

法政大学学術機関リポジトリ

HOSEI UNIVERSITY REPOSITORY

PDF issue: 2024-12-26

ディープラーニングを利用した腹腔鏡下手術 トレーニングシステムの構築

建部, 陸 / TATEBE, Riku

(出版者 / Publisher)

法政大学大学院理工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学・工学研究科編

(巻 / Volume)

61

(開始ページ / Start Page)

1

(終了ページ / End Page)

8

(発行年 / Year)

2020-03-24

(URL)

<https://doi.org/10.15002/00022752>

ディープラーニングを利用した 腹腔鏡下手術トレーニングシステムの構築

DEVELOPMENT OF A TRAINING SYSTEM FOR LAPAROSCOPIC SURGERY USING DEEP LEARNING

建部陸

Riku TATEBE

指導教員 石井千春 教授

法政大学大学院理工学研究科機械工学専攻修士課程

In recent years, laparoscopic surgery has been performed in place of open surgery. Compared to conventional laparotomy, surgeons are required to have a high level of skill for performing laparoscopic surgery. Therefore, surgeons need to perform training using a dedicated simulator. The purpose of this study is to develop a training system for laparoscopic surgery in which novice trainees can learn the ideal ligation by themselves using a box type simulator. Forceps and suture thread are identified using semantic segmentation, which is a kind of image-based deep learning. In addition, on the basis of the result of motion identification, appropriate navigation is presented to the trainees. From the result of the verification experiments, a certain training effect in use of the proposed training system was confirmed.

Key Words: *Laparoscopic surgery, Training system, deep learning, semantic segmentation*

1. 緒論

(1) 研究背景

近年、開腹手術に替わり腹腔鏡下手術が盛んに行われるようになってきている。この手術は体に数ヶ所小さな孔をあけ、そこに腹腔鏡カメラと医療鉗子を挿入して治療を行う術式であり、従来の開腹手術に比べて患者の身体への負担が少なく、回復が早い等のメリットが存在する[1]。一方、患部を腹腔鏡カメラで見ながら細長い鉗子で作業を行うため、医師には高い技術力が要求される。そのため、医師は専用のシミュレータを用いて訓練を行う必要がある。シミュレータについては文献[2]で以下のように述べられている。

- ・腹腔鏡下手術の習得には長いラーニングカーブが存在することが知られているが、最近では長いラーニングカーブを手術室に持ち込まないで、手術外のトレーニングである程度の技術習得をすることが望まれている[3][4][5]。
- ・最も簡単なシミュレータは Box タイプで、Part task trainer に分類される。安価で単純な構造ではあるが、実際の手術器具を使用することが出来、基礎トレーニングツールとして一定の有用性が認められている[6][7]。
- ・Virtual-Reality(VR)技術を応用したシミュレータは Task trainer に分類され、数社から販売されている。基礎的な訓練の他に、決められたシナリオに沿って模擬

手術が可能である。自分の技術が点数化され、客観的な評価が可能な点も VR シミュレータの利点である。最近では肝臓摘出シナリオも利用可能であり[8][9]、VR シミュレータは手術室でのパフォーマンス向上に有用であると報告されている[10][11][12]。しかし、一方で高価で実際の感覚と多少異なるというデメリットが存在する。

文献[13]では、模擬腸管による消化管縫合モデルを使用し、その内圧を指標の1つとして縫合不全試験を行うシステムを開発し、熟練医グループと初心者グループに分かれて縫合実験を行い、縫合技術評価を行っている。

文献[14]では、結紮作業を6つの動作に分類し、そのうちの1つの動作を自動識別して、さらに最も危険に繋がり易い糸結び動作と識別された時に、通常動作か通常の動作とは異なる異常動作であるかを判別するシステムを構築している。

(2) 研究目的

先行研究[15]では、初心者が正しい結紮動作をより早く身につけることを目標とし、実際に結紮動作を練習する前に、Box タイプのシミュレータを用いて、熟練医による結紮動作の理想的な鉗子操作を擬似的に体感することができると報告されている。このシステムは、トレーニング画面と評価画面の2画面で構成される。トレーニング画面では、熟練医による理想動作をガイドラインとして表示し、

ガイドラインに追従するように訓練者が鉗子を操作することで、訓練者が理想的な鉗子操作を体感できる。また、その際にどの程度理想的な鉗子操作に追従させることが出来たかを、評価画面に表示することが出来る。しかし、実際に糸を持って結紮作業を行う際には理想的な鉗子操作を疑似体験することが出来ないという問題点が存在した。これは実際の鉗子操作で生じる糸の動きと、疑似体験する熟練医の鉗子操作映像の糸の動きにズレが生じるためである。そこで、本研究では実際に糸をもって行う結紮動作内にて、適切な鉗子の操作や、糸の動かし方をナビゲーションするトレーニングシステムを開発することを目的とする。なお、対象動作は先行研究と同じく、結紮動作を対象とする。

2. トレーニングシステム

(1) 対象動作

対象動作である結紮動作は、腹腔鏡下手術の基本手技の一つであり、結紮動作を習得することで、術中の突発的な出血などにも対応することが出来るなどのメリットが有る。結紮動作には、一度のみ糸結びを行う単結紮と、複数回糸結びを行う多重結紮が存在するが、今回は多重結紮を対象とする。対象の多重結紮は、第一結紮、第二結紮、第三結紮と三回連続で糸結びを行う三重結紮であり、第一結紮と第三結紮は右鉗子で糸を把持し、左鉗子に巻き付けて糸結びを行う C loop (Fig.1), 第二結紮は左鉗子で糸を把持し、右鉗子に巻き付けて糸結びを行う逆 C loop (D loop) である。

