

腹腔鏡映像からの臓器3次元モデリングのための 深層学習によるワンショットデプスマップの生成

前川凌佑¹ 穴戸英彦² 亀田能成² 坂本堪亮³ 大城幸雄⁴ 北原格²

概要: 腹腔鏡手術は、切開範囲が小さく回復が早いなど患者にとって利点が多い術式である。一方で、術部と器具の3次元的な位置関係の把握が難しく、手術技術の取得には一定の時間を要する。ARやVRによって術者に腹腔内の3次元情報を提示する方法が提案されているが、ステレオ法やSfM (Structure from Motion) などの特徴点ベースの3次元情報推定では、テクスチャが乏しいという臓器特有の性質の影響を受けやすい。本研究では、深層学習を用いて腹腔鏡映像中のフレーム (ワンショット) 毎に生成したデプスマップを利用することで、上述した問題の解決を目指す。RGB-Dカメラで撮影したRGB画像とデプスマップを用いて学習用データを取得し、深層学習によってデプスマップ生成器を生成する。カメラキャリブレーションによって求めた腹腔鏡画像からRGB-D画像への射影変換によって、撮影した腹腔鏡画像をRGB-D画像に変換し、デプスマップ生成器に与えることにより、単眼腹腔鏡映像の各フレームにおいてデプスマップを生成する。

キーワード: 腹腔鏡映像, 外科手術, 深層学習, ワンショット, デプスマップ, カメラキャリブレーション

One-Shot Depth Map Generation for 3D Modeling of Laparoscope Video Using Deep Learning

RYOSUKE MAEKAWA^{†1} HIDEHIKO SHISHIDO^{†2} KAMEDA YOSHINARI^{†2}
TAISUKE SAKAMOTO^{†3} YUKIO OHSHIRO^{†4} ITARU KITAHARA^{†2}

Abstract: This research aims to generate depth map by one-shot in situation of monocular laparoscope using deep learning. Recently, as a method of presenting 3D information in abdominal cavity to surgeons, AR 3D annotation systems has drawn attention, and it is strongly expected to be introduced to actual medical sites. Currently, 3D information to systems is estimated by image feature based method such as SfM and stereo vision. However, these methods are intolerant of low texture. In order to solve such problem, we use deep learning to generate depth map from laparoscope by one-shot. First, using image pair (RGB image and depth map) captured from RGB-D camera to generator learning. Next, correct distortion of RGB images captured from monocular laparoscope, and execute the homography transformation from laparoscope to RGB-D camera. We also confirm the effectiveness our method to generate depth map.

Keywords: Laparoscope Video, Surgical Operation, Deep Learning, One-Shot, Depth Map, Camera Calibration

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) のひとつである。この方法は身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い術式である[1]。しかしその一方で、間接的に行われる操作や術部の3次元的な位置関係の情報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]。そ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CG (Computer Graphics) 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おり[3][4][5][6]、医療現場への導入が期待されている。

ARで3次元情報を提示するためには、術中に腹腔内の3次元情報を推定する必要がある。従来手法では、SfM (Structure from Motion) [7]を用いる方法とステレオ視を用いる方法に代表される、画像特徴点を手掛かりに3次元情報を推定する方法が多く用いられている。

SfMを用いる手法では、単眼内視鏡で撮影した多視点画像から画像特徴点を検出し、その対応関係から導出されたエピポーラ方程式に基づいて、各画像を撮影したカメラの位置姿勢と被写体の3次元情報 (3次元点群) を推定する。我々の以前の研究[6]では、SfMを用いた臓器形状推定における腹腔鏡映像の観察条件を検討し、臓器表面からの鏡面反射に対してSfMが有効な手法であることを確認した。し

¹ 筑波大学大学院システム情報工学研究科
Graduate School of Systems and Information Engineering, University of
Tsukuba
² 筑波大学計算科学研究センター
Center for Computational Sciences, University of Tsukuba

³ 株式会社ネクステッジテクノロジー
nextEDGE Technology, Inc.
⁴ 東京医科大学茨城医療センター
Tokyo Medical University Ibaraki Medical Center

