogoin Kawaramachi, Sakyo-ku, Kyoto, 606-8507, Japan

^{a)} tong.fe.i@sys.i.kyoto-u.ac.jp

ど2次元画像から臓器の3次元形状を求める研究が進んでいる。3次元形状再構成の対象は変形が微小な臓器 [3] と柔軟臓器 [4] の二種類に分けられる。骨盤や下肢などの骨格系は剛体とみなすことができ、形状復元は広く研究されている。一方、変形しやすい柔軟臓器の形状推定については Deformable Image Registration (DIR)[5][6] や統計的モデリング [7][8] などの手法が提案されており、さらに呼吸変形を対象に様々な呼吸時相における臓器の位置姿勢を予測する研究 [9][10] も多くなされてきた。しかし、柔軟臓器を対象として2次元画像から3次元形状や呼吸に伴う変形を復元する試みは難しい問題であり、研究例も限られている。

Wu ら [11] は Convolutional Neural Network (CNN) に基づく3次元形状の推定方法を提案し、虚脱肺の3次元形状を2次元投影像から復元できることを示した。しかし、この手法の出力である推定形状は点群として表されているため変形算出に重要な表面情報と点群間のトポロジー情報が失われる。肺や腹部の臓器のような変形が大きい臓器に対して、点群のみから変形前後の頂点对応を正確に得ることは困難である。Wang ら [12] は X-ray 画像を疑似的に表現した Digitally Reconstructed Radiograph (DRR) 画像1枚から、肺の呼吸運動に伴う変形を求める CNN ベースの枠組みを提案している。しかし、この手法は人工的に変形を作り出した augmentation データを用いて学習と推定を行っており、さらに、複数の3次元テンプレートを変形して3次元形状を再構築している。このため、実在する患者個人の臓器形状や変形の復元性能については未だ明らかになっていない。

我々はこれまでに患者間 (Inter-patient) の形状差を対象に肝臓の平均形状を初期テンプレートとして患者個人の二次元腹部 X-ray 画像から患者個人の三次元肝臓形状を算出するフレームワークを構築し、実在の患者の3次元 CT データを用いて肝臓全体の復元性能および横隔膜部分の復元性能について確認した [13][14]。本研究はグラフ畳み込みネットワーク (Graph Convolutional Network, GCN)[15] と CNN を組み合わせた深層学習に基づいて同一患者内 (Intra-patient) における呼吸に伴う臓器変形の推定性能を検証することを目的とする。一般画像を対象に提案された Pixel2Mesh[16] の枠組みを X-ray 画像に応用する。Pixel2Mesh は画像の特徴量を利用して楕円体のテンプレート形状から目標の三次元形状まで変形させる枠組みであり、物体と背景間の輪郭が明瞭で、かつ、原点に固定された物体に対して有効な枠組みである。これに対し、本研究が対象とする X-ray 画像は投影像であり、特に腹部領域では臓器の明確な輪郭が存在せず、一般画像に比べてコントラストも非常に低い。また、患者間 (inter-patient) の同一臓器の形状差は大きく、同一患者内 (intra-patient) では呼吸運動により臓器の位置や形状は変化している。このため、Pixel2Mesh をそのまま X-ray 画像に適用しても十分な復元精度を達成することは

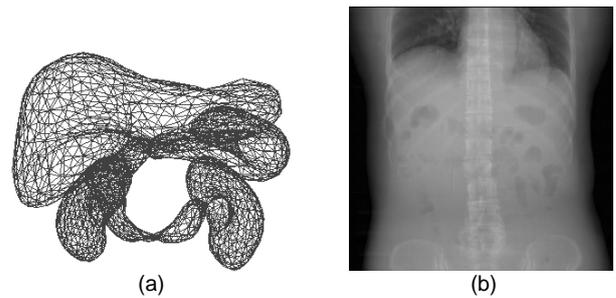


図1 対象データ。(a)変形位置合わせ後の5臓器(肝臓、胃、十二指腸、左腎、右腎)、(b)入力 DRR 画像。

難しい。本研究では新たな損失関数を定義し、問題に合わせた臓器形状の初期テンプレートを使用することによって1枚の X-ray 画像のみからより正確な3次元臓器形状を推定することを目指す。

京都大学医学部附属病院において膵がんに対する放射線治療を受けた124名の患者の腹部3D-CT(3次元CT)画像と、各症例10時相からなる35名の4D-CT(3次元に加えて時相変化を含む4次元CT)画像を用い評価実験を行った。患者間の形状差と患者内における呼吸変形を対象に、3次元CT画像から算出されたDRR画像に基づいて肝臓の3次元形状を復元する2種類の実験を行い、提案手法の有効性を検証する。提案手法は3次元臓器の形状をリアルタイムに生成できるため、例えば放射線治療において、X-ray 画像のみから照射当日のリスク臓器の領域を再構成したり、呼吸変形に伴う腫瘍位置を推定する用途への利用が期待できる。