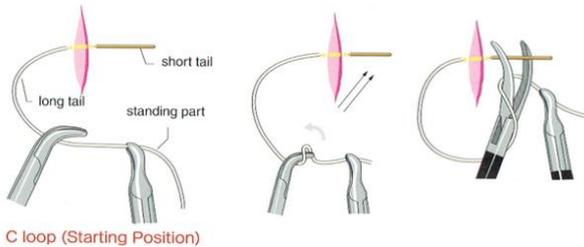


Fig.1 Method of C loop [16]

(2) ナビゲーション動作

理想動作のナビゲーションをするにあたって、熟練医と研修医の実際の結紮動作における記録映像から両者にどのような差異が生じているのかを解析した結果、鉗子に糸を巻き付ける際に C の形状が上手く出来ていない(Fig.2)事が判明した。

そこで今回構築するトレーニングシステムでは、結紮動作における C の形状の作成を主とし、Short tail の作成、巻き付け動作、引張動作のナビゲーションを行う。ここで、Short tail とは、縫合糸の針のついていない側の端(Fig.3)のことである。

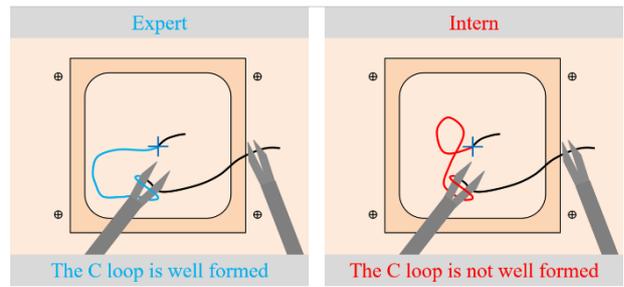


Fig.2 Difference in thread shape

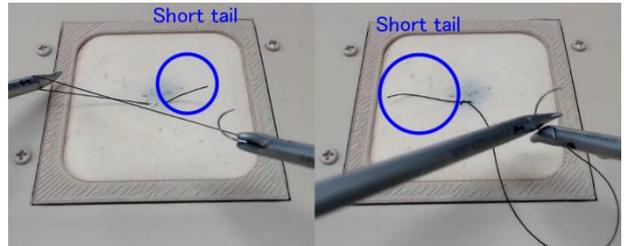


Fig.3 Short tail

(3) システム概要

本トレーニングシステムでは結紮動作中の糸や鉗子の位置をセマンティックセグメンテーションにより識別し、Fig.4 のようにモニター文字や図でのナビゲーションを提示する。

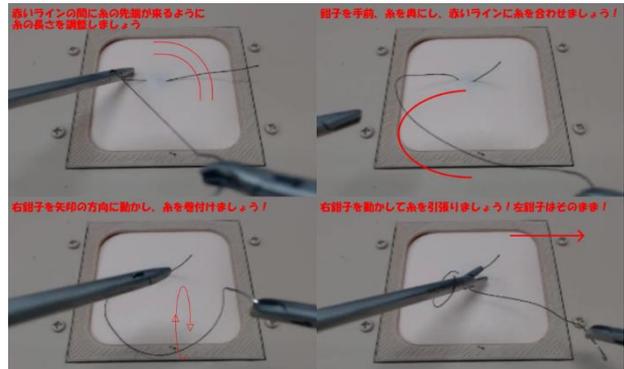


Fig.4 Navigation image

3. セマンティックセグメンテーション

本研究では、画像認識や物体検出よりも高精度な識別が可能なることから、セマンティックセグメンテーションを利用した。セマンティックセグメンテーションとは、画像系 Deep Learning の一種であり、画像中のどこに何があるのかを判別する物体検出をピクセルレベルで行う意味的領域分割と呼ばれる手法である。本研究では、セマンティックセグメンテーションを使用し、背景(クラス番号 0)、糸(クラス番号 1)、鉗子(クラス番号 2)の3つの物体の多クラス分類を行った。

(1) 学習データ

セマンティックセグメンテーションに使用する学習データを Fig.5 に示す。それぞれ上段は入力画像、下段はラベル画像となっている。鉗子や糸などの識別物体が映っている画像データに対応するラベル画像を 340 枚、背景のみ

の画像データに対応するラベル画像を 150 枚作成した. 作成した画像のサイズは 640pixel×480pixel である.

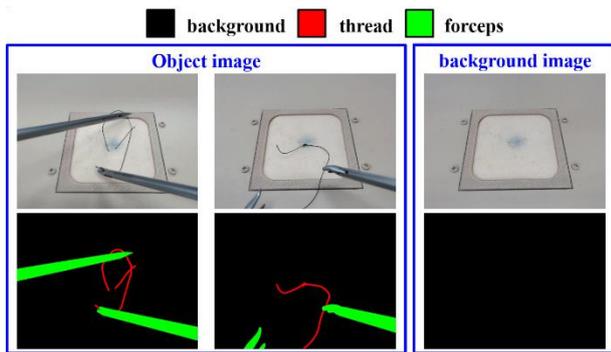


Fig.5 learning data and label data

作成した入力画像とラベル画像は Table1 に示す方法でデータ変換を行い, Data Augmentation を行った. Background image については左右反転変換を行わなかった. クロッピングは一度 512pixel×512pixel にサイズ変更を行い, 左端から, 256pixel×256pixel のサイズで 125pixel ずつずらし, 横に 3 枚, 縦に 3 枚の合計 9 枚を作成した (Fig.6). 回転変換については-15 度から 15 度まで 5 度ずつ回転を行った (Fig.6). 水増し後の学習データの枚数は入力画像, ラベル画像共に 11610 枚で, 画像サイズは全て 256pixel×256pixel である.

