



張 路陽  
ちょう ろよう

 1994/07/03

名古屋大学大学院  
情報学研究科 研究員



080-3358-2606



[dhu\\_zly@outlook.com](mailto:dhu_zly@outlook.com)



<https://github.com/lzhang30/>



<https://mypage.lzhang.click/>



## プロジェクト

### 自動診断システムの開発

半教師あり・弱教師あり学習CV解析

- CT・内視鏡ビデオ解析 脳波解析

マルチモーダルLLMの開発

- を用いたCT画像の診断レポートの自動生成

### ドローンアルゴリズム開発

- ビデオから3D再構成
- ターゲットの検出と追跡



## スキルシート



### プログラミング

- ✓ **Python:** 機械学習モデル開発、データ処理、API開発、デプロイ
- ✓ **C++:** モデル最適化、TensorRT、ONNXランタイム統合、アルゴリズム実装



### クラウド・システム開発

- ✓ **AWS:** AWS MLS資格取得、SageMaker, S3 等を活用した機械学習パイプライン構築・運用知識あり
- ✓ **Linux:** UbuntuとROSでの実務の開発経験あり
- ✓ **Docker:** コンテナを利用した開発・デプロイ環境の構築・管理経験あり

## 学歴

- 2025/03 ● 名古屋大学 知能システム学専攻  
博士 学位取得
- 2023/04 ● 復学
- 2022/04 ● 休学
- 2020/03 ● 名古屋大学 情報・通信学専攻  
修士 学位取得
- 2018/04 ● 名古屋大学 情報・通信学専攻  
修士課程 進学
- 2017/04 ● 名古屋大学 情報・通信学専攻  
研究生 進学
- 2016/10 ● 千駄ヶ谷日本語学校 進学
- 2016/08 ● DongHua University 情報学  
学士 学位取得

## 職歴

- 現在 ● 名古屋大学 研究員
- 2025/03 ● エルピクセル株式会社
- 2024/12 ● 機器学習エンジニア
- 2023/02 ● Tianjin Artificial Intelligence  
Innovation Center (TAIIC)
- 2022/07 ● AIEエンジニア

## 資格

- ✓ 2024/12: JLPT-N1 [Link](#)
- ✓ 2024/11: AWS Certified Machine Learning Specialty  
Certification [Link](#)
- ✓ 2021/11: Google Data Analytics [Link](#)
- ✓ 2021/10: 基本情報技術者試験 (FE) 合格

## 受賞

COVID-19 Lung CT Lesion Segmentation Challenge  
(2022) 最終評価 世界ランキング **6位**

博士時代の研究

# 低アノテーションコストの医用画像分割モデルの 訓練アプローチ

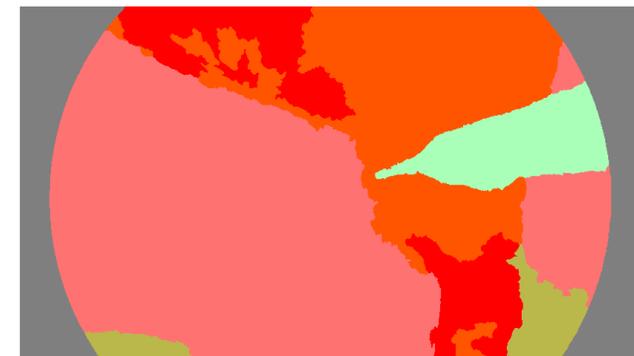
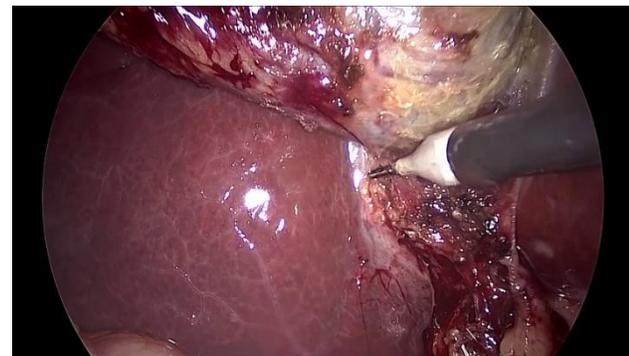
張 路陽<sup>1</sup>

<sup>1</sup>)名古屋大学大学院情報学研究科 森研究室

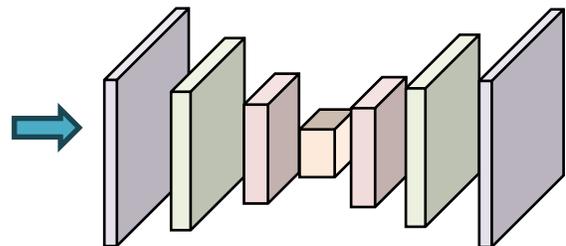
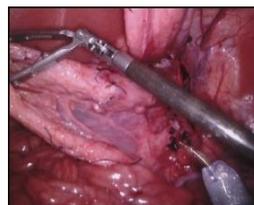
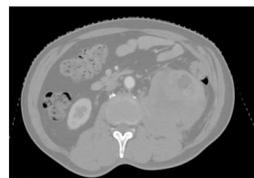
# 医療画像の自動セグメンテーション

問題点：

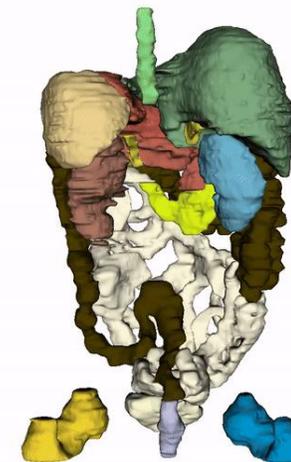
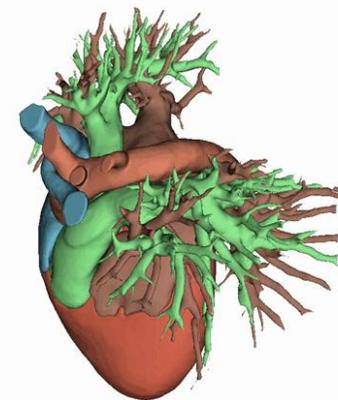
- 大量のアノテーションデータの作成が必要
- メディカル画像枚数の増加に伴ってアノテーション作成のコストが増大
- **低コストアノテーション**で**高精度**のセグメンテーションモデルを訓練するのが必要



内視鏡ビデオ画像から臓器とツールのセグメンテーション



Deep learning-based segmentation



CTから臓器のセグメンテーション, 心臓(左) 腹部臓器(右)

# Sub task 1 : 内視鏡ビデオ画像から臓器とツールのセグメンテーション

**Towards better laparoscopic video segmentation: A Class-Wise Contrastive Learning Approach with Multi-Scale Feature Extraction.** Healthcare Technology Letters 11.2-3:126-136 (2024)

# Low-cost annotation

## ビデオ画像に対する解決策

アノテーションコストが低くラベルを適用

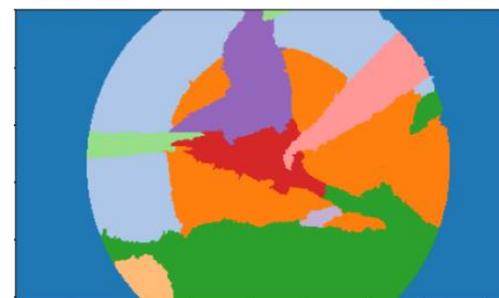


### 動機：

少数のPixel-Level アノテーションと  
多数のClass-Level アノテーションを  
用いて、セグメンテーションモデルを訓練



アノテーションコストを削減



Pixel-Level アノテーション

**ツールと臓器：**“背景”、“腹壁”、“肝臓”、“脂肪”、“鉗子”、“胆嚢”、“フック”  
**手術段階：**“胆嚢の分離”

Class-Level アノテーション

Annotation cost

High



Low



Annotation information

Complete



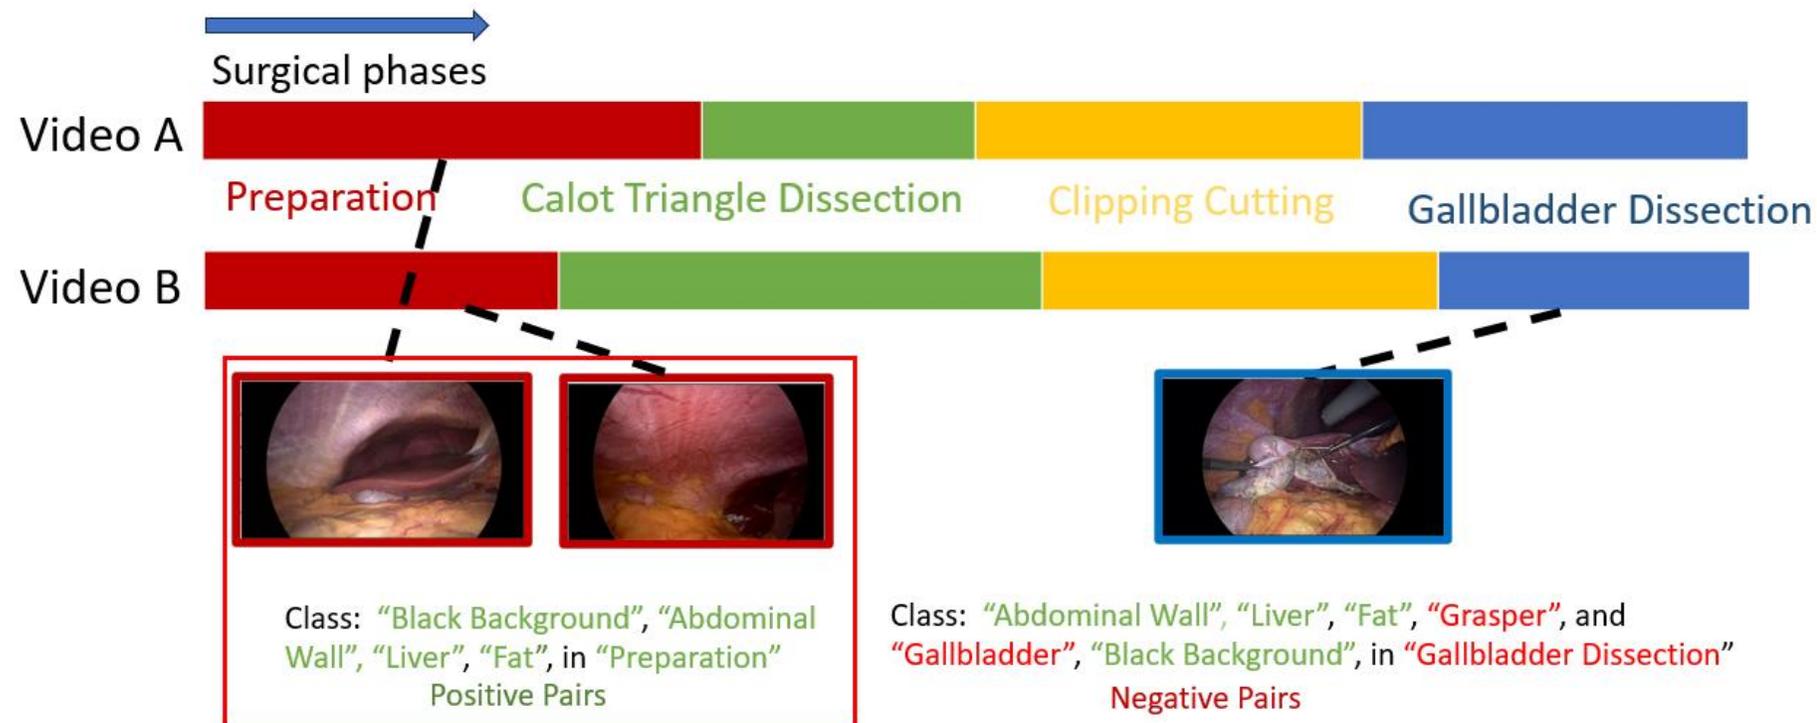
Incomplete



# 提案 : Positive pairs definition

A novel positive pairs definition method in Laparoscopic image segmentation task

- Images containing the same category are similar.
- Images captured at the **same surgical stage**, with the **same tools and organs**, are set as **positive pairs**.



