

# 単眼腹腔鏡映像からの3次元臓器モデル生成手法

○ 前川 凌佑<sup>†</sup>, 宍戸 英彦<sup>‡</sup>, 亀田 能成<sup>‡</sup>, 坂本 堪亮<sup>§</sup>, 大城 幸雄<sup>††</sup>, 北原 格<sup>‡</sup>

○ Ryosuke MAEKAWA<sup>†</sup>, Hidehiko SHISHIDO<sup>‡</sup>, Yoshinari KAMEDA<sup>‡</sup>,  
Taisuke SAKAMOTO<sup>§</sup>, Yukio OSHIRO<sup>††</sup>, Itaru KITAHARA<sup>‡</sup>

<sup>†</sup>: 筑波大学大学院システム情報工学研究科, [maekawa.ryosuke@image.iit.tsukuba.ac.jp](mailto:maekawa.ryosuke@image.iit.tsukuba.ac.jp)

<sup>‡</sup>: 筑波大学計算科学研究センター

<sup>§</sup>: 株式会社ネクステッジテクノロジー

<sup>††</sup>: 東京医科大学茨城医療センター

<要約> 本稿では, 単眼腹腔鏡映像から3次元臓器モデルを生成する手法を提案する. RGB-D カメラを用いた撮影により, 被写体の RGB 画像とデプスマップのデータセットを獲得し, そのデータセットに深層学習を適用することで RGB 画像からデプスマップへの推定処理を実現 (デプスマップ生成器を構築) する. 内部カメラパラメータのキャリブレーション処理により, 実際に臓器撮影を行う腹腔鏡カメラと RGB-D カメラ間の射影関係を求めることで, 腹腔鏡画像を RGB-D 画像に射影変換する. 変換画像をデプスマップ生成器に入力することで単眼腹腔鏡映像の各フレームにおけるデプスマップを生成する. 腹腔鏡カメラを移動させながら撮影した画像群に対して SfM (Structure from Motion) を適用した疎な3次元点群と, 各フレームの生成デプスマップによって求められる点群を統合することにより, 密で高精度な3次元点群の獲得を試みる.

<キーワード> 腹腔鏡映像, 多視点画像, 深層学習, デプスマップ, 3次元モデリング

## 1. はじめに

腹腔鏡手術は, 腹壁に開けた小さな切開部から腹腔鏡カメラなどの手術器具を挿入し, ディスプレイ上で腹腔内の状態を確認しながら施術を行う低侵襲手術 (Minimally Invasive Surgery : MIS) の一つである. この方法は, 体への負担が少なく回復が早いなど患者に対して利点が多く, 近年増加傾向にある術式である[1]. 一方で, 間接的に行われる操作や術部の3次元的な位置関係の把握が難しいことから, 開腹手術と比較すると要求される技術水準は高く, 手術技術の取得には一定の時間を要する[2]. このような問題の解決を目的とした, 術部の3次元情報を術者にわかりやすく提示する方法として, AR (Augmented Reality) や VR (Virtual Reality) 技術を応用した手術情報アノテーションシステムが数多く提案されているが[3, 4], これらの技術を腹腔鏡手術に適用するためには, 腹腔内の3次元情報の推定が必要である. しかし, 術中の CT (Computer Tomography) や MRI (Magnetic Resonance Imaging)

を用いた形状獲得や, 3次元位置計測用のマーカなどの器具の体内挿入は困難であるため, 腹腔鏡映像からの3次元情報推定への期待が高まっている.

これまでに, SfM (Structure from Motion) [5] やステレオ視などの画像特徴点ベースの3次元情報推定手法を用いた方法が提案されているが, 臓器表面の反射特性や低テクスチャ性の問題により推定可能な3次元形状は疎な点群情報に留まっている. 一方で, 近年の深層学習の発展を背景に, 単眼画像からデプスマップを推定する手法が提案され[6], 医用画像への応用も検討されている[7]. しかし, 距離情報の提示や手術計画の重畳のためには, 推定デプス値のスケーリングや, カメラ位置姿勢情報が必要であり, 推定デプスマップそのままの利用は難しい.

本研究では, 図1に示すように, 手術情報アノテーションシステムでの使用に資する, 密な3次元点群で構成される3次元臓器モデルを, 単眼腹腔鏡映像から生成する手法を提案する.