Table1 Data Augmentation list

	Object Image (340sheets)	Background Image (150sheets)	Total
Flip horizontal	1 way		
Rotation	6 ways	6 ways	
Cropping	9 ways	9 ways	340×24
Gamma correction	4 ways	4 ways	+
Edge emphasis	1 way	1 way	150×23
Gaussian blur	1 way	1 way	=
Random noise	1 way	1 way	11,610
No conversion	1 way	1 way	
Total	24 way	23 way	

(2) ネットワーク構造

本研究では U-NET を利用し, セマンティックセグメンテーションを行った. U-NET とは MICCAI 2015 において発表された U-Net: Convolutional Networks for Biomedical Image Segmentation[17]で提案されたセマンティックセグメンテーション手法である. 低次元の特徴量をスキップすることで, 位置情報を保持したままのセグメンテーションが可能であり, 物体の局所の特徴と全体的位置情報の両方を統合して学習することができる. 本研究で使用した U-NET のモデル構造を Fig.7, Table2 に示す.

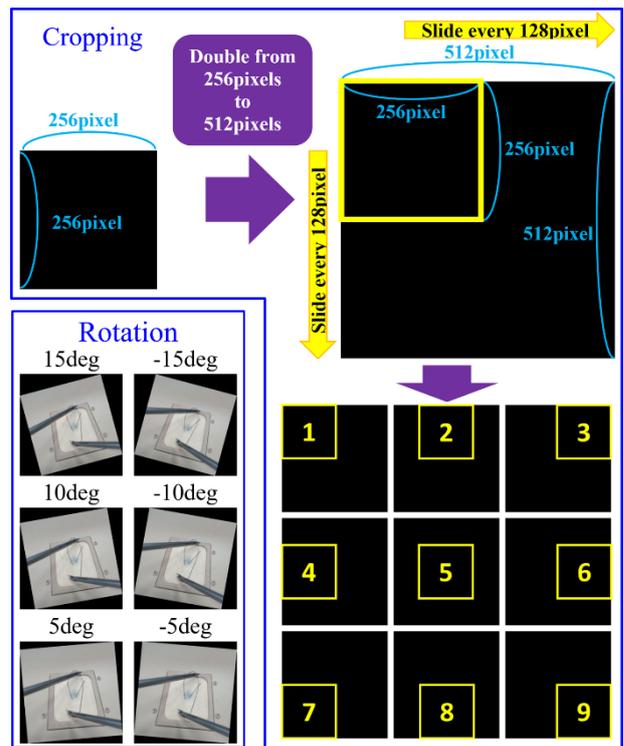
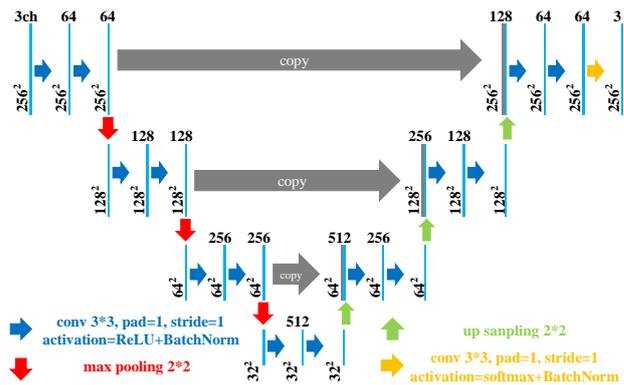


Fig.6 Details of rotation and cropping



				13layer = 12layer + 8layer		
13	conv	3×3	256	1	1	ReLU + Batch Norm
14	conv	3×3	256	1	1	ReLU + Batch Norm
15	up samp	2×2	128	0	2	
				16layer = 15layer + 5layer		
16	conv	3×3	128	1	1	ReLU + Batch Norm
17	conv	3×3	128	1	1	ReLU + Batch Norm
18	up samp	2×2	64	0	2	
				19layer = 18layer + 2layer		
19	conv	3×3	64	1	1	ReLU + Batch Norm
20	conv	3×3	64	1	1	ReLU + Batch Norm
21	conv	3×3	3	1	1	softmax + Batch Norm

(3) 定量的評価指標

モデルの学習状況を評価する指標として loss と呼ばれる指標がある。loss とは、予測と正解の誤差であり、損失関数を用いて計算することが出来る。損失関数には様々な関数が知られているが、本研究では、一般に多クラス分類問題で使用されるソフトマックスクロスエントロピーを使用し、loss を求めた。ソフトマックスクロスエントロピーは以下の(1)式で計算することが出来る。

$$\text{loss} = - \sum_{i=0}^{k-1} t_i \log y_i \quad (1)$$

ただし、 k はクラス数(クラス番号は 0~2)、 t_i は正解データ確率、 y_i は予測確率である。

モデルの精度を評価する定量的評価指標としては様々な評価指標が存在する。一般的に精度を表す指標として Pixel Accuracy が存在する。Pixel Accuracy は以下の(2)式で計算することが出来る。

$$\text{Pixel Accuracy} = \frac{\sum_{i=0}^{k-1} N_{ii}}{\sum_{i=0}^{k-1} \sum_{j=0}^{k-1} N_{ij}} \quad (2)$$