2. 提案手法

2.1 対象データ

本研究では、京都大学医学部附属病院放射線治療科において、膵がんの放射線治療を受けた124名の患者の腹部3D-CTデータ及び35名の10時相からなる4D-CTデータを用いる。本臨床データの収集は京都大学医の倫理委員会による承認の下、匿名化後データの学術研究への利用に関する患者の同意を得て実施された。放射線治療計画のために得られた各3次元CTデータに対して、事前に放射線技師によって手で肝臓、胃、左腎、右腎、十二指腸及び膵がんの輪郭がそれぞれ定義されており、三角形表面メッシュからなる臓器形状データが得られている。しかし、生成された形状データの頂点数は患者ごとに異なっており、そのままでは3次元臓器形状の学習に用いることはできない。そこで、本研究では頂点数が一致し、かつ、各点の対応が取れた臓器形状モデル群を得るために、可変形メッシュ位置合わせ (Deformable Mesh Registration)[7] を行うことで、頂点对応が取れたメッシュ群を得た。本研究では、この臓器形状モデルのメッシュを真値とした。

図1(a)に生成された5臓器のメッシュの一例を示す。位

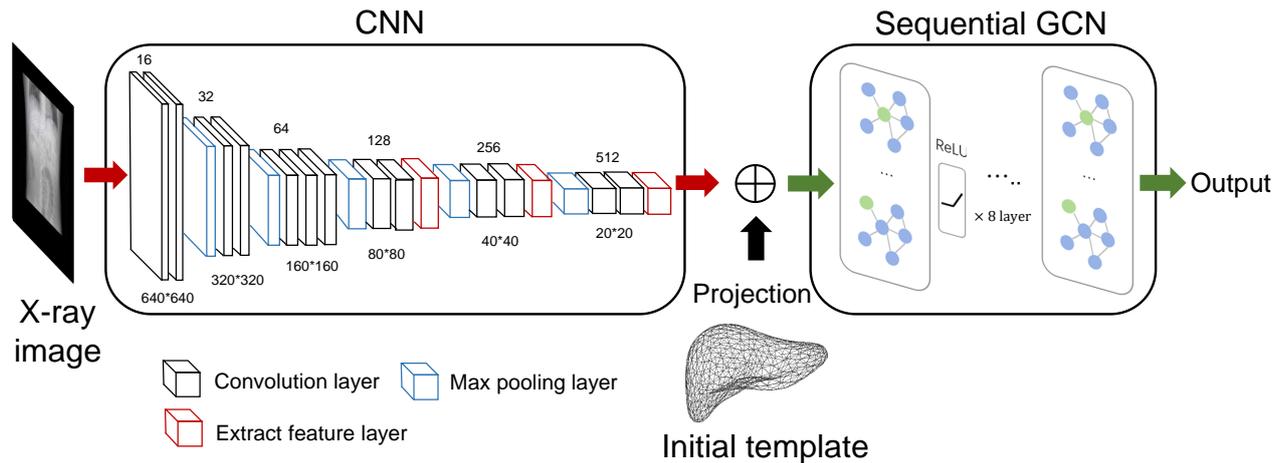


図2 提案する X-ray2Shape フレームワークのネットワーク構成。

置合わせ後の3次元形状データはいずれも各臓器で頂点数が一致した三角形メッシュであり、本研究で用いる肝臓形状は500頂点と996の三角形によって構成されている。また、図1(b)に同症例の3次元CTから生成された腹部のDRR画像を示す。DRR画像は3次元CTデータの各ボクセルを特定の方向から累積計算をすることによって生成でき、X-ray画像を疑似的に再構成したものである。本研究で用いるDRR画像の解像度は 640×640 とした。

2.2 問題設定

CT (Computed Tomography) や MRI (Magnetic Resonance Imaging) は、生体の内部構造を短時間かつ非接触で取得できるため、現在多くの医療現場で用いられている。しかし、高い精度が得られるCTは、被爆量が大きく、装置が大型かつ高価であるため、放射線治療においては、より手軽なX線撮影装置で得られるX-ray画像に基づいて治療が進められる。まず、放射線治療前日までに、予め撮像されたCTデータを用いて腫瘍位置や照射予定領域を計画する。しかし、照射当日は患者の姿勢、呼吸などの影響で臓器の変形や腫瘍位置の変化が存在する。照射当日のX-ray画像から当日の臓器形状や呼吸に伴う臓器位置の変化を推定できれば放射線の被曝線量の低減また治療成績の向上が期待できる。

図2に提案手法X-ray2Shapeのフレームワークを示す。提案するフレームワークは同一患者内 (Intra-patient) における呼吸に伴う臓器の変形を推定することが可能である。X-ray2Shapeフレームワーク全体はCNNとGCNで構成されている。メッシュの頂点に対応する2次元画像の深層特徴をCNNによって抽出し、得られた特徴に基づいてGCNがメッシュ変形を学習する。X線撮像では患者の姿勢はX線照射位置に対して固定されるため、画像撮像時のカメラの位置や角度は自明と仮定する。このとき、カメラパラメータを用いて、3次元形状の各頂点に対応する2次元画

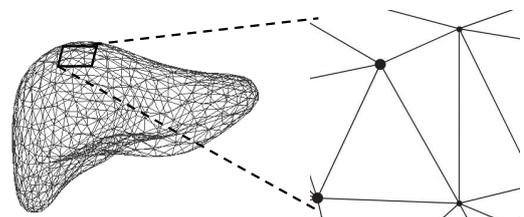


図3 500頂点と996面からなる肝臓の初期テンプレート

像上のピクセル位置を射影変換によって求めることができる。提案手法では、まず3次元初期テンプレートをDRR画像の上に投影させ、各頂点に対応する画像特徴を抽出する。頂点座標と対応する画像特徴を連結してGCNに対する入力データとし、変形後の3次元形状を出力として、ネットワークの重みを最適化する。正確で滑らかな臓器形状を得るためにMSE損失 (Mean Square Error, MSE)、離散ラプラス損失と重心損失関数を導入する。

