

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

Fei Tong[†] 中尾 恵[†] 武 淑瓊^{††} 中村 光宏^{†††} 松田 哲也[†]

[†] 京都大学大学院情報学研究科 〒606-8501 京都府京都市左京区吉田本町

^{††} 大阪大学産業科学研究所 〒567-0047 大阪府茨木市美穂ヶ丘 8-1

^{†††} 京都大学大学院医学研究科 〒606-8507 京都府京都市左京区聖護院川原町 53

E-mail: [†tong.fe.i@sys.i.kyoto-u.ac.jp](mailto:tong.fe.i@sys.i.kyoto-u.ac.jp)

あらまし コンピュータ断層撮影や磁気共鳴画像により高分解能の3次元画像が計測可能となった。一方、手術中や放射線治療中には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く、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。提案法は、X-ray 画像内の特徴量に基づいて臓器平均形状からのメッシュ変形を学習する。腹部領域の Digitally Reconstructed Radiograph 画像を用いて、肝臓形状の再構成を行い、提案法の性能を確認した。

キーワード 3次元形状推定, グラフ畳み込みネットワーク, X-ray 画像

Reconstruction of 3D Organ Shape from a Single X-ray Image using Graph Convolutional Network

Fei TONG[†], Megumi NAKAO[†], Shuqiong WU^{††}, Mitsuhiro NAKAMURA^{†††}, and Tetsuya
MATSUDA[†]

[†] Graduate School of informatics, Kyoto University

Yoshida Honmachi, Sakyo-ku, Kyoto, 606-8501 Japan

^{††} The Institute of Scientific and Industrial Research, Osaka University

8-1 Mihogaoka, Ibaraki, Osaka, 567-0047 Japan

^{†††} Graduate School of medicine, Kyoto University

53 Syogoin Kawaramachi, Sakyo-ku, Kyoto, 606-8507 Japan

E-mail: [†tong.fe.i@sys.i.kyoto-u.ac.jp](mailto:tong.fe.i@sys.i.kyoto-u.ac.jp)

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. 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 a mean template 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.

Key words 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次元医用画像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イメージング放射線量をも

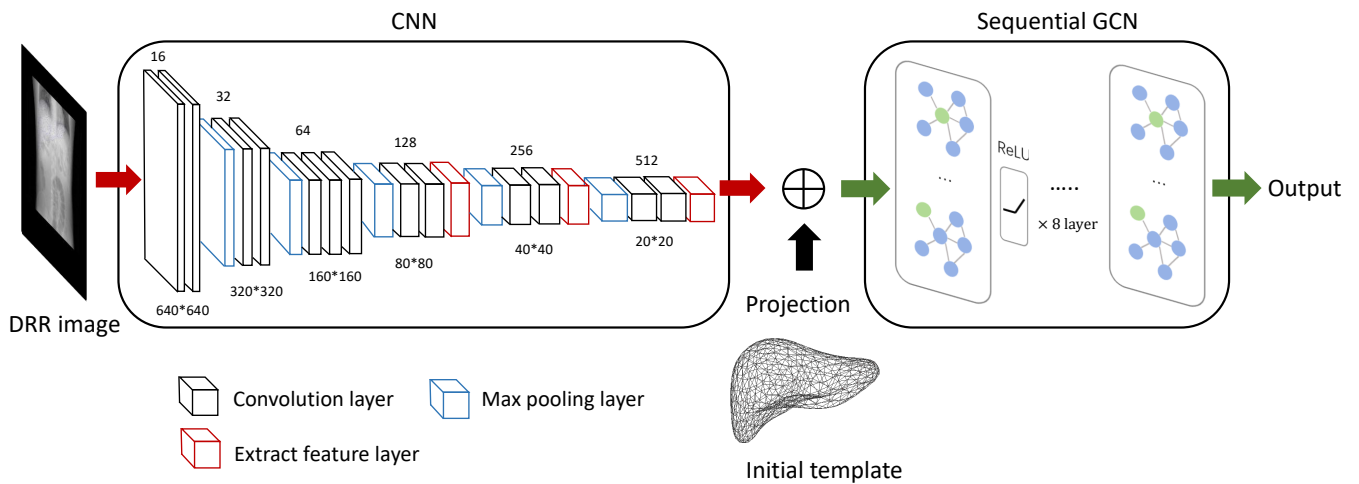


図1 提案する X-ray2Shape フレームワークのネットワーク構成.

