

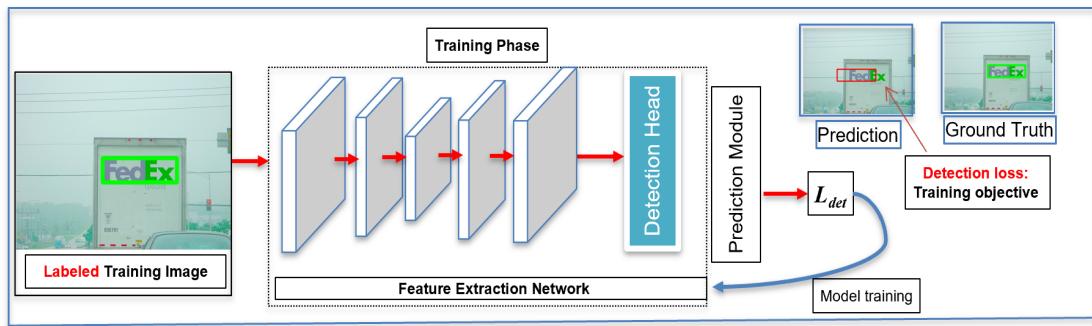
# 敵対生成ネットワークを用いた 高精度な腫瘍(異常)検出

立命館大学 情報理工学部  
教授 陳 延偉

2025年10月9日

# 腫瘍または異常検出法

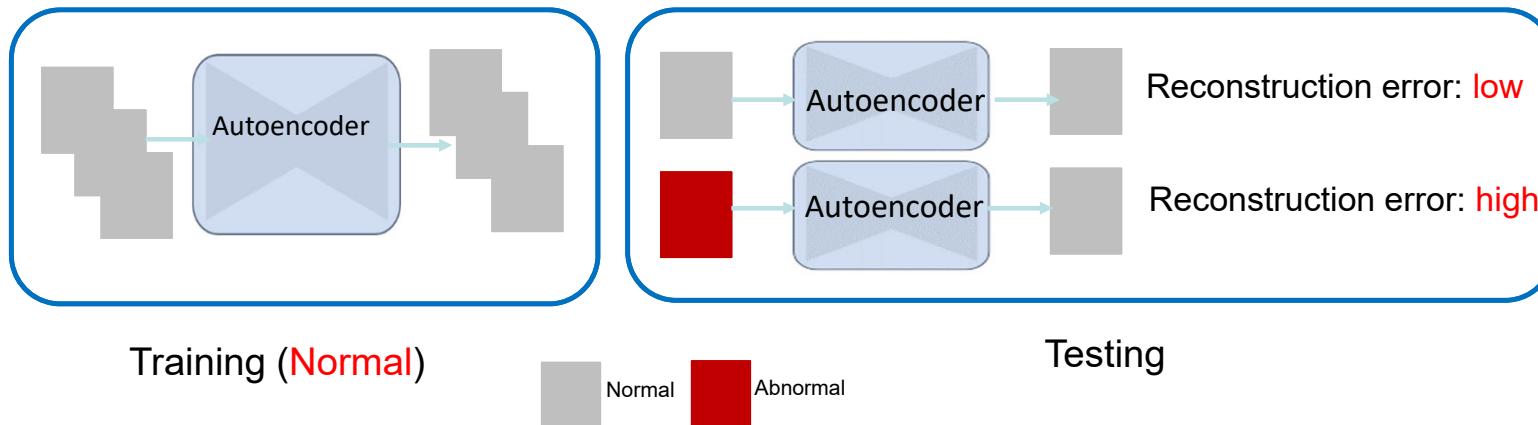
- 物体(腫瘍)レベルでの検出(教師付き学習)



異常の場所までアノテーションが必要  
学習データの準備が大変

AIモデル: Faster R-CNN, YOLO et. al.