2.3 提案フレームワーク

X-ray2Shapeフレームワークの全体像は図2に示されており、初期テンプレート、メッシュの頂点に対応する画像の特徴量を抽出するCNN、特徴量に基づいてメッシュを変形させるGCNで構成されている。各構成部分について詳しく説明する。

本研究で提案するX-ray2Shapeフレームワークは患者個人の最大吸気時相の臓器を初期テンプレートとして最大呼気時のX-ray画像から呼気時相の3次元臓器の位置と形状を求めることを目指す。今回の復元対象臓器は肝臓である。腹部領域X-ray画像から肝臓位置と形状推定実験で使用する初期テンプレートは図3に示すように、3次元肝臓データは全て500頂点と996面からなる三角メッシュ構造である。

CNNについては、図4(a)にCNNの各レイヤの詳細構造を示している。CNNは画像処理に有効かつ広く使用されているVGG-16モデル [17] を用いる。VGG-16は初期

設定では 224×224 ピクセルの画像が対象とされているが [18], 今回の入力データである DRR 画像はより高解像度の 640×640 ピクセルである. 有効な特徴量を抽出するために, 畳み込みフィルターのサイズを 3×3 から 5×5 に変更し, より広い範囲の画素から特徴を抽出することとした. 図 4 (b) に示すように, カメラパラメータを用いて, 各初期テンプレートの 3 次元頂点に対応する入力 DRR 画像のピクセル座標が求められる. 図 4 (a) に示す CNN の深層で豊富な情報を持つ赤い 3 レイヤーから特徴量を抽出し, 各頂点座標と連結する. X-ray2Shape フレームワークの前半では入力画像から有効な画像特徴量を抽出するとともに, カメラパラメータを用いて 2 次元画像と 3 次元形状の連結も実現される. なお, カメラパラメータは DRR 画像が作成されたとき得られる.

GCN[15] は, ディープラーニングをグラフデータに適用する手法である. グラフとは頂点 \mathcal{V} とその隣接関係を示す辺 \mathcal{E} によって構成されたデータ構造である. 例えば, 人間関係や Web ページのリンク, 道路網, 化学分野における化合物など, 本研究の三角メッシュ構造もグラフデータの一種である. GCN はグラフデータに対して畳みこみを行う手法である. グラフデータには, ノード自体の性質を表すノード特徴量と, エッジによるノード相互の隣接関係を示すデータが含まれている. グラフデータにおける畳み込みは, グラフ内のターゲットノードが持っている特徴量に対して隣接関係にあるノードの特徴量に重みを乗じたものを加えていく作業である. この作業によって, ターゲットノードの特徴量にはターゲットノード自体の特徴量だけでなく, どのような隣接関係を持ち, 周囲ノードにはどのような特徴量を持つものがあるのかといった情報が含まれることになる. 本研究で使われている GCN は図 5 に示すように連続 8 層のグラフ畳み込みレイヤーで構成されている. 各畳み込みレイヤーは式 (1) のように定義する,

$$\mathcal{F}^{(l+1)} = \sigma(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} \mathcal{F}^{(l)} W^{(l)}) \quad (1)$$

$\mathcal{F}^{(l)}$ と $\mathcal{F}^{(l+1)}$ はそれぞれ畳み込み前後の頂点の特徴ベクトルであり, n は頂点総数である. 隣接行列はその要素 \hat{A}_{ij} が頂点 i から頂点 j への辺が存在する時は 1, 存在しない時は 0 であるような正方行列であり, 次数行列は個々の頂点に接続した辺の数を要素として持つ対角行列, W は学習対象となる重み行列である. 畳み込み前の初期特徴ベクトル $\mathcal{F}^{(l)}$ は初期テンプレートの頂点座標と CNN から得られた各頂点に対応する画像特徴を連結したものである. $\mathcal{F}^{(l)}$ の更新によって初期テンプレートを変形させることができる.