# 提案手法

## Segmentation task

Pixel-Level アノテーションあり画像に対して、セグメンテーション損失を算出

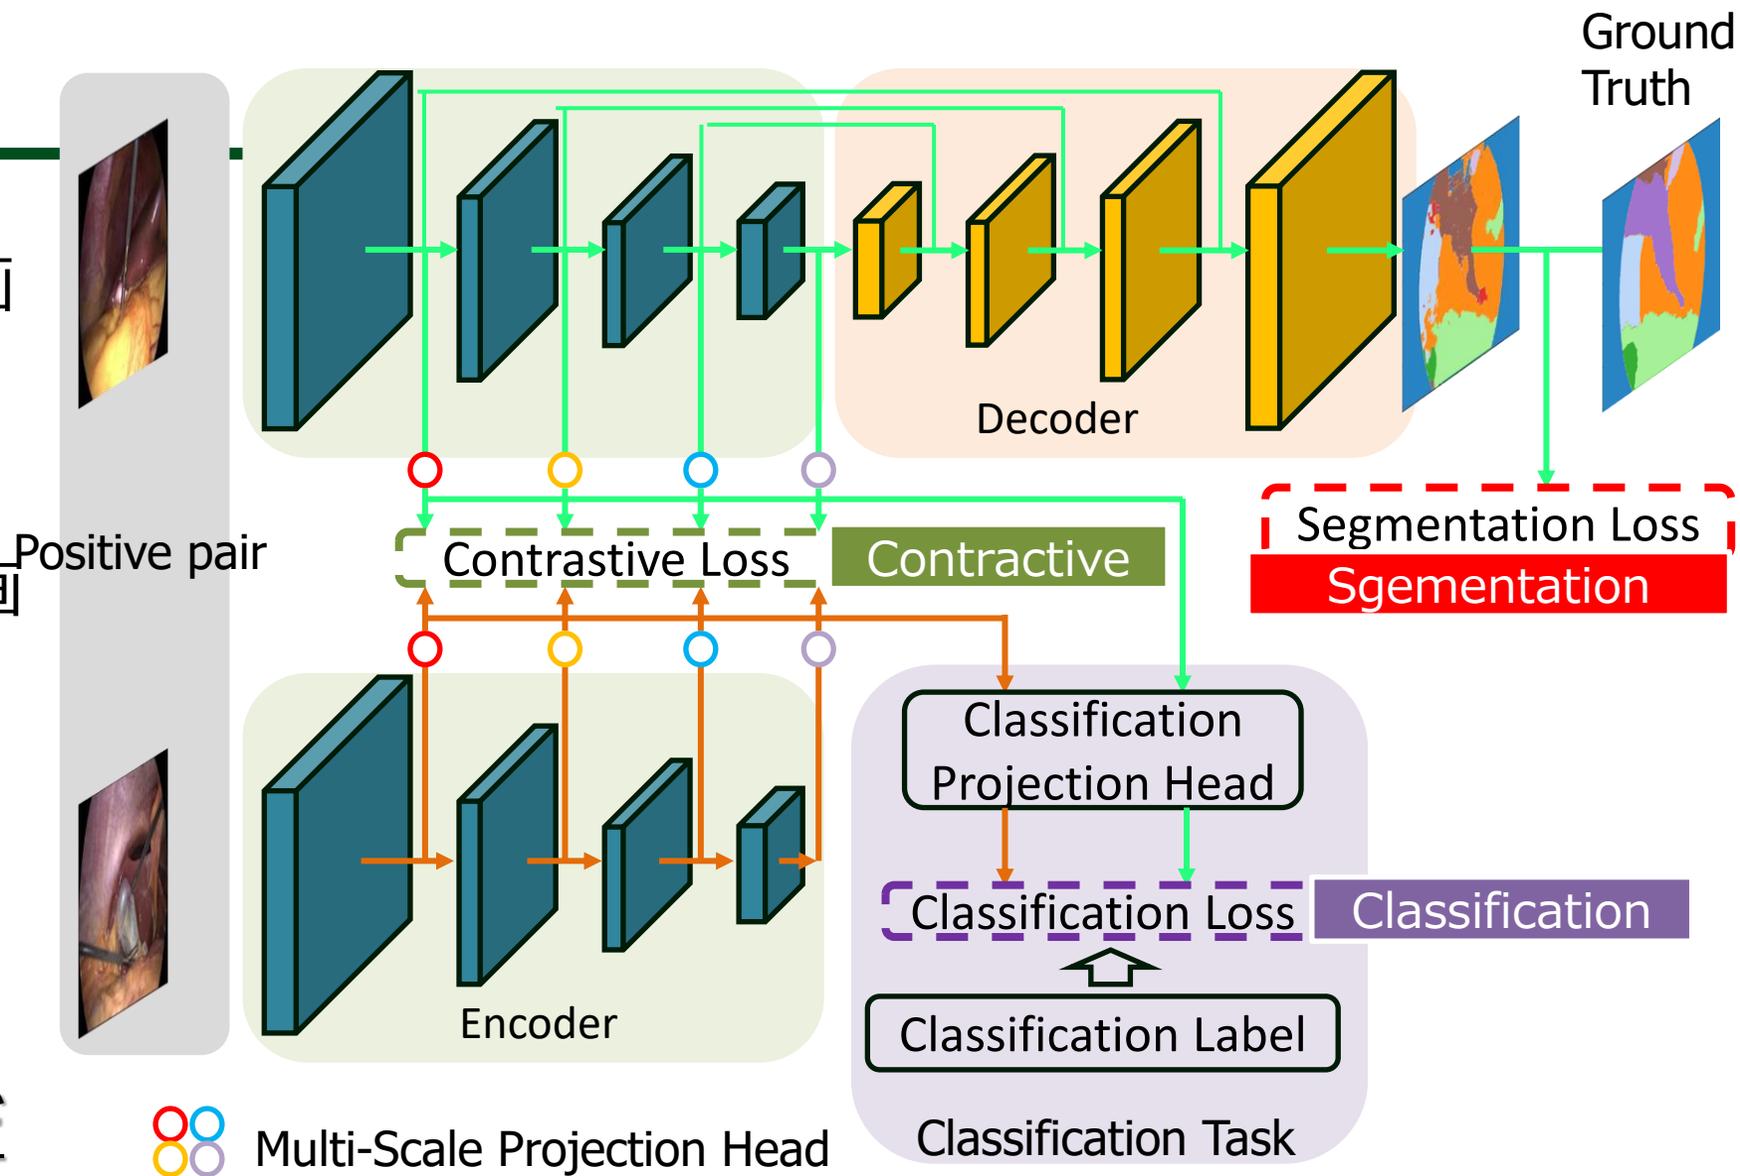
## Classification task

Pixel-Level アノテーションなし画像に対して、分類損失を算出

## Contrastive learning task

正例間からMSPHで抽出した特徴の対照損失を算出

セグメンテーション損失、分類損失、対照損失の加算をモデルの損失と設定



# Experiment result (IOU)

The performance of the proposed methods outperforms related methods, especially in improving segmentation accuracy for **small targets**.

	Pixel labeled Samples	Background	Abdominal Wall	Liver	Fat	Grasper	Connective Tissue	L-hook Electrocautery	Gallbladder
<b>U-Net [1]</b>	1%	0.953 ± 0.004	0.519 ± 0.009	0.442 ± 0.036	0.761 ± 0.005	0.157 ± 0.006	0.007 ± 0.009	0.132 ± 0.005	0.241 ± 0.021
	5%	0.926 ± 0.034	<u>0.664 ± 0.052</u>	0.501 ± 0.045	0.796 ± 0.024	<u>0.326 ± 0.112</u>	0.265 ± 0.063	0.310 ± 0.123	0.360 ± 0.078
	10%	0.941 ± 0.008	0.612 ± 0.034	0.461 ± 0.023	0.767 ± 0.004	0.226 ± 0.042	0.091 ± 0.120	0.187 ± 0.132	0.335 ± 0.038
<b>SimCLR [2]</b>	1%	0.905 ± 0.012	0.482 ± 0.007	0.431 ± 0.023	0.742 ± 0.004	0.188 ± 0.030	0.040 ± 0.027	<u>0.200 ± 0.057</u>	0.210 ± 0.016
	5%	0.901 ± 0.008	0.558 ± 0.018	0.464 ± 0.023	0.762 ± 0.013	0.303 ± 0.014	0.009 ± 0.006	0.328 ± 0.017	0.324 ± 0.012
	10%	0.932 ± 0.002	0.633 ± 0.015	0.403 ± 0.008	0.780 ± 0.005	0.311 ± 0.030	0.342 ± 0.061	0.401 ± 0.008	0.393 ± 0.027
<b>Ours DCL</b>	1%	0.952 ± 0.005	0.542 ± 0.048	<u>0.519 ± 0.017</u>	0.755 ± 0.000	0.154 ± 0.020	<u>0.096 ± 0.071</u>	0.128 ± 0.148	0.252 ± 0.019
	5%	<u>0.953 ± 0.003</u>	0.606 ± 0.066	<u>0.505 ± 0.038</u>	0.797 ± 0.018	0.300 ± 0.092	0.246 ± 0.139	0.264 ± 0.188	<u>0.374 ± 0.111</u>
	10%	0.936 ± 0.004	0.631 ± 0.024	0.484 ± 0.007	0.792 ± 0.008	0.310 ± 0.059	0.305 ± 0.098	<b>0.420 ± 0.059</b>	0.421 ± 0.033
<b>Ours cls</b>	1%	<u>0.955 ± 0.000</u>	0.534 ± 0.034	0.494 ± 0.019	<u>0.773 ± 0.016</u>	<u>0.192 ± 0.004</u>	0.053 ± 0.047	0.001 ± 0.001	0.262 ± 0.028
	5%	0.925 ± 0.013	0.576 ± 0.057	0.444 ± 0.014	0.775 ± 0.022	0.245 ± 0.089	0.182 ± 0.079	<u>0.356 ± 0.092</u>	0.320 ± 0.076
	10%	0.945 ± 0.005	<b>0.657 ± 0.025</b>	0.485 ± 0.016	<b>0.796 ± 0.019</b>	0.341 ± 0.031	0.400 ± 0.133	0.417 ± 0.064	<b>0.458 ± 0.023</b>
<b>Ours DCL+cls</b>	1%	0.952 ± 0.006	<u>0.614 ± 0.034</u>	0.498 ± 0.019	0.762 ± 0.005	0.178 ± 0.005	0.060 ± 0.035	0.137 ± 0.019	<u>0.287 ± 0.017</u>
	5%	0.944 ± 0.012	0.624 ± 0.023	0.438 ± 0.035	<u>0.798 ± 0.004</u>	0.296 ± 0.070	<u>0.336 ± 0.031</u>	0.338 ± 0.046	0.365 ± 0.027
	10%	<b>0.948 ± 0.013</b>	0.638 ± 0.019	<b>0.485 ± 0.008</b>	0.791 ± 0.009	<b>0.407 ± 0.016</b>	<b>0.404 ± 0.042</b>	0.405 ± 0.032	0.447 ± 0.030

# Sub task 2 : 内視鏡ビデオ画像から臓器とツールのセグメンテーション

[Double-Mix Pseudo-Label Framework: Enhancing Semi-Supervised Segmentation on Category-Imbalanced CT Volumes.](#) International Journal of Computer Assisted Radiology and Surgery

# 低コストのアノテーション

## 解決策

アノテーションなしのデータを活用

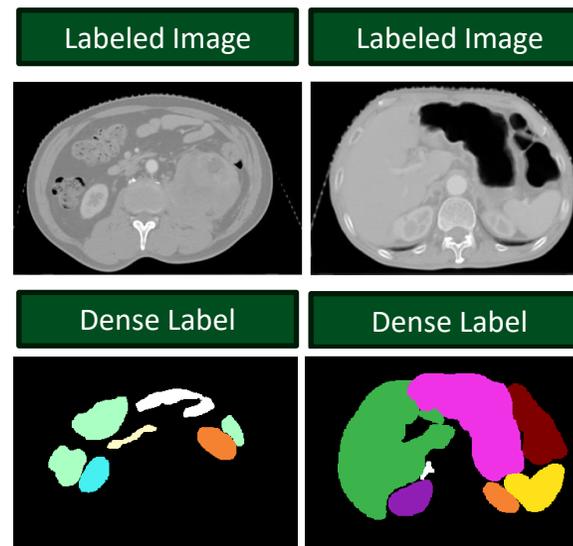
## 動機：

少数の**アノテーション付けたデータ**と  
多数の**アノテーションなしのデータ**を  
用いて、セグメンテーションモデルを訓練



## アノテーションコストを削減

### Fully-Supervised Segmentation

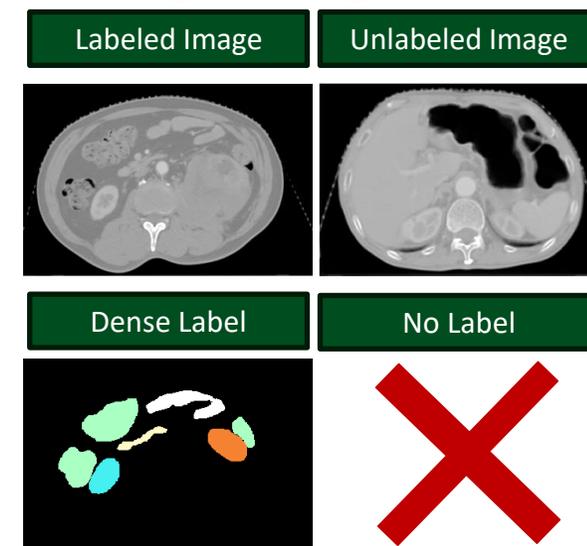


Annotation cost

High



### Semi-Supervised Segmentation



Low



Annotation information

Complete



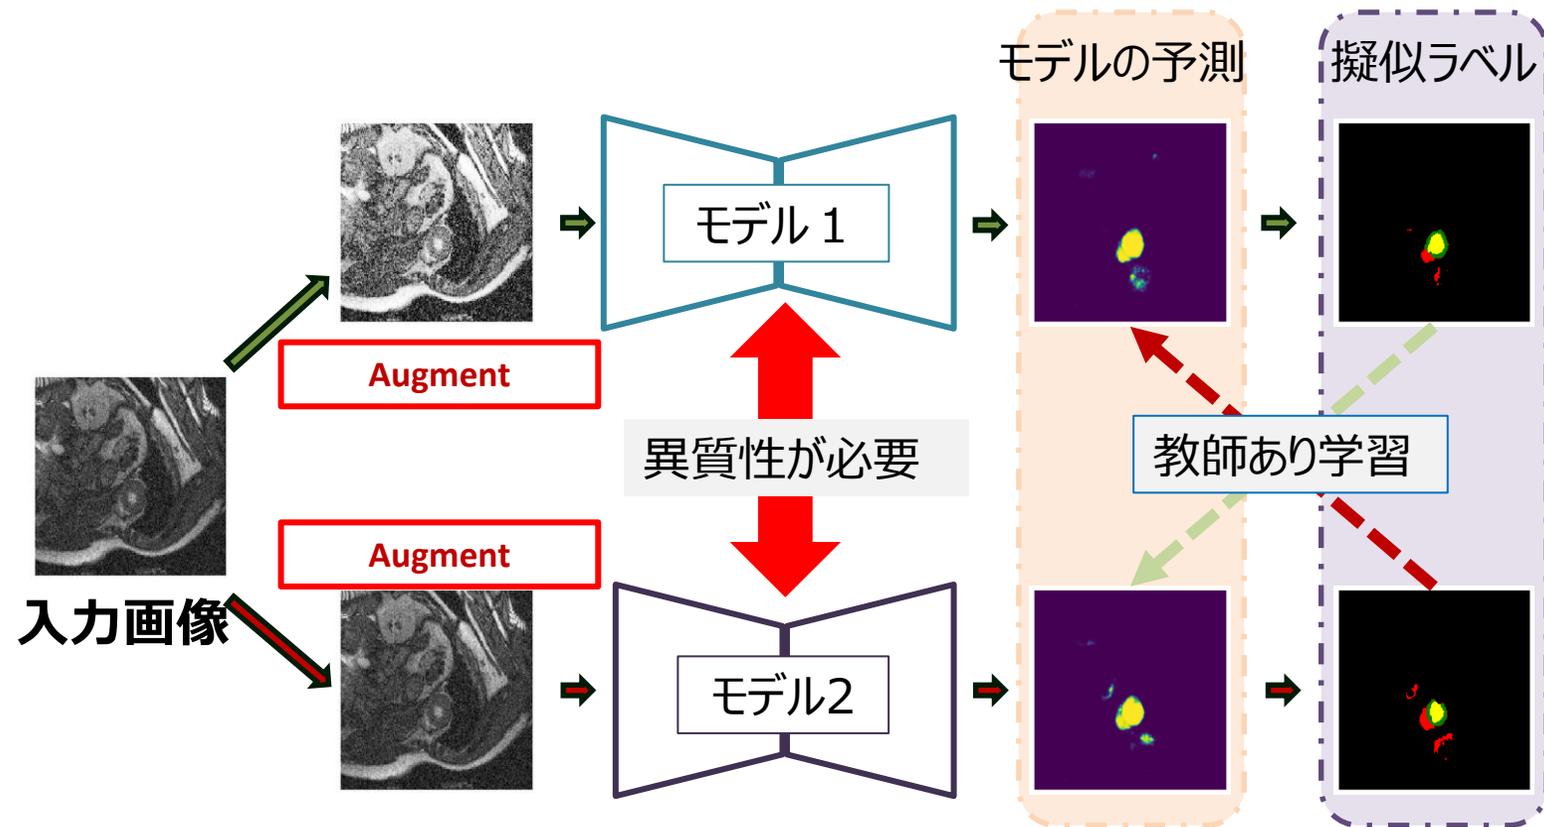
Incomplete



異なるモデルからの疑似ラベルを用いた**Cross Pseudo Supervision (CPS)**を活用

# Cross Pseudo Supervision (CPS)

- 2つの異なるネットワークが**同じ画像の異なる拡張**に対して予測を行い、**擬似ラベル**を生成
- 一方の擬似ラベルで他方の教師データとしてモデルを訓練
- Cross Pseudo(クロス擬似)**でラベルなしのケースでも使用可能
- モデル間の**異質性**が増すにつれて、精度が向上[1]