ただし、 k はクラス数(クラス番号は 0~2)、 N_{ij} は正解ラベル番号*i*、予測ラベル番号*j*のピクセル数である。

しかし、Pixel Accuracy は画像全体の画素数に対して、class imbalance(画像中のクラス数に偏りがある)が起きている際に、少ないクラスへの予測誤差の影響が相対的に小さくなってしまい、モデルを正しく評価することが出来ない。本研究では背景(黒色ピクセル)の割合が、糸(赤色ピクセル)や、鉗子(緑色ピクセル)よりも多い為、予測結果画像が黒色一色になっていても、Pixel Accuracy では高い精度を示してしまう。そこで本研究では、クラス平均 IoU(mIoU : mean Intersection over Union)を使用し、モデルを評価する。IoU とは、予測領域(Positive)と正解領域(True)の和領域に対する予測が正解した領域(True positive)の割合(Fig.8)であり、mIoU はクラス毎に算出した IoU の平均

値を計算することで求められ、(3)式で計算することが出来る。

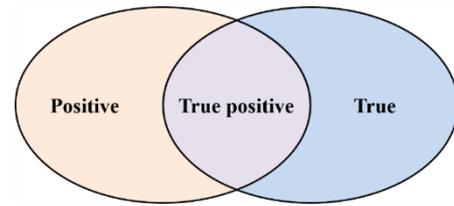


Fig.8 IoU

$$\text{mIoU} = \frac{1}{k} \sum_{i=0}^{k-1} \frac{N_{ii}}{\sum_{j=0}^{k-1} N_{ij} + \sum_{j=0}^{k-1} N_{ji} - N_{ii}} \quad (3)$$

ただし、 k はクラス数(クラス番号は 0~2)、 N_{ij} は正解ラベル番号*i*、予測ラベル番号*j*のピクセル数である。

(4) 学習結果

学習はバッチサイズ 3 のミニバッチ勾配降下法、エポック数 400、全データの 90%(10,449 データ)を学習に、残りの 10%(1161 データ)を検証に使用した。また、勾配降下法の最適化アルゴリズムは Adam を使用した。

Fig.9 に loss を、Fig.10 に mIoU を、Fig.11 に学習したパラメータで予測した予測画像を示す。

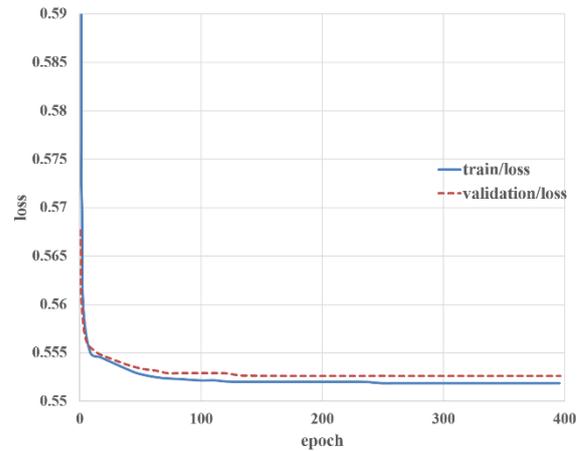


Fig.9 loss

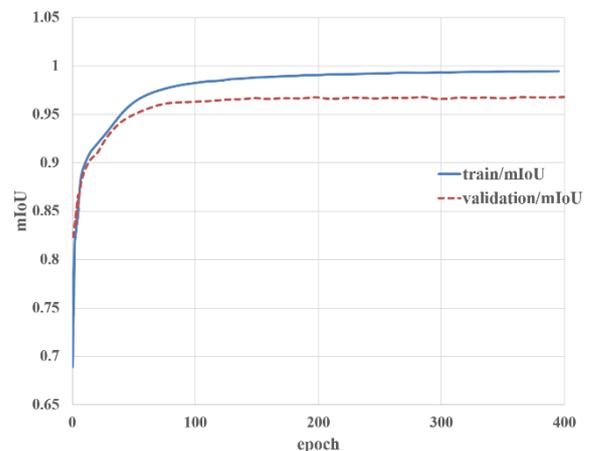


Fig.10 mIoU

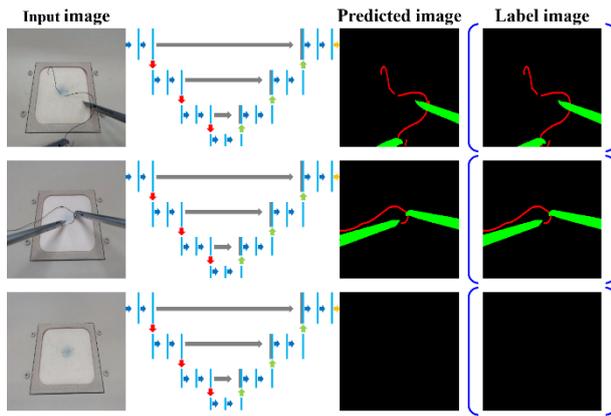


Fig.11 Label image and learning result image

Fig.10 での mIoU は 0.95 以上をマークしており, Fig.11 での予測画像も高い精度で予測が出来ている. また, 文献 [18]では, 自分の身体を制御しているかのような使用感が損なわれず, 作業効率も維持される視覚映像の臨界遅れ時間は 300~350ms であるとしている. 今回の識別プログラムでは, カメラ画像から取得した画像 1 フレームに対して, 識別にかかる時間は平均約 24.6ms であり, 上記の臨界遅れ時間以内であった.