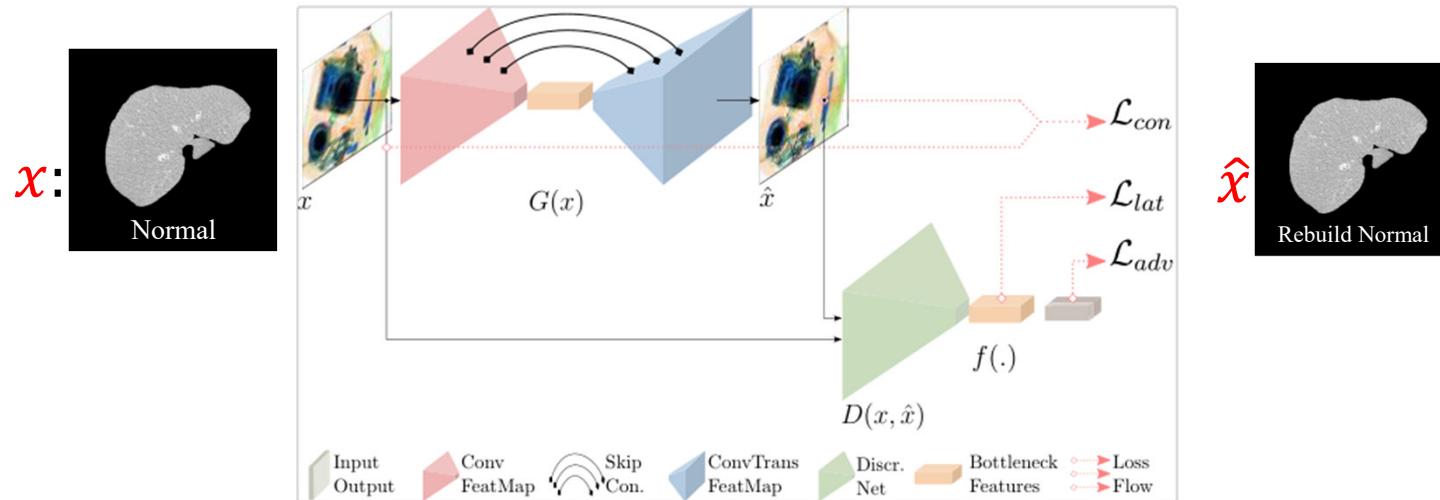
- イメージレベルでの検出(非教師付き正常学習)



正常データのみ  
を用いて学習  
異常箇所のアノテ  
ーション不要

AIモデル: Autoencoder,  
GAN  
精度が低い

# 非教師付き正常学習:既存技術



目標: 正常データを再構成できるautoencoder (G)を学習する.

$$L = L_{adv} + \lambda L_{con}$$

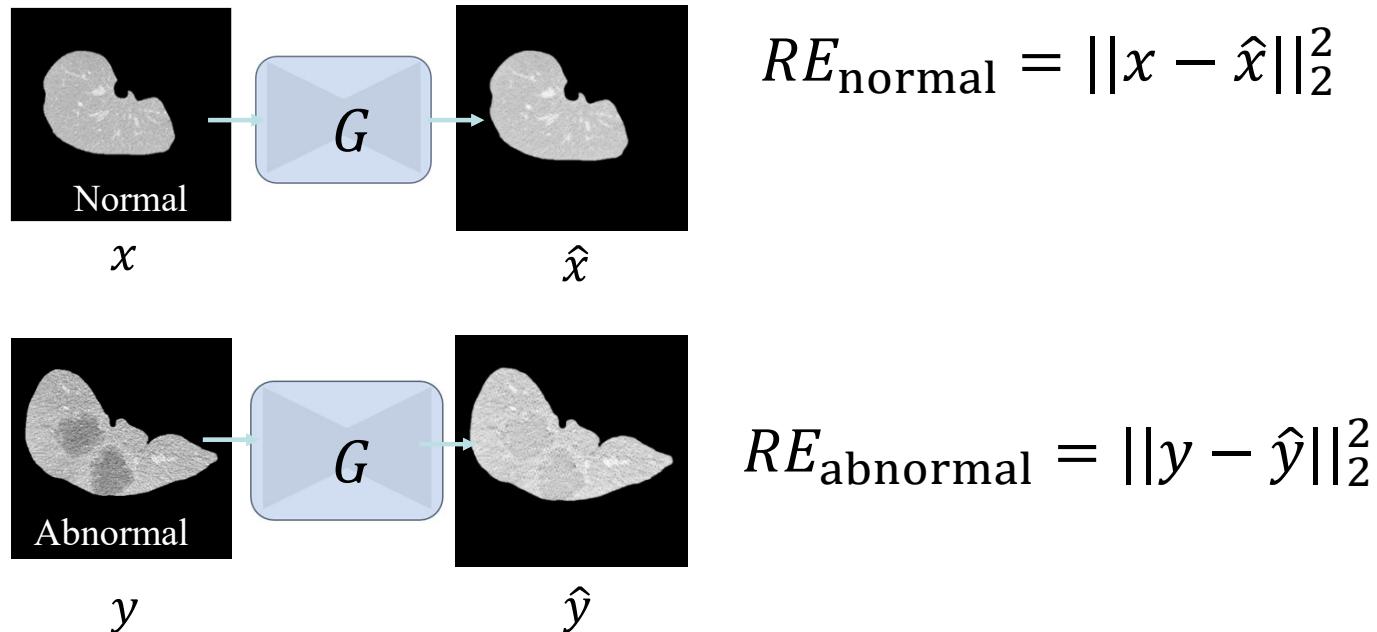
$$L_{adv} = \mathbb{E}_{x \sim p_x} [\log D(x)] + \mathbb{E}_{x \sim p_x} [\log(1 - D(\hat{x}))]$$

$$L_{con} = \mathbb{E}_{x \sim p_x} \|x - \hat{x}\|_1$$

[1] Akcay, Samet and Atapour-Abarghouei, Amir and Breckon, Toby P, "Skip-ganomaly: Skip connected and adversarially trained encoder-decoder anomaly detection," 2019 International Joint Conference on Neural Networks (IJCNN), IEEE, pp. 1–8, 2019.