2.4 損失関数の設計

本節では正確かつ滑らかな臓器形状を得るために, 3 種類の損失関数を導入する. MSE 損失はメッシュ頂点位置を

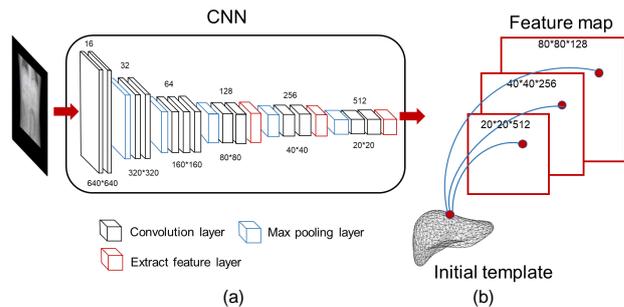


図 4 X-ray2Shape フレームワークの前半. (a) CNN の構成, (b) カメラパラメータを用いて 2 次元画像と 3 次元形状を連結

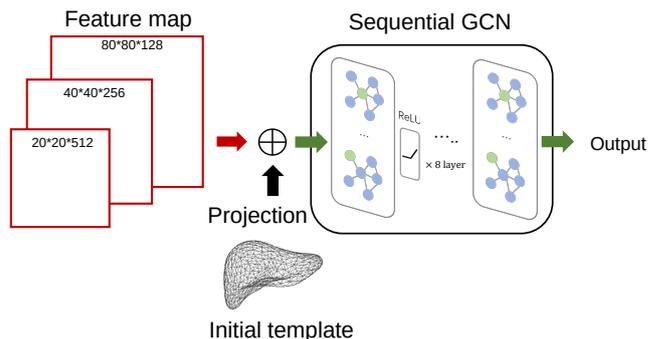


図 5 X-ray2Shape フレームワークの後半, 8 層グラフ畳み込み層からなる GCN

制約するために, 離散ラプラシアン損失 [7] はメッシュ表面の滑らかさを維持するために, また重心損失はメッシュ頂点全体の移動方向を学習するために定義している. 少ない頂点数を持つ同一楕円体から変形する Pixel2Mesh と異なり, 本研究では同じ頂点数を持つ初期テンプレートから異なる患者の臓器形状の復元及び同一患者内における呼吸に伴う臓器への変形を学習する.

MSE 損失は予測形状と真値の対応する頂点間の距離誤差を定量する. MSE 損失は式 (2) のように定義する.

$$\mathcal{L}_{MSE} = \frac{1}{n} \sum_{i=0}^n \|v_i - \hat{v}_i\|_2^2 \quad (2)$$

n は頂点の総数である. $v_i \in \mathcal{V} (i = 1, 2, \dots, n)$ は頂点座標の真値であり, \hat{v}_i は頂点の予測値である. この損失関数は予測頂点に対応する真値の頂点位置に収束させる働きがある.

離散ラプラシアン損失は予測結果の表面の滑らかさを評価する指標として用いる. 図 6 に離散ラプラシアンの例を示す. 各頂点 v_i に対して離散ラプラシアンは式 (3) のように定義される [19].

$$L(v_i) = \frac{1}{N(v_i)} \sum_{j \in N(v_i)} (v_i - v_j) \quad (3)$$

各頂点の離散ラプラシアンは $L(v_i)$ と表記し, $N(v_i)$ は頂点 v_i に隣接する頂点の個数であり, v_j はその隣接頂点の座標である. 三次元メッシュ形状には凹凸が存在し, 図 6 に示すように, 離散ラプラシアンベクトル $L(v_i)$ の方向と

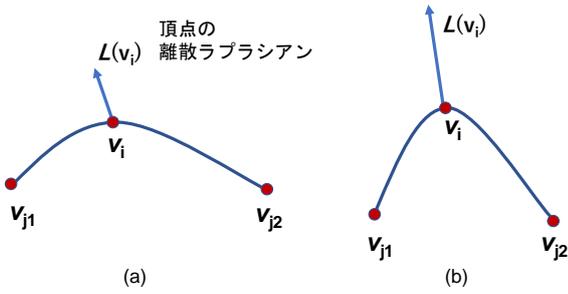


図6 頂点の離散ラプラシアン $L(v_i)$

長さはそれぞれ三次元表面の凸方向と曲率の大きさを表現する。図6(a)のように、滑らかなところでは曲率が小さく、注目頂点 v_i が持つラプラシアンベクトル $L(v_i)$ の長さも短い。一方、図6(b)のように、曲率が大きいところでは対応するベクトル長さが長い。離散ラプラシアン損失は式(4)のように定義する。 $L(v_i)$ と $L(\hat{v}_i)$ はそれぞれ離散ラプラシアンの真値と予測値に対応する。MSE 損失のみでは、頂点に対する制約が少なく、メッシュの表面形状が崩れやすい。離散ラプラシアン損失より表面の曲率を維持しつつ、真値に近い臓器形状が得られるような変形を学習することが可能と考えられる。

$$\mathcal{L}_{Laplacian} = \frac{1}{n} \sum_{i=0}^n \|L(v_i) - L(\hat{v}_i)\|_2^2 \quad (4)$$

重心損失はメッシュ頂点全体の移動方向を学習する。Pixel2Mesh は輪郭が明確な一般画像から形状復元する枠組みであり、初期テンプレートの各頂点は画像特徴量によって輪郭周辺まで移動し、目標形状に変形する。しかし、X-ray 画像は明確な輪郭は存在せず、腹部領域の X-ray 画像では横隔膜の輪郭しか確認できない。輪郭が明確な横隔膜付近の頂点は画像特徴量に応じて変形することが可能であるが、残りの頂点は画像特徴量によって正しく変形できない。このような問題点を解決するために、重心損失を定義する。臓器の重心は式(5)のように表現され、重心損失を式(6)のように定義する。

$$G(v_i) = \frac{1}{n} \sum_{i=1}^n (v_i) \quad (5)$$

$$\mathcal{L}_{Gravity} = \|G(v_i) - G(\hat{v}_i)\|_2^2 \quad (6)$$

$G(v_i)$ と $G(\hat{v}_i)$ はそれぞれメッシュ重心の真値と予測値である。横隔膜付近の頂点が画像特徴量に応じて移動すれば、残りの頂点を同じ方向に移動させることが可能となる。重心の真値と予測値の差を減少させることにより、初期テンプレートの頂点全体の移動方向を学習する。以上の3つの損失を用い、損失関数 \mathcal{L}_{total} を式(7)のように定義する。

$$\mathcal{L}_{total} = \lambda_{MSE} \mathcal{L}_{MSE} + \lambda_{Laplacian} \mathcal{L}_{Laplacian} + \lambda_{Gravity} \mathcal{L}_{Gravity} \quad (7)$$