4. 動作識別

(1) 動作分類

本研究では多重結紮を以下の 11 動作に分類し, 動作の識別, ナビゲーションを行った. ①刺入, ②糸の長さ調節 (short tail を作成), ③糸を C 字状にする(第一結紮), ④巻付け(左軸), ⑤糸結び引張, ⑥糸を逆 C 字状にする(第二結紮), ⑦巻付け(右軸), ⑧ ⑤と同様, ⑨ ③と同様(第三結紮), ⑩ ④と同様, ⑪ ⑤と同様

(2) 動作識別

動作識別では, 画面上に様々な形状の領域を設定し, その領域でのピクセル情報から各動作の終了条件を設定した. 各動作の終了条件を次動作の開始条件とし, 動作の開始時点(前動作の終了時点)から終了条件を満たすまでを, 図や文字でナビゲーションを行う区間とした. 具体的なナビゲーションのフローチャートを Fig.12 に示す.

なお, 今回は①刺入動作のナビゲーションは行わないものとする. Fig.13~16 に各動作で設定した領域を, Table3~6 にはその領域での終了条件の閾値を示す.

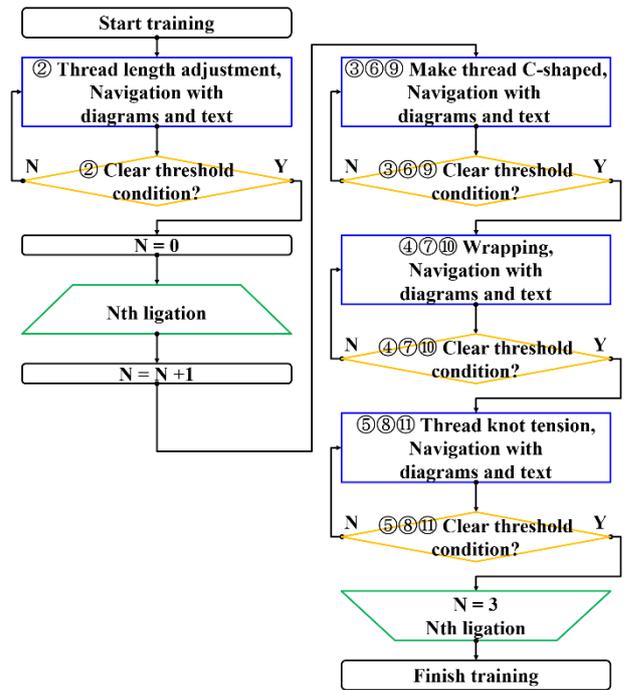


Fig.12 System flowchart

②糸の長さ調節動作で設定した領域を Fig.13, 閾値を Table3 に示す.

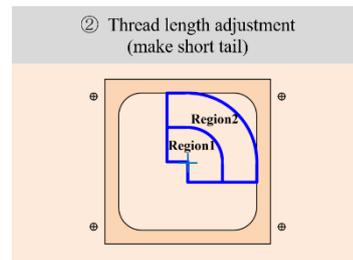


Fig.13 Area in Thread length adjustment (make short tail)

Table3 Threshold of each area in Thread length adjustment (make short tail)

	Region1	Region2
Number of red pixels	Over 400	Under 150

③⑨糸を C 字状にする(第一, 第三結紮), ⑥糸を逆 C 字状にする(第二結紮)動作で設定した領域を Fig.14, 閾値を Table4 に示す.

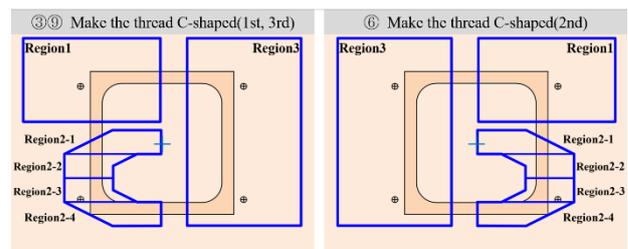


Fig.14 Area in Make thread C-shaped

Table4 Threshold of each area in Make thread C-shaped

	Region1		Region2			Region3
	2-1	2-2	2-3	2-4		
Number of red pixels	Under 400		Over 50			Under 12000
Number of green pixels						

④⑩巻付け(左軸), ⑦巻付け(右軸)動作で設定した領域を Fig.15, 閾値を Table5 に示す.

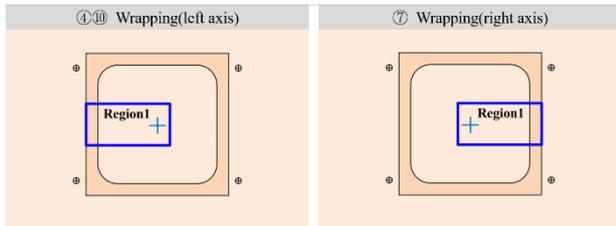


Fig.15 Area in Wrapping (left axis and right axis)

Table5 Threshold of area in Wrapping (left axis and right axis)

	Region1
Number of red pixels	Over 1600 and Under 3000
Number of green pixels	Over 4000

⑤⑧⑩糸結び引張動作で設定した領域を Fig.16, 閾値を Table6 に示す.