たらず [1][2]. 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イメージング線量も減ることができるが, それに応じて画像品質が低下する. 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 線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, 一部の研究者は内視鏡画像や X 線画像などの 1 枚の 2 次元画像から術中臓器の 3 次元形状を求める方法を提案している [3][4][5]. 例えば, Wu らは Convolutional Neural Network (CNN) に基づく 3 次元形状再構築アルゴリズムを提案し, 虚脱肺の 3 次元形状を 2 次元投影画像から復元できることを示した [4]. 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. 点群のみから肺や腹部の臓器のような, 変形が大きい臓器に対して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, 肺の呼吸変形を求める CNN ベースの枠組みを提案している [5]. 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, 複数の三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.

本研究はグラフ畳み込みネットワーク (Graph Convolutional Network, GCN) [6] と CNN を組み合わせた深層学習に基づいて患者個人の 2 次元の X-ray 線画像から臓器の 3 次元形状を復元することを目的とする. 一般画像を対象に提案された Pixel2Mesh [7] の枠組みを疑似 X-ray 画像である DRR 画像に応用する. X-ray 画像や DRR 画像は投影画像であり, 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ため, 形状復元は困難な課題である. 本研究は臓器の平均形状を初期テンプレートとし, DRR の画像特徴を

利用して初期テンプレートから個人の臓器への変形を求める手法を提案する. 提案法は 3 次元臓器の画像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 線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推定への利用が期待できる.

2. 提案手法

2.1 問題設定

図 1 に提案手法の枠組みを示す. ネットワーク全体は 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.

本研究では, 患者の肝臓の平均形状を初期テンプレートと患者個人の DRR 画像から患者個人の肝臓の 3 次元形状を算出することを目指した. 正確で滑らかな臓器形状を得るために平均二乗誤差 (Mean Square Error, MSE) と離散ラプラシアンに基づく損失関数を導入する.

2.2 提案フレームワーク

本節では提案する Xray2Shape フレームワークの各モジュールについて説明する. 初期テンプレートについては, トレーニングデータから作成された臓器の平均形状 (図 2 (a)) を用いる. 本実験で使用する肝臓の初期テンプレートは 500 頂点と 996 面からなる三角メッシュ構造である. すべての推定形状はこの初期テンプレートから変形して算出する.

CNN については, 図 1 に各レイヤの詳細構造を示している. 今回 CNN の部分は画像処理に有効かつ広く使用されて

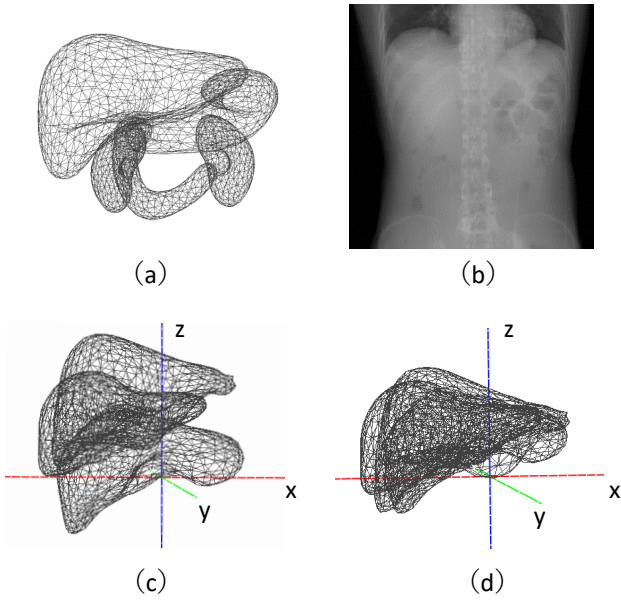


図2 実験データ。(a)5臓器(肝臓、胃、十二指腸、左腎、右腎)の初期テンプレート、(b)入力DRR画像、(c)前処理を行ってない肝臓データ、(d)前処理を行った後の肝臓データ

いるVGG-16モデル[8]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[9]、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。カメラパラメータを用いて、各3次元頂点に対応する入力DRR画像のピクセル座標を求める。また形状を正しく学習するために、CNNの後ろの豊富な情報を持つレイヤー(図1の赤)から特徴量を抽出し、連結する。