Strong Augmented Sample Process

Weakly Augmented Sample Process

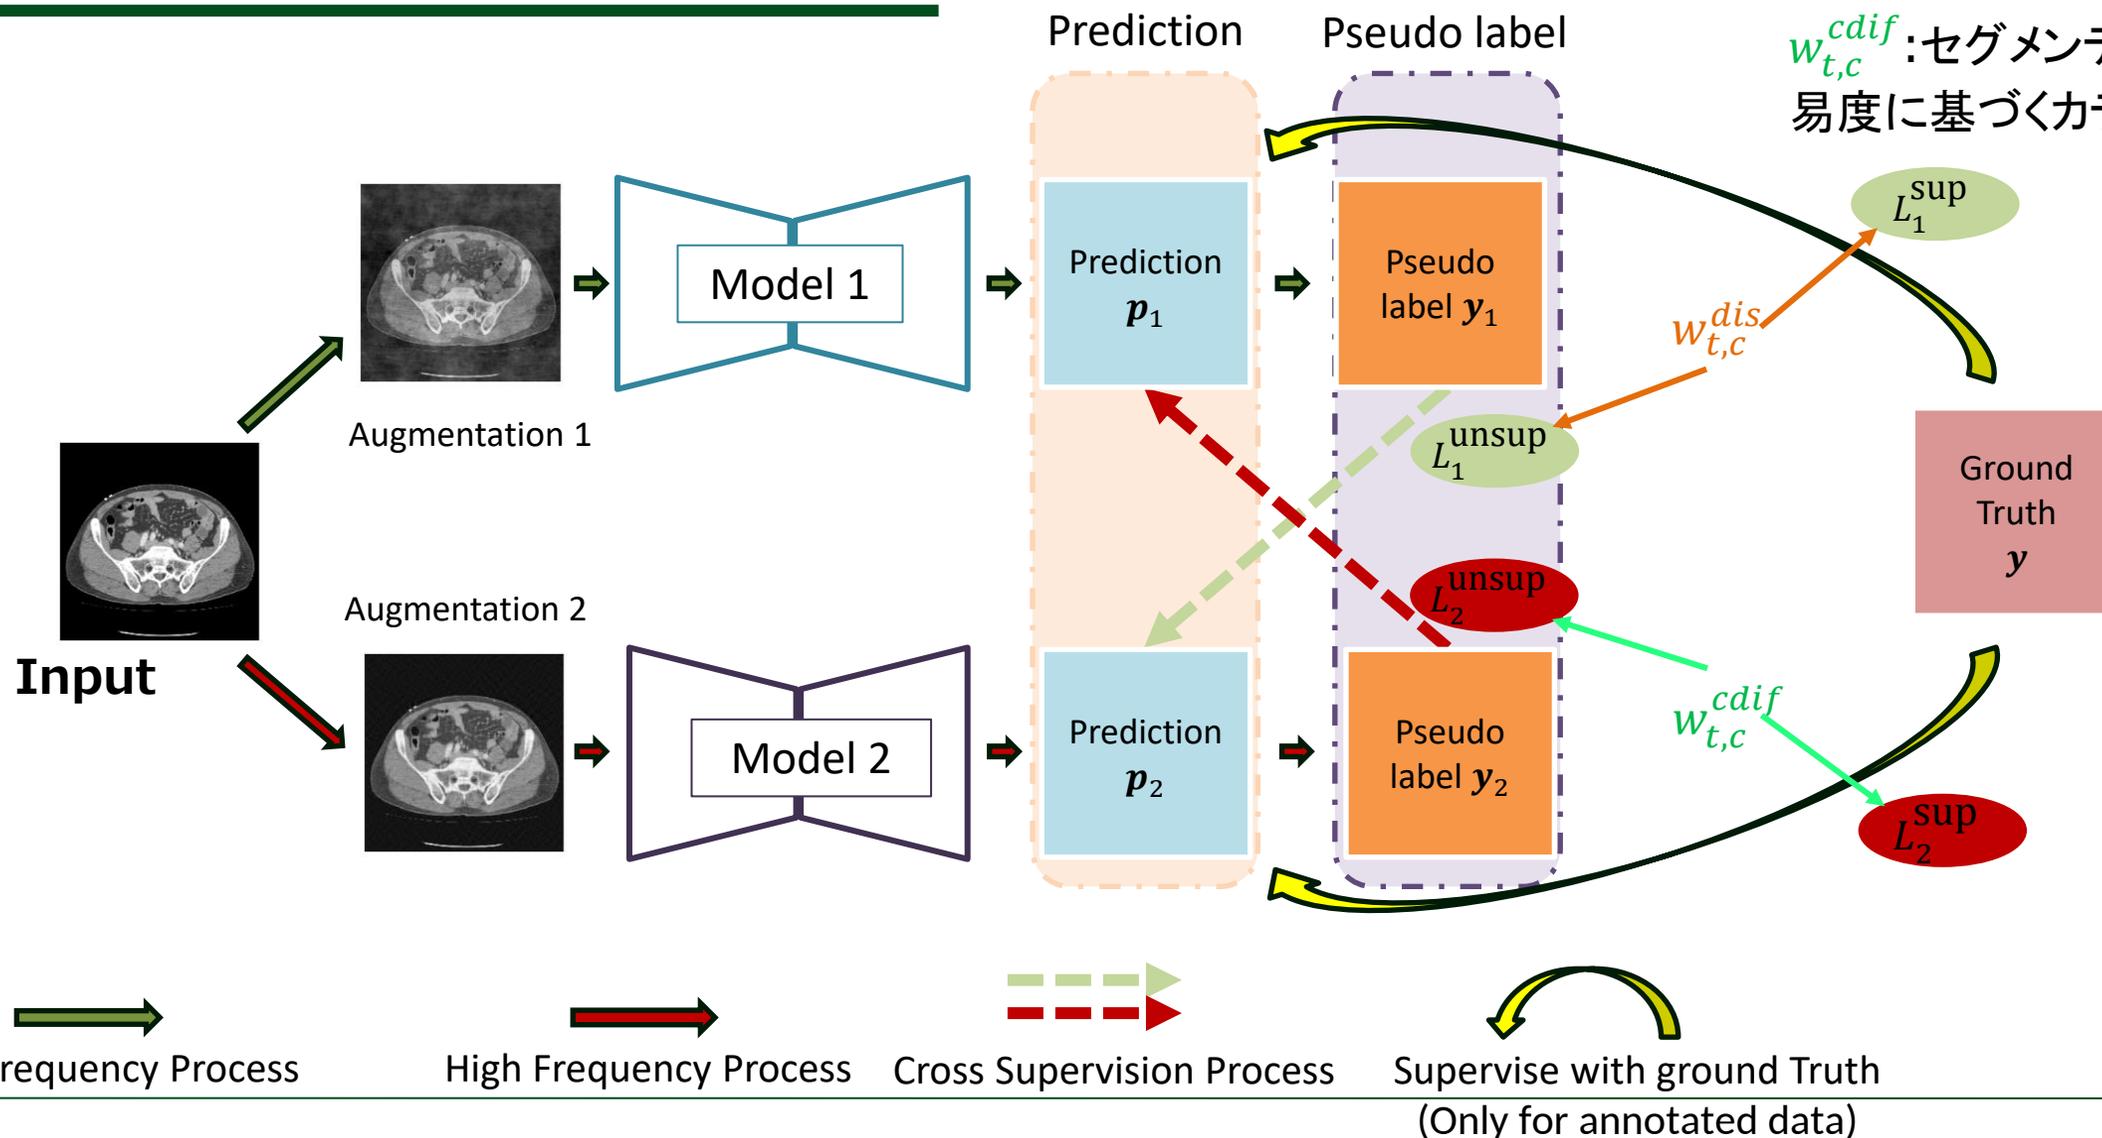
Cross Supervision Process

[1] Krogh A, and Jesper V. Neural network ensembles, cross validation, and active learning. NIPS 1994:7

# 異なる重みで異なるモデルを訓練、異質性を向上

$w_{t,c}^{dis}$ : サンプル数に基づくカテゴリ重み

$w_{t,c}^{cdif}$ : セグメンテーションの難易度に基づくカテゴリ重み



$w_{t,c}^{dis}$  (orange arrow) points to  $L_1^{sup}$  (green oval)

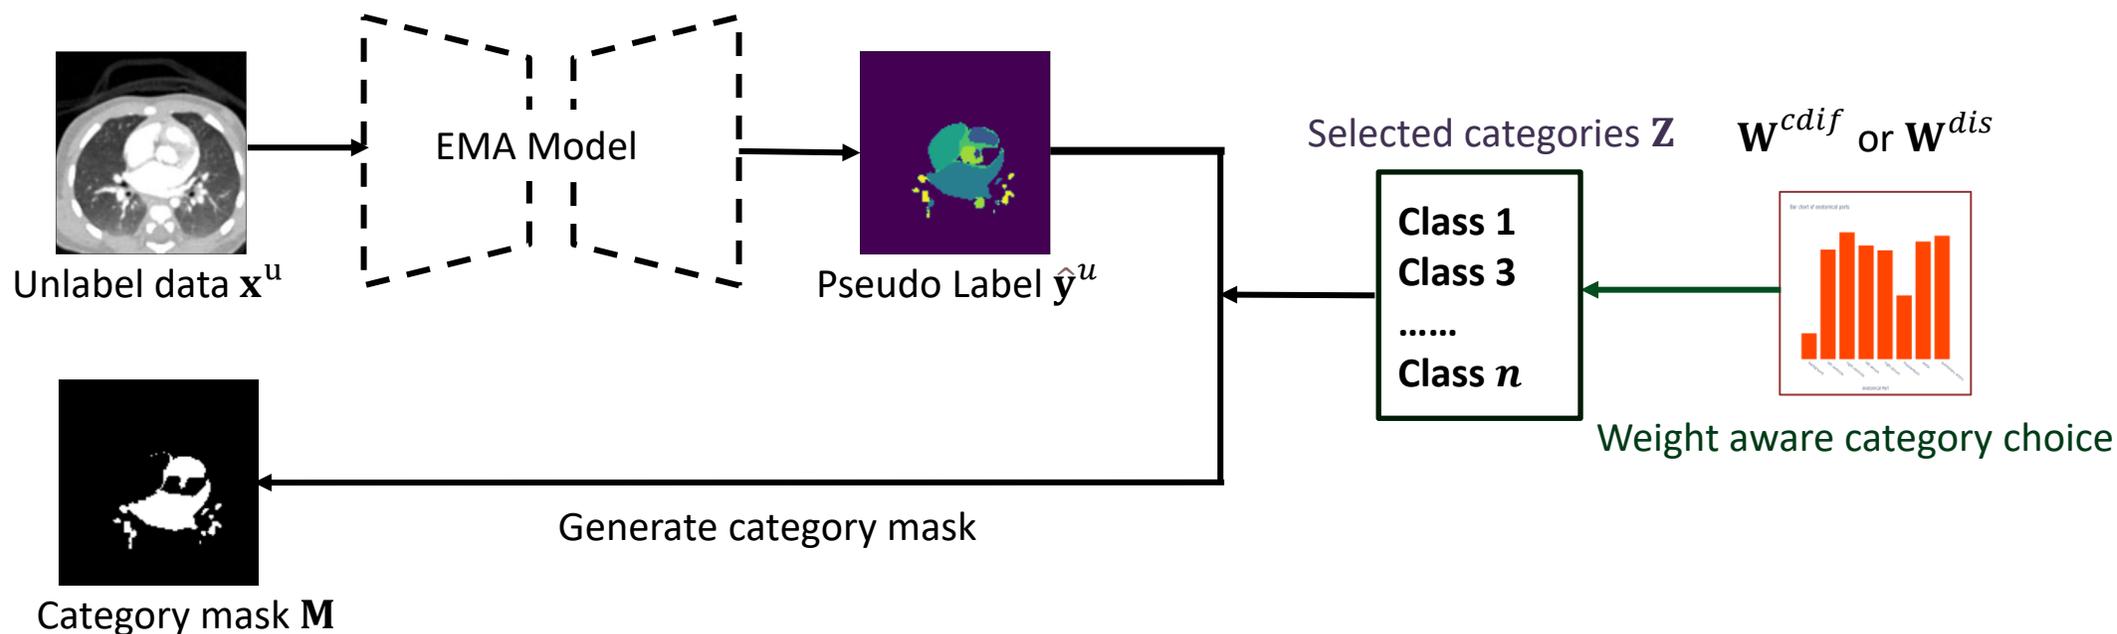
$w_{t,c}^{cdif}$  (green arrow) points to  $L_2^{sup}$  (red oval)

$L_1^{unsup}$  (green oval) and  $L_2^{unsup}$  (red oval) are connected by a dashed green arrow representing cross-supervision.

# 高難易度カテゴリに特化した画像拡張

## Propose: Double-Mix Pseudo Label (DMP)

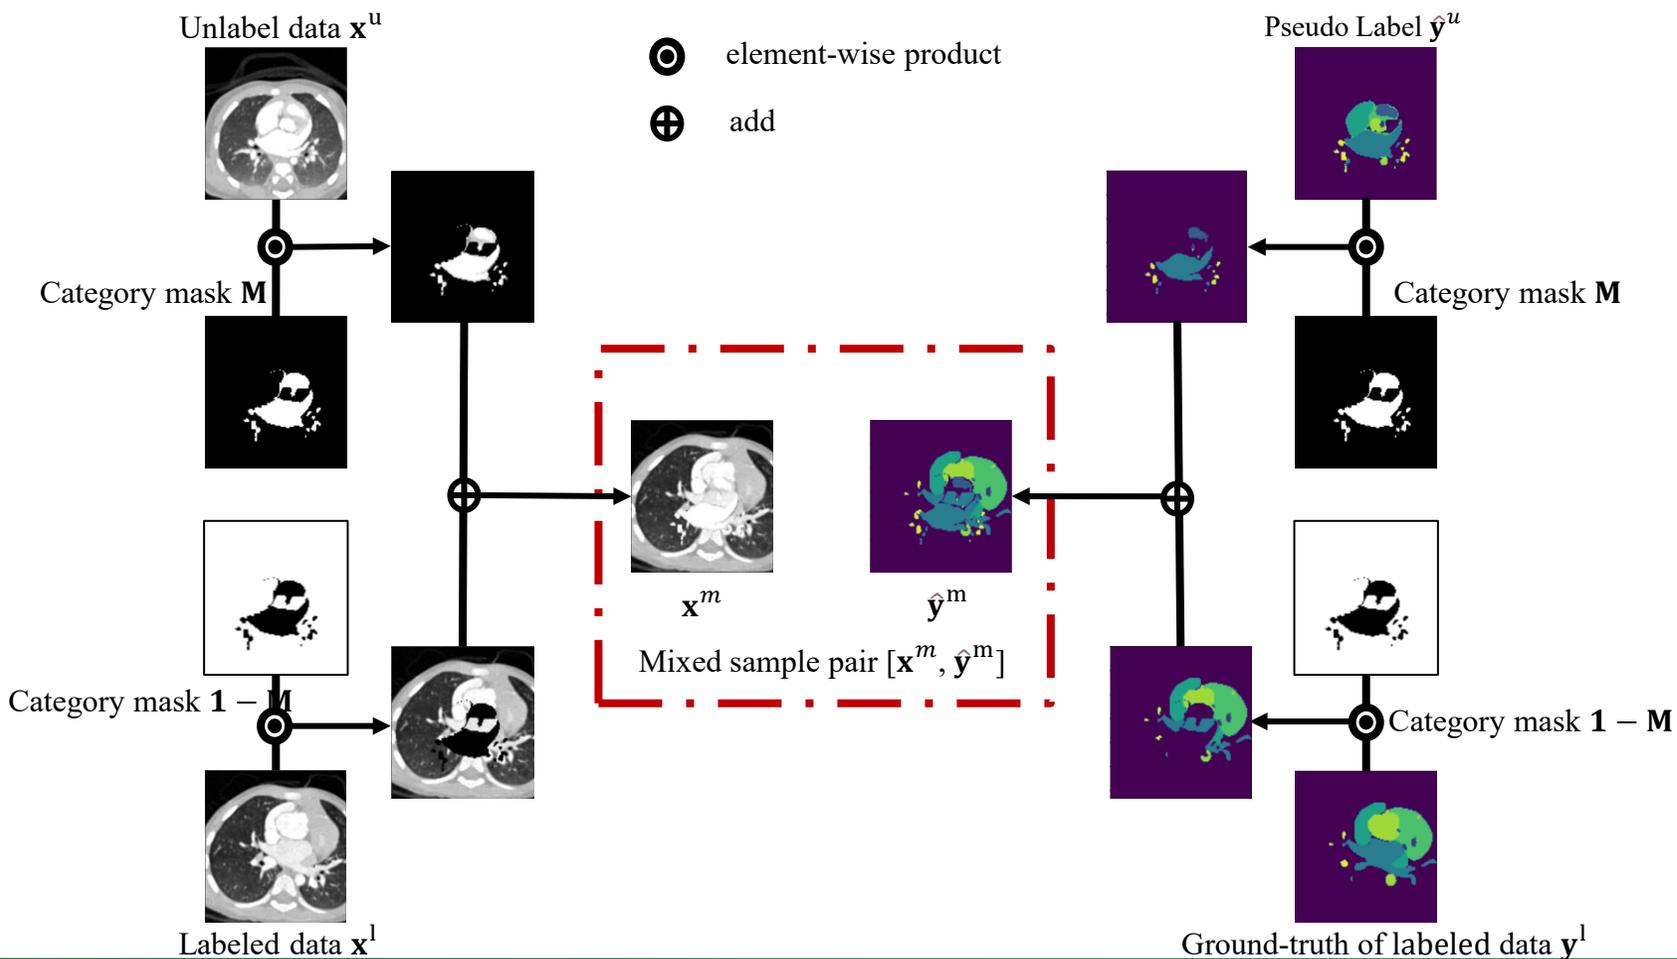
Generate category mask  $\mathbf{M}$  by selected categories  $\mathbf{Z}$  and pseudo label  $\hat{\mathbf{y}}^u$



# 高難易度カテゴリに特化した画像拡張

Generate mixed sample pair  $[\mathbf{x}^m, \hat{\mathbf{y}}^m]$

## Propose: Double-Mix Pseudo Label (DMP)



Unlabeled data  $\mathbf{x}^u$   
 Pseudo label  $\hat{\mathbf{y}}^u$   
 Labeled data  $\mathbf{x}^l$   
 Ground truth  $\mathbf{y}^l$

$$\mathbf{x}^m = \mathbf{x}^u \odot \mathbf{M} + \mathbf{x}^l \odot (1 - \mathbf{M})$$

$$\hat{\mathbf{y}}^m = \hat{\mathbf{y}}^u \odot \mathbf{M} + \mathbf{y}^l \odot (1 - \mathbf{M})$$