3次元臓器モデル生成の処理手順を, 図2に示す. 腹腔鏡カメラで撮影した映像をフレーム毎に分割し,

(1) SfM で被写体の疎な 3 次元点群および腹腔鏡カメラの位置姿勢を推定する。次に、(2) 深層学習を用いて単眼腹腔鏡画像からデプスマップを生成し、(3) (1) で推定した 3 次元情報を用いて (2) の生成デプスマップから新たに点群を追加することで、密な 3 次元臓器点群を生成する。

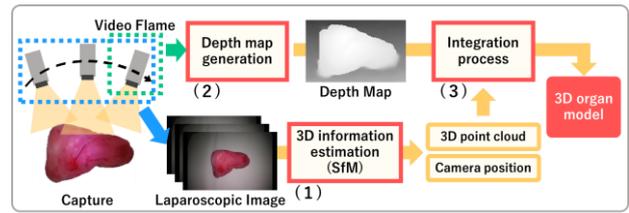


図 2 臓器モデル生成フロー

## 2. 腹腔鏡映像の撮影と 3 次元情報推定

### 2.1 臓器模型の撮影

肝臓は腹腔内で最も大きな臓器であり、腹腔鏡手術中に他の組織による被覆が起りにくく術野に映りやすいことから、本研究では、3 次元モデル生成の対象として肝臓を選択する。

実際の腹腔鏡手術映像では真値が取得できず、提案手法の有効性を議論できないため、本論文では真値を持つ肝臓の模型を用いて各処理を説明する。図 3 (左) に示す肝臓の石膏模型は、実際の手術患者の CT データから切り出した肝臓領域の点群データ (図 3 右) を 3D プリントによって実寸大で形成したものである。肝臓点群データは生成モデルの精度評価実験の真値データとして用いる。

肝臓模型全体が画面中で観察されるよう腹腔鏡カメラと模型の距離を調整しながら撮影を行う。撮影した映像をフレーム毎に分割し、3 次元情報推定のための多視点画像を得る。

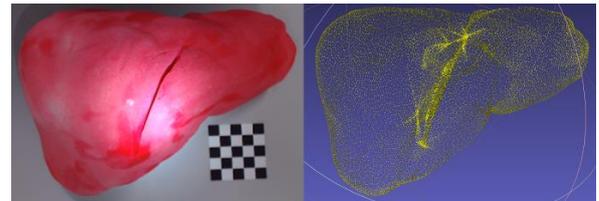


図 3 肝臓模型と 3 次元点群

### 2.2 SfM による 3 次元情報推定

多視点画像に対して SfM を使用し、臓器模型の 3 次元点群と各フレームにおける腹腔鏡カメラの位置姿勢を推定する。得られる 3 次元点群は特徴点のみに対応しているため点群は疎な状態となりやすい。そのため、腹腔鏡映像に SfM のみを用いた場合では、臓器の低テクスチャ性の影響により点群が極端に少なくなる恐れがある。

### 2.3 撮影方法の工夫による鏡面反射の影響軽減

SfM で推定される点群データの密度が疎になる原因の一つとして、臓器表面の粘膜構造に起因するテクカリやヌメリによる鏡面反射が考えられる。撮影時に照射した照明光が鏡面反射された結果ハイライトが生じ、特徴点検出・対応点探索が困難となるため、鏡面反射の 3 次元点群推定が失敗するためである。

撮影対象に対して上下左右方向に腹腔鏡カメラを移動させることにより、画像中の鏡面反射領域も移動し、臓器全体のテクスチャを観察することができる。図 4 (左) は鏡面反射を発生する物体 (ボール) と、一定方向から観察した画像群を用いて SfM による 3 次元情報推定を行った結果 (図 4 (中)) を示し、鏡面反射領域において点群が生成されていない。一方で、図 4 (右) はカメラを上下左右に移動させながら物体を撮影した場合の結果であり、全体から点群が得られていることがわかる。

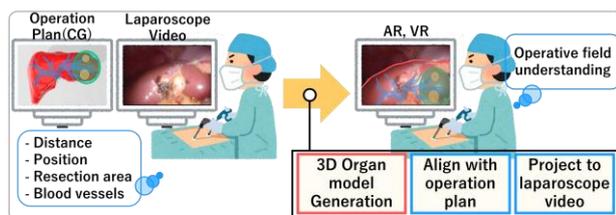


図 1 手術情報アノテーションシステムの利用

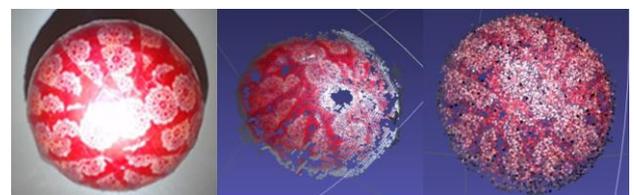


図 4 鏡面反射物体 (左), 推定結果 (中), 改善後 (右)

## 3. 深層学習を用いたデプスマップ生成

### 3.1 デプスマップ生成方法

単眼腹腔鏡映像から深層学習を用いてデプスマッ

プを生成する方法の処理を図5に示す. 本研究では, RGB-D カメラから取得された RGB 画像とデプスマップのペアを用いて, 深層学習によるデプスマップ生成器の学習を行う. 腹腔鏡から得られた画像の見え方を RGB-D カメラ側に合わせるため, レンズ歪み補正および射影変換を行う. 同様に各フレームの見え方を変換して生成器に入力することで, 単眼腹腔鏡映像からのデプスマップ生成を実現する.