GCN[6]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。本研究では、グラフデータの一つである三角形メッシュの各頂点に対応する画像特徴に基づいて頂点位置を更新することで全体形状を変形させる。本実験で使われているGCNは連続8層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次のように定義する、

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

$\mathcal{F}^{(l)}$ 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、 $\hat{A} \in \mathbb{R}^{n \times n}$ は隣接行列(adjacency matrix)、 $\hat{D} \in \mathbb{R}^{n \times n}$ は \hat{A} の次数行列(degree matrix)、 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。

2.3 損失関数

本節では正確かつ滑らかな臓器形状を得るために、MSE損失

と離散ラプラシアン損失[10]に基づく損失関数を導入する。少ない頂点数を持つ楕円体から変形するpixel2meshと異なり、本実験では同じ頂点数を持つ平均形状から患者個人の臓器形状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動きがある。

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。頂点 v_i の離散ラプラシアンは式(3)のように定義する。

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

$N(v_i)$ は頂点 v_i と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。離散ラプラシアン損失は次のように定義する。

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

$L(v_i)$ 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を得る変形を学習することができる。

全体の損失は、2つの損失関数の重み付き合計である。

$$\mathcal{L}_{total} = \lambda_{MSE} \mathcal{L}_{MSE} + \lambda_{laplacian} \mathcal{L}_{laplacian} \quad (5)$$

本研究では、重みパラメータについて幾つかのパラメータセットを試行し、最も推定性能が高かった $\lambda_{MSE} = 1$ 及び $\lambda_{laplacian} = 100$ を用いる。

3. 評価実験

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て、放射線治療を受けた124名の膵がん患者の腹部3次元CTデータを用いる。治療計画時に医師によって5臓器(肝臓、胃、十二指腸、左腎、右腎)の輪郭が定義されており、曲面を三角形要素分割することにより、臓器形状の三角形メッシュが生成されている。事前に肝臓形状のメッシュ(頂点数:500,三角形数:996)をすべての患者データにメッシュ変形位置合わせ(Deformable Mesh Registration)[10]を適用することで、真値となる頂点对応が取れたメッシュ群を得た。3次元CTデータに対して投影計算を行うことによってDRR画像(図2(b))を生成することができる。DRR画像の解像度は 640×640 ピクセルとした。しかし、CTの撮影範囲は患者ごとに異なるため、CT画像から得られた座標値をそのまま臓器変形の学習に用いることはできない。例えば、図2(c)では異なる患者3人の肝臓の座標を示している。放射線治療時において、体表の特定の1点を計測あるい