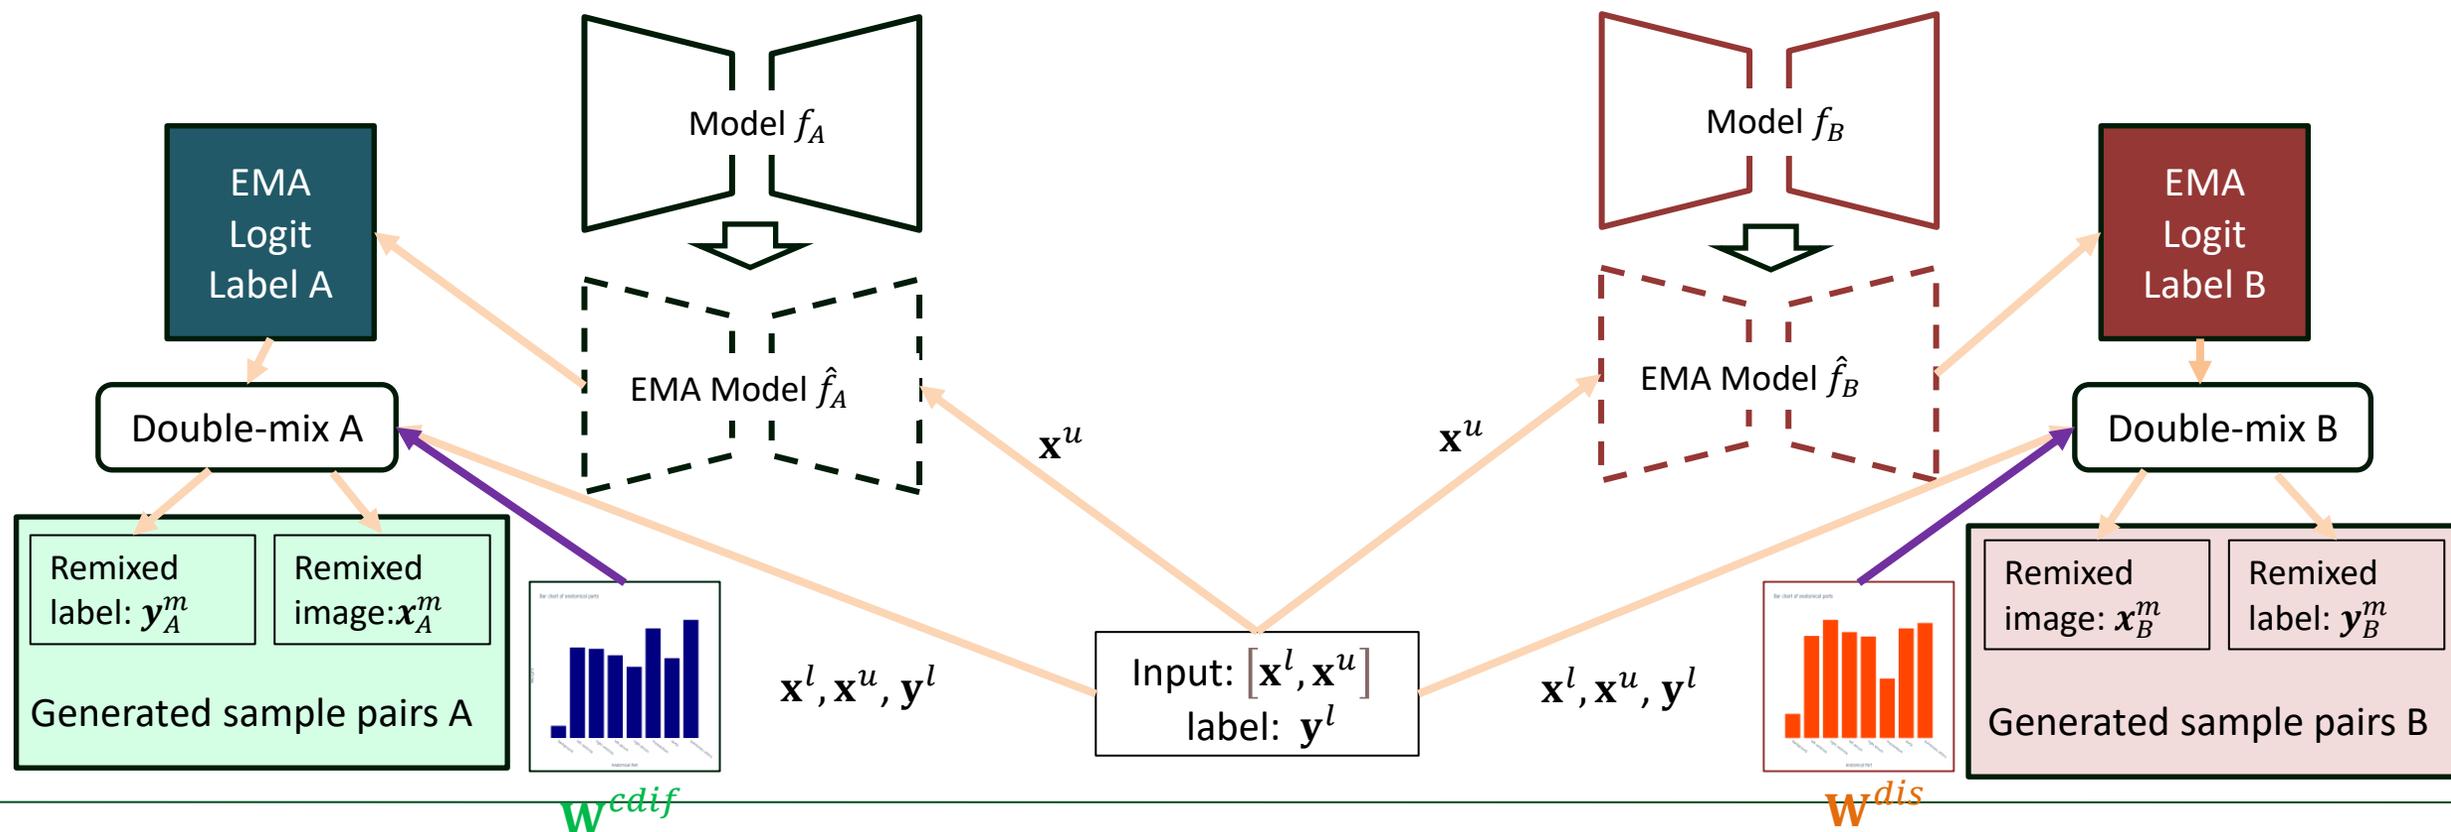
Mixed sample pair  $[\mathbf{x}^m, \hat{\mathbf{y}}^m]$

# Different image augmentations

## Propose: Double-Mix Pseudo-label (DMP)

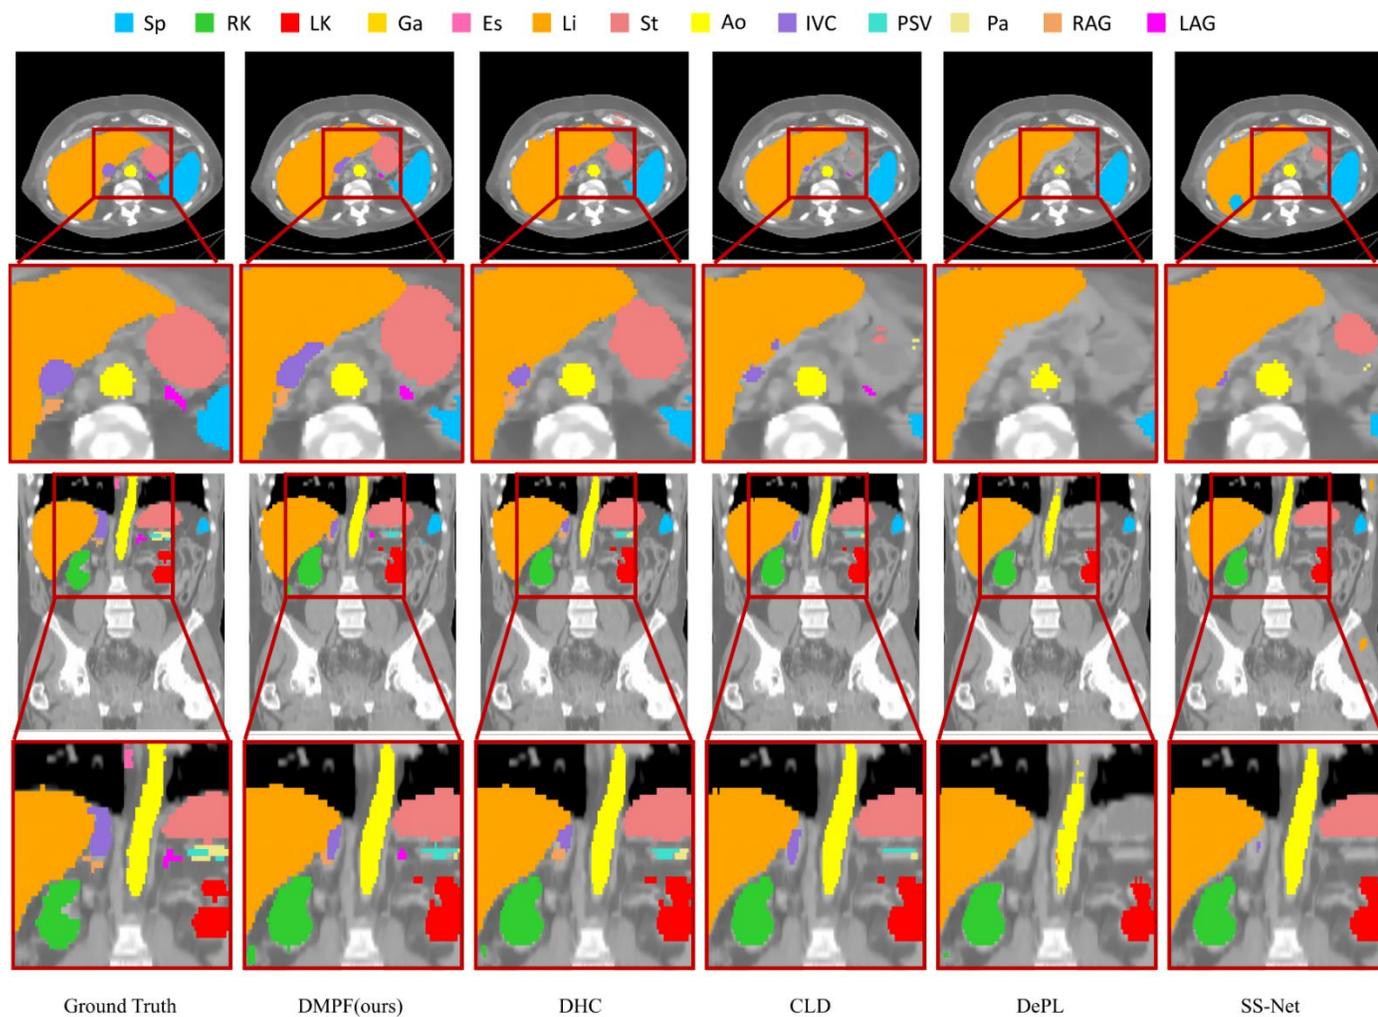
$f_A, f_B$ : Segmentation models  
 $\hat{f}_A, \hat{f}_B$ : EMA models of  $f_A, f_B$

Generate mixed sample pairs  $[y_A^m, x_A^m]$  and  $[y_B^m, x_B^m]$  based on  $W^{cdif}$  and  $W^{dis}$



# 結果

Method	Average Dice	ASD
SS-Net	49.7	7.9
DST	62.3	5.6
Depl	63.6	<b>5.1</b>
CPS	62.0	<u>5.5</u>
CReST	61.5	6.4
CLD	62.4	5.9
DHC	64.1	6.7
Ours w/o DMP	<u>64.3</u>	6.0
Ours	<b>66.5</b>	6.0



Ground Truth

DMPF(ours)

DHC

CLD

DePL

SS-Net

# Sub task 3 : 半教師ありScribbleアノテーションを用いたセグメンテーションモデルのトレーニング

[Cross-Neighbor-Information based Pseudo-Label for Better Semi-Scribble-Supervised Medical Image Segmentation.](#)

International Journal of Computer Assisted Radiology and Surgery

# Semi-scribble supervised medical image segmentation

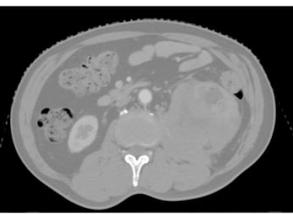
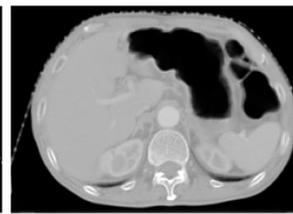
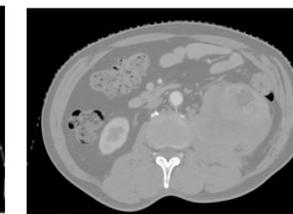
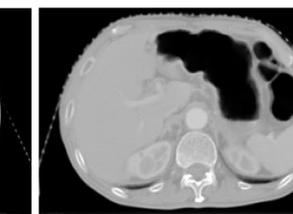
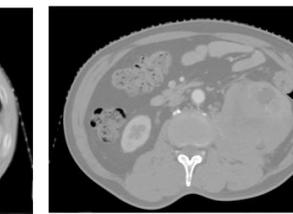
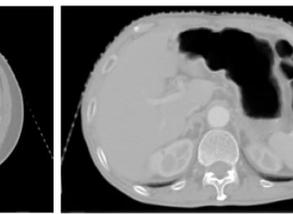
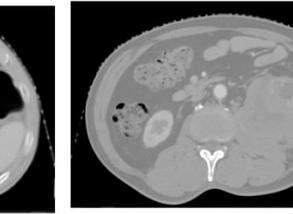
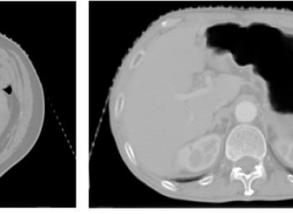
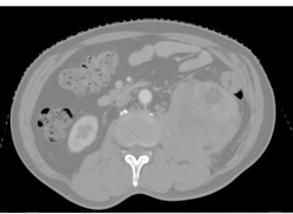
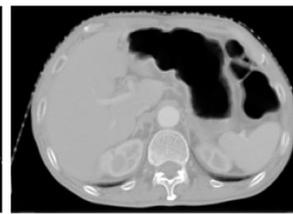
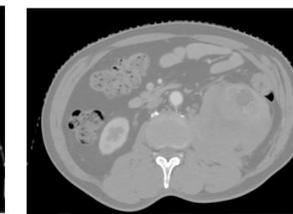
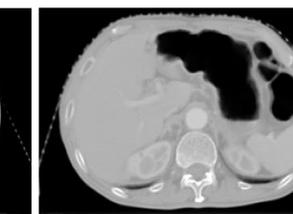
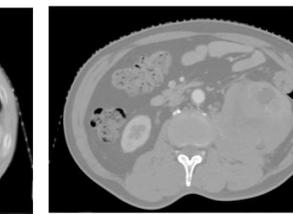
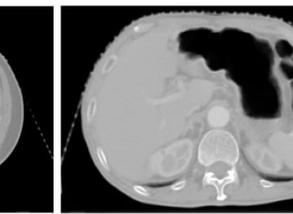
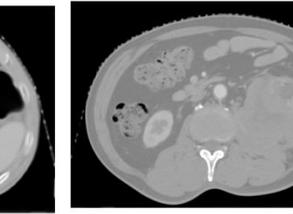
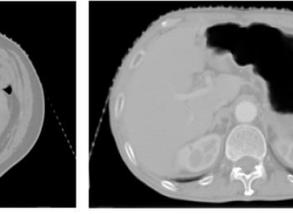
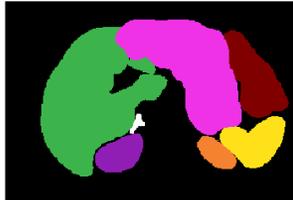
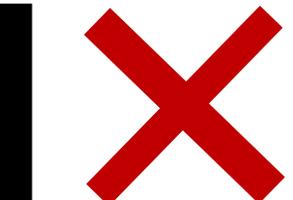
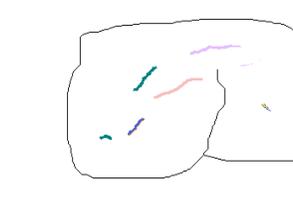
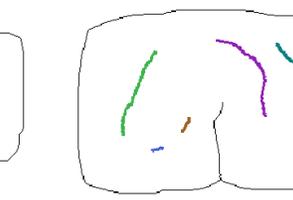
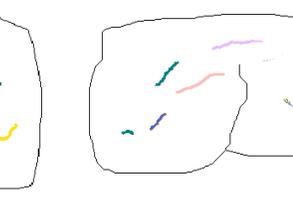
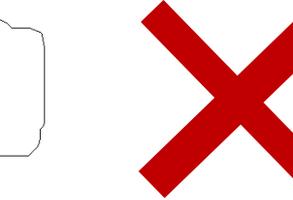
- Semi-scribble supervised: less annotation cost