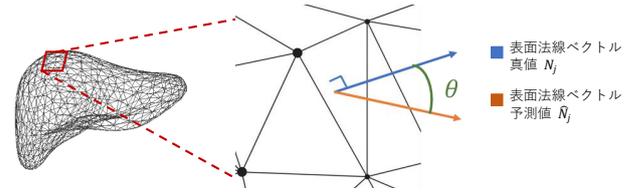


図7 法線ベクトルの予測値と真値のなす角 θ

ここで λ_{MSE} , $\lambda_{Laplacian}$, $\lambda_{Gravity}$ はそれぞれの損失の重みである。第3節の評価実験では重みパラメータについていくつかのパラメータセットを用いた試行を行い、最も推定性能が高かった損失関数重みを設定する。

3. 評価実験

3.1 評価指標

本節では予測結果と真値の距離誤差を評価するために平均形状間距離誤差 \mathcal{D}_{Mean} [20] とユークリッド距離誤差 $\mathcal{D}_{Euclidean}$ を導入し、予測結果と真値の表面の向きを評価するために法線ベクトルのなす角誤差 $\cos(\theta)$ を用いる。この3つの評価値に加えて、各実験の予測結果を可視化することによって、推定された臓器形状の表面の滑らかさやメッシュの品質を確認することとした。

\mathcal{D}_{Mean} は予測値と真値のメッシュ間で、メッシュの各頂点とその頂点から最も近いもう一方のメッシュの表面三角形との距離を双方向で算出し、その平均値を取ったものである。

ユークリッド距離誤差 $\mathcal{D}_{Euclidean}$ は予測結果と真値の対応頂点のずれを評価する指標である。ユークリッド距離誤差が小さいほど対応頂点のずれが小さく、予測結果の精度が高いことを示す。 $\mathcal{D}_{Euclidean}$ は式(8)のように定義する。

$$\mathcal{D}_{Euclidean} = \frac{1}{n} \sum_{i=0}^n \sqrt{(v_i - \hat{v}_i)^2} \quad (8)$$

法線ベクトルのなす角誤差 $\cos(\theta)$ は予測結果と真値の表面の向きのずれを評価する指標である。図7のように N_j は三角メッシュ表面の法線ベクトルの真値であり、 \hat{N}_j は法線ベクトルの予測値である。予測結果と真値の法線ベクトルのなす角 $\cos(\theta)$ は式(9)のように定義し、 m は面の個数である。 $\cos(\theta)$ は1に近づくほど予測結果と真値の表面の向きのずれが小さいことを示す。

$$\cos(\theta) = \frac{1}{m} \sum_{j=1}^m \frac{N_j \cdot \hat{N}_j}{|N_j| |\hat{N}_j|} \quad (9)$$

3.2 実験データ

本実験では、呼吸に伴う臓器変形の推定精度を向上させるために実患者の3D-CTデータに対する学習データを生成する。作成データを用いてX-ray2Shapeフレームワークをトレーニングし、動体追尾照射による治療を受けた患者の35症例の4D-CTデータを用いてテストする。学習デー

	λ_{MSE}	$\lambda_{Laplacian}$	$\lambda_{Gravity}$	$\bar{D}_{Euclidean}$	\bar{D}_{Mean}	$\cos(\theta)$
条件 (a)	1	1	1	10.1mm	4.8mm	0.968
条件 (b)	0.75	1	1	10.2mm	5.1mm	0.969
条件 (c)	0.5	1	1	10.3mm	4.8mm	0.969
条件 (d)	0.25	1	1	10.7mm	5.4mm	0.967
条件 (e)	0.5	0.75	1	10.6mm	5.1mm	0.968
条件 (f)	0.5	0.5	1	9.9mm	4.6mm	0.968
条件 (g)	0.5	0.25	1	10.3mm	5.1mm	0.968

表 1 異なる損失関数の重みに対する推定誤差

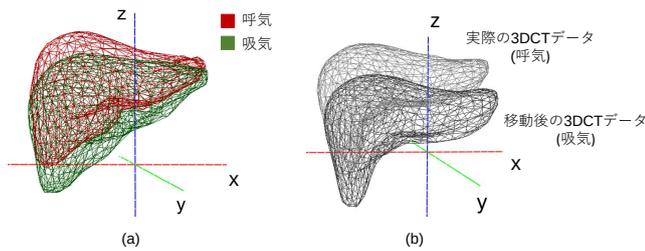


図 8 学習データ作成の流れ

タは以下のように作成する。

STEP1

図 8 (a) のように、35 症例の 4D-CT データの最大呼気と最大吸気時相の肝臓の重心より症例ごとの最大呼気に伴う臓器変位を算出する。

STEP2

4.1 節で用いた 124 症例の 3D-CT データは患者の最大呼気時相と仮定する。

STEP3

STEP1 で求めた最大呼気と最大吸気時相の臓器変位について、35 症例間の差異を示す範囲の中で 124 症例の 3D-CT データをランダムに移動させる。図 8 (b) のように、移動後の 3D-CT データは患者の最大吸気時相とする。