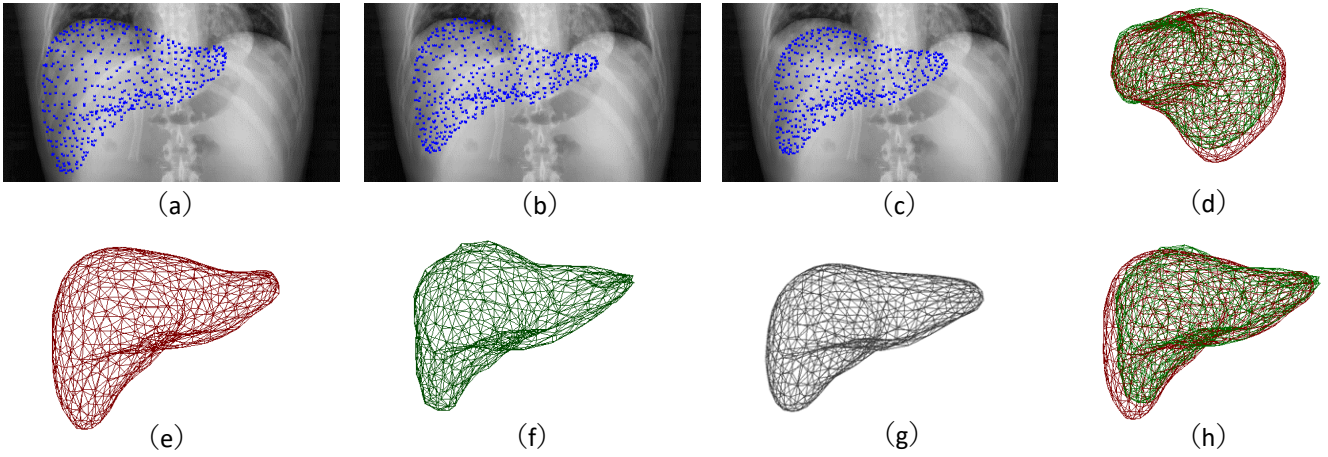


図3 提案手法による肝臓形状の3次元再構成の例. (a) X-ray 画像に対する肝臓メッシュ頂点 (真値) 投影図, (b) 肝臓メッシュ頂点 (予測値) の投影図, (c) 肝臓メッシュ頂点 (初期テンプレート) の投影図, (d) 肝臓メッシュの真値 (赤) と予測値 (緑) の側面図, (e) 3次元肝臓形状 (真値), (f) 3次元肝臓形状 (予測値), (g) 初期テンプレート, (h) 肝臓メッシュの真値 (赤) と予測値 (緑) の正面図

は位置決めすることは可能である. そこで, 本研究では, 前処理として5臓器 (肝臓, 胃, 十二指腸, 左腎, 右腎) の重心を計算し, その重心を原点として3次元臓器を平行移動した. 本前処理によって, 図2 (d) に示すように異なる患者の肝臓は同じ範囲内に移動された. 前処理後の124症例のデータをランダム的に分割して, そのうちトレーニングデータは104症例とし, 残りの20症例はテストデータとする.

3.2 評価関数

本節では予測結果と真値の差を評価するために平均形状間距離誤差 \mathcal{D}_{Mean} [11] とユークリッド距離誤差 $\mathcal{D}_{Euclidean}$ を導入する. \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. また $\mathcal{D}_{Euclidean}$ を用いて予測形状と真値の対応する頂点の距離誤差を評価する. $\mathcal{D}_{Euclidean}$ は式 (6) のように定義する.

$$\mathcal{D}_{Euclidean} = \frac{1}{n} \sum_{i=0}^n \sqrt{(v_i - \hat{v}_i)^2} \quad (6)$$

この2つの評価値に加えて, 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.

3.3 実験1および結果

実験1の目的はコントラストが低い単一 DRR 画像を用いて患者ごとに異なる肝臓の3次元形状を再構成することである. X-ray2Shape フレームワークは Tensorflow-GPU で実装し, pre-trained ネットワークを用いずに, 学習率 1×10^{-4} と重み減衰量 5×10^{-6} の Adam optimizer を使用してネットワークをトレーニングした. バッチサイズは1, エポック数は1000とした. 学習には NVIDIA GeForce RTX 2070 を用いて全体で4.5時間を要した.

図3に肝臓形状の3次元再構成結果の1例を示す. 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




図4 テスト20症例の平均距離誤差とユークリッド距離誤差の分布

Our losses		pixel2mesh losses	
$\hat{\mathcal{D}}_{Mean}$	$\hat{\mathcal{D}}_{Euclidean}$	$\hat{\mathcal{D}}_{Mean}$	$\hat{\mathcal{D}}_{Euclidean}$
6.71mm	16.0mm	9.1mm	19.3mm

表1 本研究の損失と pixel2mesh 損失の比較

するために, メッシュ形状を DRR 画像の上に射影し, 各頂点に対応する DRR 画像のピクセルを青とした (図3 (a-c)). 初期テンプレートの投影像 (図3 (c)) のずれが大きく, 特に右肺下部の輪郭と合っていない. 予測結果の形状 (図3 (b)) はかなり改善されており, 特に横隔膜周辺のずれが減少した. 図3 (d) と (h) は予測値と真値を同一座標系へ重ね合わせて表示した例である.

図4にテストデータ20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. 青のバーはユークリッド距離誤差 $\mathcal{D}_{Euclidean}$ を示し, 全テストデータの平均値は16mmである. 緑のバーは平均距離誤差 \mathcal{D}_{Mean} を示し, 平均値は6.71mmである. 次に, 本研究において提案する損失関数と