## Fully-Supervised Segmentation

## Semi-Supervised Segmentation

## Scribble-Supervised Segmentation

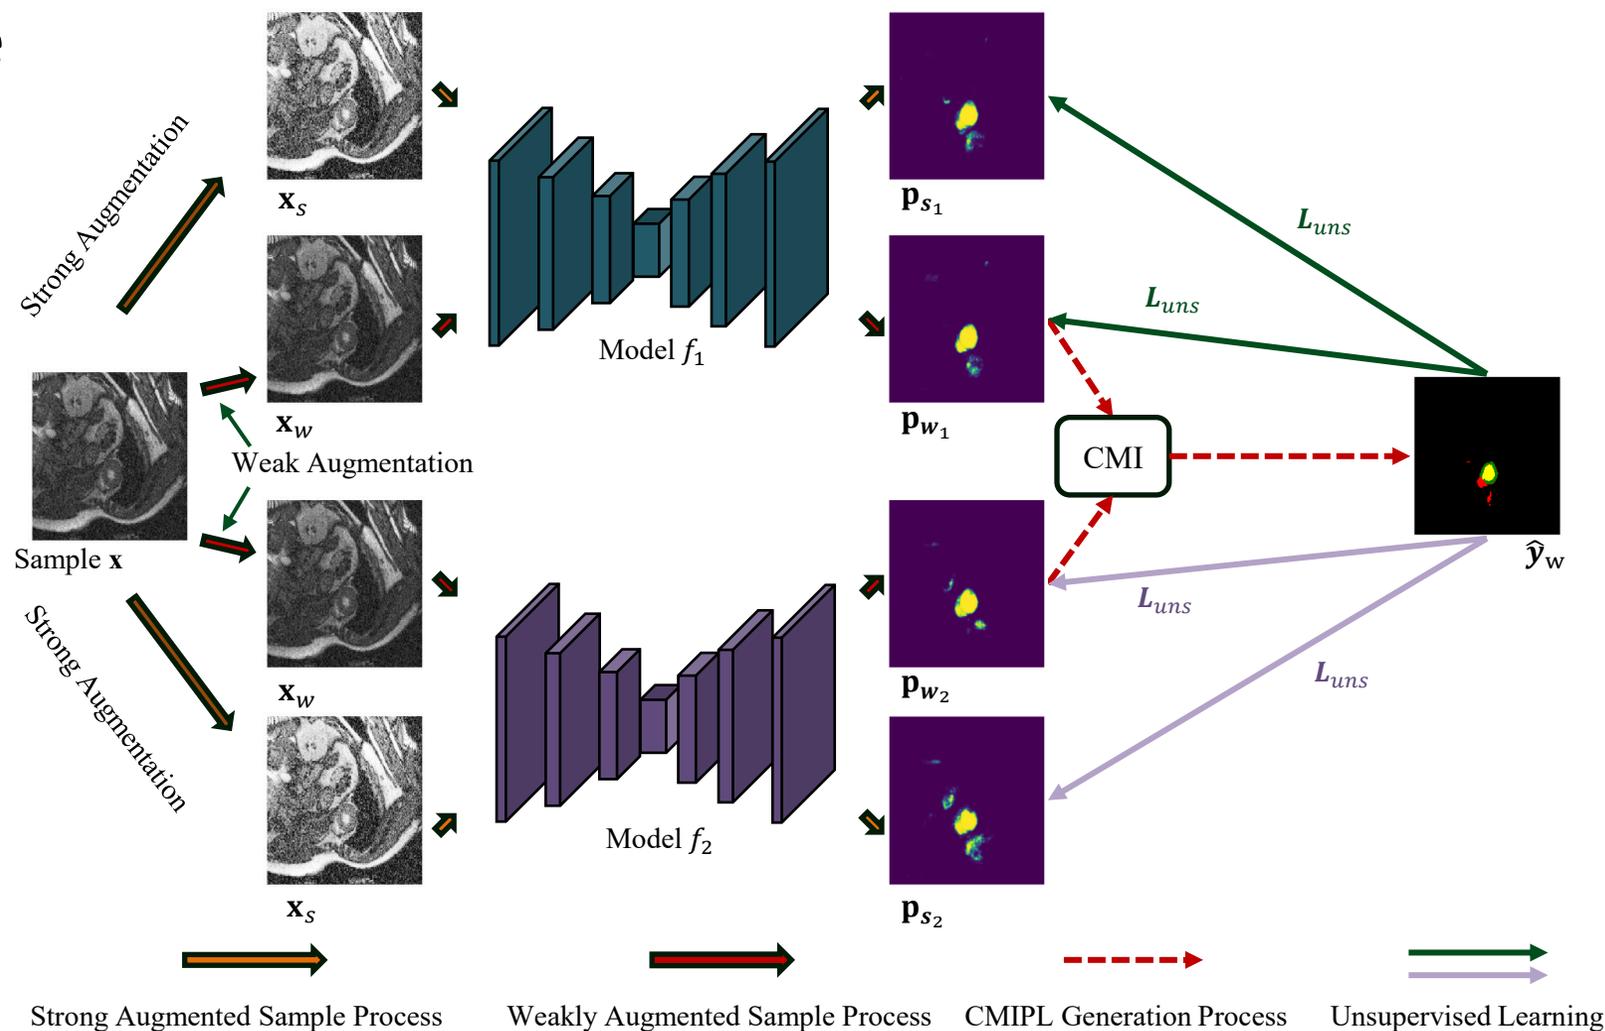
## Semi-Scribble-Supervised Segmentation

Labeled Image		Labeled Image		Labeled Image		Unlabeled Image		Labeled Image		Labeled Image		Labeled Image		Unlabeled Image	
															
Dense Label		Dense Label		Dense Label		No Label		Scribble		Scribble		Scribble		No Label	
															

Hard to annotate Easy to annotate

# Semi-scribble supervised medical image segmentation

- Training Structure



# Semi-scribble supervised medical image segmentation

- 擬似ラベルの最適化

- アノテーションの**スパース性**が高く



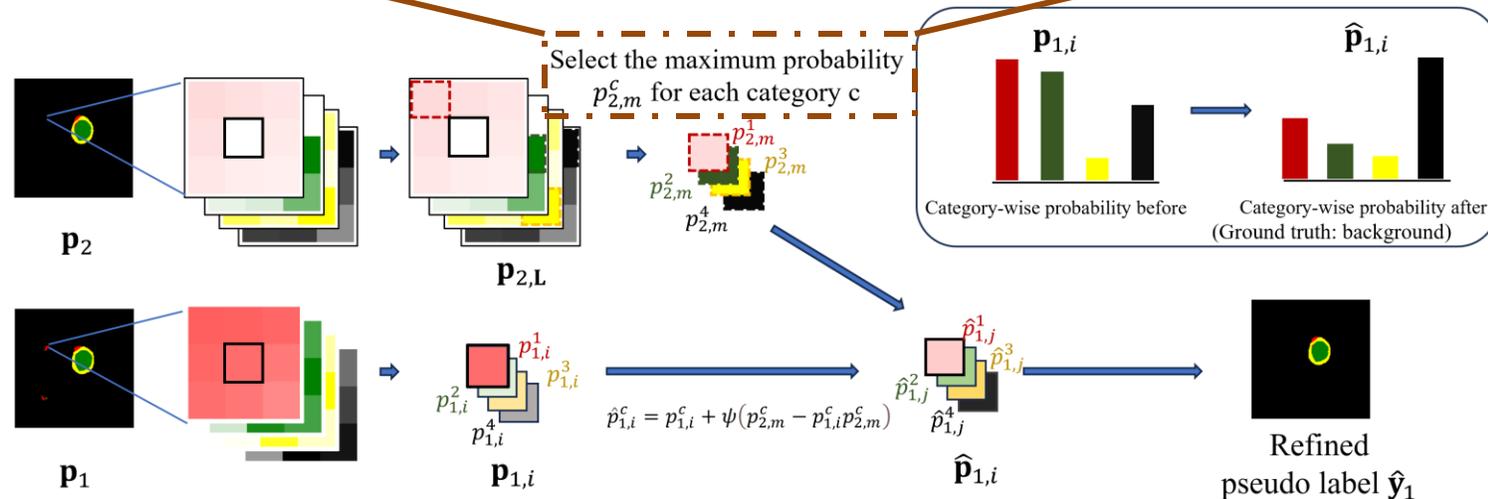
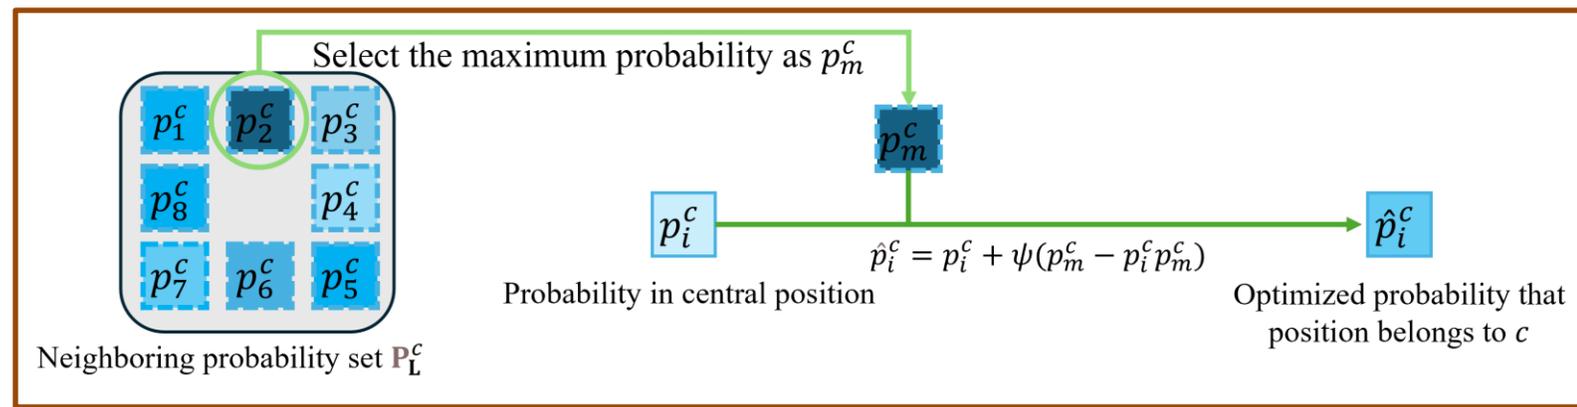
- 擬似ラベルの**精度**が低い



- ラベルの**局所的な平滑性**を考慮

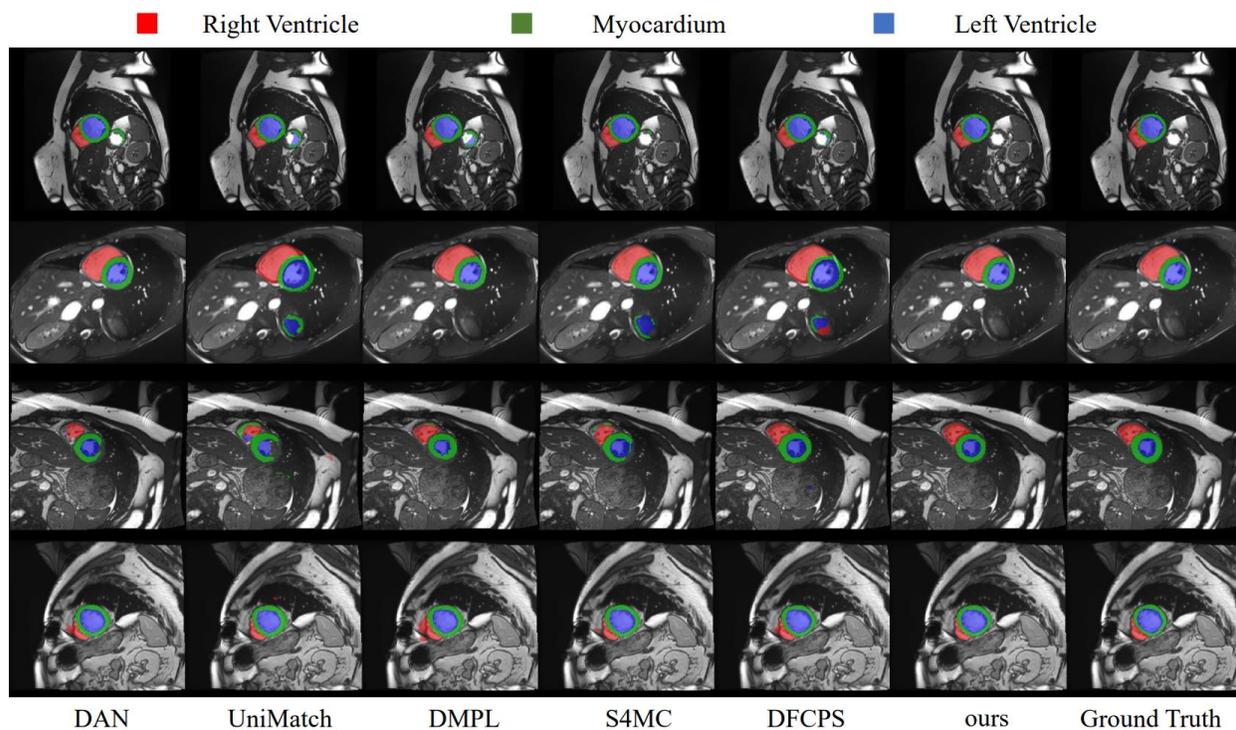


- 周囲のピクセル**を用いて擬似ラベルを**最適化**する。



# Semi-scribble supervised medical image segmentation

## 結果



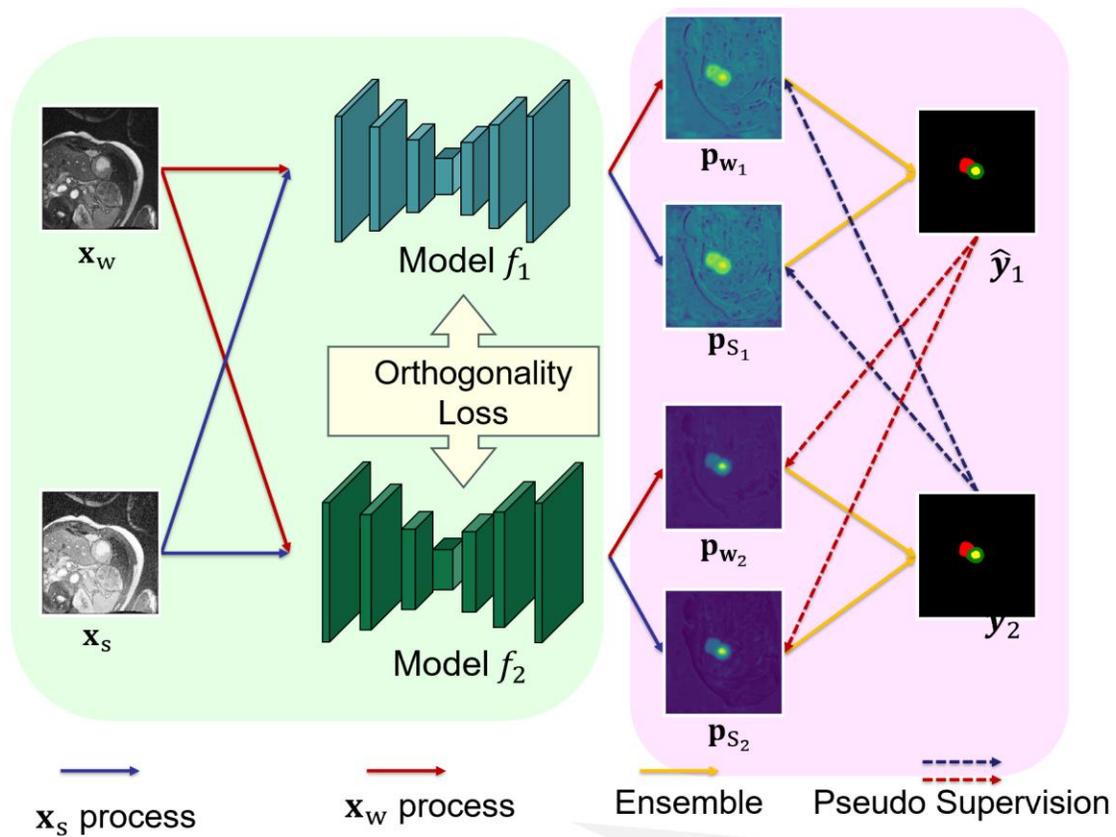
**Table 1.** Segmentation outcomes between our method and other semi- or scribble-segmentation methods using different counts of scribble-annotated ACDC cases. The best performance is denoted using bold, and the second-best performance is marked by underline. The results are presented in the form of “mean(std)”.