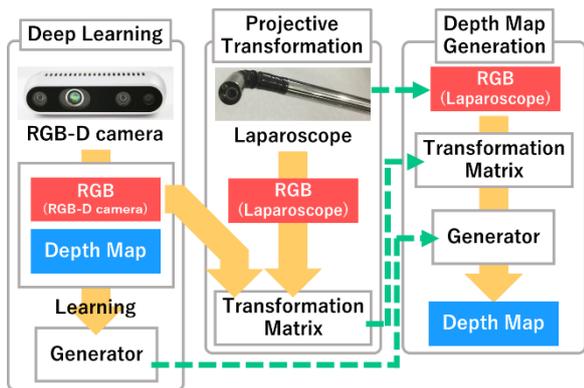


図5 腹腔鏡映像からのデプスマップ生成フロー

### 3.2 データセットの構築

#### 3.2.1. RGB 画像とデプスマップの撮影

RGB-D カメラを用いて, デプスマップ生成器学習用データセットを構築する. 台上に撮影対象である肝臓模型を配置し, その上部に RGB-D カメラを固定する. また, 腹腔鏡カメラと同様の照明条件となるように, RGB センサに腹腔鏡の先端を近づけ画像中心を照らすよう調整する. 臓器模型の撮影パターンは, 図6に示すように, 多方向から臓器の観察を行うようなカメラ配置とし, また観察方向毎に 20-40cm の範囲を 4 段階に分けカメラと模型との距離を変えながら撮影することで, 多視点画像に対応可能なデータセットを構築する. 加えて, カメラの位置が定まった状態で模型を 45 度ずつ回転させることで一つの位置につき 8 枚の画像ペアを撮影する.

#### 3.2.2. Hole Filling 処理

図7(左)は RGB-D カメラによって取得されたデプスマップの例であり, デプスマップの模型の輪郭付近にデプス値が取得されていない領域(黒色の領域)が存在する. デプスマップ生成器の学習やその後の統合処理に悪影響を与える可能性があるため, 近傍のデプス値を挿入する Hole Filling 処理により

除去する. 図7(右)は処理後のデプスマップを示し, 黒色の欠損領域が補完されていることが分かる.

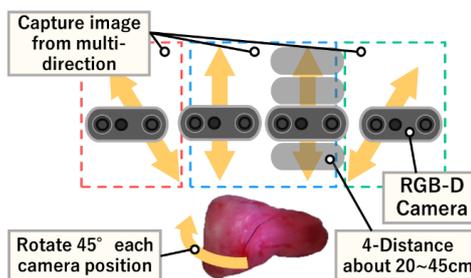


図6 臓器模型の撮影パターン

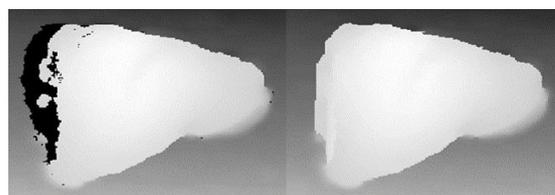


図7 Hole Filling 処理前(左), 処理後(右)

#### 3.2.3. デプスマップ平滑化処理

Hole Filling 処理後の臓器模型のエッジは, RGB 画像中の臓器模型と一致していない場合がある. また, デプスマップ全体にノイズが見られ, これを軽減するためにクロスバイラテラルフィルタ[8]を用いる. この手法は, 同一視点において異なるモダリティで観測された 2 枚の画像のうち, ノイズの少ない画像を基準としてもう一方の画像のフィルタリングを行う. 本研究では, RGB 画像を基準として, デプスマップの平滑化を行う. 結果として, 図8(右)に示すように, エッジを保持しながらデプスマップの平滑化が可能となる.

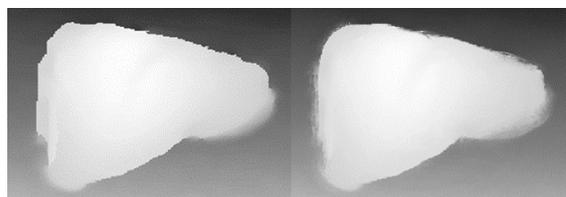


図8 デプスマップ平滑化処理の結果

### 3.3 デプスマップ生成器の構築

本研究では, cGAN (Conditional Generative Adversarial Network) を用いた深層学習によって RGB 画像から対応するデプスマップを生成し, 単眼腹腔鏡映像からのデプスマップ生成を実現する.