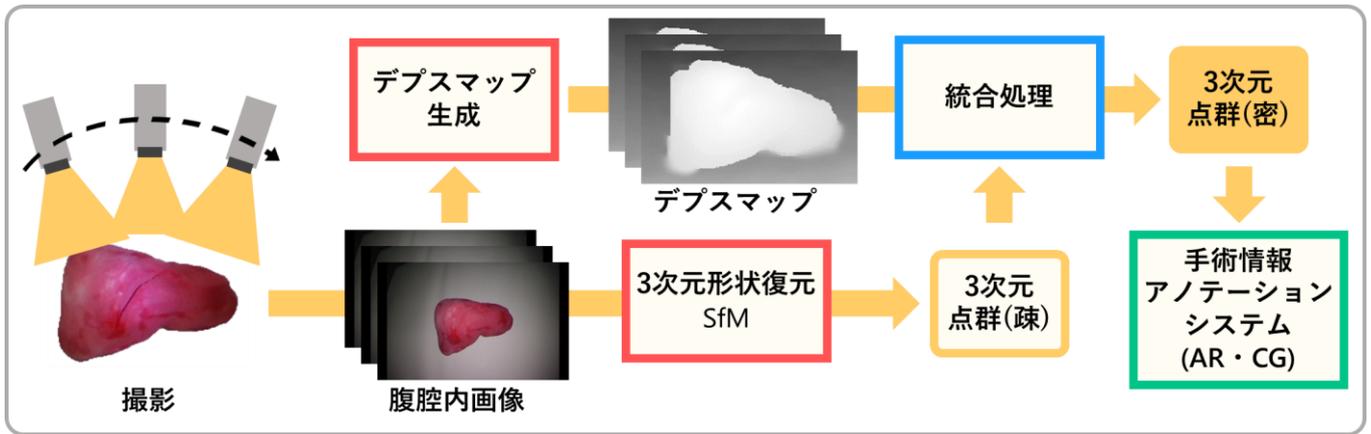


図 1 ワンショットデプスマップ生成手法と SfM の統合

Fig. 1 Integration of one-shot depth map generation method and SfM

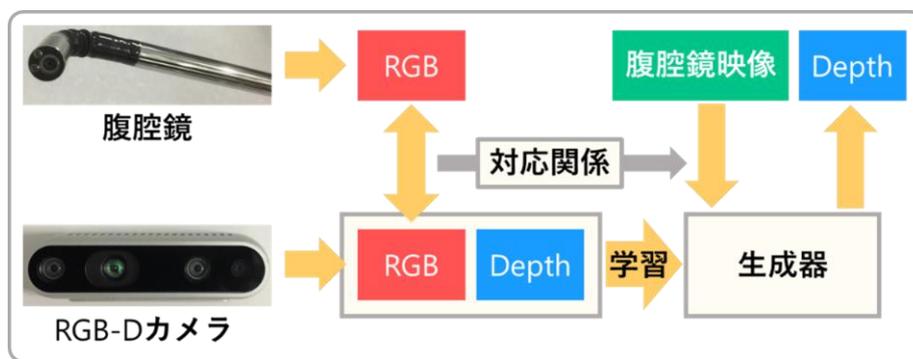


図 2 深層学習を用いた腹腔鏡映像からのワンショットデプスマップ生成フロー

Fig. 2 The work flow of the one-shot depth map generation of laparoscope video using deep learning

かし、形状推定に対する臓器の低テクスチャ性の影響は大きく、腹腔鏡手術映像を用いた形状推定は困難であった。

ステレオ視を用いる方法では、ステレオ内視鏡で取得したペア画像から SIFT 特徴量[8]などを用いて対応点を検出し、三角測量の原理に基づいて被写体の 3次元情報推定を実現している。SfM と比較して密な 3次元情報の推定が可能で、かつフレーム毎の奥行き推定が可能である一方、腹腔鏡ではカメラ間のベースライン距離が短くなるため、撮影対象に十分接近する必要があり、肝臓のような大きな臓器の概観を観察するような見え方を得にくいという問題が存在する。また、ほぼ同じ方向から観察した画像対を用いて 3次元情報を推定するため、鏡面反射領域の 3次元推定が困難であるという問題も存在する。

ステレオ視を用いる手法に関連して、複数枚のステレオ画像を統合し、密で広範囲の 3次元モデルを推定する研究も行われている[9]。しかし、前述したカメラ間のベースライン距離の短さから、広い範囲を観察しようとするとき奥行き分解能が下がり、腹腔内において統合が困難となる恐れがある。

そこで本研究では、従来手法が抱える臓器の低テクスチャ性という問題に対処し、将来的に SfM 手法との統合を行うための深層学習によるワンショットデプスマップ生成を

考える。図 1 はワンショットデプスマップ生成手法と SfM を統合した 3次元情報推定処理を示す。術中に観測された腹腔内映像から、RGB 画像を取得する。RGB 画像を用いて SfM により臓器の 3次元点群を推定する。この点群は、臓器の低テクスチャ性や SfM の特性により疎であるため、RGB 画像から生成したデプスマップを用いることで密な 3次元情報を生成する。

