

変位場の学習による単一投影像に対する可変形モデル位置合わせ

中尾 恵[†] 中村 光宏^{††} 松田 哲也[†]

[†] 京都大学大学院情報学研究科 〒606-8501 京都市左京区吉田本町
^{††} 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: [†]megumi@i.kyoto-u.ac.jp

あらまし 治療時に取得可能な単一投影像に基づく臓器形状の再構成は放射線治療や外科手術支援等、臨床における応用範囲が広い研究課題である。本研究では単一視点の2次元投影像に対して3次元臓器モデルの可変形位置合わせを達成する image-to-graph convolutional neural network の枠組みを構築した。本枠組みでは、2次元投影像が変位場へ変換され、グラフ畳み込みネットワークによって3次元メッシュの頂点変位と変位場の関係が学習される。4D-CT から生成した疑似X線画像を学習済みのネットワークへ適用し、画像上で輪郭の大部分が視認できない腹部臓器の3次元形状と位置を臨床において利用可能な精度で再構成可能であることを確認したので報告する。

キーワード 可変形位置合わせ, 形状推定, 変位場, グラフ畳み込みネットワーク, 深層学習

Deformable model registration for a single projection image by learning displacement fields

Megumi NAKAO[†], Mitsuhiro NAKAMURA^{††}, and Tetsuya MATSUDA[†]

[†] Graduate School of informatics, Kyoto University
Yoshida Honmachi, Sakyo-ku, Kyoto, 606-8501, Japan

^{††} Graduate School of Medicine, Kyoto University
54 Kawahara-chou, Shougoin, Sakyo-ku, Kyoto, 606-8507, Japan
E-mail: [†]megumi@i.kyoto-u.ac.jp

Abstract Shape reconstruction of organs from a single-viewpoint projection image is a research target including broad clinical applications such as image-guided surgery and radiotherapy. In this study, we constructed an image-to-graph convolutional neural network that achieves deformable registration of 3D organ models to a single-viewpoint 2D projection image. In this framework, the 2D projection image is translated into a displacement field. The graph convolution network learns the relationship between the vertex displacement of the 3D mesh and the displacement field. We applied digitally reconstructed radiographs generated from 4D-CT data to the trained network and confirmed that the 3D shape and location of the abdominal organs, where most of the contours are invisible, can be reconstructed with clinically acceptable errors.

Key words Deformable registration, shape reconstruction, displacement field, graph convolutional network, deep learning

1. はじめに

3次元医用画像から得られる臓器や腫瘍の位置や形状は、診断および治療前の計画に必要な不可欠な患者固有の形態的情報である。しかし、外科手術時や数週間にわたる放射線治療において、臓器は移動、変形する可能性がある。撮像後に臓器に生じる時系列的な形状変化は腫瘍位置同定を妨げ、正確な治療を困難なものとしている。治療中には利用可能なイメー

ジング装置の制限のため、内視鏡画像やX線画像などのリアルタイム計測が可能な2次元画像が活用され、3次元イメージングの利用は限定的である。

本研究では、幅広い画像誘導型治療への応用を想定し、単一の2次元投影画像から臓器の3次元形状を再構成する問題に着目している。これは2次元空間における点から、より高次元の空間における点への変換を求める問題であり、事前知識なしでは不良設定問題である。この課題に対し、臨床では

治療前に撮像される密な 3D-CT や MRI 画像から患者固有の臓器形状をサンプリングし、事前知識として活用する方法が考えられる。リアルタイムに撮像が可能な 2 次元投影像に対して臓器形状モデルの配置や変形を求めるアプローチである。これは 2D/3D 位置合わせと呼ばれ、この 10 年間医用画像解析の研究領域において精力的に研究がなされている [1] [2]。

軟臓器を対象とした 2D/3D 可変形位置合わせは、2 次元画像と 3D ボリューム間で点対点の局所的な対応を求める問題である。剛体位置合わせと異なり、サンプリング点数に比例する大規模なパラメータの最適化が必要となる。これに近い問題として、ボリューム間の可変形位置合わせがあるが、大規模なパラメータセットに対する最適化に要する計算コストが問題とされてきた。この課題に対し、深層学習を用いて 3 次元変位場を学習する枠組み [3] が報告されている。Graphic Processing Unit (GPU) による並列演算により訓練された学習モデルはより高速な位置合わせを実現可能である。