# 非教師付き正常学習:既存技術

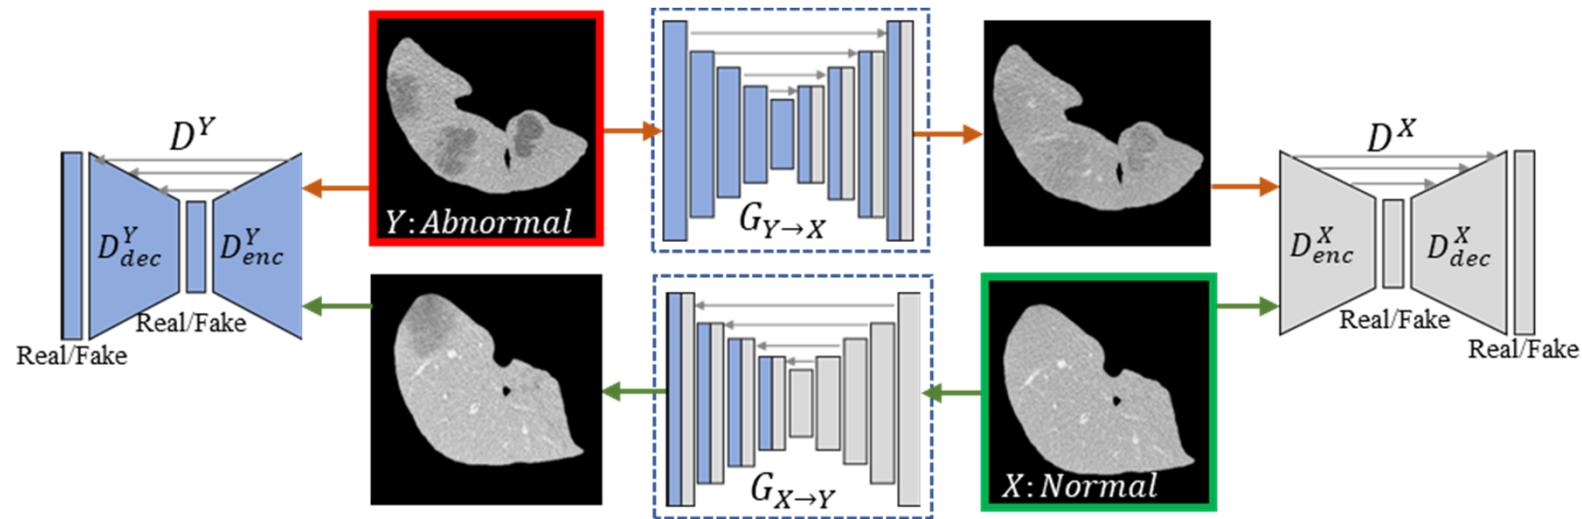
Testing



If  $RE_{\text{abnormal}} > RE_{\text{normal}}$ , 異常と判定される.

欠点: 異常に関する学習がないので、精度が低い

# 提案技術1：弱教師付き学習



- ・正常データと異常データの両方を学習に用いる
- ・異常箇所のアノテーションは不要

# 提案技術1：弱教師付き学習

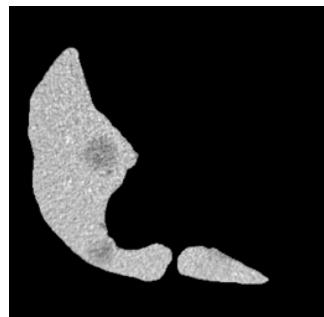
Gradient Magnitude Similarity (GMS) [1] を用いた高精度な異常箇所の検出

$$1. G(x) = \sqrt{(x * p_x)^2 + (x * p_y)^2}, G(\hat{x}) = \sqrt{(\hat{x} * p_x)^2 + (\hat{x} * p_y)^2}$$

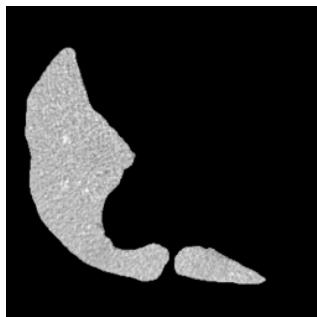
$$2. GMS(x, \hat{x}) = \frac{2G(x)G(\hat{x}) + c}{G(x)^2 + G(\hat{x})^2 + c}$$

$$3. RE(x, \hat{x}) = 1 - \frac{1}{4} \sum_{l=1}^4 GMS(x_l, \hat{x}_l)$$

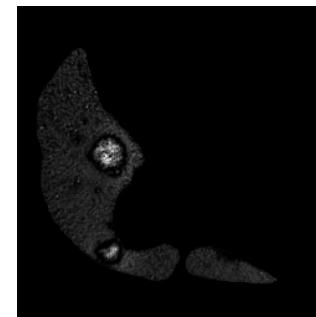
$p_x, p_y$ : Prewitt filters, \* :convolution, c : constant



