

分類損失を導入した CycleGAN を用いた人工造影 CT 画像の生成

Creation of Synthetic Contrast-Enhanced CT Images Using CycleGAN with Classification Loss

深沢 貴希¹ 亀谷 由隆¹ 山田 啓一¹ 堀田 一弘¹
佐々 直人² 松川 宜久³ 岩野 信吾³ 山本 徳則³
Takaki Fukazawa Yoshitaka Kameya Keichi Yamada Kazuhiro Hotta
Naoto Sassa Yoshihisa Matsukawa Shingo Iwano Tokunori Yamamoto

1 はじめに

近年、深層学習技術を腹部 CT 画像の分析に応用する試みが見られる。例えば、腎腫瘍の検出 [3] [4] や、腫瘍の良性・悪性の識別 [9]、CT 画像を MRI 画像に変換する [5] など医療画像のドメイン変換がある。

腹部 CT 画像を用いた診断をする場合、造影剤を投与することで組織間のコントラストを明確化した造影 CT (contrast-enhanced CT, 以下 CECT) 画像を撮影する。しかし、アレルギーなどで造影剤が投与できない場合は、非造影 CT (un-enhanced CT, 以下 UCT) 画像で診断することになる。そこで、鈴木らは診断前のスクリーニングにおいて造影剤なしに腎腫瘍を検出することを目的に、画像変換モデルである pix2pix を用いて UCT 画像から人工 CECT 画像を生成した。そして、UCT 画像と人工 CECT 画像を入力とする多相畳み込みニューラルネットワーク (convolutional neural network, 以下 CNN) で腎腫瘍の検出を行い、UCT 画像単体で検出するよりも優れた検出精度を示した [1]。しかし、分類モデルが生成画像の粗やノイズを腎腫瘍と勘違いしたように見える事例が散見されることで偽陽性が増える傾向があった。また、佐々らは人工 CECT 画像は臨床スクリーニングに利用できるように示唆したが、腎腫瘍の診断や手術計画に使用するためには更なる改良が必要であると示した [2]。

本研究では CycleGAN [8] を用いて人工 CECT 画像を生成する。pix2pix は学習にペア画像が必要となるが、UCT 画像と CECT 画像の撮影時間が異なるため厳密なペアではない。しかし、CycleGAN はペア画像を必要とせずにドメイン間の変換が可能であるため、pix2pix より優れた品質が期待できる。また、GAN の識別器は画像の真贋を判別するが、腫瘍の有無を判別していないことから、腫瘍部分の特徴が考慮されない画像が生成される可能性がある。そのため、本研究ではクラス分類損失を含めた CycleGAN によって、腫瘍の特徴が考慮された人工 CECT 画像を生成することを狙う。評価実験では人工 CECT 画像をテストデータとして物体検出によって腎腫瘍の検出を行うことで、元の CycleGAN と提案手法を比較する。なお、先行研究として、CycleGAN を用いた医療画像のデータ拡張 [6] が知られているが、本研究では UCT 画像から生成した人工 CECT 画像で腎腫瘍の診断を行うことができる品質を目指す。

本論文は以下の構成をとる。まず準備として 2 節では本研究で用いるデータセットについて説明する。そして、3 節で提案手法を説明する。4 節で実験方法、5 節で結果について述べる。最後に 6 節でまとめ、今後の課題を述べる。

¹名城大学理工学研究科情報工学専攻

²愛知医科大学医学部

³名古屋大学大学院医学系研究科

2 準備

本研究では名古屋大学附属病院で収集された腹部 CT 画像を使用する⁴。このデータセットは UCT・CECT 画像と腫瘍の有無に加えて、腎臓領域の BBox (Bounding Box) のアンテーション情報が含まれている [4]。CECT 画像は造影剤注入後 30 秒経過した後に撮影されたものを使用した。

CT 画像ごとにクラスラベル (腫瘍の有無) を付与するため、まず専門医が各 CT 画像に対して腎臓や腎腫瘍の上端と下端の位置を提案した。そして、腎臓の範囲外にある CT 画像には「腫瘍有」、それ以外の CT 画像には「腫瘍無」のラベルを付与した。また、CT 画像をデジタル画像とするために CT 値を画素値に変換した。本研究では、専門医の助言の下、110~190HU の範囲で CT 値を正規化して作成したグレースケール画像を使用する。更に左右それぞれの腎臓が写るように、元サイズ (512, 512) の CT 画像から、サイズ (256, 256) の範囲の領域を切り取った。本研究では左右の腎臓は対称であると見なし、左の腎臓の画像は左右反転させて、別の患者として扱う。また、腎臓領域が非常に小さい画像等を除外したため、UCT 画像と CECT 画像で枚数の差がある。使用する CT 画像の例を図 1 に示す。