本研究が対象としている単一画像に対する 2D/3D 可変形位置合わせは ボリューム間の位置合わせよりも利用可能な制約が少なく、安定な最適解の算出が難しい。入力画像のみに基づく予測は不確実性が高いため、事前知識として用いる臓器形状のモデルと入力となる 2 次元画像間のマッピング、及び、その学習方法が鍵となる。医用画像分野においてはこれまでに Convolutional neural network(CNN) を用いて 2 次元投影画像上の領域と 3 次元ボリューム内の局所領域との対応を学習する方法が提案されている [4] [5]。また、軟臓器を対象とした 2D/3D 可変形位置合わせについては、外科手術支援を目的とした 2 次元カメラ画像に対するモデルベース最適化が試みられている [6] [7] [8]。しかし、深層学習に基づく 2D/3D 可変形位置合わせの枠組みは少なく、特に腹部臓器を対象とした実証例は報告例がない。

本研究では変位場の学習による単一投影像に対する可変形モデル位置合わせの開発を目指している。我々はこれまでに 2 次元投影像に基づいて 3 次元臓器の形状再構築を可能とする image-to-graph convolutional neural network (IGCN) [9] [10] を報告した。本稿では、IGCN における特徴抽出部を変位場生成モデルへ拡張することで位置合わせ精度を向上させた枠組みを提案する。生成モデルでは、変形前後で頂点对応を取った 3 次元メッシュに基づいて 2 次元投影像から変位場への変換を学習する。生成された変位場からサンプリングされた変位ベクトルとメッシュ頂点の位置ベクトルが結合され、形状保持制約を満たす最終的な 3 次元変位ベクトルへの変換が学習される。最終的に IGCN は入力された 2 次元投影像に対して位置合わせされた 3 次元メッシュを出力する。

実患者の 4D-CT から生成した疑似 X 線画像を 提案位置合わせネットワークへ適用し、呼吸性移動を伴う腹部臓器の再構成性能の評価を目指した。治療時に実時間で X-ray 画像が撮像可能な放射線治療への応用を想定し、画像上で輪郭の大部分が視認できない肝臓、胃、十二指腸、膵がん Gross Tumor Volume (GTV)、腎臓の形状再構成を行い、それぞれの形状誤差を確認したので報告する。




図 1 本研究が対象とする単一 2 次元投影像に対する可変形モデル位置合わせ

2. 提案方法

本研究では、治療前の診断や計画のために 3D-CT/MRI ボリュームデータが取得されており、同一患者について治療中に異なる時刻、場所で 2 次元投影像が得られる状況を想定している (図 1)。治療前の 3D-CT 画像から生成された初期メッシュを M とし、推定対象となる治療時の状態において取得された 2 次元投影画像を I とする。 M と I が表現する臓器形状は異なり、空間的に位置合わせもされていない。したがって、図 1 の横隔膜付近にみられるように M を I に対して投影した初期配置では両者にずれが生じる。臓器の非線形な変形を反映しつつ、初期メッシュを 3 次元的に適切に位置合わせできれば、治療時の臓器形状と位置を同定することが可能である。ここで、治療時に取得される X 線画像または内視鏡画像が I の候補であるが、本研究では、4D-CT データから生成可能な疑似 X 線画像 (DRR) を入力画像として用いることによって提案位置合わせ方法の定量評価を目指す。

2.1 IGCN の構成と処理の流れ

図 2 は、IGCN の構成と可変形モデル位置合わせの処理の流れを示している。IGCN は、変位場生成モデル g と頂点変換モデル f を統合した臓器に依存しない枠組みとして設計された。各モデルには様々なアーキテクチャが採用可能であるが、本実験では g に UNet ベースのネットワーク構造 [11] を使用し、 f にグラフ畳み込みニューラルネットワーク [12] を採用した。