Method	RV		Myo		LV		Avg.	
	Dice(%) $\uparrow$	HD95(mm) $\downarrow$						
8 Scribble-labeled cases + 92 unlabeled cases								
DAN [19]	51.0(8.4)	34.9(6.8)	61.9(4.9)	23.4(7.1)	64.3(8.7)	126.3(30.1)	59.1	61.6
CPS [2]	85.8(0.7)	10.1(1.7)	81.2(1.3)	5.9(0.6)	88.7(0.9)	6.8(0.8)	85.2	7.6
DMPLS [11]	85.8(0.5)	<b>8.0(0.9)</b>	81.3(1.3)	5.7(0.6)	89.0(0.8)	6.7(0.5)	84.7	7.7
S4MC [5]	83.9(0.8)	9.6(0.4)	80.2(1.2)	6.6(0.6)	88.5(0.4)	7.0(0.6)	84.2	7.7
UniMatch [17]	86.2(0.5)	10.1(0.9)	82.2(0.9)	6.0(0.8)	88.9(0.4)	6.7(0.5)	<u>85.8</u>	<u>7.6</u>
DFCPS [3]	81.0(2.0)	19.5(7.2)	79.9(0.8)	7.8(1.6)	88.2(0.5)	10.9(2.0)	83.0	12.7
ours	<b>88.0(0.6)</b>	9.2(2.4)	<b>83.2(0.7)</b>	<b>5.5(0.4)</b>	<b>89.3(0.7)</b>	<b>6.6(1.2)</b>	<b>86.8</b>	<b>7.1</b>
16 Scribble-labeled cases + 84 unlabeled cases								
DAN [19]	79.3(1.5)	17.5(5.2)	80.6(1.8)	11.5(3.5)	83.9(1.3)	63.3(24.5)	81.3	30.8
CPS [2]	86.0(0.9)	8.8(1.8)	82.2(0.8)	5.7(0.3)	88.9(0.5)	8.1(1.6)	85.7	7.6
DMPLS [11]	85.8(1.3)	13.6(4.9)	82.1(0.9)	8.6(3.1)	88.7(0.8)	16.2(10.0)	85.5	12.8
S4MC [5]	85.9(1.1)	8.4(1.9)	82.7(0.9)	5.2(0.6)	89.5(0.4)	6.7(1.3)	86.0	6.8
UniMatch [17]	82.7(1.3)	19.2(4.3)	81.1(1.2)	8.3(1.4)	88.4(0.5)	11.7(1.9)	84.0	13.1
DFCPS [3]	87.5(0.6)	8.5(1.4)	84.1(0.5)	<b>5.0(0.4)</b>	<b>89.7(0.4)</b>	6.6(1.3)	<u>87.1</u>	<u>6.7</u>
ours	<b>88.1(0.4)</b>	<b>8.2(1.5)</b>	<b>84.4(0.3)</b>	5.3(0.3)	89.5(0.2)	<b>6.3(0.9)</b>	<b>87.4</b>	<b>6.6</b>

## Sub task 4 : **ほかの研究**

- [1] SemiOrth: A Novel Orthogonal Dual Network Architecture for Enhanced Semi-Supervised Medical Image Segmentation. SPIE Medical imaging 2025
- [2] 信頼度と距離情報に基づく疑似ラベル最適化によるMRI画像の半教師ありScribbleセグメンテーション手法. JAMIT 2025
- [3] ランダム周波数マスクングと疑似ラベル微調整を用いたCT像からの多臓器半教師ありセグメンテーション. 第33回日本コンピュータ外科学会大会
- [4] CT像からの腹部臓器セグメンテーションのための角度許容位置ベース対照損失の提案. 2023年度日本生体医工学会東海支部大会 2023  
など

# [1] SemiOrth: A Novel Orthogonal Dual Network Architecture for Enhanced Semi-Supervised Medical Image Segmentation.



Methods	Average		RV		Myo		LV	
	Dice↑	HD95↓	Dice↑	HD95↓	Dice↑	HD95↓	Dice↑	HD95↓
DMPL [4]	80.3	11.9	79.2	12.7	81.7	11.0	80.1	11.9
ICT [5]	81.8	15.9	82.7	11.4	80.4	21.9	82.3	14.5
UA-MT [1]	83.1	15.6	82.5	19.0	80.2	14.7	83.5	13.2
S4MC [6]	83.2	11.4	84.5	10.7	82.0	13.3	83.1	10.2
DFCPS [7]	84.6	9.8	85.8	9.8	82.1	11.3	85.9	8.3
Ours*	85.0	8.3	86.0	<b>7.2</b>	82.5	11.2	86.0	8.3
Ours	<b>85.2</b>	<b>8.6</b>	<b>86.1</b>	7.8	<b>83.0</b>	<b>9.0</b>	<b>86.4</b>	<b>7.8</b>

# [2] 信頼度と距離情報に基づく疑似ラベル最適化によるMRI画像の半教師ありScribbleセグメンテーション手法

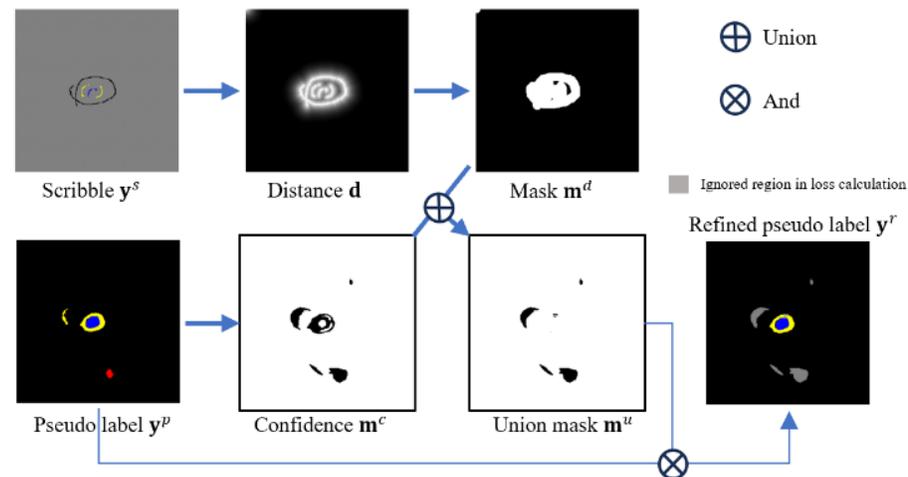
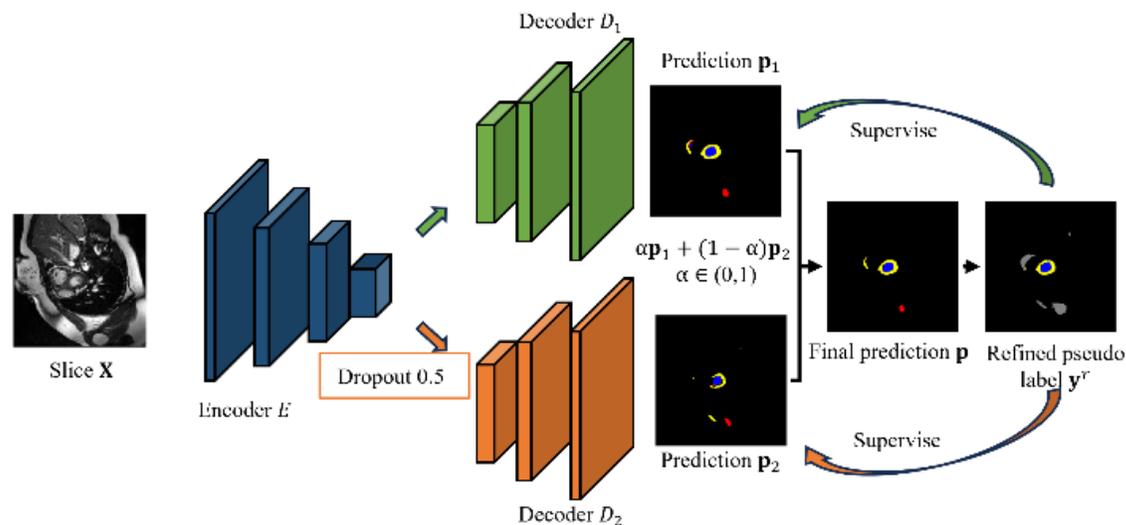
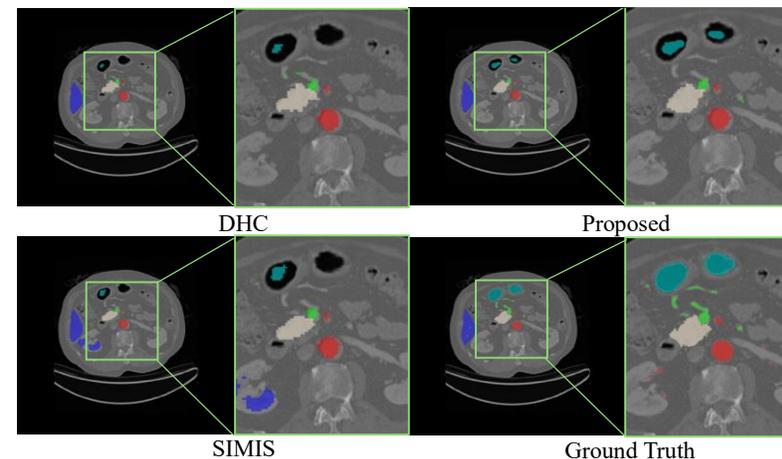
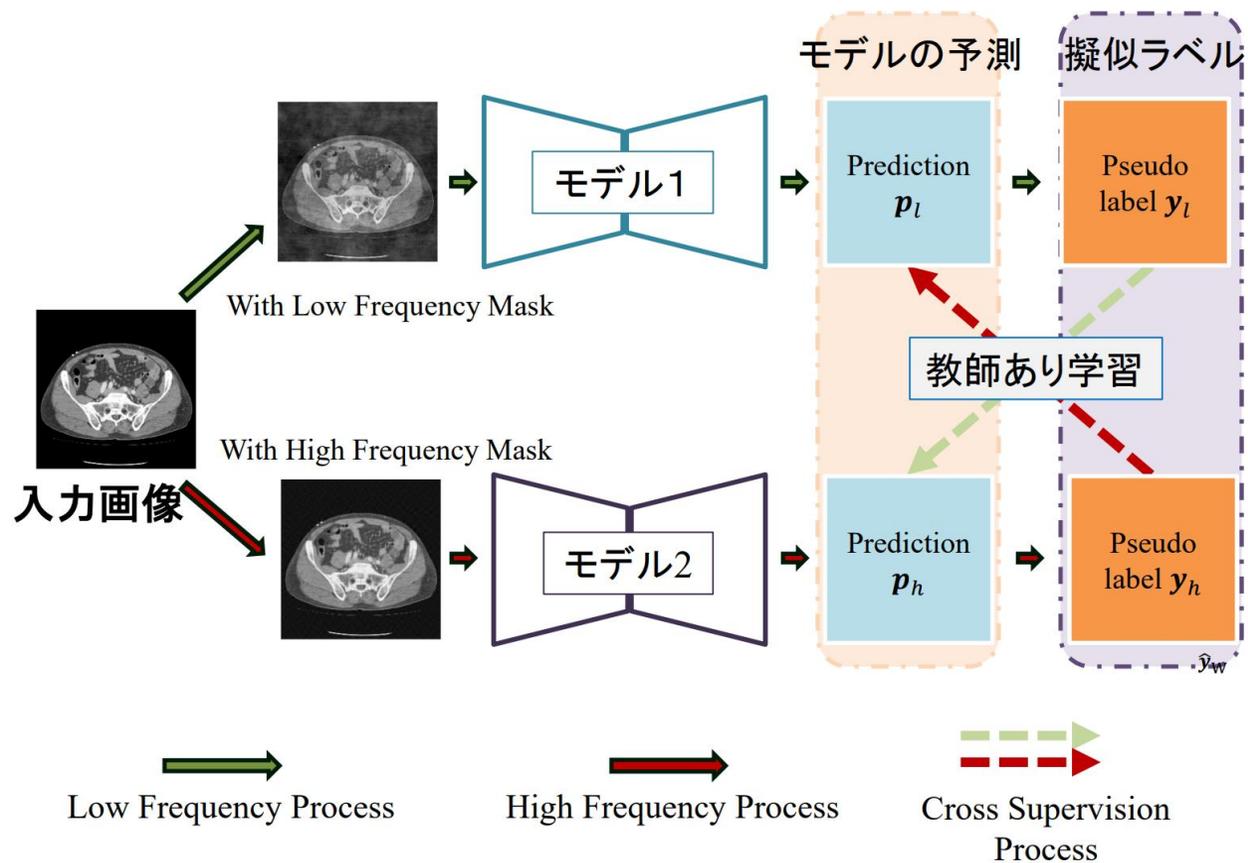


Table.1 Segmentation outcomes between our method and other semi- or scribble- segmentation methods using 8 cases of scribble-annotated ACDC cases. The best performance is denoted using **bold**, and the second-best performance is marked by underline.

Method	RV		Myo		LV		Avg.	
	Dice	HD95	Dice	HD95	Dice	HD95	Dice	HD95
DMPL[3]	85.8	<b>8.0</b>	81.3	5.7	<u>89.0</u>	6.7	84.7	7.7
S4MC[1]	83.9	9.6	80.2	6.6	88.5	7.0	84.2	7.7
UniMatch[5]	<u>86.2</u>	10.1	<u>82.2</u>	6.0	88.9	<u>6.7</u>	<u>85.8</u>	<u>7.6</u>
DFCPS[6]	81.0	19.5	79.9	7.8	88.2	10.9	83.0	12.7
outs	<b>86.7</b>	<u>8.4</u>	<b>83.4</b>	<u>5.9</u>	<b>89.1</b>	<b>6.5</b>	<b>86.4</b>	<b>6.9</b>