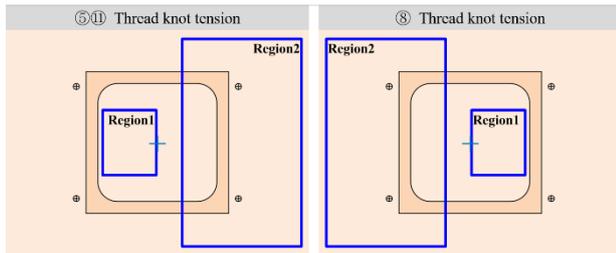


Fig.16 Area in Thread knot tension

Table6 Threshold of each area in Thread knot tension

	Region1	Region2
Number of green pixels	Over 1000	Under 100

5. 検証実験

(1) 実験方法

本トレーニングシステムの有効性を検証するために, Group1(トレーニングシステムを使用するグループ)と Group2(トレーニングシステムを使用しないグループ)の2グループに分け, 検証実験を行った. 検証実験では, 初めに結紮のお手本動画を2回視聴し, 5分間の練習時間を設け, その後10回結紮を行った. 10回の中で1回目と10回目は両グループともトレーニングシステム, 参考書の使用を不可とした. 2~9回目では, Group1は参考書使用不可とし, Group2は参考書のみ使用可とした. 今回の実験では文献[16]を参考書とした. 実験の詳細は Table7 に示す通りである.

Table7 Experiment process

period	1day	
subject	10 people (5 people in each group)	
method	Group1 (Use training system)	Group2 (No training system)
1st	Watch an ideal ligation video(twice) practice(5min) training system× reference book×	Watch an ideal ligation video(twice) practice(5min) training system× reference book×
2nd ~ 9th	training system○ reference book×	training system× reference book○
10th	training system× reference book×	training system× reference book×

(2) 評価項目

評価項目として, 以下の1~3の3つを使用した.

- 各結紮に要する時間
第一結紮, 第二結紮, 第三結紮に要する時間を評価.
- C loop のピクセル数
動作分類で設定した③, ⑥, ⑨を評価. Fig.14 に示す領域 2-1~2-4 に含まれる糸のピクセル数を評価する. トレーニングシステムを使用し, 理想的なCの字が作れている場合は, Fig.14 に示す領域 2-1~2-4 に含まれる糸のピクセル数が多くなる.
- Short tail のピクセル数
動作分類で設定した②, ⑤, ⑧, ⑩を評価. Short tail のピクセル数を評価する. トレーニングシステムを使用し, 理想的な長さの Short tail が出来ている場合は, Short tail の糸のピクセル数が理想値に近くなる.
C loop のピクセル数の理想範囲は 2500pixel 以上, Short tail のピクセル数の理想範囲は 500pixel~1500pixel とし, ピクセル数の計算の際にはカメラからの距離によるピクセル数の変化をキャンセルする為に, 出力されたラベル画像に Zhang-Suen のアルゴリズムでの細線化処理を施した.

(3) 実験結果

Group1 と Group2 の1回目(Before practice 以下 Before)と10回目(After practice 以下 After)の実験結果を Table8, Table9 に示す.

各結紮に要する時間の向上率は(4)式で計算し, どれだけ時間が減少したかを向上率とした.

$$Growth\ rate[Time] = \frac{(Before - After)}{Before} \quad (4)$$

各結紮での C loop のピクセル数の向上率は(5)式で計算し, どれだけピクセル数が増加したかを向上率とした.

$$Growth\ rate[C\ loop] = \frac{(After - Before)}{Before} \quad (5)$$

各結紮での Short tail のピクセル数の向上率は Before と After の前後で理想範囲内にあるかどうかで 3 つに場合分け、(6)~(8)式で計算した。

$$Growth\ rate[Short\ tail] = 1 \quad (6)$$

(Before:理想範囲内 After:理想範囲内)

$$= -\left(\frac{Growth\ rate[Short\ tail]}{|1000 - After| - |1000 - Before|}\right) \quad (7)$$

(Before:理想範囲内 After:理想範囲外)

$$= \frac{Growth\ rate[Short\ tail]}{|1000 - Before| - |1000 - After|} \quad (8)$$

(Before:理想範囲外 After:理想範囲内)
(Before:理想範囲外 After:理想範囲外)

Table8 Experimental results and growth rate (Group1)

		Group1(Use training system)					
		Before practice	After practice	Growth rate	Before practice	After practice	Growth rate
Subject		A			B		
	C loop	201.8	48.8	76%	117.8	33.7	71%
Time[s]	D loop	64.7	52.4	19%	88.6	16.7	81%
	C loop	135.9	51.7	62%	40.5	16.0	60%
	Total	402.4	152.9	62%	246.9	66.4	73%
	C loop [Pixel]	2835	4052	43%	1757	2792	59%
C loop [Pixel]	D loop	1032	3936	281%	1203	3550	195%
	C loop	2366	4004	69%	2177	2278	5%
Short tail [Pixel]	C loop	1743	1653	12%	1307	1536	-43%
	D loop	1669	1091	86%	1393	1459	100%
	C loop	2465	1373	75%	936	1565	-89%
Subject		C			D		
	C loop	193.7	32.6	83%	126.0	86.6	31%
Time[s]	D loop	59.7	56.7	5%	135.5	26.4	81%
	C loop	106.2	39.1	63%	89.8	47.0	48%
	Total	359.6	128.4	64%	351.3	160.0	54%
	C loop [Pixel]	1738	3109	79%	498	3744	652%
C loop [Pixel]	D loop	2320	2919	26%	3295	4445	35%
	C loop	2417	3108	29%	1907	2645	39%
Short tail [Pixel]	C loop	1435	1353	100%	1724	1060	92%
	D loop	1567	1099	83%	1302	928	100%
	C loop	1599	1479	20%	1405	1058	100%
Subject		E					
	C loop	68.7	31.1	55%			
Time[s]	D loop	67.0	33.4	50%			
	C loop	118.1	117.9	0%			
	Total	253.8	182.4	28%			
	C loop [Pixel]	3122	3040	-3%			
C loop [Pixel]	D loop	2079	3705	78%			
	C loop	1122	3887	246%			
Short tail [Pixel]	C loop	2194	1139	88%			
	D loop	2066	871	88%			
	C loop	2742	1874	50%			