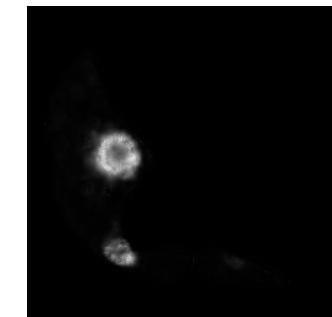
Abnormal test sample



Prediction



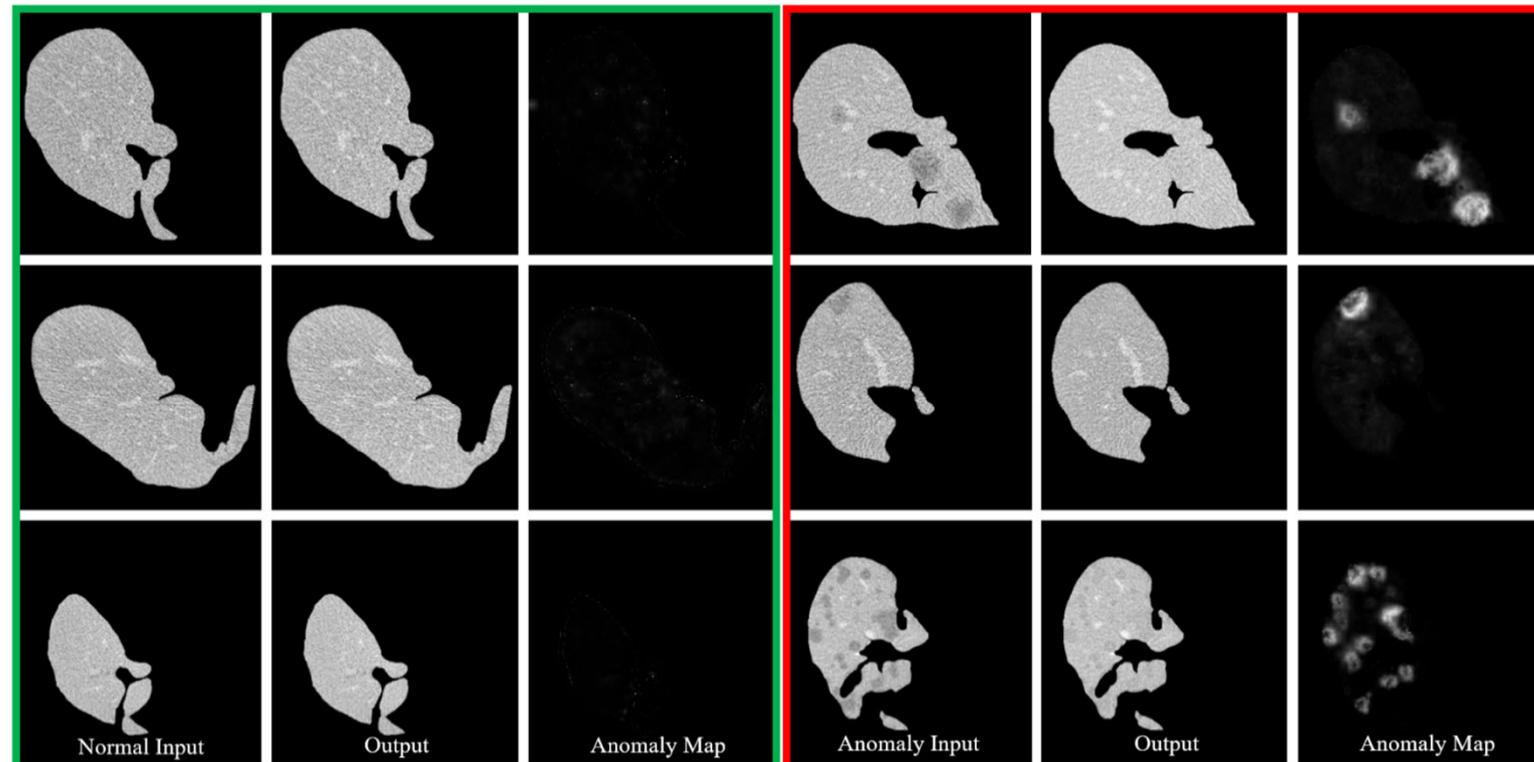
Anomaly map: MSE



Anomaly map: GMSD

[1] Xue, Wufeng, et al. "Gradient magnitude similarity deviation: A highly efficient perceptual image quality index." IEEE Transactions on Image Processing vol. 23.2 pp. 684-695, 2013