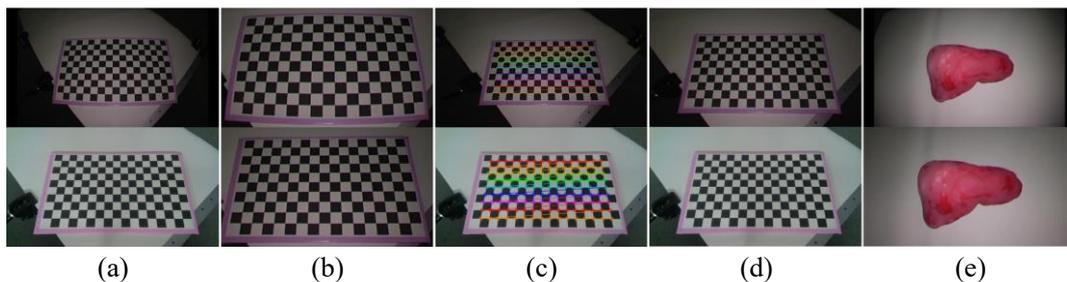


図 10 カメラ間対応関係導出の様子, (a): 腹腔鏡カメラ (上) と RGB-D カメラ (下), (b): レンズ歪み補正の様子, (c): 格子模様からの交点検出の様子, (d): 射影変換の適用結果, (e): 腹腔鏡映像の変換

図 9 に RGB 画像からデプスマップを生成する cGAN の学習モデルを示す. このモデルでは, 生成器  $G$  に変換前の RGB 画像を入力し, 識別器  $D$  には  $G$  が生成した画像, もしくは本物のデプスマップを入力し,  $D$  はどちらの画像が入力されたのか判断する.  $G$  は  $D$  を欺くようなデプスマップ生成を,  $D$  は  $G$  が生成した画像と本物のデプスマップを識別できるように, 互いに競い合わせながら学習を進めていく. 十分に学習が行われた後の  $G$  を用いることで, RGB 画像からのデプスマップ生成が実現される.

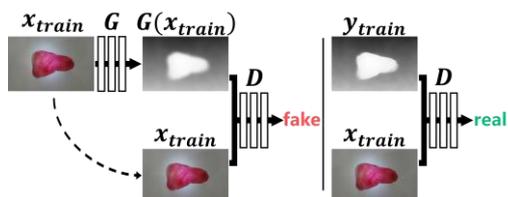


図 9 デプスマップを生成する学習モデル

### 3.4 カメラ間対応関係の導出

腹腔鏡カメラで撮影した画像の見え方を RGB-D カメラ側に合わせるため, カメラ間対応関係を求める. はじめに, 各カメラでキャリブレーションボードを撮影する. 撮影の際, 腹腔鏡カメラと RGB-D カメラの位置と光軸およびレンズ中心を一致させるため, 映像にプロットした十字線が各映像においてボード上の同じ位置に重なるよう配置して撮影を行う.

図 10 (a)上の腹腔鏡カメラで撮影した画像は, レンズ歪みによって格子模様が樽状に膨らんだ形で観察されている. 一方で, 後述するカメラ視点変換のための射影変換行列の推定処理は, レンズ歪みが存在しないことを前提としているため, 腹腔鏡カメラで撮影した画像に対してレンズ歪み補正を行う必要がある. 図 10 (b)は, 図 10 (a)上に対し歪み補正を行った結果であり, 画像が下図のように補正される.

レンズ歪み補正後の腹腔鏡画像 (図 10 (b)下) と, RGB-D カメラで撮影した RGB 画像 (図 10 (a)下) から格子の交点 (対応点) を検出し, その対応点情報から画像間の射影変換行列を算出する. 各画像からキャリブレーションボード (格子模様) の交点を検出した結果が図 10 (c)であり, レンズ歪み補正後の腹腔鏡画像に対して射影変換を適用した結果が図 10 (d)上で, 図 10 (d)下の RGB-D カメラの視点と同じ状態となっていることがわかる. 図 10 (e)は, 上の肝臓模型を撮影した腹腔鏡画像に対して本節の処理を適用した結果を示し, 図 10 (e)下は RGB-D カメラで観察した見え方に変換された腹腔鏡画像を示す.

## 4. SfM 情報と生成デプスマップの統合

### 4.1 統合方法

2章で説明した手法で取得された 3次元情報と, 3章で説明した手法で生成されたデプスマップの統合処理を図 11 に示す. はじめに, SfM で推定した 3次元点群をデプスマップ上に投影し, 腹腔鏡カメラから各点群との 3次元距離を求める. デプス値と 3次元距離の関係から近似直線を求め, 臓器模型領域から新たに追加した点群に対して適用する. 最後に, SfM で推定した点群のある世界座標系に追加点を逆投影することで, 密な 3次元臓器モデルを実現する.