変位場生成モデル g は、2 次元投影画像 I と I に対して初期メッシュ M を投影することで得られる臓器領域ラベル S を結合した 2 チャネル画像を入力とする。本研究では、入力画像サイズに $640 \times 640 \times 2$ を使用したが、ハードウェアによる制限がなければ任意の画像サイズに対応可能である。 g は入力画像の各画素に対して 3 次元変位ベクトルが格納された変位マップ u への変換を学習する。

頂点変換モデル f は、変位マップ u と初期メッシュ M から特徴ベクトルを受け取る。 M が 2 次元画像空間に投影され、初期メッシュの各頂点に対応する u の値が取得される。 M の 3 次元頂点座標と各頂点に対応する 3 次元変位ベクトルは連結され、メッシュの変形を学習するグラフ畳み込みネットワークに渡される。 f は最終的に、投影画像 I に位置合わせされた変形メッシュを出力する。




図2 提案する Image-to-graph convolutional network (IGCN) の構成とデータ処理の流れ

2.2 変位マップ生成関数

変位場生成モデルでは、教師有り学習の枠組みに基づいて、2次元投影像 I から変位マップ u への変換関数 g_θ を学習する。図3は肝臓を対象として g_θ の学習プロセスを例示している。最初に初期メッシュとターゲットメッシュ間の可変形メッシュ位置合わせ (図3(a)) [13] によって頂点对応が取れた位置合わせ済みメッシュを得る。変形前後の対応点から (b) に示すように各頂点 v_i の変位ベクトル d_i が得られる。 d_i をユークリッド空間から色空間へ変換し、初期メッシュの表面色として用いたレンダリングを行うことによって (c) に示すような3チャンネルの投影像が得られる。これは各ピクセルに3次元変位ベクトルが格納された2次元画像であり、求める変位マップ u を表現している。

変位場生成モデルの学習において、初期メッシュの投影演算によって得られる対象臓器の2次元投影ラベル S を初期の注目領域として利用することでより安定なネットワークの最適化が可能である。本研究では、提案する変換関数 g_θ を式 (1) のように定義する。

$$u = g_\theta(I, S) \quad (1)$$

2次元投影像 I に加えて臓器領域ラベル S を追加の属性情報として用い、2チャンネルの入力画像とすることで安定な学習が可能となり、より効率的にネットワークの最適化が達成される。

ここで、 u は3次元メッシュの変形を表現する3次元変位場の投影像であるため、マップ内の投影点 p はメッシュの複数の頂点 v_α, v_β から参照されうる。この場合、 p に写像されたすべての頂点に対して同一の変位ベクトルが割り当てられる。しかし、 v_α, v_β は異なる臓器の一部を構成していたり、同一臓器内の前面と背面のような異なる部位を構成するため、それぞれ異なる変位を表現可能でなければならない。この課題は後述するグラフ畳み込みネットワークにおいて、変位マップから得られる3次元ベクトルに加えて、メッシュの各頂点における局所形状とトポロジーが埋め込まれた学習によって解決される。




図3 変位マップ生成のための画像変換モデルの学習, (a) 目的形状と初期形状間の可変形メッシュ位置合わせ, (b) 対応点から得られる3次元変位ベクトル, (c) 変位マップとサンプリング点

2.3 頂点座標の変換関数

本節では、生成された変位マップ u と初期メッシュ M の構造を用いてメッシュの各頂点を更新する頂点座標の変換関数 f を提案する。 f はグラフ畳み込みネットワークに基づいてメッシュの各頂点の空間的な変換を担う関数であり、式 (2) のように定義される

$$\hat{v}_i = f_\varphi(v_i, u(p_i)) \quad (2)$$

ここで、 v_i は正規後の頂点座標であり、 $u(p_i)$ は変位マップ内の対応する投影点 p_i から得られる3次元変位ベクトルである。 f_φ はグラフ畳み込みネットワークと学習可能なパラメータ φ によって構成し、 v_i と $u(p_i)$ が結合されたベクトルを入力とし、頂点座標の予測値 $\hat{v}_i$ を出力する。初期メッシュ M を構成するすべての頂点 $v_i \in \mathcal{V} (i = 1, 2, \dots, n)$ に対して、学習済みの関数 f_φ による変換を行うことで、メッシュ全体の変形が算出される。