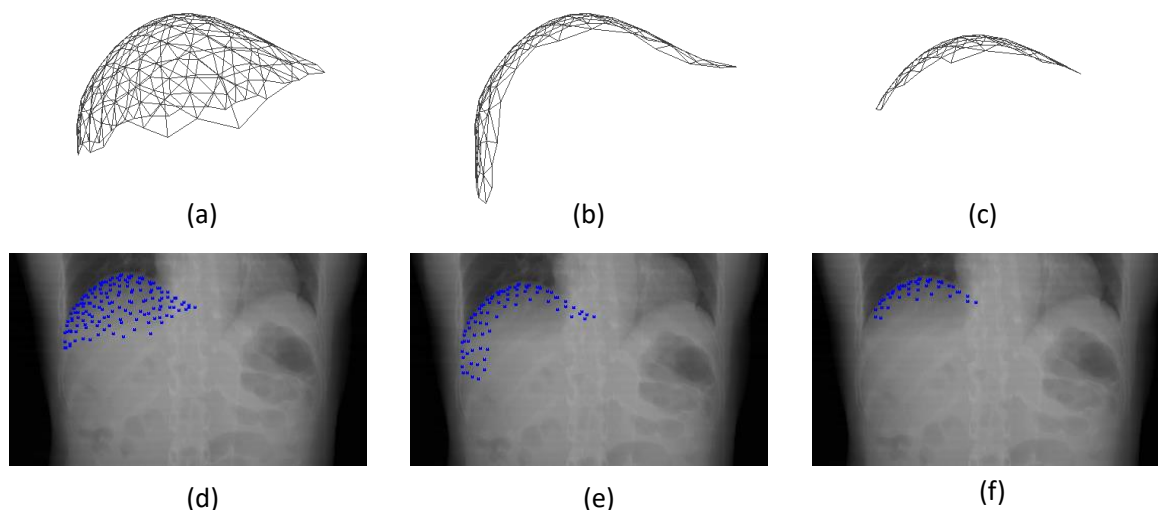


図5 肝臓の一部分の抽出仕方. (a) 500 頂点のうち 146 頂点を抽出, (b) 81 頂点を抽出, (c) 44 頂点を抽出, (d)-(f) 抽出部分の投影図

	ハウスドルフ距離	ユークリッド距離
部分形状 1	17.6mm	22.9mm
部分形状 2	17.4mm	18.3mm
部分形状 3	14.3mm	12.3mm

表2 抽出方式より予測形状の誤差比較

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1に比較結果を示す。 \bar{D}_{Mean} はテストデータ 20 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。本研究で提案している損失関数を使って得られた予測結果の誤差は pixel2mesh の損失関数より得られた誤差が小さい。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 2.2×10^{-5} と 8.8×10^{-8} であり、両者の平均値には有意差が確認された。

3.4 実験2および結果

臓器形状は患者間で差が大きく、特に DRR 画像内に臓器の輪郭が全く視認できない箇所においては、距離誤差が大きくなる傾向が見られた。そこで実験2では、コントラストが低い単一 DRR 画像を用いて肝臓の3次元形状の一部を再構成することを目的とした。肝臓データの上部、横隔膜に接する領域のみを抽出し、その部分形状の再構成性能を調査する。肝臓の部分形状は以下の3通りの方法で抽出することとした。

- 部分形状1: 肝臓の上部 146 頂点を抽出 (図5(a))
- 部分形状2: 肝臓の上部 81 点を抽出 (図5(b))
- 部分形状3: 肝臓の上部 44 点を抽出 (図5(c))

図5(d)-(f)は抽出部分をそれぞれ DRR 上に射影して3次元頂点に対応するピクセルを青とした画像である。

実験2として、部分形状データ群を推定対象としてネットワーク全体をそれぞれ再学習し、予測値を得た。実験条件は対象となる臓器形状が部分形状である以外は実験1と同様とした。表2に提案方法によって予測した各部分形状のユークリッ

ド誤差とハウスドルフ距離 [12] を示す。表から部分形状3の距離誤差が最も小さくなり、予測対象の形状を横隔膜の輪郭付近に絞るほど距離誤差が小さくなることが確認された。

図6はハウスドルフ距離とユークリッド距離誤差が一番小さかった部分形状3の可視化結果である。初期テンプレートの投影像 (図6(c)) は横隔膜の輪郭とのずれが大きいが、予測結果の投影図 (図3(b)) は横隔膜の輪郭とほぼ一致することが確認された。提案フレームワークは低コントラストな DRR 画像において、輪郭が視認できる横隔膜周辺についてより高精度な形状再構成が可能であることを確認した。