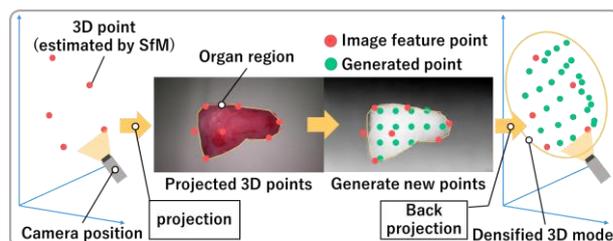


図 11 SfM 推定情報と生成デプスマップの統合

## 4.2 デプスマップのスケール値の算出

### 4.2.1. 生成デプスマップへの3次元点群投影

生成デプスマップ上への3次元点群の投影は、レンズ歪み補正画像上へ投影した後に射影変換画像へと座標が変換されることで行われる。3次元点群の投影によって再投影誤差が発生するため、元画像(補正無し腹腔鏡画像)における画像特徴点から3次元点群と対応するものを抽出し、レンズ歪み補正および射影変換を行うことで同等の操作を実現する。

### 4.2.2. 腹腔鏡カメラと3次元点群の距離の計算

デプスマップのスケール値算出のために、世界座標系における腹腔鏡カメラと各3次元点との距離を求める。世界座標系における腹腔鏡カメラの位置は、SfMによって推定されるカメラの回転行列と平行移動行列を用いて求める。また、腹腔鏡カメラと各3次元点との距離  $d$  は、カメラ座標と3次元点座標のユークリッド距離により求まる。

### 4.2.3. スケール値の算出

デプスマップは、視野の奥行の範囲を量子化レベル  $n$  で表現する。例えば、一般的なRGB-Dカメラは奥行の範囲を8bit量子化により  $n=256$  段階に分けて表現している。このため、SfMの推定情報との統合のためには、SfMで推定した3次元情報と同じスケールを与える必要がある。図12は、前節で求めた腹腔鏡カメラと各3次元点との距離  $d$  と、その点の投影位置のデプス値の関係を示した例である。モデル生成の対象となる輝度値が高い臓器部分のみを用いて近似直線を求めることでスケール推定精度を向上する。

## 4.3 密な3次元点群の生成

### 4.3.1. 新たな点群の追加

デプスマップ中の臓器領域を参照し、点群を追加することで高密度な3次元臓器モデルを生成する。デプスマップと対応するRGB画像のRGB値をLab色空間に変換した後、色成分  $a$  に基づいて閾値を設定して2値化処理を行うことで、臓器領域を切り出す(領域分割)。臓器領域の輪郭付近ではノイズが発生しやすいため、臓器領域中の輝度値の高い領域を使用することで追加点の信頼性を高める。

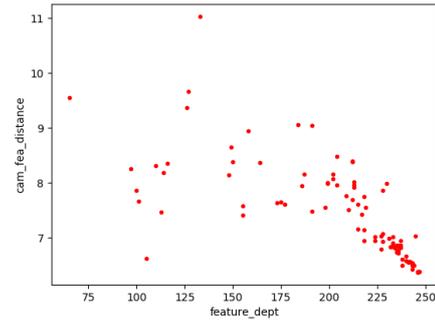


図12 デプス値(横軸)と距離  $d$  (縦軸) の関係

### 4.3.2. 追加点の3次元空間への逆投影

デプスマップに新たに追加した点群を世界座標系に逆投影し、高密度な3次元臓器モデルを生成する。追加した点に対して4.2.3節で求めた近似直線を適用し、距離  $d$  を得る。デプスマップ上の追加点を正規化画像座標系へ変換し、さらにカメラ座標系  $(X_c, Y_c, Z_c)$  に変換するために、距離  $d$  を用いて式(1)を解く。この際、腹腔鏡カメラの構造上背面を観察することがないため、奥行き  $Z_c$  は常に0以上となり一意に定まる。カメラ座標系の追加点に対し、カメラ回転行列および平行移動行列を用いて世界座標系に変換することで、高密度な3次元臓器モデルが得られる。

$$Z_c = \sqrt{d^2 - (X_c^2 + Y_c^2)}, \quad (Z_c \geq 0) \quad (1)$$

## 5. 評価実験

### 5.1 臓器モデルの撮影

3次元臓器モデル生成に使用する臓器モデルの撮影を行った。図13に撮影時の様子と、使用した腹腔鏡映像撮影装置を示す。先端湾曲型の腹腔鏡カメラ(OLYMPUS LTF S190-10)と映像処理装置(OLYMPUS VISERA Elite-II)を用いて、解像度1080p, 60fpsで映像を撮影した。この際、2.3節で説明した腹腔鏡映像の撮影条件を満たすように、模型に対して左右方向に2往復するよう腹腔鏡カメラを動かし、31秒間撮影した。その後、取得された映像が2往復分、1往復分、0.5往復分となるようフレーム分割し、合計62, 32, 16枚の多視点腹腔鏡画像を取得した。