2.4 損失関数

ネットワーク全体のパラメータ群 (θ, φ) は同時に更新され、目的関数を最小化する値に最適化される。本節では、空間的に滑らかな変換となるような制約を与えつつ、2D/3D 可変形メッシュ位置合わせを達成する三つの損失関数を導入する。

本研究では、真値となる目的形状を構成するメッシュの3次元頂点座標は可変形メッシュ位置合わせによって得られている。点単位の厳密な評価のために、目的形状と予測形状の頂点間で定義される平均ユークリッド距離誤差を評価する損失関数 $\mathcal{L}_{pos}$ を導入する。 $\mathcal{L}_{pos}$ は次のように定義される。

$$\mathcal{L}_{pos} = \frac{1}{n} \sum_{i=1}^n \|v_i - \hat{v}_i\|_2^2, \quad (3)$$

ここで n はメッシュの頂点数であり、 $v_i \in \mathcal{V}(i = 1, 2, \dots, n)$ は目的形状の頂点座標、 $\hat{v}_i$ は予測形状の頂点座標である。本損失は予測頂点を目的形状の頂点位置に収束させる働きを担う。

メッシュ頂点座標に対する損失に加えて、変位場生成モデルが生成する変位マップ u の正確な予測に繋がるように損失を定義する。特に目的形状が並進と局所変形の両方を含む場合、変位マップ生成の安定的な学習は重要である。本研究では、次式によって定義される変位マップに対する損失 $\mathcal{L}_{map}$ を導入する。

$$\mathcal{L}_{map} = \|u - \hat{u}\|_1, \quad (4)$$

ここで、 u は目的の変位マップであり、 $\hat{u} = g(I, S)$ は入力画像 I から変換された予測変位マップである。

臓器変形は一般に空間的に非線形でかつ非一様であるが、同一患者内における異なる時刻間の臓器変形は一定範囲に限定されており、かつ、空間的に滑らかであることが予想される。本研究では、初期メッシュの表面の滑らかさを保存した変形となるよう、メッシュの平均曲率を近似的に表現する離散ラプラシアンを算出し、正則化項 $\mathcal{L}_{smooth}$ として用いる。

$$\mathcal{L}_{smooth} = \frac{1}{n} \sum_{i=0}^n \|L(v_i) - L(\hat{v}_i)\|_2^2, \quad (5)$$

ここで、 $L(\cdot)$ は Laplace–Beltrami 演算子であり、 $L(v_i)$ は $L(v_i) = \sum_{j \in N(v_i)} (v_i - v_j) / N(v_i)$ によって定義される頂点 v_i の離散ラプラシアンである。 $N(v_i)$ は v_i と辺を共有する隣接頂点 v_j の数である。本損失は初期形状から曲率の変化が大きい変形を制限し、メッシュ表面のノイズや低品質な三角形要素の発生を抑制する働きがある。

全体の目的関数 $\mathcal{L}$ は次のように三つの損失関数の重み付き線形和として定義する。

$$\mathcal{L} = \mathcal{L}_{pos} + \mu \mathcal{L}_{map} + \lambda \mathcal{L}_{smooth}. \quad (6)$$

2.5 統計的生成モデル

医療機関において呼吸同期された腹部領域の 4D-CT 画像が撮像される機会は限定的であり、複雑な臓器変形やモーションの学習に十分な症例数を集積することは容易ではない。この学習データ数の制限に対し、統計的生成モデルに基づくデータ拡張を提案する。少数の 4D-CT データから得られる呼吸変形の統計的な性質を反映した変位を 3D-CT データから得られるメッシュへ与える。具体的には、4D-CT ボリュームから生成されるメッシュについて、すべての症例間で DMR [13] を行って頂点对応が取れたメッシュを得た後、主成分分析を通して形状及び変位に関する統計モデルを得る。