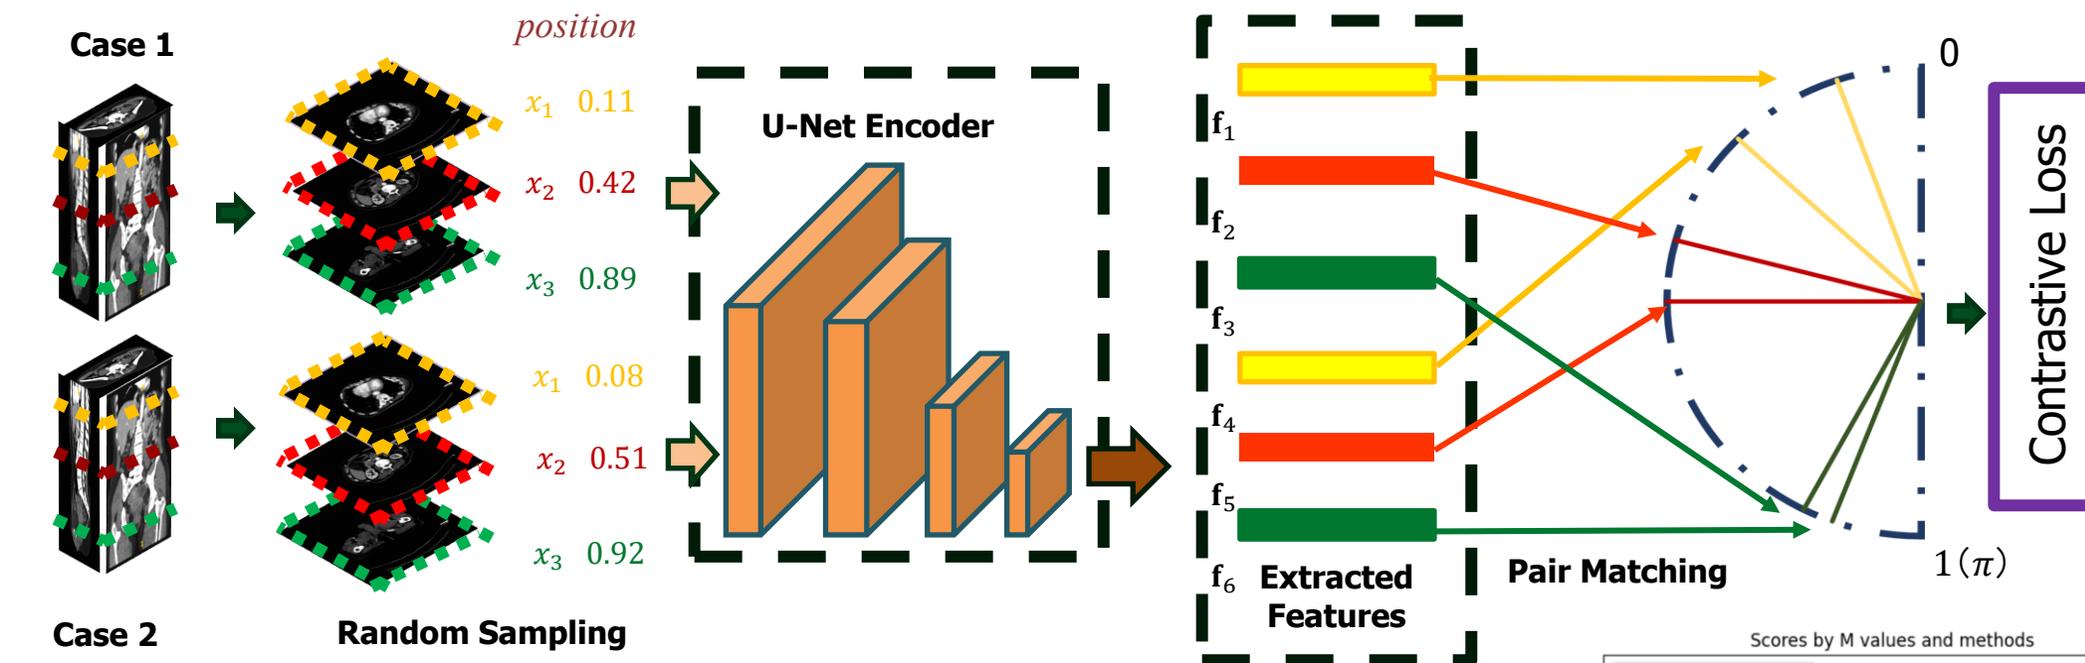
# [3] ランダム周波数マスクングと疑似ラベル微調整を用いたCT像からの多臓器半教師ありセグメンテーション



**Table 1** The result (Dice) of our experiments and related works. Each experiments used different count of labeled cases, and repeated 3 times with different dataset splits

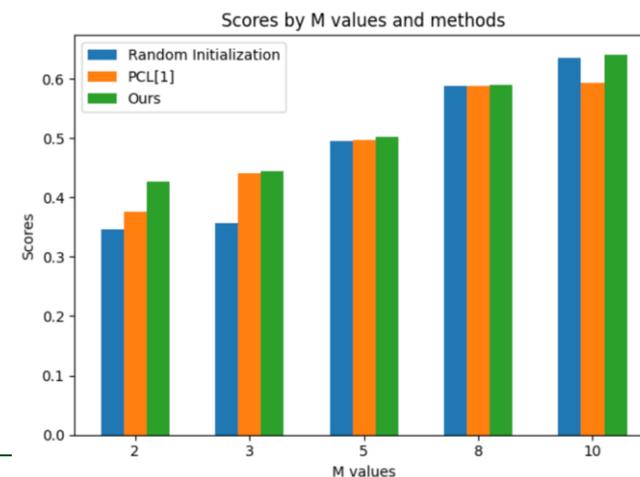
Methods	Labeled Data Used		
	2 case	4 cases	9 cases
CPS <sup>1)</sup>	63.1±1.1	70.8±0.2	75.3±0.5
Depl <sup>2)</sup>	62.3±0.8	70.9±0.2	75.4±0.6
Dst <sup>3)</sup>	64.4±0.4	70.7±0.6	74.9±0.1
SIMIS <sup>4)</sup>	66.4±0.7	<u>73.4±0.2</u>	76.0±0.3
DHC <sup>5)</sup>	<u>66.9±1.4</u>	72.1±0.2	<u>76.7±0.7</u>
S4MC <sup>6)</sup>	65.3±1.0	72.5±0.6	75.6±0.8
<b>Proposed</b>	<b>67.6±0.9</b>	<b>73.8±0.1</b>	<b>77.1±0.3</b>

# [4] CT像からの腹部臓器セグメンテーションのための角度許容位置ベース対照損失の提案.



Method	M=2	M=3	M=5	M=8	M=10
ランダム初期化	0.347	0.356	0.495	0.587	0.635
PCL[1]	0.376	0.441	0.497	0.587	0.593
Ours	<b>0.427</b>	<b>0.445</b>	<b>0.502</b>	<b>0.589</b>	<b>0.641</b>

M : 訓練で使した症例数



ポストクの研究

# 生体内サイバネティック・アバターによる時空間体内 環境情報の構造化

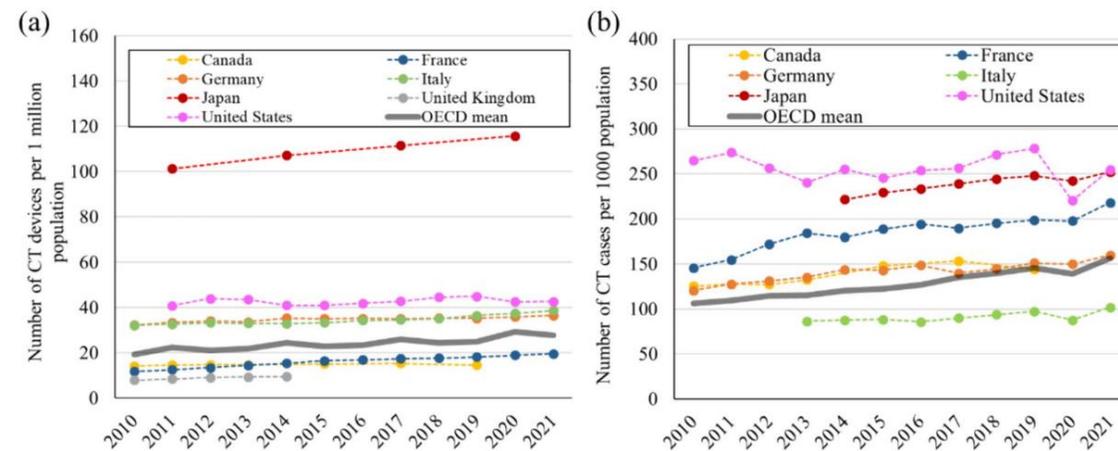
張 路陽<sup>1</sup>

<sup>1</sup>)名古屋大学大学院情報学研究科 森研究室

# 3D CTボリュームからの放射線レポート自動生成のためのVLM開発

- The need of an automatically report generation

- Japan leads the world in CT device density, resulting in the execution of approximately 30 million CT scans each year
- Interpreting CT volumes poses a significant burden on the already **understaffed radiology workforce**, leading to delays in clinical decision-making and a decline in diagnostic quality.

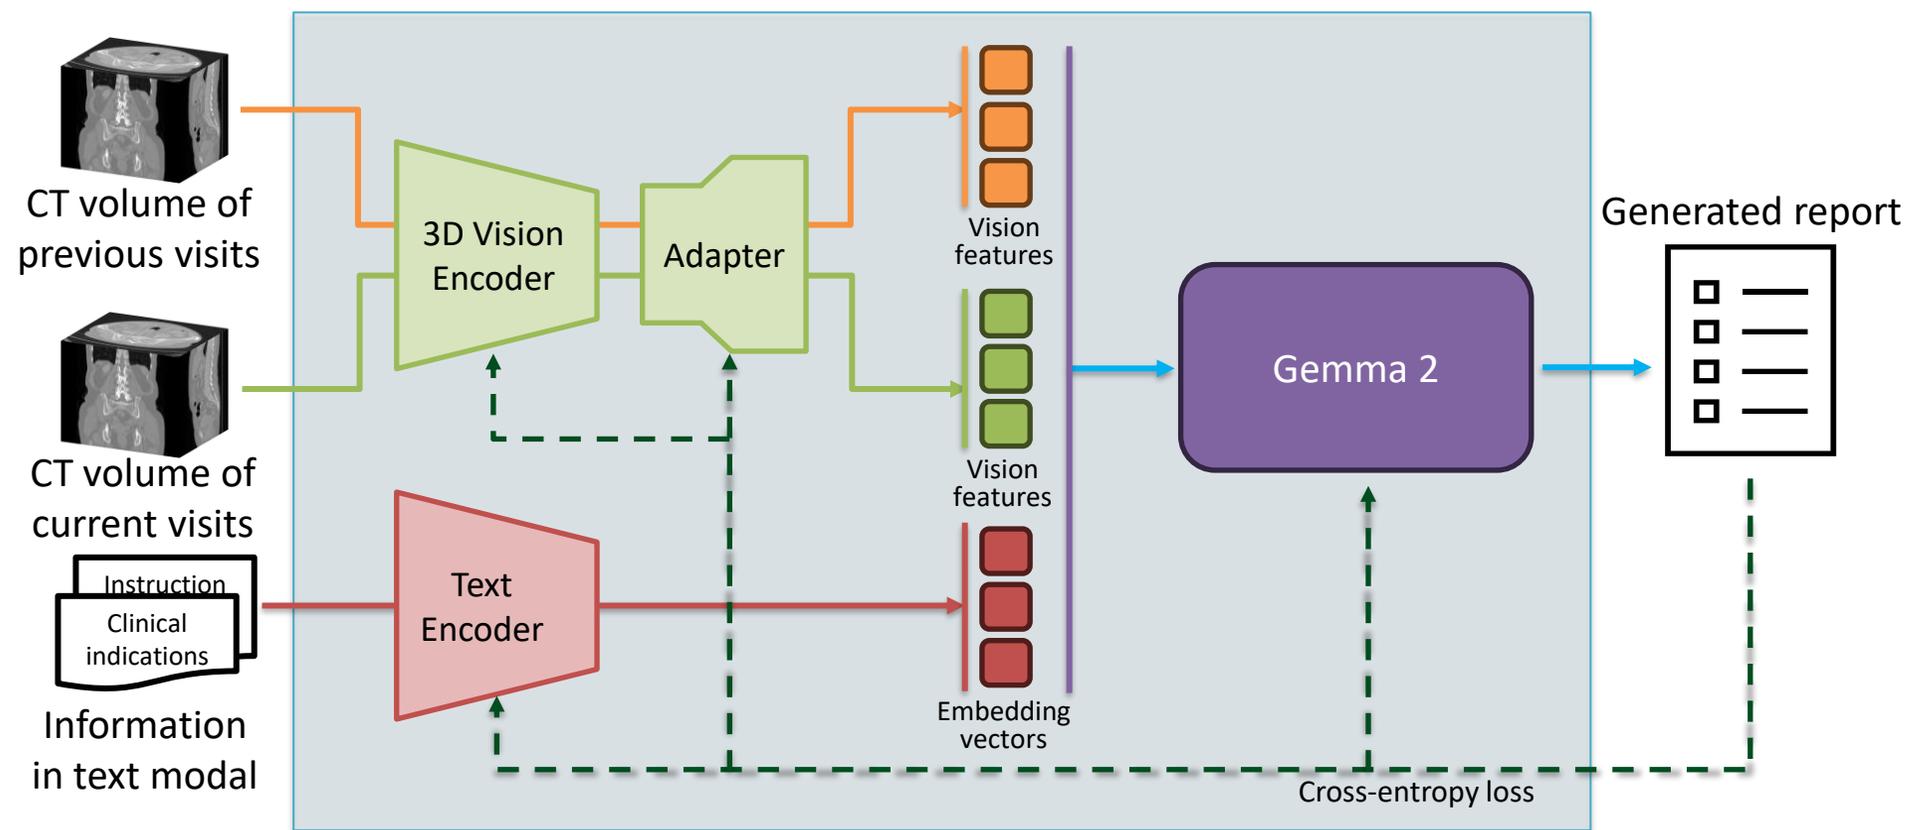


The trend in the density of CT devices and CT cases

- The potential of Vision Language Models (VLMs)

- Recent advancements in **VLMs have shown great performance** in text and 2D images, even with complex languages like Japanese.
- Extend to 3D CT images is challenging** because 3D images requires the model to handle much more information.

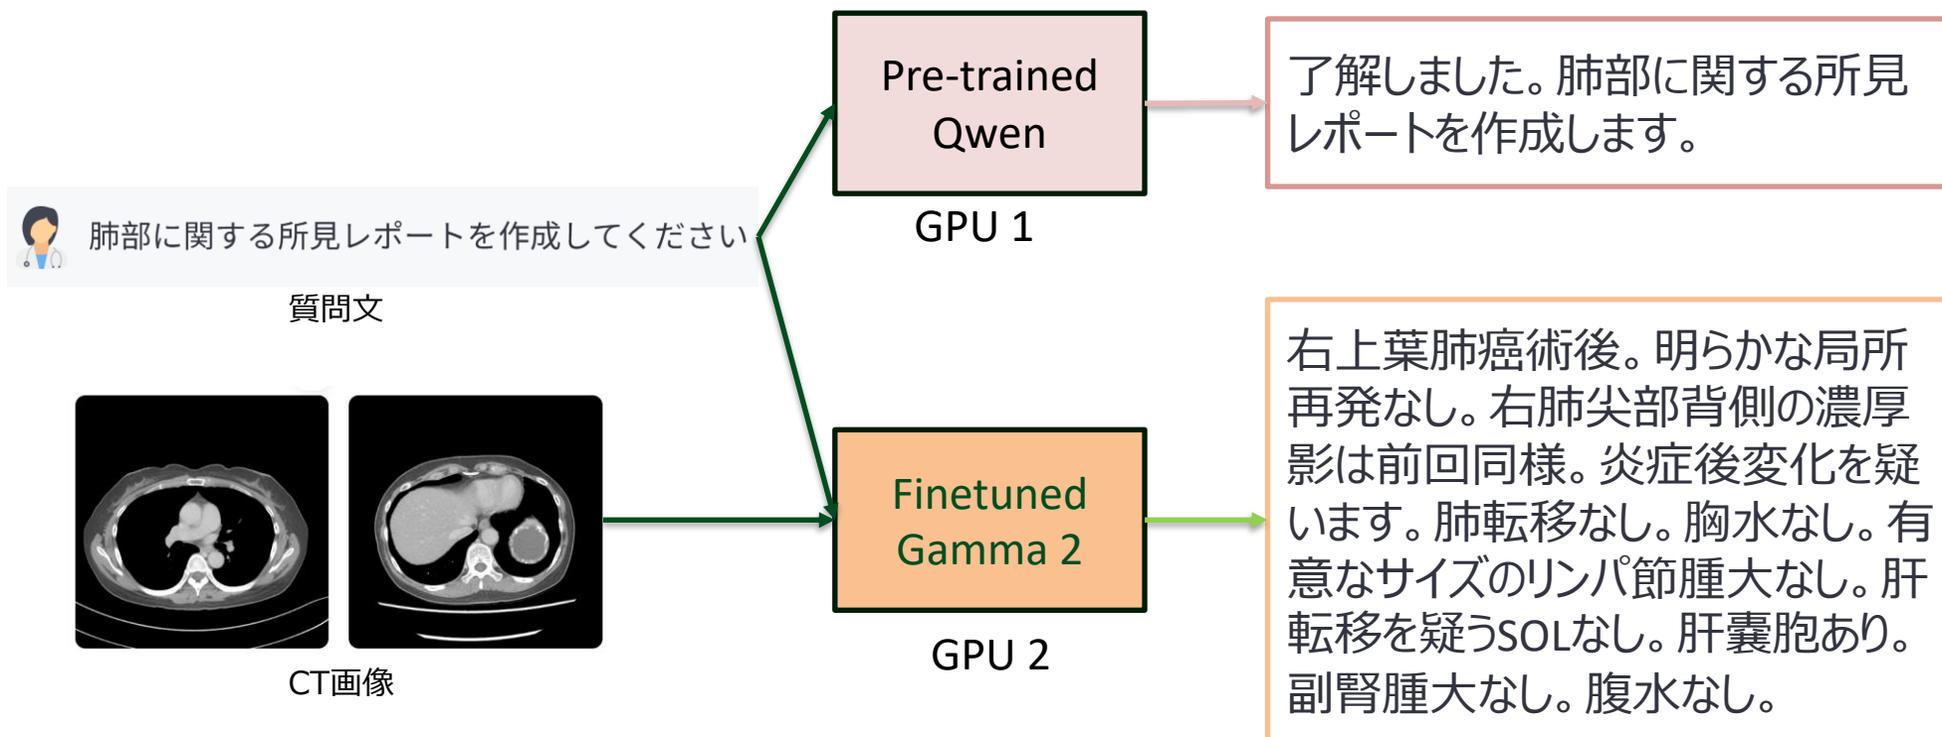
# LLM Finetuning



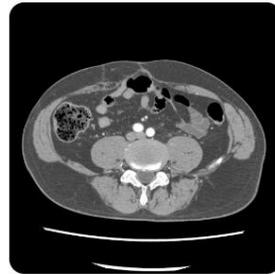
Overview of our method

[Pretrained 3D Vision Encoder](#)