人工的に作成した 124 症例の最大呼気と最大吸気データをトレーニングデータとして、動体追尾照射による治療を受けた 35 症例の最大呼気と最大吸気の 4D-CT データをテストデータとする。

3.3 損失関数重みの設定

本実験では、図 8 (a) に示したように、患者個人の吸気時相と呼気時相の臓器間では変位が大きいが、形状差は小さい。したがって、形状を保ったまま頂点全体が移動する必要がある。そこで、重心損失の重みは相対的に大きく設定すべきであると考えられる。重みパラメータセットの試行実験は表 1 のように示す、重心損失の重みを 1 に固定し、他の損失関数の重みを 1 から減少させた。入力データは全て事前に正規化済みである。

	\bar{D}_{Mean}	$\bar{D}_{Euclidean}$	$\bar{D}_{Hausdorff}$
初期テンプレートのずれ	7.7mm	11.5mm	23.3mm
Pixel2Mesh	29.3mm	36.5mm	77.6mm
X-ray2Shape	4.6mm	9.9mm	16.3mm

表 2 従来法と提案方法による距離誤差の比較

表 1 に示したように、条件 (f) で $\bar{D}_{Euclidean}$, \bar{D}_{Mean} は最小となった。 $\cos(\theta)$ についてはいずれも大きな差異は認められなかった。以降、本実験では条件 (f) の $\lambda_{MSE} = 0.5$, $\lambda_{Laplacian} = 0.5$, $\lambda_{Gravity} = 1$ を用いることとした。

3.4 実験結果および従来研究との比較

本節では $\lambda_{MSE} = 0.5$, $\lambda_{Laplacian} = 0.5$, $\lambda_{Gravity} = 1$ の時、35 症例の 4D-CT テストデータの推定結果及び従来手法 Pixel2Mesh との比較実験の結果を示す。

図 9 に症例 case18 の肝臓形状の 3 次元再構成結果を示す。図 9 (a-c) は呼気時相の肝臓メッシュの真値、呼気時相の予測値と吸気時相の初期テンプレートである。初期テンプレートや予測値のメッシュの頂点と画像特徴との対応を確認するために、メッシュ形状を呼気 DRR 画像の上に射影し、図 9 (d-f) のように各頂点に対応するピクセルを青で示した。図 9 (f) では吸気初期テンプレートを呼気時相の DRR 画像上に投影すると輪郭のずれが大きく、特に右横隔膜の輪郭と乖離している。図 9 (e) では予測呼気時相の肝臓の投影図はかなり改善されており、呼気時相の DRR 画像との位置ずれが減少した。図 10 にテストデータ 35 症例の予測結果に対する平均距離誤差とユークリッド距離誤差を示す。青の棒グラフはユークリッド距離誤差 $\bar{D}_{Euclidean}$ と各頂点ごとの標準偏差 (Standard deviation, SD) を示し、全テストデータの平均値は 9.9mm である。緑の棒グラフは平均距離誤差 \bar{D}_{Mean} を示し、平均値は 4.6mm である。

すべての呼気時相の推定形状は患者個人の吸気時相の肝臓から変形して算出されているが、吸気初期テンプレートと呼気真値間のずれは表 2 の第 1 行目に示す通りである。 \bar{D}_{Mean} はテストデータ 35 症例の平均距離誤差の平均値であり、 $\bar{D}_{Euclidean}$ はユークリッド距離の平均値である。初