図 2 にデプスマップ生成フローを示す。RGB 画像とデプスマップのペアを取得可能な RGB-D カメラを用いて CT データから作成された肝臓模型を撮影することでデータセットの作成を行う。RGB 画像中のエッジを保持しつつ、対応するデプスマップの平滑化を行うクロスバイラテラルフィルタ (Cross Bilateral Filter : CBF) [10] を適用することで、デプスマップの信頼性を高める。データセットを用いてデプスマップ生成器の学習を行う。本研究では、データを生成する Generator と、そのデータの信頼性を判断する Discriminator 双方を学習することにより、効率よく正解と同等の精度を持つデータの生成を実現する敵対的生成ネットワーク (Generative Adversarial Network : GAN) [11] を用いて生成器 (Generator) を学習する。腹腔鏡と RGB-D カメラで同一のキャリブレーションボードを撮影し、腹腔鏡画像から RGB-D 画像への射影変換を求める。腹腔鏡カメラ

で撮影した画像に上記射影変換を適用し、それを生成器に与えることでワンショットデプスマップ生成を実現する。

2. データセットの作成

2.1 RGB 画像とデプスマップペアの作成

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の作成を行う。図 3 は撮影の様子を示しており、作業台上に撮影対象（CT データから作成された肝臓の石膏模型）を配置し、RGB-D カメラを模型上部に固定した。また、手術中は臓器に対して腹腔鏡先端部から観察のための光を照射するため、撮影時にクリップライトを用いて画像中心を照らすことで同様の観察条件となるようにした。模型の撮影パターンは、図 4 に示すように模型上部から観察するものと、左右から斜めに観察する視点を含む 4 つのカメラ配置とし、また観察方向毎に 20-45cm の範囲を 4 パターン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、より多くの視点からの観察に対応可能なデータセットを生成する。加えて、カメラを固定した状態で模型を 45 度ずつ回転させ、1 視点につき 8 枚の画像ペアを撮影し、合計 128 組の画像ペアを持つデータセットを作成する。

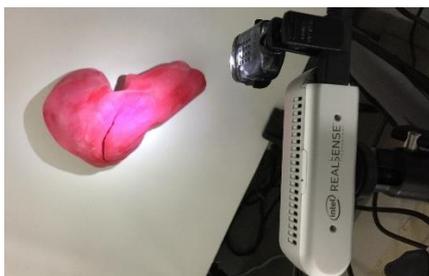


図 3 データセット用画像ペアの撮影環境
Fig. 3 Capturing environment of image pair for dataset

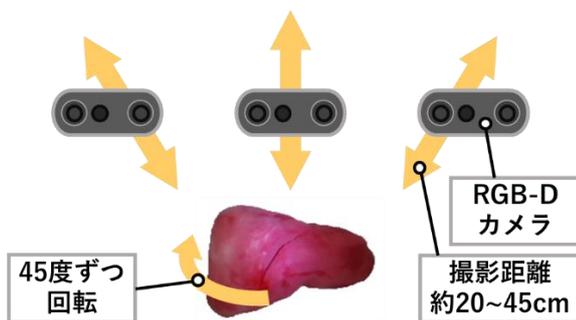


図 4 模型の撮影パターン
Fig. 4 Pattern of phantom capturing

図 5 (a) に RGB-D カメラから取得された画像ペアを示す。デプスマップの模型部分にはオクルージョンにより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。この領域はデプスマップ生成器の学習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

を行うことで除去する。図 5(b) に Hole Filling 処理後の模型部分を示す。黒色領域が良好に補完されていることが確認できる。

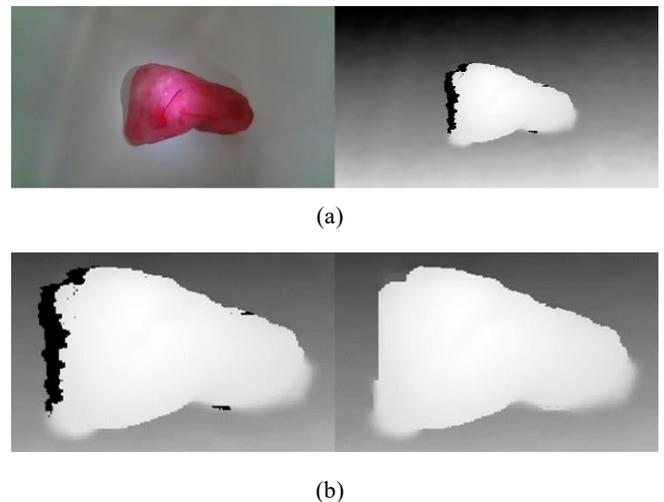


図 5 (a) RGB 画像とデプスマップのペア, (b) Hole Filling 処理の結果

Fig. 5 (a) Pair of depth map and RGB image, (b) Result of hole filling process

2.2 デプスマップの平滑化処理

図 5(b) に見られるように、Hole Filling 処理によってデプス値の補完処理が行われた領域のエッジは、RGB 画像中の模型のエッジと一致していない場合がある。また、デプスマップ全体にもノイズが見られるため、クロスバイラテラルフィルタを用いることでこれらの問題を軽減する。クロスバイラテラルフィルタは、同一視点で異なるモデルにより観測された 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手法である。RGB 画像とデプスマップのペアにおいては、ノイズの少ない RGB 画像を基準とすることでデプスマップのフィルタリング処理が可能である。適用するフィルタの式を以下に示す。