最終的に、腫瘍の有無の割合を維持したまま、データセットを患者単位でランダムに学習用データセット、検証用データセット、評価用データセットに分割した。表 1 に分割したデータセットの構成を示す。

3 提案手法

本節では、まず CycleGAN について説明し、その後、提案手法であるクラス分類損失を導入した CycleGAN について説明する。

3.1 CycleGAN

鈴木らは条件付き GAN の一種である pix2pix を用いて UCT 画像から人工 CECT 画像を生成した。しかし、pix2pix は変換前と変換後の画像の一対一のペアが必要とする制限がある。CycleGAN はドメイン間の変換を学習できるように pix2pix を拡張することで、一対一のペアを作らずに学習を行えるという特徴がある。

まず、ソースドメイン X とターゲットドメイン Y がある状況を考え、 X に含まれる画像を x 、 Y に含まれる画像を y とする。本研究では X が UCT 画像の集合、 Y が CECT 画像の集合である。CycleGAN は、2 つの生成器と 2 つの識別器で構成される。 $X \rightarrow Y$ への画像変換をする生成器を G 、 $Y \rightarrow X$ への画像変換をする生成器を F 、入力が G によって生成された偽物の X の画像か本物の X の画像かを判別する識別器 D_X 、入力が F によって生成された偽物の Y の画像

⁴本研究は名古屋大学と名城大学の倫理委員会の承認を得ている。




図 1: CT 画像の例

か本物の Y の画像かを判別する識別器 D_Y をそれぞれ定義する。

CycleGAN では、式 1~4 の 4 つの損失の和で表される式 5 を生成器 G, F の損失関数として、式 6 を識別器 D_X, D_Y の損失関数として用いて学習する。式 1, 式 2 はそれぞれドメイン X からドメイン Y , ドメイン Y からドメイン X への変換における敵対性損失を表す。式 3 はサイクル一貫性損失であり、画像 x を入力した G によって生成された画像を F によってドメイン X の画像に戻したとき元画像 x に一致するように制約をかける。式 3 を最小化すると、再変換された画像が元の画像と同様の構造を保つことになるため、サイクル一貫性損失によって、ドメイン X, Y に共通する構造を保つようなドメイン変換を可能にしている。 λ_{cyc} はサイクル一貫性損失の重みである。式 4 は同一性損失であり、 G に y を入力しても y と一致するように制約をかけることで画像の自己同一性を保つ。同一性損失は入力画像のうち必要な箇所のみを変換するという役割がある。 λ_{idt} は同一性損失の重みである。以上により CycleGAN は画像の一对一のペアを必要とせずにドメイン間の変換を可能としている。

3.2 分類損失の導入

CycleGAN によって UCT 画像と CECT 画像のペアを作らなくても UCT 画像と CECT 画像の対応関係を学習し、UCT 画像から人工 CECT 画像の生成が可能となった。しかし、腎腫瘍診断の観点では腫瘍部分の特徴が残るように生成される必要があるが、CycleGAN の識別器は画像の真贋の識別をするものであるため、ドメイン内のクラスを考慮した生成をするように学習するのは難しい。

既存の CycleGAN の拡張モデルに条件付き CycleGAN [5] や SBADAGAN (Symmetric Bi-Directional Adaptive GAN) [7] が知られている。条件付き CycleGAN は CycleGAN の生成器の入力を画像とクラス情報に変更し、生成画像のクラスを識別する分類器を追加する。これによって 1 つの生成器で複数のクラスへ変換が可能となるが、生成器の入力にクラス情報が必要となる。しかし、診断対象の CT 画像の腫瘍の有無は、診断しなければわからないため、生成器の入力にクラス情報を使うことはできない。また、SBADAGAN はターゲットドメイン Y がラベル付けされていない状況を想定しているが、本研究で使用するデータセットは UCT・CECT どちらもラベルが存在する。

これらを踏まえて本研究では、CycleGAN の生成器と識

表 1: データセットの構成

データセット	画像単位				患者単位			
	UCT		CECT		UCT		CECT	
腫瘍の有無	有	無	有	無	有	無	有	無
学習用	702	4979	719	5106	147	147	148	146
検証用	136	963	139	1005	28	32	30	30
テスト用	173	1323	192	1368	39	40	39	40