Group1, Group2 の Time, C loop, Short tail の向上率に関して、平均値の検定である Welch の t 検定、中央値の検定である Man-Whitney の U 検定の 2 つの検定を片側検定、有意水準 0.05 で行った。Table 10 に検定の結果を示す。

Table9 Experimental results and growth rate (Group2)

		Group2(No training system)					
		Before practice	After practice	Growth rate	Before practice	After practice	Growth rate
Subject		F			G		
	C loop	63.8	84.8	-33%	36.0	35.4	2%
Time[s]	D loop	73.2	65.2	11%	108.4	22.4	79%
	C loop	43.3	39.6	9%	154.4	30.1	81%
	Total	180.3	189.6	-5%	298.8	87.9	71%
	C loop [Pixel]	1108	2086	88%	2451	1980	-19%
C loop [Pixel]	D loop	1396	2084	49%	2541	1399	-45%
	C loop	1215	1734	43%	2058	2118	3%
Short tail [Pixel]	C loop	2812	2577	13%	1553	571	22%
	D loop	2736	2397	20%	1534	915	84%
	C loop	2941	1958	51%	2140	799	82%
Subject		H			I		
	C loop	93.2	50.2	46%	66.4	32.4	51%
Time[s]	D loop	33.5	23.0	31%	94.0	23.0	76%
	C loop	56.3	23.1	59%	44.1	49.0	-11%
	Total	183.0	96.3	47%	204.5	104.4	49%
	C loop [Pixel]	1011	1358	34%	2141	2840	33%
C loop [Pixel]	D loop	806	984	22%	1662	2088	26%
	C loop	1606	145	-91%	4113	2116	-49%
Short tail [Pixel]	C loop	2339	1762	43%	1584	1699	-20%
	D loop	1770	1448	42%	951	1339	100%
	C loop	1744	1670	10%	1837	1788	6%
Subject		J					
	C loop	45.4	21.7	52%			
Time[s]	D loop	21.7	47.7	-120%			
	C loop	46.3	70.0	-51%			
	Total	113.4	139.4	-23%			
	C loop [Pixel]	2124	1680	-21%			
C loop [Pixel]	D loop	979	2285	133%			
	C loop	366	697	90%			
Short tail [Pixel]	C loop	2880	2288	31%			
	D loop	3279	2733	24%			
	C loop	2459	2568	-7%			

Table10 Significant difference test for each Growth rate

	Growth rate [Time]	Growth rate [C loop]	Growth rate [Short tail]
Welch's p	0.008495	0.02079	0.08840
Man-Whitney's p	0.008865	0.01318	0.02486

Growth rate[Short tail]の t 検定以外で有意差が見られた。また、Group1 と Group2 のトレーニング後の C loop と Short tail のデータ比較を行った。Group1 と Group2 のデータがそれぞれ理想範囲内にある確率は、Group1 は 73.3%(11/15)、Group2 は 0.0%(0/15)であった(Fig.17)。

Group1, Group2 のトレーニング後の Time, C loop, Short tail に関して、Welch の t 検定、Man-Whitney の U 検定の 2 つの検定を片側検定、有意水準 0.05 で行った。Table 11 に検定の結果を示す。

Table11 Significant difference test for each evaluation item

10th data	Time	C loop	Short tail
Welch's p	0.2883	0.0000	0.01188
Man-Whitney's p	0.3079	0.0000	0.01836

トレーニング後のデータにおいては Time 以外の項目で有意差が見られた。

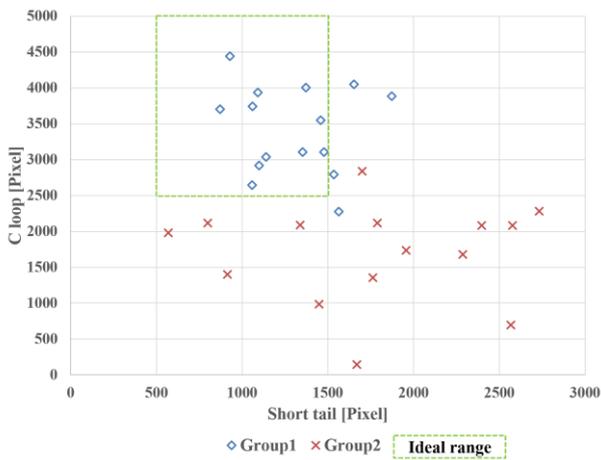


Fig.17 10th C loop and Short tail in Group 1 and Group 2

Table 10 と Table 11 から、本トレーニングシステムを使用することでの結紮所要時間の向上は見られなかった。しかし、適切な鉗子の操作や、糸の動かし方を習得することが可能であると考えられる。