## 検出結果例



(a) Normal test samples

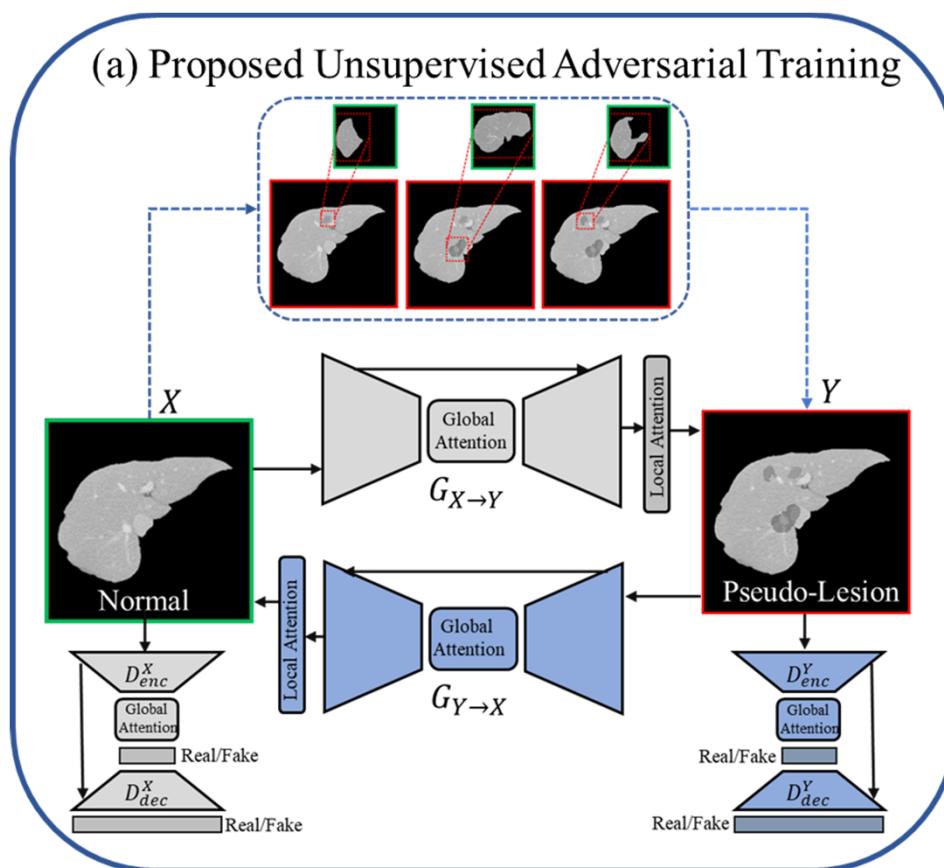
(b) Abnormal test samples

## 既存技術との比較

QUANTITATIVE RESULTS OF DIFFERENT METHODS FOR LIVER LESION  
DETECTION. THE BEST RESULTS ARE HIGHLIGHTED IN **BOLD**.

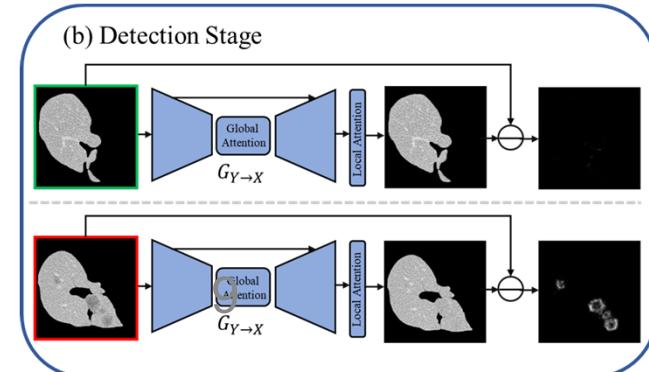
Methods	LiTS		Private	
	AUC	AP	AUC	AP
f-AnoGAN [46]	0.607	0.734	0.610	0.741
GMVAE [47]	0.662	0.777	0.659	0.773
GANomaly [12]	0.618	0.753	0.610	0.747
Skip-GANomaly [13]	0.652	0.773	0.657	0.779
RIAD [48]	0.624	0.716	0.623	0.705
MNAD [20]	0.637	0.755	0.624	0.716
MemAE [19]	0.642	0.726	0.638	0.707
CutPaste [49]	0.657	0.799	0.649	0.762
AnoVAEGAN [50]	0.631	0.724	0.627	0.698
Proposed	<b>0.867</b>	<b>0.937</b>	<b>0.855</b>	<b>0.921</b>