$$D_p = \frac{\sum_{r \in N} d(\|p-r\|_2) c(\|I_p - I_r\|_2) D_r}{\sum_{r \in N} d(\|p-r\|_2) c(\|I_p - I_r\|_2)}$$

$$d(\|p-r\|_2) = \exp\left(-\frac{\|p-r\|_2}{2\sigma_1^2}\right),$$

$$c(\|I_p - I_r\|_2) = \exp\left(-\frac{\|I_p - I_r\|_2}{2\sigma_2^2}\right)$$

ここで、 p は注目画素座標、 r は参照画素座標、 D はデプス値、 I は輝度値、 σ は定数、 N は参照画素座標の集合を表す。注目する画素位置に対して、参照する画素位置との距離と、

RGB 画像上における色類似度を重みとすることで、デプス値を推定する。これにより、図 6(b)に示すように、RGB 画像のエッジを保持しながらデプスマップを平滑化することが可能となる。

本節で述べた方法により肝臓の石膏模型を撮影し、取得された RGB 画像とデプスマップのペアに対して Hole Filling 処理およびクロスバイラテラルフィルタを適用し、128 組のペア画像からなるデータセットを作成した。

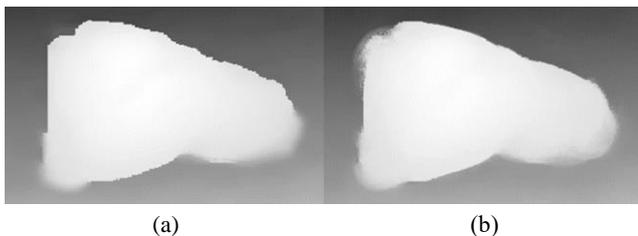


図 6 デプスマップの平滑化処理 : (a) 処理前, (b) 処理後
Fig. 6 Depth map smoothing process : (a) Before process, (b) After process

3. デプスマップ生成器

本研究では、GAN 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、腹腔鏡映像からのワンショットデプス推定を実現する。デプスマップ生成手法として、条件付き GAN の一種であり、状態の異なる 2 画像間の対応関係を学習し変換する手法である pix2pix[12]を採用する。pix2pix は、航空写真から地図への変換や線画画像から着色画像への変換などの画像変換タスクに用いられており、多様な形態の画像間の変換への有効性が確認されている。また、学習に必要なデータ数が比較的少数で機能するという点も pix2pix を用いる利点である。従来の機械学習手法では多くの学習データが必要とされてきたが、GAN の特徴である Generator と Discriminator のモデル構造により、少ないデータで高い性能を実現できる。

デプスマップを生成するプロセスについて説明する。図 7 に RGB 画像からデプスマップの生成を行う pix2pix の学習モデルを示す。このモデルでは、Generator を示す G に変換前の RGB 画像を入力し、Discriminator を示す D には G が生成した画像、もしくは用意した変換後となる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、互いに競合さ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 を用いることにより、RGB 画像からのデプスマップ生成器が実現される。

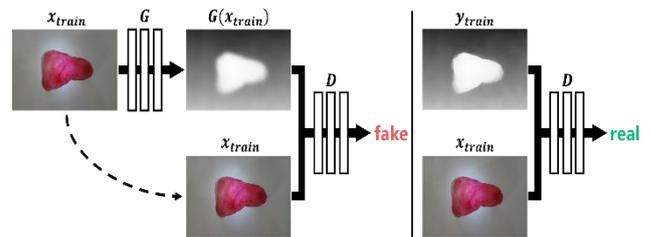


図 7 RGB 画像からデプスマップを生成する学習モデル
Fig. 7 Training model that generates depth map from RGB image

4. 腹腔鏡映像の変換

デプスマップ生成器は、RGB-D カメラで取得されたデータセットを用いて学習されるため、腹腔鏡映像の見え方を RGB-D 画像に変換した後、生成器に与えるのが適当である。

4.1 キャリブレーションボードの撮影

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、映像に対して十字線をプロットすることで、線が各カメラ映像においてボード上の同じ位置に重なるよう配置する。各カメラから取得された画像を図 8(a)に示す。