図 13 腹腔鏡映像撮影環境

## 5.2 SfM を用いた 3 次元情報推定

多視点画像の処理は、CPU: Intel Core i9-9900k 3.60GHz, GPU: NVIDIA RTX2080ti, メモリ: 64.0GB を装備したデスクトップ PC で行った。本研究では、SfM を実行するにあたり、SfM ライブラリである COLMAP[9] を利用した。5.1 節で取得した 3 種類の画像群からの 3 次元情報推定は全て 1 分未満で行われた。この際、32 枚と 16 枚の画像群について、SfM 処理において対応が取れない画像が存在し、実際に推定に使用された画像はそれぞれ 28 枚と 12 枚であった。また、臓器表面から離れて存在する推定点（外れ値）について、追加点の奥行推定への影響を考慮し手動で取り除いた。

## 5.3 デプスマップ生成器の実装

画像変換タスクを実現する学習モデルとして、cGAN の一種であり、航空写真の地図化や線画画像への着色など多様な変換タスクへの適用が行われている pix2pix[10] を採用した。RGB 画像とデプスマップのペアの撮影は最小距離 20cm からのデプス計測が可能な RGB-D カメラ (Intel Realsense D435, RGB センサ: 1920 画素 × 1080 画素, デプスセンサ: 1280 画素 × 720 画素) を使用し、3.2 節の方法で合計 288 組の画像ペアからなるデータセットを構築した。生成デプスマップの評価用として、それぞれ撮影方向が異なる 5 枚のペア画像をデータセットから抽出し、残りの 283 組を用いて学習を行った。

## 5.4 生成デプスマップの評価

学習済みデプスマップ生成器に対して、評価用の

5 枚の RGB 画像を入力し、生成されたデプスマップと真値デプスマップを比較することで生成器の学習回数の目安を判断した。類似性の評価には、画像評価指標である PSNR (Peak Signal-to-Noise Ratio) と SSIM (Structural Similarity) を用いた。表 1, 2 に、学習回数に対する PSNR および SSIM の結果を、図 14 に、学習回数 100 回, 200 回, 300 回の場合の生成デプスマップの一部を示す。

デプスマップ生成器の学習の結果として、283 組という従来の深層学習手法と比較して少ない画像枚数においても、図 14 (b) のように見かけ上類似する画像が生成されていることがわかる。また、PSNR と SSIM の結果からも、定量的に生成画像と真値デプスマップの類似性が高いことが示されている。PSNR 値の平均は学習回数 200 回以降に 31dB 前後であり、SSIM についても同様に 0.96 前後から大きく変動していないことから、学習終了の目安は 200 回以上降となる。本研究では、腹腔鏡画像と RGB-D カメラ間の照明条件を統一することでドメイン間の差異の埋め合わせを行ったが完全ではなく、画像の彩度や明度が若干異なる。そのため、過度な学習を行うと RGB-D カメラの画像に特化した生成器となり、腹腔鏡画像に対する適用性能が低下する恐れがある。そこで、100 回から 300 回までの学習済み

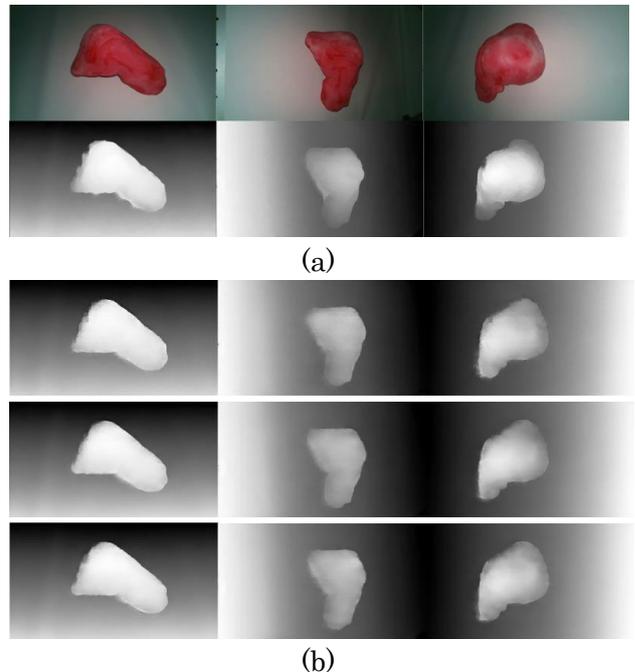


図 14 (a): 入力 RGB 画像 (No.1, 2, 3), (b): 生成デプスマップ (上から 100, 200, 300 epochs)