## 提案技術2: 非教師付き学習



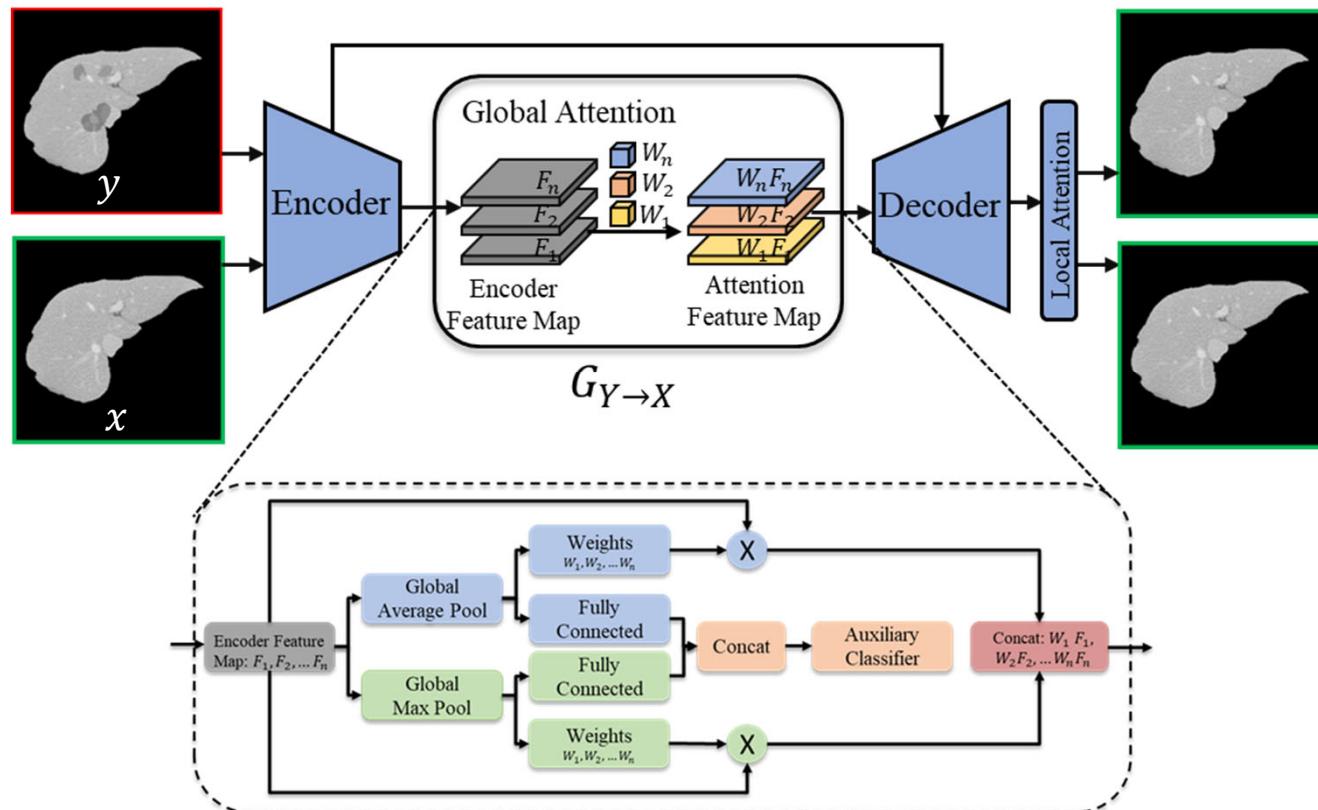
提案技術1(弱教師学習)：  
X: 正常  
Y: 異常

提案技術2(非教師学習)：  
X: 正常  
Y: 擬似異常

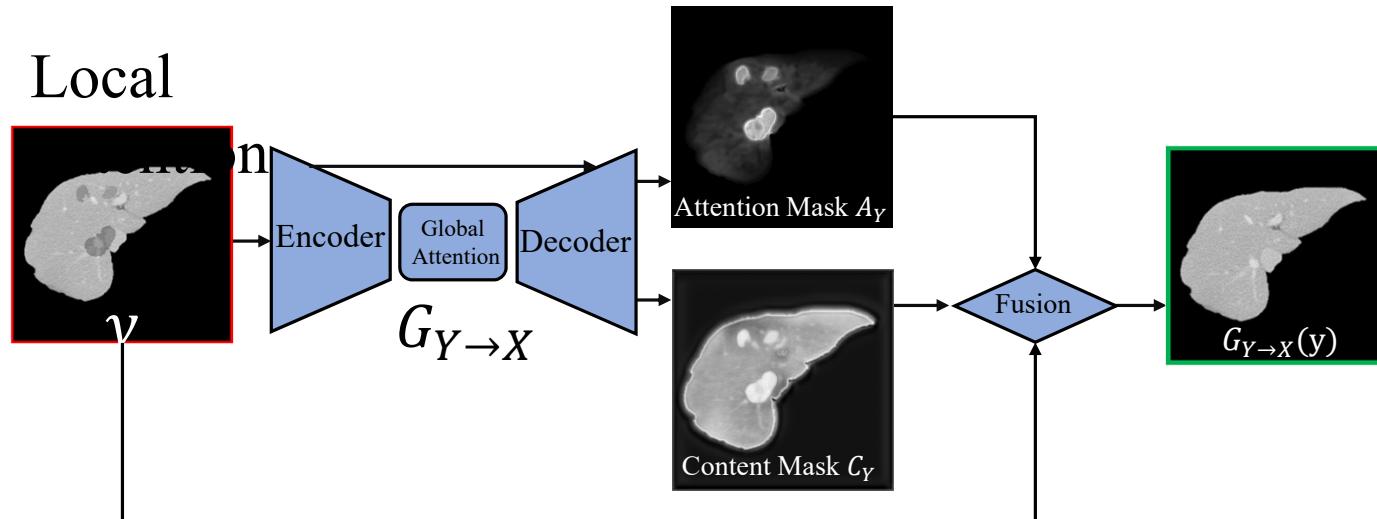


## 提案技術2: 非教師付き学習

Global Attention

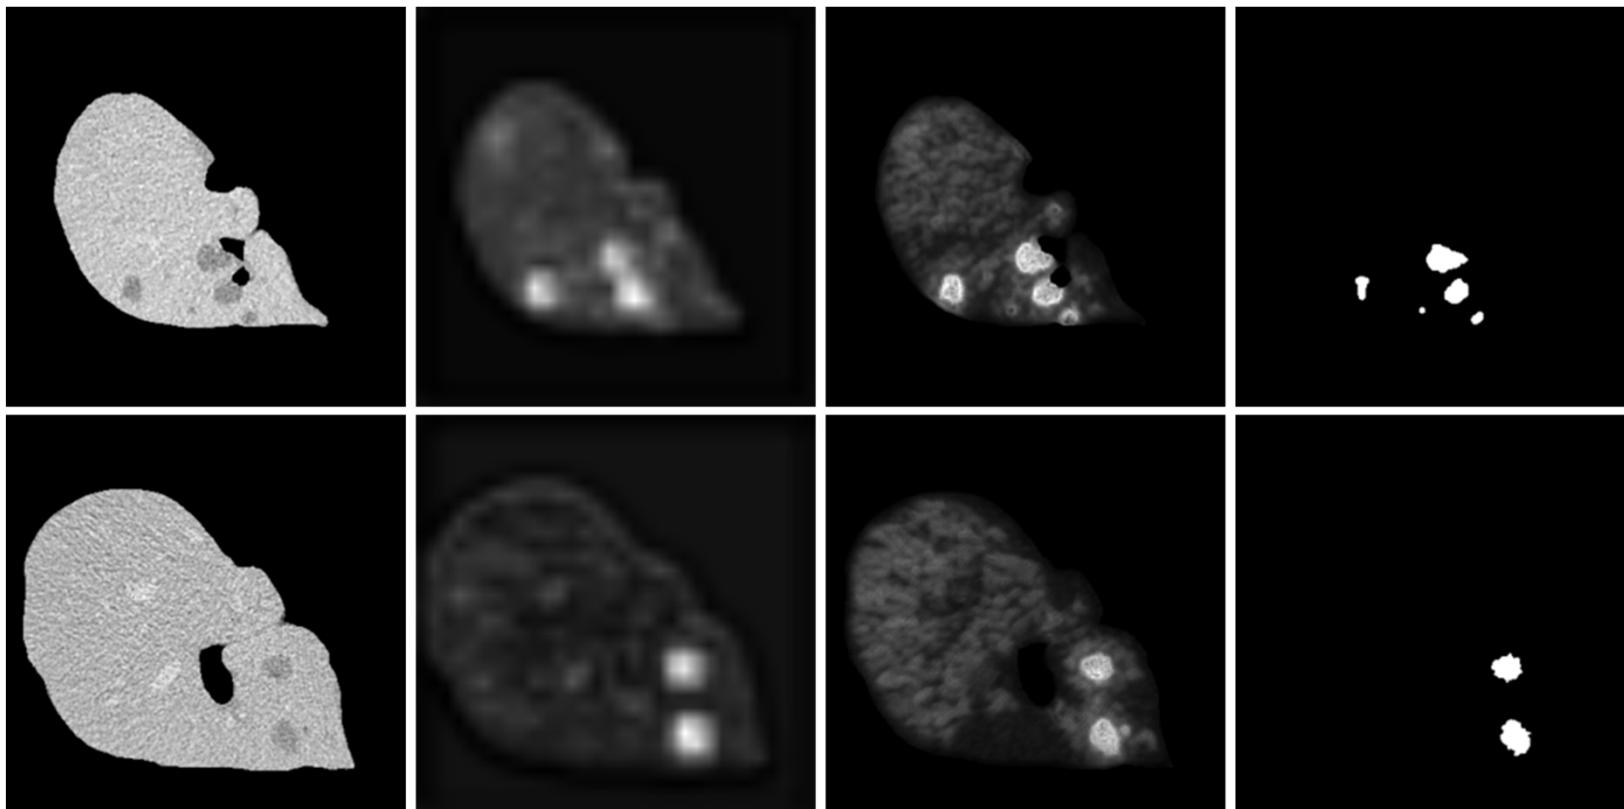


## 提案技術2: 非教師付き学習



$$G_{Y \rightarrow X}(y) = A_Y(y) \times C_Y(y) + (1 - A_Y(y)) \times y$$

# Experiments



(a) Abnormal images

(b) Global attention maps

(c) Local attention maps

(d) Lesion masks

# Experiments

## Ablation studies

Method s	+PL	+UNetD	+ $RE_{mGMSD}$	GA	LA	AUC (MSE)	AUC ( $RE_{mGMSD}$ )
BL1						0.587	0.596
BL2	✓					0.791	0.833
BL3	✓	✓				0.815	0.841
BL4	✓		✓			0.807	0.847
BL5	✓	✓	✓			0.831	0.865
BL6	✓	✓	✓	✓		0.857	0.891
BL7	✓	✓	✓		✓	0.889	0.905
BL8	✓	✓	✓	✓	✓	0.901	0.913

The network structure is the same as the weakly supervised learning method. The results are close to the weakly supervised learning method (MSE: 0.825, mGMSD: 0.867).