4.2 レンズ歪み補正

図 8(a)上は腹腔鏡から取得された画像であり、レンズ歪みによってボードが膨らんだ形となっている。後にカメラ視点変換の実現のために行われる射影変換行列の推定は、平面を別の平面に射影する手法であるため、レンズ歪みによって曲面として映るボードからは正しい変換式が得られない。よって、腹腔鏡から取得された画像に対してレンズ歪み補正を行う。事前の準備として、腹腔鏡を用いて取得した複数枚のキャリブレーションボード画像から、交点の 2 次元座標をそれぞれ取得し、以下のレンズ歪み補正式によってカメラ固有の歪みを表すパラメータを求めておく。

$$\begin{aligned} x &= (\tilde{x} - c_x) / f_x \\ y &= (\tilde{y} - c_y) / f_y \\ r^2 &= x^2 + y^2 \\ x' &= \frac{x - 2p_1xy - p_2(r^2 + 2x^2)}{1 + k_1r^2 + k_2r^4} \\ y' &= \frac{y - p_1(r^2 + 2y^2) - 2p_2xy}{1 + k_1r^2 + k_2r^4} \end{aligned}$$

ここで、 x, y はカメラ座標上の歪みを含む点、 \tilde{x}, \tilde{y} は画像座標上の歪みを含む点、 x', y' はカメラ座標上の歪みを補正した点である。また、 $(c_x, c_y), (f_x, f_y)$ が画像中心と焦点距離、 $(k_1, k_2), (p_1, p_2)$ は半径方向と円周方向の歪みパラメータを示す。図 8(b)は、図 8(a)上の画像に対して歪み補正を行った

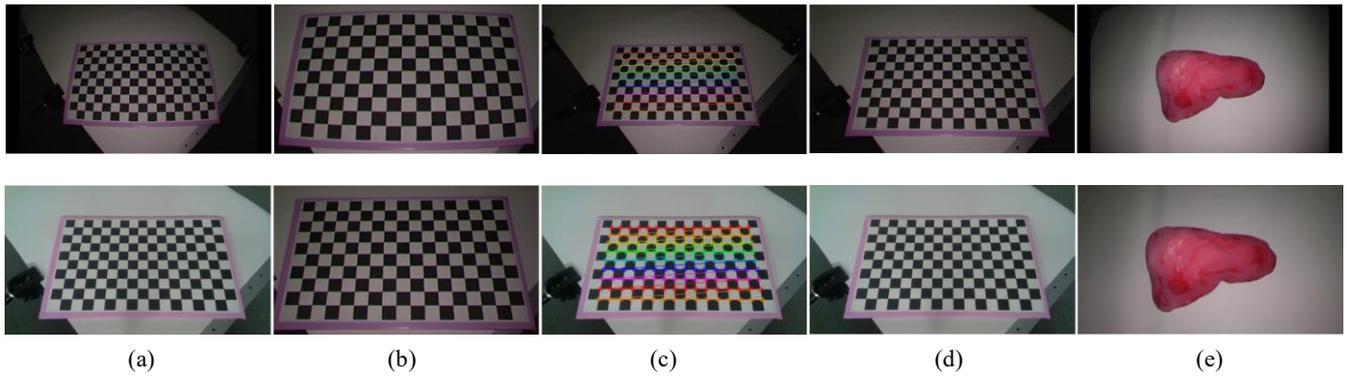


図 8 腹腔鏡と RGB-D カメラの対応付け処理

Fig. 8 Process of camera view registration between laparoscope and RGB-D camera : (a) above image taken from laparoscope and below taken from RGB-D camera, (b) lens distortion correction, (c) corner detection from checkboard, (d) above is a result image of homography transformation, (e) result of process explained in chapter 4

た結果であり，上図の湾曲した画像が下図のように補正される。

4.3 射影変換

レンズ歪み補正が行われた腹腔鏡画像（図 8(b)下）と，RGB-D カメラから取得された RGB 画像（図 8(a)下）からコーナ位置を検出し，その情報を用いて射影変換行列を求める．図 8(c)は各画像からキャリブレーションボードのコーナを検出した結果である．ボードから検出された点 x, y を， x', y' に変換する式を以下に示す．

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} \sim \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}, \quad H = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix}$$

$$x' = \frac{h_{11}x + h_{12}y + h_{13}}{h_{31}x + h_{32}y + h_{33}}$$

$$y' = \frac{h_{21}x + h_{22}y + h_{23}}{h_{31}x + h_{32}y + h_{33}}$$

検出されたコーナ位置情報を複数用いることで，上式から変換行列 H を得る．この際，より精密な値を得るために RANSAC[13]を用いた外れ値除去を行う．図 8(d)は，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であり，図 8(d)下の RGB-D カメラの視点と腹腔鏡の視点と同じ状態となっている．図 8(e)は，肝臓模型を撮影した画像(図 8(e)上)に対して 4 節で説明した処理を同様に適用した結果を示し，図 8(e)下は変換により RGB-D カメラから観察したような見え方となった腹腔鏡画像を示す．

5. 実験

デプスマップ生成器の学習と性能を確認し，腹腔鏡カメラから取得した画像を用いてデプスマップを生成する．デ

ータセットの作成には，最小距離 11 cm からのデプス計測が可能な RGB-D カメラ (Intel Realsense D435) を使用した．また，本 RGB-D カメラの RGB 画像とデプスマップの解像度は共に 640 画素 \times 360 画素である．撮影に使用した腹腔鏡システムは図 9 に示す OLYMPUS VISERA ELITE II OTV-S300 (映像処理装置) と，OLYMPUS LTF-S190-10 (単眼腹腔鏡カメラ) であり，画像解像度は 1920 画素 \times 1080 画素である．