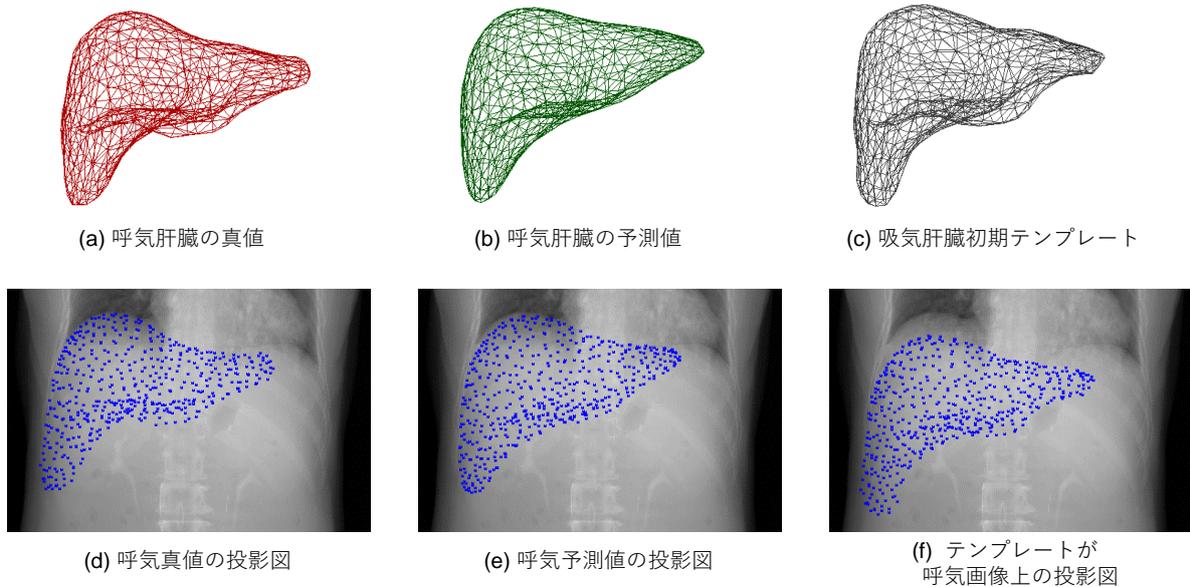


図9 提案手法による肝臓形状の3次元再構成の例。(a)3次元呼気肝臓形状(真値), (b)3次元呼気肝臓形状(予測値), (c)3次元吸気肝臓形状(初期テンプレート), (d)呼気X-ray画像に対する肝臓メッシュ頂点(呼気真値)投影図, (e)肝臓メッシュ頂点(呼気予測値)の投影図, (f)肝臓メッシュ頂点(吸気初期テンプレート)の投影図

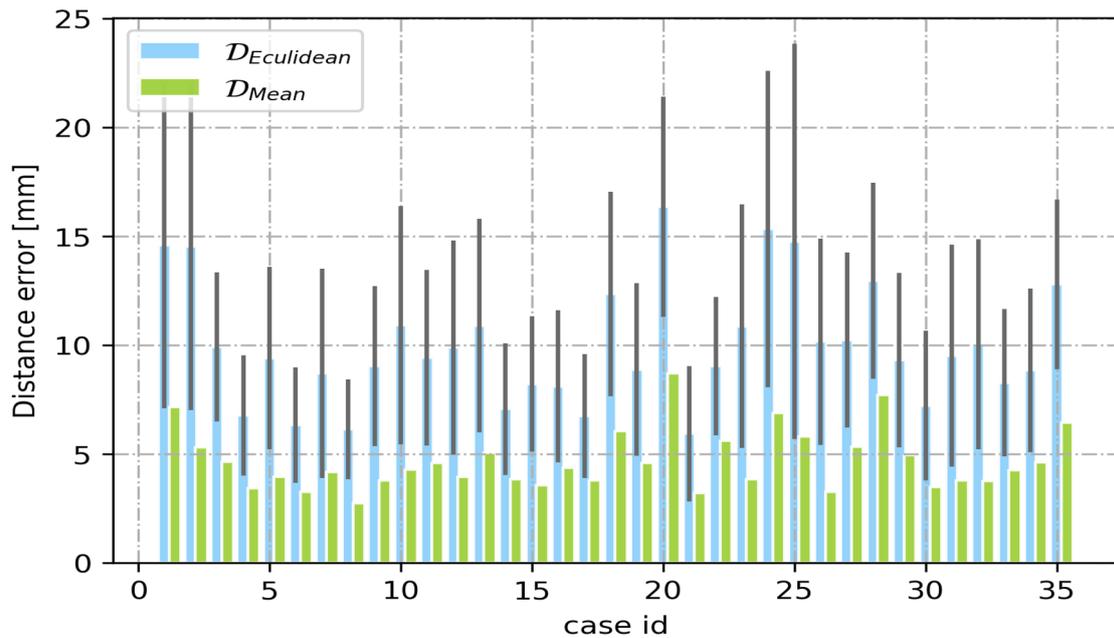


図10 テスト 4D-CT35 症例の平均距離誤差とユークリッド距離誤差の分布

期テンプレートのずれに比べ、推定形状の距離誤差は減少した。

次に、本研究において提案されている損失関数と Pixel2Mesh において提案された損失関数を用いてそれぞれネットワークをトレーニングし、予測結果を比較した。表2に比較結果を示す。本研究で提案している損失関数より得られた予測結果は Pixel2Mesh の損失関数より得られた結果に比べ、距離誤差がはるかに小さい。t-test において、ユークリッド距離誤差と平均距離誤差の p 値はそれぞ

れ 2.3×10^{-21} と 2.3×10^{-20} であり、両者の平均値には有意差が確認された。Pixel2Mesh で定義した損失関数では初期テンプレートから目標形状まで大きな変形(例:楕円体から飛行機まで形状変形)を学習することができるが、形状を維持しながら位置の推定ができないため、表2に示すように距離誤差が大きかった。

4. おわりに

本研究では、グラフ畳み込みネットワークを用いて単一 X-ray 画像から臓器形状を再構成する X-ray2Shape の枠組みを提案した。形状復元の精度および品質を確保するために新たな損失関数を定義し、同一患者内における呼吸に伴う臓器変形を求める手法を提案した。また、放射線治療を受けた 124 名の患者の腹部 3D-CT 画像と、各症例 10 時相からなる 35 名の 4D-CT 画像及び X-ray 画像を疑似的に表現した Digitally Reconstructed Radiograph (DRR) 画像を用いて提案手法の有効性を評価するための実験を行った。

提案手法によって同一患者内における呼吸に伴う臓器変形の推定を行った結果、平均形状間距離誤差 4.6mm、平均ユークリッド距離誤差 9.9mm の誤差で推定が可能であることを示した。本研究では問題に合わせた臓器形状の初期テンプレートをを用いることや、新たな損失関数を定義することで、一般画像を対象とした従来手法である Pixel2Mesh と比較して距離誤差が改善された。t-test において、両者の距離誤差には有意差が確認された。これまで、実際の患者の二次元 X-ray 画像から三次元臓器形状を復元する場合の復元性能についての解析は知られておらず、本研究により実在する患者個人の臓器形状の復元結果が得られた。今後の展望として、多視点画像や新しい損失関数を使用することによって、より高性能な 3 次元形状の再構成方法の改良が期待される。