教師あり学習に利用可能な拡張データは、3D-CT ボリュームから得られた位置合わせ済みメッシュ M_t を d_i に基づいて変形させることによって得られる。すなわち、 M_t の各頂点 v_i に対して、 $v_i \leftarrow v_i - d_i$ として頂点座標を更新する。変形され

たメッシュ M と 3D-CT ボリュームから得られる投影像 I のセットを入力データとする。更新前のメッシュ M_t は投影像 I に対応する目的形状として利用可能である。各 epoch において ω_k をランダムに変更し、様々な変形バリエーションを表現した統計的データ生成をオンラインで行いつつ、ネットワーク全体が構成するモデル $g \circ f$ のトレーニングを実施する。

3. 実験

提案方法の性能と臨床への適用可能性を検証するために、動体追尾放射治療への応用を想定した複数臓器の形状再構成を対象に実験を行った。提案する IGCN は Python 3.6 と Tensorflow をバックエンドとする tflearn によって実装した。学習における バッチサイズは 1 とし、トレーニング epoch は 300、ネットワークの最適化には学習率を 1×10^{-4} とした Adam を用いてネットワーク全体の学習を行った。損失関数のパラメータには幾つかの組み合わせを検討し、 $\mu = 1.0$, $\lambda = 0.1$ を用いた。

3.1 データセット

本実験には、京都大学医学部附属病院において強度変調放射線治療を受けた患者から取得した 124 例の 3D-CT ボリュームと 35 例の 4D-CT ボリュームを用いた。本研究は京都大学医学研究科 医の倫理委員会によって承認された (承認番号: R1446)。4D-CT ボリュームは呼吸同期の条件下で測定され 1 呼吸サイクル 10 時相 ($t = 0, 10, \dots, 90\%$) の 3D-CT から構成される。ここで、 $t = 0$ は吸気終末期であり、 $t = 50$ は呼気終末期に対応する。3D-CT ボリュームは 512×512 pixel からなる 88-152 枚の 2 次元断層画像 (1voxel: $1.0 \text{ mm} \times 1.0 \text{ mm} \times 2.5 \text{ mm}$) から構成されており、放射線治療の計画のために肝臓、胃、十二指腸、左腎、右腎、膵がん GTV の各領域が放射線腫瘍医によってラベリング済みである。なお、すべての 3D-CT 及び 4D-CT のうち $t = 0$ のボリュームについて、治療用ベッドに対して照射対象が中央に位置するよう撮像がなされている。

各臓器の領域ラベルから表面メッシュを生成し、DMR を使用して頂点对応が取れた臓器メッシュモデルを取得した。一連のセットアップ及び DMR による腹部臓器形状の位置合わせ精度は [13] において報告されており、平均距離誤差 0.2mm 及び ハウスドルフ距離誤差 1.1mm で初期メッシュが患者固有の臓器形状に位置合わせ可能である。この位置合わせ誤差は十分小さいため、位置合わせ済みメッシュ群を本実験における真値の目的形状として利用する。

3.2 腹部臓器の形状再構成性能

4D-CT から 10 時相の時系列 DRR を生成し、肝臓、胃、十二指腸、膵がん GTV の 3 次元形状を予測する実験を行った。複数臓器の形状を推定する際の問いとして、単一の臓器ごとに学習するアプローチと複数臓器を同時に学習するアプローチの 2 通りが考えられる。後者は推定対象のメッシュの頂点数が増え、形状表現の複雑さは増加するが、臓器間の位置関係や変形における相互作用を効果的に学習できる可能性がある。本実験では、それぞれのアプローチを単一臓器の再構成と複数臓器の再構成と呼称し、推定性能を比較する。最終的に得




図 4 可変形位置合わせ及び単一臓器及び複数臓器の再構成事例. Case 13: 平均的な形状誤差の場合, Case25: 形状誤差最大の場合.