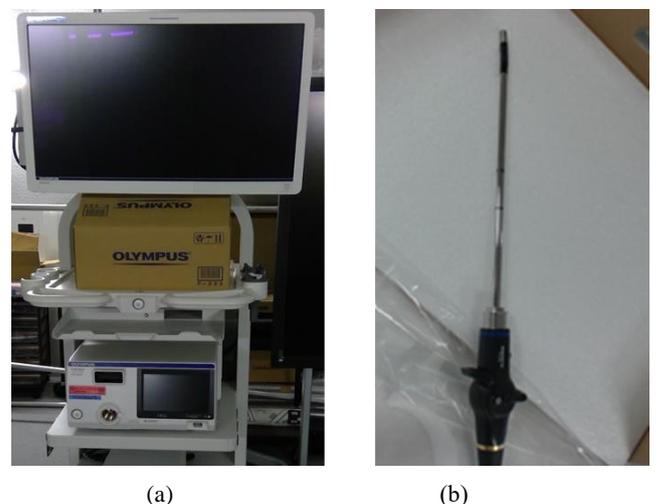


図 9 腹腔鏡システム : (a) 映像処理装置とモニタ, (b) 腹腔鏡カメラ

図 9 Laparoscope system : (a) Video processor and monitor, (b) Laparoscope camera

5.1 デプスマップ生成器の学習と画像生成

3 節で説明した pix2pix と，2 節で構築したデータセットを用いてデプスマップ生成器の学習を行う．学習データとして，データセットから無作為に抽出した 123 組のペア画像を使用し，学習後の画質評価には，学習に使用しなかった画像ペア 5 組を用いる．生成画像の定量的評価として，

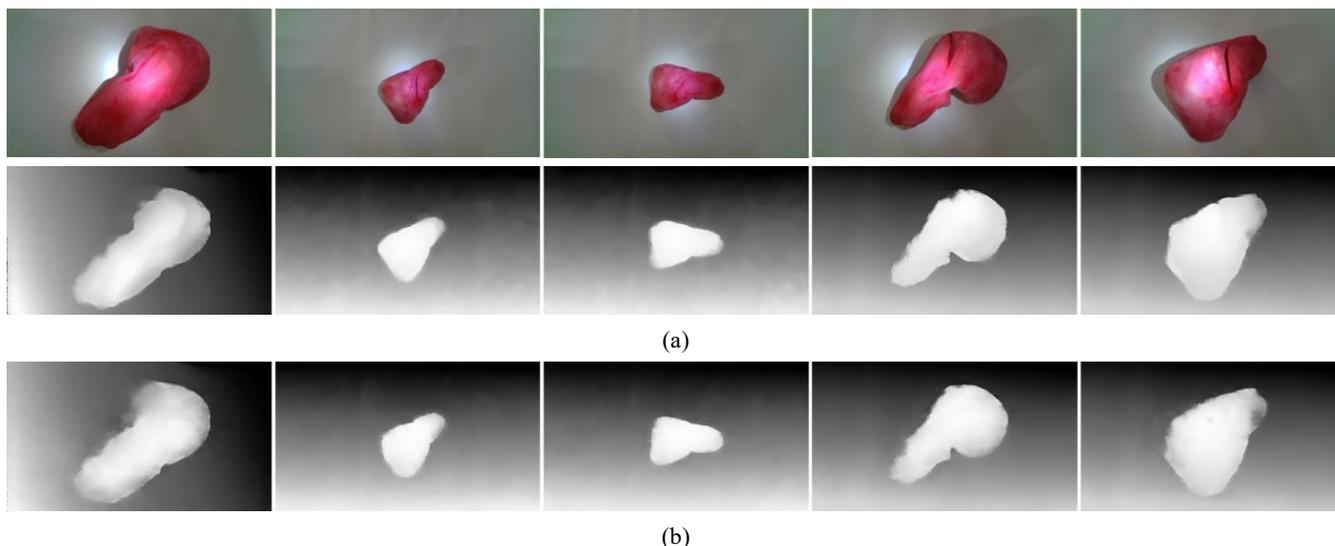


図 10 比較結果 : (a) RGB 画像と真値デプスマップ, (b) 生成画像

Fig. 10 Comparison result : (a) RGB images and Ground truth depth maps, (b) Generated images