謝辞

本研究は科研費基盤研究 (B) 課題番号：18H02766, 挑戦的研究 (萌芽) 課題番号：18K19918 の助成による

参考文献

- [1] M. Islam, T. Purdie, B. Norrlinger, H. Alasti, D. Moseley, M. Sharpe, J. Siewerdsen, and D. Jaffray, "Patient dose from kilovoltage cone beam computed tomography imaging in radiation therapy", *Medical Physics*, vol. 33, pp. 1573-1582, 2006.
- [2] M. Kan, L. Leung, W. Wong, and N. Lam, "Radiation dose from cone beam computed tomography for image-guided radiation therapy", *International Journal of Radiation Oncology Biology Physics*, vol.70, pp. 272-279, 2008.
- [3] CJF. Reyneke, M. Luthi, V. Burdin, TS. Douglas, T. Vetter, TE. Mutsvangwa, "Review of 2-D/3-D reconstruction using statistical shape and intensity models and X-ray image synthesis: toward a unified framework", *IEEE Rev Biomed Eng* 12, pp. 269-286
- [4] Y. Fu, L. Yang, T. Wang, W.J. Curran, T. Liu, X. Yang, "Deep learning in medical image registration: a review", *Physics in Medicine & Biology*, 2020.
- [5] K.M. Brock, J.M. Balter, L.A. Dawson, "Automated generation of a four-dimensional model of the liver using warping and mutual information", *Med Phys*. 2003 Jun;30(6):1128-33.

- [6] E. Ferrante, PK. Dokania, RM. Silva, N. Paragios, "Weakly supervised learning of metric aggregations for deformable image registration", *IEEE J. Biomed. Health* 23, pp.1374-1384, 2018.
- [7] 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
- [8] M. Nakamura, M. Nakao, N. Mukumoto, R. Ashida, H. Hirashima, M. Yoshimura, T. Mizowaki, "Statistical shape model-based planning organ-at-risk volume: application to pancreatic cancer patients," *Physics in Medicine and Biology*, vol. 66, no. 1, 014001, 2021.
- [9] D. Yang, W. Lu, DA. Low, JO. Deasy, AJ. Hope, I. El Naqa, "4D-CT motion estimation using deformable image registration and 5D respiratory motion modeling", *Med Phys*. Oct;35(10), pp.4577-4590, 2008
- [10] Y. Lei, Y. Fu, T. Wang, Y. Liu, P. Patel, W. J. Curran, T. Liu, and X. Yang, "4D-CT deformable image registration using multiscale unsupervised deep learning", *Phys Med Biol*, 65(8):085003, 2020.
- [11] 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 Int. Conf. on Biomed. Health Info.(BHI)*, pp. 1-4, 2019.
- [12] Y. Wang, Z. Zhong, and J. Hua, "DeepOrganNet: On-the-fly reconstruction and visualization of 3D/4D lung models from single-view projections by deep deformation network", *arXiv preprint*, Art. no. arXiv:1907.09375, 2019.
- [13] F. Tong, M. Nakao, S. Wu, M. Nakamura, T. Matsuda, "X-ray2Shape:Reconstruction of 3D liver shape from a single 2D projection image", *Proc. 42nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 1608-1611, 2020.
- [14] Fei Tong, 中尾 恵, 武 淑瓊, 中村 光宏, 松田 哲也, グラフ畳み込みネットワークを用いた単一 X-ray 画像からの 3 次元臓器形状の再構成, 電子情報通信学会技術報告 (MI), Vol. 120, No. 156, pp.45-50, 2020.
- [15] T. N. Kipf, and M. Welling, "Semi-supervised classification with graph convolutional networks", in *International Conference on Learning Representations (ICLR)*, 2016.
- [16] N. Wang, Y. Zhang, Z. Li, Y. Fu, W. Liu, and Y.-G. Jiang, "Pixel2mesh: Generating 3d mesh models from single rgb images", in *Proc. of the European Conference on Computer Vision (ECCV)*, 2018
- [17] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. C. Berg, and L. Fei-Fei, "ImageNet large scale visual recognition challenge", *Int. J. Comput. Vis. (IJCV)*, vol. 115, pp. 211-252, 2015.
- [18] K. Simonyan, and A. Zisserman, "Very deep convolutional networks for large-scale image recognition", in *International Conference on Learning Representations (ICLR)*, 2015.
- [19] M. Nakao, J. Tokuno, T. F. Chen-Yoshikawa, H. Date, T. Matsuda, "Surface Deformation Analysis of Collapsed Lungs using Model-based Shape Matching", *Int. J. Computer Assisted Radiology and Surgery*, 14(10), pp. 1763-1774, 2019.
- [20] J. Kim, C. Valdes-Hernandez Mdel, N. A. Royle, and J. Park, "Hippocampal shape modeling based on a progressive template surface deformation and its verification", *IEEE Trans. Med. Imag.*, vol. 34, pp. 1242-1261, 2015.