表 1 単一臓器及び複数臓器を対象とした形状再構成の性能比較

	単一臓器再構成			複数臓器再構成		
	MD [mm]	HD [mm]	DSC [%]	MD [mm]	HD [mm]	DSC [%]
肝臓	1.83 ± 0.89	8.49 ± 4.57	95.32 ± 2.31	1.86 ± 0.89	8.35 ± 4.52	95.13 ± 2.31
胃	3.59 ± 1.92	11.59 ± 9.24	80.14 ± 9.77	1.77 ± 0.92	6.49 ± 3.93	90.89 ± 5.40
十二指腸	2.97 ± 1.38	11.33 ± 4.72	75.83 ± 13.19	1.64 ± 0.82	7.34 ± 4.47	86.75 ± 7.82
膵がん GTV	2.08 ± 1.43	6.42 ± 3.00	82.16 ± 13.25	1.10 ± 0.74	3.86 ± 2.36	89.90 ± 6.56

られる性能が 適応的放射線治療に求められる 3 次元臓器領域の同定精度を達成するかどうかについて確認する.

4D-CT データをトレーニングにも用いた方が形状再構築の性能向上が見込めるため, 本トレーニングにおいては前節と同様の 35 名の患者を 12, 12, 11 の 3 グループに分割することによる 3-fold cross validation を採用し, 異なる 124 名の患者の 3D-CT データを変形することによって得られる統計的生成モデルに加えて, テストデータに非採用となった残りの 2 グループ, 23 名の 4D-CT の計 354 ボリュームを用いて学習を実施した.

単一臓器再構成 では, 学習済みのネットワークに基づいて肝臓, 胃, 十二指腸, 膵がん GTV について, 各々の 3 次元形状を 1 枚の DRR から予測して誤差を算出することとした. 複数臓器再構成では, 1 枚の DRR から 4 臓器すべての 3 次元形状を同時に予測した後, 各臓器ごとに形状誤差を算出した.

表 1 に単一臓器再構成と複数臓器再構成のそれぞれの場合における各臓器の誤差を示す. 肝臓では単一臓器再構成と複数臓器再構成の間に有意差は見られなかった. 一方, 胃, 十二指腸, 膵がん GTV では両者間に有意差 (ANOVA; $p < 0.05$) が確認され, 複数臓器再構成において, 形状誤差がそれぞれ 50.7%, 44.8%, 47.2% 改善された.

米国医学物理学会では, 画像位置合わせに関するガイドライン [14] において, 定量評価指標の許容誤差 は MD について 2-3mm, DSC について 80-90% としている. 得られた結果は

この水準と同程度, あるいは, それを超える精度で形状再構築が達成されることを示しており, 提案方法は臨床利用可能なレベルと言える.

3.3 腹部臓器の形状再構築例

図 4 に形状再構築の典型例として, 形状変化が大きい $t = 50$ の場合を対象に 平均的な形状誤差を示した Case13 と 最大の形状誤差を示した Case 25 の結果を示す. 図 4 左の画像群は複数臓器再構成 の結果を示しており, 中央の画像 では, 入力 DRR 画像に対して得られた 3 次元臓器メッシュの頂点が臓器ごとに色付けされて重畳可視化されている. その右側の画像では投影画像上に真値の形状 (マゼンタ) と予測形状 (シアン) の 2 形状を投影した結果であり, 各臓器の形状誤差を局所的に確認することができる. 肝臓と異なり, 胃, 十二指腸, 膵がん GTV については DRR 画像において輪郭が全く視認されないが, 各臓器の真値となる位置及び形状からずれが小さい形状再構成が達成されている.