表 1 学習回数 (epochs) と PSNR 値 (dB)

No.	100	200	300	400	500
1	30.18	30.33	30.79	30.24	30.27
2	30.04	30.76	30.22	29.05	28.77
3	25.62	25.43	25.80	27.92	27.91
4	30.25	35.01	34.58	34.71	35.02
5	32.32	33.80	33.53	33.50	33.59
avg	<b>29.68</b>	<b>31.07</b>	<b>30.98</b>	<b>31.08</b>	<b>31.11</b>

表 2 学習回数 (epochs) と SSIM 値

No.	100	200	300	400	500
1	0.948	0.958	0.959	0.951	0.953
2	0.958	0.968	0.967	0.961	0.964
3	0.946	0.956	0.956	0.951	0.955
4	0.954	0.975	0.973	0.970	0.973
5	0.963	0.974	0.972	0.968	0.970
avg	<b>0.954</b>	<b>0.966</b>	<b>0.965</b>	<b>0.960</b>	<b>0.963</b>

生成器に絞って、腹腔鏡画像への適用性能について評価した。図 15 は、学習回数 100 回、200 回、300 回の生成器 (以降生成器 A, B, C とする) に対して 5.1 節で用意した 62 枚の腹腔鏡画像を入力し、各出力結果から同じフレームを抽出した様子を示す。

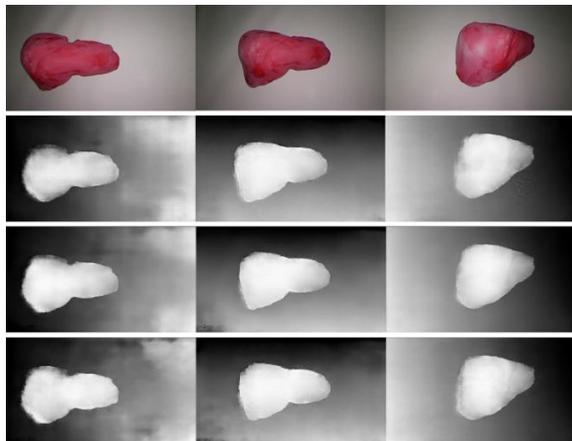


図 15 腹腔鏡映像からのデプスマップ生成 (上から、入力画像, 100, 200, 300 epochs)

図 15 の結果より、生成器 A の生成デプスマップは、臓器の輪郭付近の滲みが他の結果より顕著であった。生成器 B の生成デプスマップは、全生成器の中で最も滑らかにデプス勾配を表現できていることが確認できる。生成器 C の生成デプスマップは、生成器 A と同様に滲んだ状態となっており、臓器領域

内のデプス値が乱れていることがわかる。以上のことから、学習回数 100 回の生成器は腹腔鏡画像に対して不適であり、また学習回数 300 回以降は異なるドメインに対する汎化性能が低下していると判断し、学習終了の目安を 200 回とした。

### 5.5 3次元臓器モデルの評価

学習済み生成器から生成されたデプスマップと SfM 推定情報を用いて、密な点群で構成される 3次元臓器モデルを生成する。4 章の方法で取得した距離とデプス値の関係から、臓器領域に使用される輝度値 180 以上のデプス値の範囲で回帰直線を推定し、追加点の 3次元距離を推定した。この際、決定係数が 0.6 以上となるフレームを点群生成に使用した。臓器領域の輝度値 200 以上の領域から新たに追加した点群を統合し、それぞれの腹腔鏡画像群から 3次元臓器モデルを生成した。高密度化に使用したデプスマップは、各画像群でそれぞれ 8 枚、5 枚、6 枚であり、点群の生成に平均 7 分を要した。図 16 に、各腹腔鏡画像群における 3次元点群 (高密度化処理前、提案手法) を示す。また、生成された点群の精度を、CT データから作成された肝臓の真値点群との ICP (Iterative Closest Point) を求めることで評価する。表 3 に、生成モデルの ICP 結果を示す。

図 16 (a) の SfM により推定された 3次元点群は、使用する画像が少なくなるほど疎となることが分かり、12 枚の画像から復元されたものは、形状の判断が困難な状態となっている。また、全 3次元点群の共通点として、左葉領域 (モデル右半分) が疎であり、モデルの低テクスチャ性が影響したことがわかる。