# Experiments

Comparison of the proposed method with the state-of-the-art methods on liver lesion detection.

Methods	Public (LiTS) AUC	Private AUC
f-AnoGAN [13]	0.612	0.593
Skip-GANomaly [14]	0.656	0.637
MemAE [15]	0.668	0.676
MNAD [16]	0.659	0.644
AnoVAEGAN [32]	0.633	0.615
CutPaste [62]	0.677	0.678
ULDP [27]	0.865	0.846
Proposed	<b>0.913</b>	<b>0.909</b>

The AUC value is equivalent to the probability that a randomly chosen positive example is ranked higher than a randomly chosen negative example. [1]

[1] Fawcett T. An introduction to ROC analysis[J]. Pattern recognition letters, 2006, 27(8): 861-874.

# 新技術の特徴・従来技術との比較

技術	データ準備	精度	位置情報
従来技術_教師付き学習	×	○	要
従来技術_非教師付き学習	◎	△	不要
提案技術1_弱教師付き学習	○	◎	不要
提案技術2_非教師付き学習	◎	◎	不要

## 想定される用途

- 本技術の特徴は、腫瘍などの異常箇所のアノテーションは不要で、高精度な検出ができる。
- 医用画像における腫瘍検出以外に、さまざまな製品の異常検出に利用できる。

## 実用化に向けた課題

- 現在、手法は開発済み。医用画像における肝臓腫瘍検出の有効性が検証済である。
- 今後、さまざまなデータにその有効性を検証していく必要がある。

## 企業への期待

- 方法はほぼ確立しており、今後さまざまなデータでの検証により、実用化が可能であると考えている。
- 人工知能による異常検出の技術を持つ、企業との共同研究を希望。
- また、異常検出法を開発中の企業には、本技術の導入が有効と思われる。

## 企業への貢献、PRポイント

- 本技術は低コストで高精度な異常検出が可能なため、実用化することでより企業に貢献できると考えている。
- 本技術の導入にあたり必要な追加実験を行うことで科学的な裏付けを行うことが可能。
- 本格導入にあたっての技術指導等

## 本技術に関する知的財産権

- 発明の名称 : 敵対生成ネットワークを用いたイメージレベルでの腫瘍検出システム、及び、腫瘍を検出する方法
- 出願番号 : 特願2022-093220
- 出願人 : 学校法人立命館
- 発明者 : 陳 延偉、他 2 名

## 产学連携の経歴

- 2004年-現在 多くの企業と产学連携をしてきた。主な企業を以下に示す：  
島津、花王、オムロン、キャノン、サムソン、  
三井E&Sシステム技研、東京計器、JAXA、など
- 2020年-2026年 中国浙江大学、インド工科大学(IIT)などの世界トップ大学と国際共同研究
- 2006年-2007年 JST つなぐしきみ事業事業に採択

# お問い合わせ先

立命館大学  
研究部 BKCリサーチオフィス

TEL 077-561-2802  
e-mail [liaisonb@st.ritsumei.ac.jp](mailto:liaisonb@st.ritsumei.ac.jp)