6. 結論及び今後の課題

(1) 結論

本研究では、ディープラーニングの一種であるセマンティックセグメンテーションを用いて鉗子と縫合糸を識別し、さらに、画面上に様々な形状の領域を設定し、その領域でのピクセル情報から結紮動作の識別を行い、識別結果に基づいて訓練者に適切な鉗子操作をナビゲーションする腹腔鏡下手術トレーニングシステムを開発した。検証実験の結果から、本トレーニングシステムを使用することで一定のトレーニング効果を得られることが確認できた。

(2) 今後の課題

鉗子や糸の識別精度や、動作識別での精度などに改善の余地が見受けられた。現在の動作識別とナビゲーションのフローでは、結紮動作中のやり直しを識別することが出来ない。そこで今後は、訓練者が結紮動作中に動作をやり直した際にも、適切な動作ナビゲーションを行えるように改良する必要がある。

謝辞：本研究にあたり、ご指導・ご支援をいただき、指導教員である石井千春教授には深く感謝申し上げます。

参考文献

- 1) 橋爪誠, 小西晃造, 他: 安全な内視鏡外科手術のための基本手技トレーニング, 鍼谷書店, pp.14-15, 2006
- 2) 横山和秀: 患者特異的腹腔鏡下手術シミュレータ, Japanese Journal of Endourology.25:84-88, 2012
- 3) Wignall GR, Denstedt JD, Preminger GM, Cadeddu JA, Pearle MS, Sweet RM, McDougall EM : Surgical Simulation: A Urological Perspective, The Journal of Urology, Vol.179, No.5, pp.1690-1699, May, 2008
- 4) Aggarwal R, Darzi A : From scalpel to simulator: A surgical journey, Surgery, Vol.145, No.1, pp.1-4, Jan, 2009

- 5) Scott DJ, Dunnington GL : The New ACS/APDS Skills Curriculum: Moving the Learning Curve Out of the Operating Room, Journal of Gastrointestinal Surgery, Vol.12, No.2, pp.213-221, Feb, 2008
- 6) Fried GM, Derossis AM, Bothwell J, Sigman HH : Comparison of Laparoscopic Performance In vivo With Performance Measured in A Laparoscopic Simulator, Surgical Endoscopy, Vol.13, No.11, pp.1077-1081, Nov, 1999
- 7) Scott DJ, Bergen PC, Rege RV, Laycock R, Tesfay ST, Valentine RJ, Euhus DM, Jeyarajah DR, Thompson WM, Jones DB : Laparoscopic Training on Bench Models: Better and More Cost Effective than Operating Room Experience?, Journal of the American College of Surgeons, Vol.191, No.3, pp.272-283, Sep, 2000
- 8) Brewin J, Nedas T, Challacombe B, Elhage O, Keisu J, Dasgupta P : Face, content and construct validation of the first virtual reality laparoscopic nephrectomy simulator, BJU international, Vol.106, No.6, pp.850-854, Sep, 2010
- 9) Wijn RP, Persoon MC, Schout BM, Martens EJ, Scherpbier AJ, Hendriks AJ : Virtual Reality Laparoscopic Nephrectomy Simulator Is Lacking in Construct Validity, Journal of Endourology, Vol.24, No.1, pp.117-122, Jan, 2010
- 10) Seymour NE : VR to OR: A review of the Evidence that Virtual Reality Simulation Improves Operating Room Performance, World Journal of Surgery, Vol.32, No.2, pp.182-188, Feb, 2008
- 11) Aggarwal R, Ward J, Balasundaram I, Sains P, Athanasiou T, Darzi A : Proving the effectiveness of virtual reality simulation for training in laparoscopic surgery, Annals of Surgery, Vol.246, No.5, pp.771-779, Nov, 2007
- 12) Grantcharov TP, Kristiansen VB, Bendix J, Bardram L, Rosenberg J, Funch-Jensen P : Randomized clinical trial of virtual reality simulation for laparoscopic skills training, The British Journal of Surgery, Vol.91, No.2, pp.146-150, Feb, 2004
- 13) 山下実, 植村宗則, 他: 内視鏡外科手術における縫合技術評価法の有用性に関する研究, 日本コンピュータ外科学会誌, Vol.17., No.1, pp.15-16, 2015
- 14) C. Ishii, T. Sato, K. Murano and H. Kawamura : Automatic Identification for Laparoscopic Surgical Procedure for Ligation and Online Distinction of Abnormal Manipulation for Thread Knotting, International Journal of Clinical Medicine, pp.887-898, 2015
- 15) 建部陸, 石井千春: 腹腔鏡下手術トレーニングシステムの構築—初心者のための視覚的アシストを用いた理想動作のトレース—, ロボティクス・メカトロニクス講演会講演論文集, 1P1-E04, 2018
- 16) 橋爪誠, 小西晃造, 他: 安全な内視鏡外科手術のための基本手技トレーニング, 鍼谷書店, pp.101,105, 2006
- 17) Ronneberger O, Fischer P, Brox T : U-Net: Convolutional Networks for Biomedical Image Segmentation, MICCAI, Springer, LNCS Vol.9351, pp.234-241, 2015
- 18) 神谷聖那, 葭田貴子: 遅延した自己身体像や視野映像が自己のものとして感じられなくなる臨界遅れ時間, 日本視覚学会学会誌「VISION」, Vol.26, No.3, pp.122-126, 2014