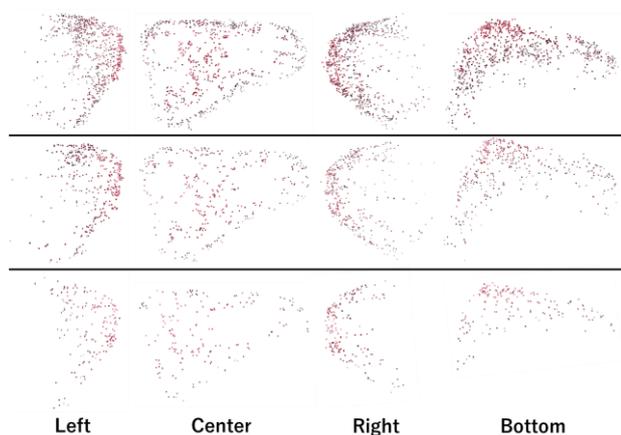
図 16 (b) の提案手法により高密度化された 3次元点群は、どの画像枚数においても十分な高密度化が行われた。全生成モデルに共通する特徴として、右葉領域 (モデル左半分) の下部の点群が、モデルの形状から離れている点が挙げられる。肝臓の中心部分から離れるほど差が大きくなることが確認でき、この領域の勾配を正しく生成するためには、データセットの増強が必要である。真値との ICP の結果としては、RMSE が約 1.97cm であり、右葉下部の誤差が大きく影響したと考えられる。

評価実験の結論として、提案手法により生成した 3次元臓器モデルは、デプスマップ生成器に使用した 283 組という少ないデータセットを考慮すると十分な精度を達成したといえる。また、3次元情報を

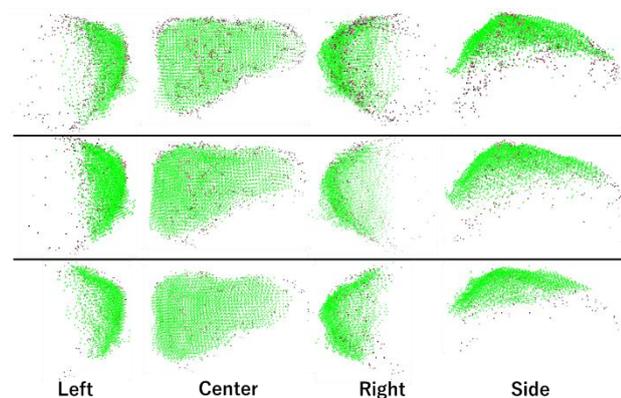
推定するにあたり制約の多い腹腔内環境において、提案手法は臓器の低テクスチャ性や鏡面反射の影響を低減できる点で有用である。

表 3 ICP の結果 (200 epochs)

Image_size	Point_size	RMSE (cm)
62	6374	1.99
28	3890	2.03
12	4716	1.90



(a) SfM により推定された疎な点群



(b) 提案手法による高密度化 (200 epochs)

図 16 各 3 次元臓器モデルの様子

## 6. おわりに

本研究では、手術情報アノテーションシステムでの使用に資する、密な 3 次元点群によって構成される 3 次元臓器モデルを、単眼腹腔鏡映像から生成する手法を提案した。デプスマップ生成器を構築し、SfM によって推定される疎な 3 次元点群を、腹腔鏡映像から生成されたデプスマップを用いて高密度化

した。撮影装置間のドメイン適合処理および学習データの増強によって、3 次元臓器モデル全体で高い精度を実現することが可能である。本研究は科研費 (17H01772) および (18H03546) の助成を受けたものである。

## 参考文献

- [1] 日本内視鏡外科学会, “内視鏡外科手術に関するアンケート調査”, 日本内視鏡外科学会誌, Vol.21, No.6, 2016.
- [2] 日本内視鏡外科学会, “腹腔鏡下手術にあたってのガイドライン”, <http://www.jses.or.jp/members/regulation.html>, (参照 2019-12-11)
- [3] J.C.Wang et al, “Video see-through augmented reality for oral and maxillofacial surgery”, International Journal of Medical Robotics and Computer Assisted Surgery, 2016.
- [4] F.Volonte et al., “Augmented reality and image overlay navigation with osirix in laparoscopic and robotic surgery: not only a matter of fashion”, Journal of Hepato-Biliary-Pancreatic Sciences, Vol.18, pp.506-509, 2011.
- [5] C.Wu, “VisualSfM: A Visual Structure from Motion System”, <http://ccwu.me/vsfm/>, (参照 2019-12-11)
- [6] E.David et al., “Depth Map Prediction from a Single Image using a Multi-Scale Deep Network”, In NIPS, 2014.
- [7] R.Anita et al., “Implicit domain adaptation with conditional generative adversarial networks for depth prediction in endoscopy”, International Journal of Computer Assisted Radiology Surgery, Vol.14, pp.1167-1176, 2019.
- [8] Q.Yang et al., “Fusion of Median and Bilateral Filtering for Range Image Upsampling”, IEEE Transactions on Image Processing, Vol.22, No.12, 2013.
- [9] J.L.Schonberger et al., “Structure-from-motion revisited”, In CVPR, 2016.
- [10] I.Phillip et al., “Image-to-Image Translation with Conditional Adversarial Networks”, In CVPR, 2017.