# LLM Finetuning



# WebUI



1



1

78

1



1

98

Previous Visit

Current Visit

ⓘ ボタン「Previous Visit」または  
 「Current Visit」をクリックすると  
 WL/WWが調整できます。



肺部に関する所見レポートを作成してください



了解しました。CTスキャンの比較を行い、肺部に関する所見レポートを作成いたします。

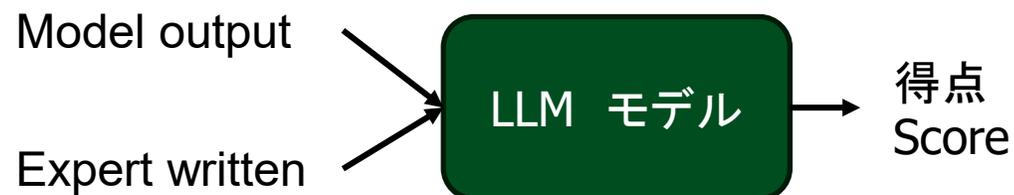
右腎癌凍結療法後1ヶ月。凍結域は前回より縮小。再発を疑う像は指摘できません。両腎嚢胞あり。肝転移なし。膵体部に小さな嚢胞性病変あり、著変なし。上行結腸憩室あり。腹水なし。有意なリンパ節腫大なし。

何か入力してください。



Clear conversation history and start a new one

# 評価基準モデルの作成



生成文 : 原発巣 は 縮小 を 維持して います

レポート: 原発巣 は 縮小 を 維持して いない

Method	Score
BLEU-1	0.889
ROUGE-L	0.889
Ours	0.0

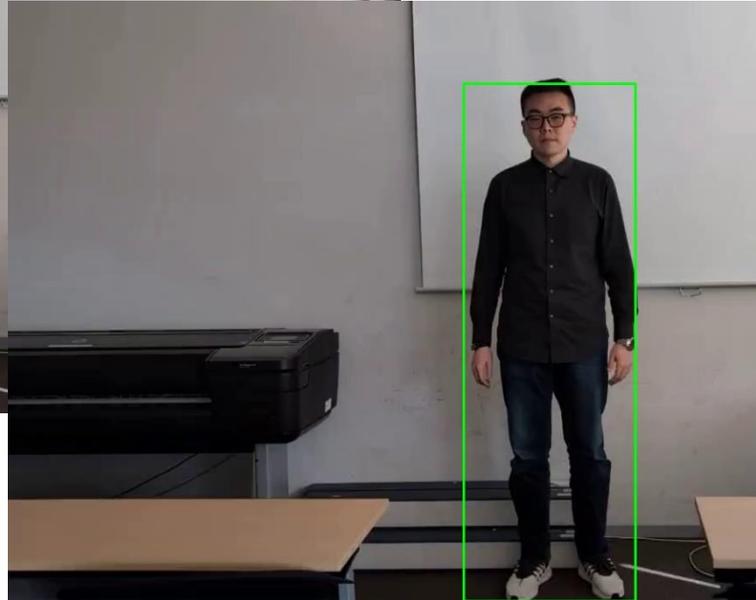
Input text	所見文を作成してください。子宮頸癌CCRT後。
(Translated)	Please create a report. After CCRT for cervical cancer.
Model output	原発巣は縮小を維持しています。有意なサイズのリンパ節腫大なし。肝転移を疑うSOLなし。肝嚢胞あり。両腎嚢胞あり。腹水なし。肺転移は指摘できません。胸水なし。
(Translated)	The primary lesion remains reduced in size. There is no significant lymph node enlargement. No suspicious SOL indicating liver metastasis. Liver cysts are present. Bilateral kidney cysts are present. No ascites. No evidence of lung metastasis. No pleural effusion.
Expert written	原発巣は縮小を維持しています。有意なリンパ節腫大なし。肝転移なし。肺転移なし。胸腹水なし。
(Translated)	The primary lesion remains reduced in size. There is no significant lymph node enlargement. No liver metastasis. No lung metastasis. No pleural or peritoneal effusion.

Score=0.92の例

# 正面像から体型同定の流れ



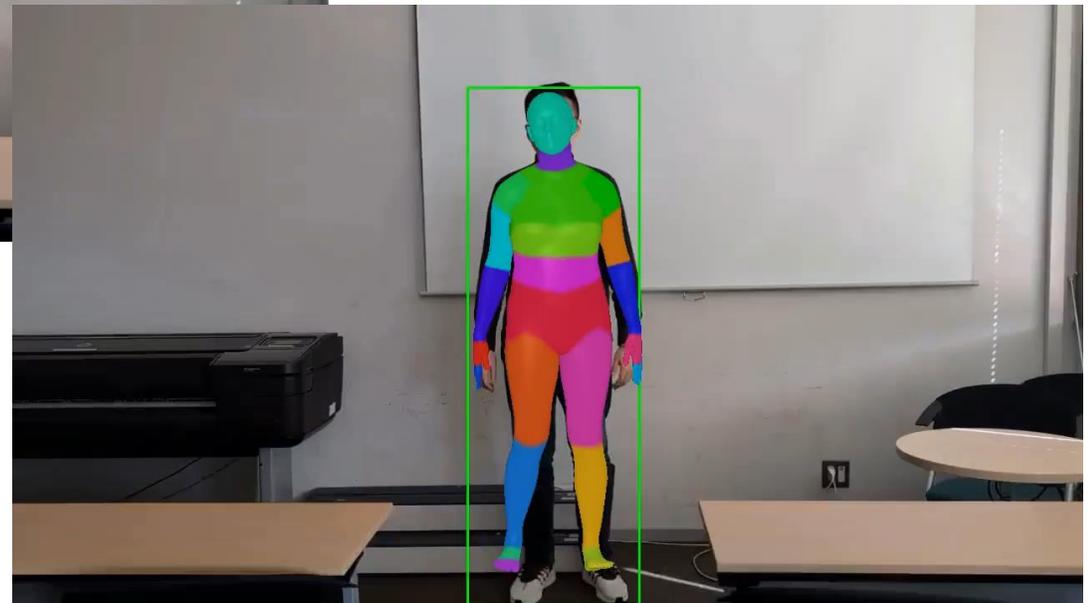
写真撮り (カメラ)



人体を検出



人体抽出



3D体型推定・Motion tracking

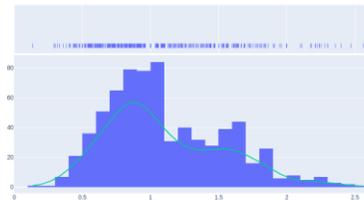


# 大規模CTデータセットを用いた各年齢層の臓器の推定

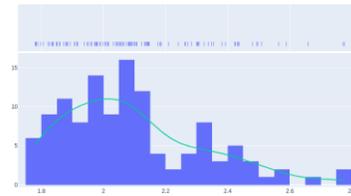
生体データセット



体型の分布



体型の分布



マッチング  
(CDF により)

各年齢層のCTデータセット



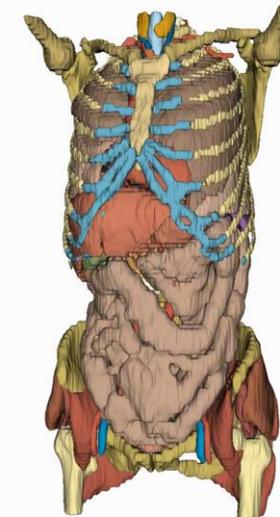
体型から各年齢層のCTを探す



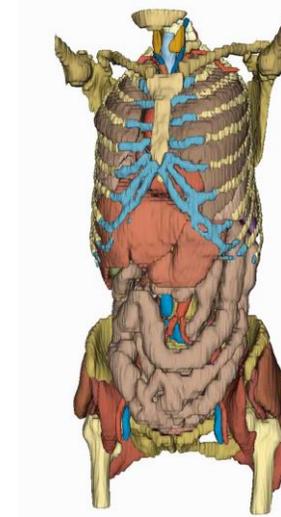
体型



幼年



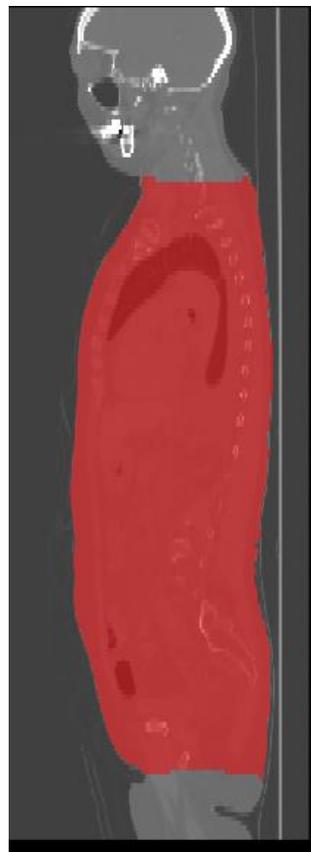
中年



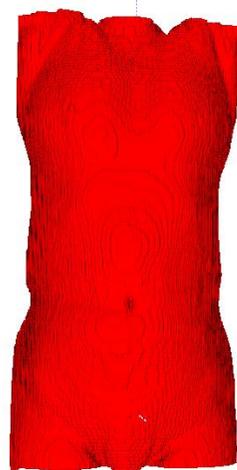
老年



# 大規模CTデータセットを用いた各年齢層の臓器の推定



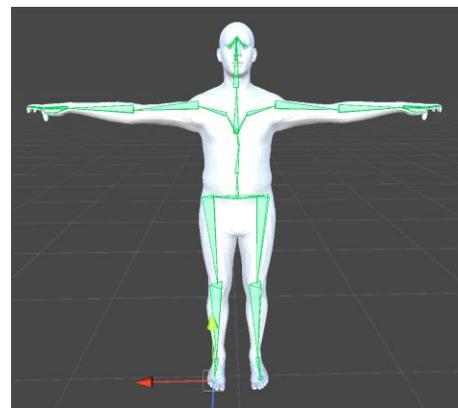
CT 全身像



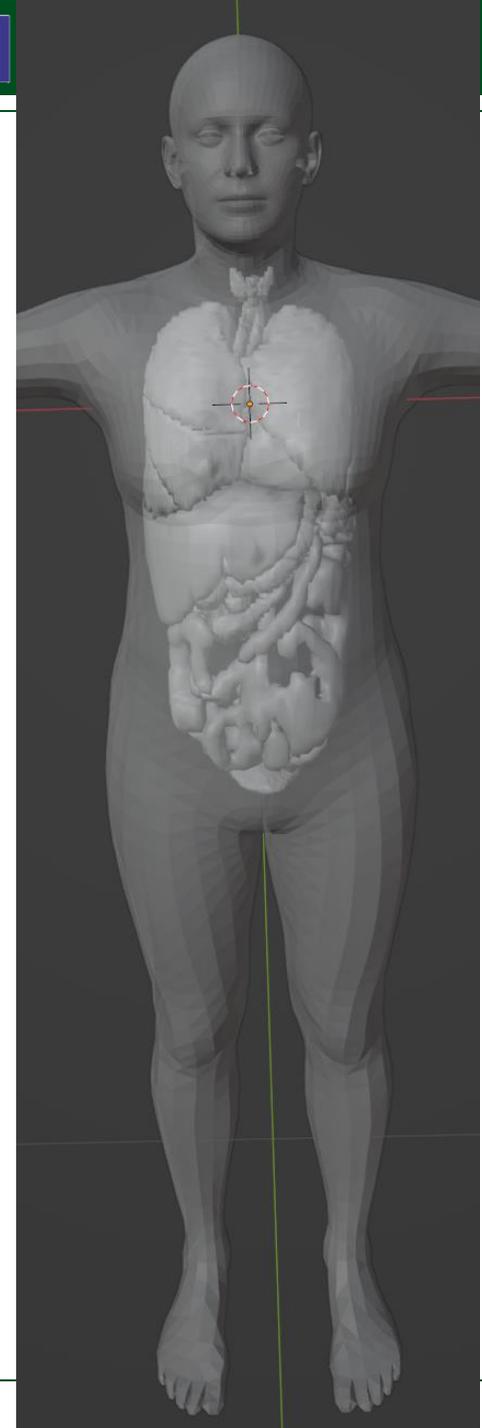
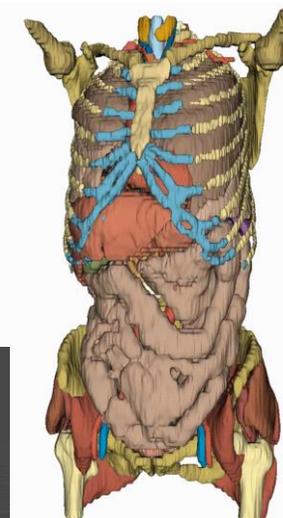
CT Body  
Segmentation



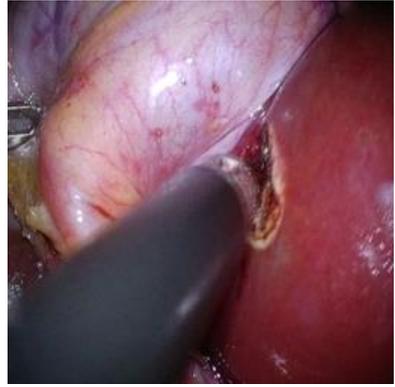
位置合わせ



体型モデル  
Segmentation



# 深度推定で内視鏡画像を用いた3D再構成モデルの開発



3D深度推定



ビデオ



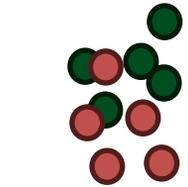
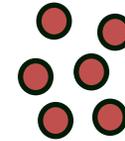
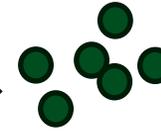
画像選択



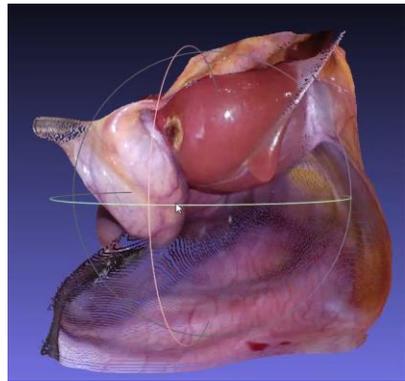
位置推定



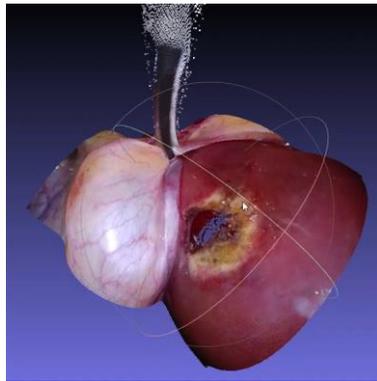
グローバル最適化



グローバルクラウドポイント



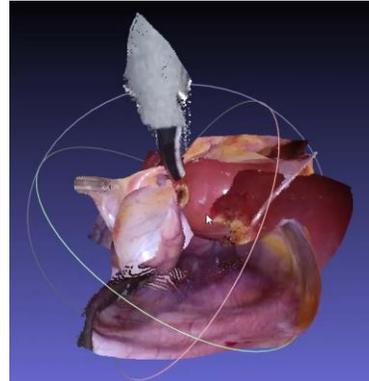
DAMで作成した  
ローカルクラウドポイント



DepthCrafterで作成した  
ローカルクラウドポイント



Aligning &  
Merge



融合させた  
ローカルクラウドポイント