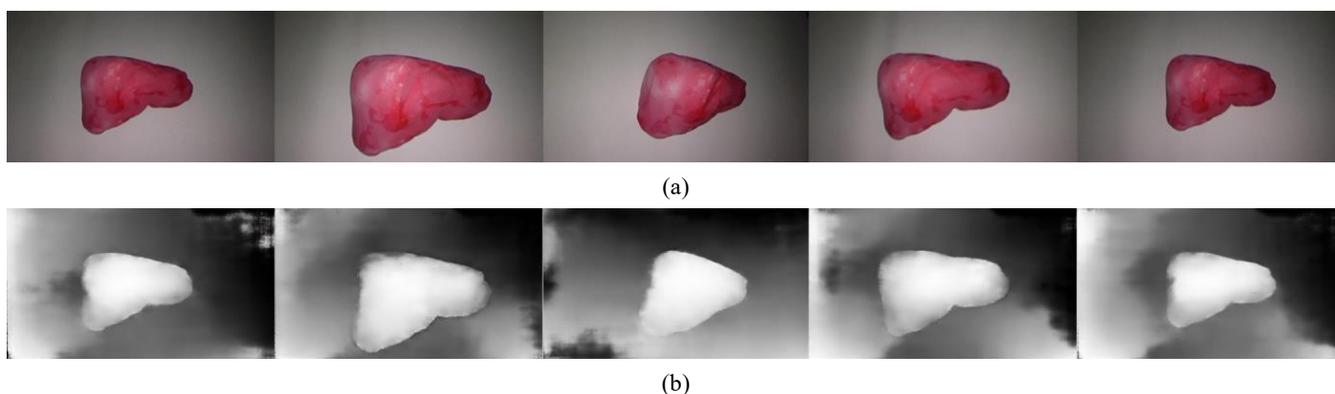


図 11 腹腔鏡映像からのデプスマップ生成結果 : (a) 入力画像, (b) 生成画像

Fig. 11 Result of depth map generation from laparoscope image : (a) input images, (b) output images

画像評価指標である PSNR (Peak Signal-to-Noise Ratio) と SSIM (Structural Similarity) を用いることで、正解データとの類似性を定量的に評価する。学習モデルは、Github 上で公開されている pix2pix のソースコード[12]をベースとして、作成したデータセットの解像度に適した層構造により構築した。学習では、GPU Tesla K80 による並列処理を行うために、Google が提供するクラウド上で実行可能な Jupyter ノートブック環境である Google Colab[14]を使用し、300epochs の学習に約 200 分を要した。図 10 に、学習後の生成器に評価用画像 5 枚を入力し、デプスマップへと変換した結果を示す。また、表 1 に各生成画像と対応する真値デプスマップの PSNR および SSIM の結果を示す。

5.2 腹腔鏡映像からのデプスマップ生成

学習後の生成器に対して腹腔鏡から取得された肝臓模型画像を入力し、デプスマップの生成を行う。図 11(a)は、観

察方向を変えながら肝臓模型を撮影し、4 節で説明した手法により RGB-D カメラの見え方に合わせた画像の一例である。これを生成器に入力することで、図 11(b)に示すような画像が生成される。

表 1. PSNR と SSIM の値
Table 1 Value of PSNR and SSIM

Image pair	PSNR [dB]	SSIM
1	26.09	0.919
2	33.85	0.954
3	33.58	0.955
4	27.89	0.940
5	29.40	0.942
平均	30.16	0.942

5.3 考察

デプスマップ生成器の学習では、123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10のように見かけ上似た画像が生成されていることがわかる。PSNR値が平均30.16、SSIM値が平均0.942と、定量的にも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。1番目のペアのように模型が大きく映る画像について、PSNR値とSSIM値が低くなる傾向があったが、これは肝臓部分が背景と比較して複雑な構造であり、最適化が不完全であったことが考えられる。この数値は学習データ数と学習時間を増やすことにより上昇していくと考えられるが、本研究の目的は、腹腔鏡により取得された画像からのデプスマップ生成結果の検討であるため、生成器の学習は図10および表1の結果から十分な精度であると考えた。以上より、臓器模型を観測するRGB画像とデプスマップのペアにおいて、pix2pixが有効な手法であることが確認できた。

5.2節では、腹腔鏡から取得された肝臓模型の画像からデプスマップ生成を行った。結果として、模型部分のデプス値は中央へ向かうにしたがって高くなってゆき、図10のRGB-Dカメラから取得された画像と似た構造が生成されたといえる。しかし、模型の背景部分のデプス値に大きな違いが見られ、デプスマップ全体としては信頼性が低下したといえる。背景部分のデプス値が大きく乱れた原因として、腹腔鏡が持つ周辺減光の特性が挙げられる。図12は、各カメラを通して白い背景を観察した様子であり、腹腔鏡側(図12(a))には周辺減光による明度の変化が見られる。生成器の学習は一様な明るさを持つデータを用いて行われたため、周辺減光を持つ画像を正常に処理できなかったことが考えられる。この改善案として、腹腔鏡から得られる画像の減光特性を解析し、入力画像に対して補正を行う方法と、学習データに対して腹腔鏡が持つ減光特性を適用して学習を行う方法が挙げられる。また、我々は将来的にSfMと本手法の統合を考えているため、結果を照らし合わせ、差が大きい部分を外れ値とする方法も考えられる。