4. おわりに

本研究はコントラストが低い単一の DRR 画像から肝臓の3次元形状を再構成するために、GCN と CNN を組み合わせた深層学習のフレームワーク X-ray2Shape を提案した。正確かつ滑らかな3次元形状を生成するために、MSE 損失および離散ラブラシアン損失を用いてネットワークをトレーニングした。本研究で使っている実験データは augmentation データを用いずに、124 名の患者の実際3次元 CT データを使用した。pixel2mesh が対象とした画像とは異なり、DRR 画像はコントラストが低く、視認できる臓器の輪郭は一部である。しかし、本実験により提案フレームワークは平均形状間距離誤差 6.7mm で肝臓形状の再構成ができることを確認した。特に輪郭が視認できる横隔膜周辺について誤差が小さく、部分形状であればより高精度な推定が可能であった。今後の研究では、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を検討予定である。

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。

文献

- [1] M. Islam, T. Purdie, B. Norrlinger, H. Alasti, D. Moseley, M. Sharpe,

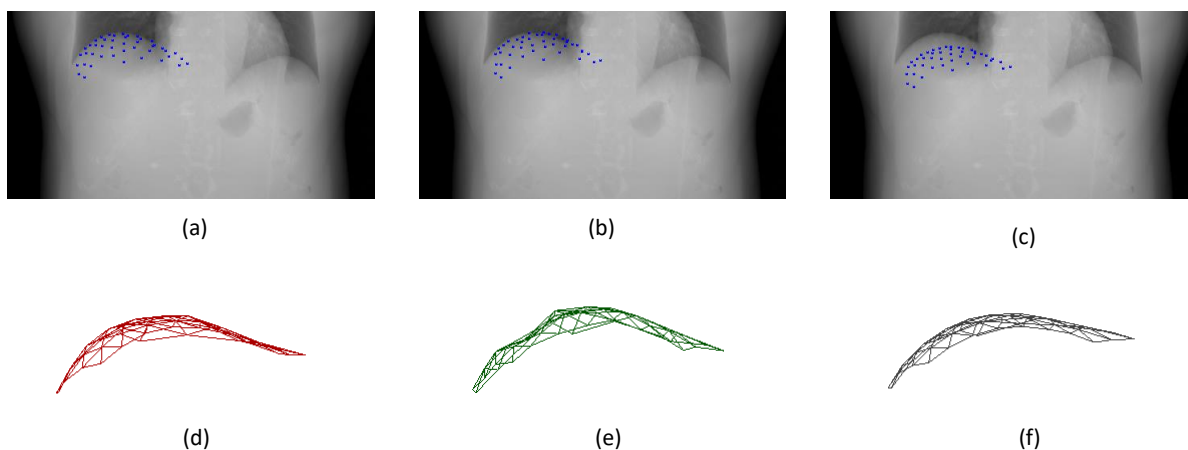


図6 提案手法による肝臓形状の一部分3次元再構成の例。(a) X-ray画像に対する肝臓メッシュ頂点(真値)投影図, (b) 肝臓メッシュ頂点(予測値)の投影図, (c) 肝臓メッシュ頂点(初期テンプレート)の投影図, (d) 一部分3次元肝臓形状(真値), (e) 一部分3次元肝臓形状(予測値) (f) 初期テンプレート

- 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] A. Saito, M. Nakao, Y. Uranishi, and T. Matsuda, "Deformation Estimation of Elastic Bodies Using Multiple Silhouette Images for Endoscopic Image Augmentation", *IEEE International Symposium on Mixed and Augmented Reality (ISMAR)*, pp. 170-171, 2015.
- [4] 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.
- [5] 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.
- [6] T. N. Kipf, and M. Welling, "Semi-supervised classification with graph convolutional networks", in *International Conference on Learning Representations (ICLR)*, 2016.
- [7] 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.
- [8] 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.
- [9] K. Simonyan, and A. Zisserman, "Very deep convolutional networks for large-scale image recognition", in *International Conference on Learning Representations (ICLR)*, 2015.
- [10] M. Nakao, M. Nakamura, T. Mizowaki, and T. Matsuda, "Statistical deformation reconstruction using multi-organ shape features for pancreatic cancer localization", *arXiv preprint*, Art. no. 1911.05439, 2019.
- [11] 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.
- [12] 小林 晃太郎, 中尾 恵, 徳野 純子, 陳 豊史, 伊達 洋至, 松田 哲也, モデルベース位置合わせによる動物気胸肺の変形解析, *電子情報通信学会技術報告 (MI)*, Vol. 119, No. 193, pp.31-36, 2019.