また, 図 4 右に単一臓器再構成と複数臓器再構成によって得られた肝臓, 胃, 十二指腸の 3 次元臓器メッシュを異なる 2 方向から可視化した結果を示す. 単一臓器再構成では, 胃と十二指腸の位置に大きなずれが確認された. 各臓器に対応する DRR 画像内の 2 次元領域から得られる画像特徴のみでは形状復元が困難であることを示している. 一方, 複数臓器位置合わせでは真値と予測形状の良好な一致が見られた. 胃は内容物の影響によって患者間で形状バリエーションが大きく, 一

部にずれが確認された。

4. おわりに

本論文では単一視点の2次元投影像に対して3次元臓器モデルの変形位置合わせを達成するImage-to-graph convolutional networkの枠組みを提案した。本枠組みは、3次元変位マップの生成ネットワークとグラフ畳み込みネットワークによって構成される教師有り学習モデルによって低計算コストな2D/3D変形位置合わせを実現する。呼吸変形を対象とした統計的生成モデルに基づくデータ拡張を行い、実患者データに基づいて輪郭が直接視認されない腹部5臓器の形状再構成を行った。臨床において利用可能な平均形状間距離2mm以下の精度で臓器形状が再構成可能であることを確認した。

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] P. Markelj, D. Tomaževič, B. Likar, and F. Pernuš, A review of 3D/2D registration methods for image-guided interventions, *Medical image analysis*, vol. 16, no. 3, pp. 642-661, 2012.
- [2] C. J. F. Reyneke, M. Lüthi, V. Burdin, T. Douglas, T. Vetter, and T. Mutsaers, 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, 2019.
- [3] G. Balakrishnan, A. Zhao, M. R. Sabuncu, J. Guttag, and A. V. Dalca, VoxelMorph: A learning framework for deformable medical image registration, *IEEE Trans Med Imaging* vol. 38, no. 8, pp. 1788-1800, 2019.
- [4] S. Miao, Z. J. Wang, and R. Liao, A CNN regression approach for real-time 2D/3D registration, *IEEE Trans Med Imaging*, vol. 35, no. 5, pp. 1352-1363, 2016.
- [5] R. Schaffert, J. Wang, P. Fischer, A. Borsdorf, and A. Maier, Learning an Attention Model for Robust 2-D/3-D Registration Using Point-To-Plane Correspondences, *IEEE Trans Med Imaging*, vol. 39, no. 10, pp. 3159-3174, 2020.
- [6] M. Nakao and K. Minato, Physics-based interactive volume manipulation for sharing surgical process,, *IEEE Trans. Info. Tech. Biomed.*, vol. 14, no. 3, pp. 809-816, 2010.
- [7] B. Koo, E. Ozgur, B. L. Roy, E. Buc, and A. Bartoli, Deformable registration of a preoperative 3D liver volume to a laparoscopy image using contour and shading cues, *Proc. Medical Image Computing and Computer Assisted Intervention (MICCAI)* 2017.
- [8] 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 Internal Conference on Biomedical and Health Informatics (BHI)*, pp. 1-4, 2019.
- [9] M. Nakao, M. Nakamura, and T. Matsuda, Image-to-Graph convolutional network for deformable shape reconstruction from a single projection image, *Proc. Medical Image Computing and Computer Assisted Intervention (MICCAI)*, pp. 259-268, 2021.
- [10] F. Tong, M. Nakao, S. Wu, M. Nakamura, and T. Matsuda, X-ray2shape: Reconstruction of 3D liver shape from a single 2D projection image, *Annu Int Conf IEEE Eng Med Biol Soc*, vol. 2020, pp. 1608-1611, 2020.
- [11] O. Ronneberger, P. Fischer, and T. Brox, U-net: Convolutional networks for biomedical image segmentation, *Medical Image Computing and Computer Assisted Intervention (MICCAI)*, pp. 234-241, 2015.
- [12] T. N. Kipf and M. Welling, "Semi-supervised classification with graph convolutional networks," *Proc. 5th International Conference on Learning Representations (ICLR)*, 2017.
- [13] M. Nakao, M. Nakamura, T. Mizowaki, and T. Matsuda, Statistical deformation reconstruction using multi-organ shape features for pancreatic cancer localization, *Medical image analysis*, vol. 67, p. 101829, 2021.
- [14] K. K. Brock, S. Mutic, T. R. McNutt, H. Li, and M. L. Kessler, Use of image registration and fusion algorithms and techniques in radiotherapy: Report of the aapm radiation therapy committee task group no. 132, *Med Phys*, vol. 44, no. 7, pp. e43-e76, 2017.