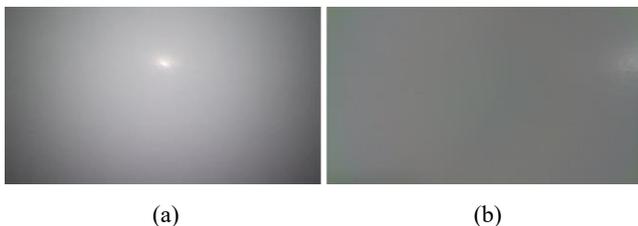


図12 周辺減光 : (a) 腹腔鏡, (b) RGB-Dカメラ
Fig. 12 Lens shading : (a) laparoscope, (b) RGB-D camera

6. おわりに

本研究では、腹腔鏡映像からの臓器3次元モデリングの

ための深層学習を用いたデプスマップ生成手法について提案した。RGB-Dカメラから取得したペア画像で事前に学習を行い、一度のカメラ間対応付けにより、単眼腹腔鏡から取得された画像からデプスマップの生成が実現できることを示した。一方で、デプスマップ背景部分の不均一性は、カメラ間対応付けにおける照明条件の重要性を示しており、4節で説明した変換処理は不十分であることが考えられる。そこで、さらなるデプスマップの信頼性向上のためには、腹腔鏡特有の周辺減光特性を明らかにし、補正する必要がある。また、本研究では腹腔鏡とRGB-Dカメラ双方でのキャリブレーションボード撮影は手動により行われていたが、今後はより正確なカメラ間対応付けが行えるよう、各カメラを固定するための装置の作成が課題である。加えて、臓器の変形に対する提案手法の有効性を検討するために、再現性のある変形を行う撮影対象の作成を行う必要がある。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] Veldkamp, R., Kuhry, E., "Laparoscopic surgery versus open surgery for colon cancer: Short-term outcomes of a randomized trial", *Lancet Oncol*, Vol.6, pp.477-484, 2005
- [2] 日本内視鏡外科学会, "内視鏡下手術にあたってのガイドライン", <http://www.jses.or.jp/member/regulation.html>, (参照 2019-07-25)
- [3] Haouchine, N., Cotin, S., Peterlik, I., "Impact of soft tissue heterogeneity on augmented reality for liver surgery", *Vis. Comput. Graph. IEEE Trans.*, Vol.21, No.5, pp.584-597, 2015
- [4] Long, C., Wen, T. et al., "SLAM-based Dense Surface Reconstruction in Monocular Minimally Invasive Surgery and its Application to Augmented Reality", *Computer Methods and Programs in Biomedicine*, 2018.
- [5] Andrés F. Mármol Vélez, Jan, M., Rolf-Rainer, G., *Structure from Motion Based Approaches to 3D Reconstruction in Minimal Invasive Laparoscopy*. Vision Systems, Hamburg University of Technology, 2012
- [6] 前川凌佑, 戸英彦, 亀田能成, 坂本堪亮, 大城幸雄, 北原格, 3次元臓器CGモデル生成に適した腹腔鏡映像撮影条件の検討, 第27回日本コンピュータ外科学会大会, Vol.20, No.4, 2018
- [7] Changchang, W., "VisualSfM: A Visual Structure from Motion System", <http://ccwu.me/vsfm/>, (参照 2019-07-25)
- [8] D. G. Lowe et al., "Object recognition from local scale invariant features", *Proc. of IEEE International Conference on Computer Vision (ICCV)*, pp.1150-1157, 1999
- [9] Richard, A., Andrew, D., Shahram, I., Pushmeet, K., Otmar, H., Jamie, S., David, M., Steve, H., David, K., Andrew, F., "KinectFusion: Real-time dense surface mapping and tracking", *Proc. IEEE Int. Symp. Mixed Augmented Reality*, pp. 127-136, 2011.
- [10] Eisemann, E., Durand, F., "Flash photography enhancement via intrinsic relighting", *ACM Transactions on Graphics*, Vol.23, No.3, pp.673-678, 2004
- [11] Goodfellow, I. et al., "Generative Adversarial Nets", *Advances in Neural Information Processing Systems* 27, 2014
- [12] Phillip, I., Jun-Yan, Z., Tinghui, Z., Alexei, A., "Image-to-Image Translation with Conditional Adversarial Networks", *CVPR* 2017

- [13] Fischler, M. A. et al., Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. Communications of the ACM, 1981, vol.24, no.6, p.381-395.
- [14] Google Colab, <https://colab.research.google.com/>, (参照 2019-07-25)