表 2: 画像変換モデルのハイパーパラメータ

パラメータ	数値	詳細
λ_{cyc}	100	サイクル一貫性損失の重み
λ_{idt}	0.1	同一性損失の重み
ngf	64	生成器の第 1 層のチャンネル数
ndf	128	識別器の第 1 層のチャンネル数
n_epochs	100	初期学習率でのエポック数
n_epochs_decay	100	学習率を減衰させるエポック数
lr	0.0002	学習率

別器を変更せずに、ドメイン X のクラスを識別する分類器 C_X とドメイン Y のクラスを識別する分類器 C_Y を導入することで、生成器の入力は画像のまま、クラスを考慮した生成をするように拡張することを提案する。提案手法のネットワーク構成を図 2 に示す。まず生成器 G, F の損失関数として、CycleGAN でも用いた式 1~式 4 と式 7 の 5 つの損失の和で表される式 8 を用いる。式 7 はクラスを考慮するために新たに導入した分類損失であり、クロスエントロピー損失を使用する。 λ_{cls} は分類損失の重みである。そして識別器 D_X, D_Y の損失関数は CycleGAN の式 6 をそのまま用いる。最後に式 9 は分類器 C_X, C_Y の損失関数である。

4 実験方法

本研究は腫瘍の特徴を考慮した人工 CECT 画像を生成することを目的とする。そのため、画像の評価は、画像の類似度評価と物体検出による腎腫瘍検出の精度の 2 点に分けて行う。本節では画像生成モデルの学習設定と画像類似度評価手法、物体検出による腎腫瘍検出およびその評価の方法について説明する。

以降、CycleGAN で生成した人工 CECT 画像を SynCECT (Synthetic CECT)、提案手法である分類損失を導入した CycleGAN で生成した人工 CECT 画像を SynCECT*、両方を示す場合は人工 CECT と表記する。

4.1 画像変換モデルの学習

本研究では pix2pix と CycleGAN の PyTorch 実装 (<https://github.com/junyanz/pytorch-CycleGAN-and-pix2pix>) を元に拡張を施し、生成器には ResNet 9 block, 識別器には 70x70 PatchGAN, データ拡張は実装が提供するものを使用した。ハイパーパラメータチューニングを人手で行った結果、表 2 の通りに設定した。分類損失を導入した CycleGAN では分類損失の重み $\lambda_{cls} = 2$ とし、他のハイパーパラメータは CycleGAN と同様に設定した。分類器には ResNet50 [14] を使用した。予備実験の結果、本研究では Tanaka らの実験 [3] と同じ方法で UCT・CECT 画像をそれぞれで事前に学習されたものを CycleGAN の識別器と同時にファインチューニングする方法を採用した。

$$\mathcal{L}_{\text{GAN}}(G, D_Y) = \mathbb{E}_{y \sim p_{\text{data}}(Y)}[\log D_Y(y)] + \mathbb{E}_{x \sim p_{\text{data}}(X)}[\log(1 - D_Y(G(x)))] \quad (1)$$

$$\mathcal{L}_{\text{GAN}}(F, D_X) = \mathbb{E}_{x \sim p_{\text{data}}(X)}[\log D_X(x)] + \mathbb{E}_{y \sim p_{\text{data}}(Y)}[\log(1 - D_X(F(y)))] \quad (2)$$

$$\mathcal{L}_{\text{cycle}}(G, F) = \mathbb{E}_{x \sim p_{\text{data}}(X)}[\|F(G(x)) - x\|_1] + \mathbb{E}_{y \sim p_{\text{data}}(Y)}[\|G(F(y)) - y\|_1] \quad (3)$$

$$\mathcal{L}_{\text{identity}}(G, F) = \mathbb{E}_{y \sim p_{\text{data}}(Y)}[\|G(y) - y\|_1] + \mathbb{E}_{x \sim p_{\text{data}}(X)}[\|F(x) - x\|_1] \quad (4)$$

$$\mathcal{L}_G(G, F, D_X, D_Y) = \mathcal{L}_{\text{GAN}}(G, D_Y) + \mathcal{L}_{\text{GAN}}(F, D_X) + \lambda_{\text{cyc}} \mathcal{L}_{\text{cycle}}(G, F) + \lambda_{\text{idt}} \mathcal{L}_{\text{identity}}(G, F) \quad (5)$$

$$\mathcal{L}_D(D_X, D_Y, G, F) = -\mathcal{L}_{\text{GAN}}(G, D_Y) - \mathcal{L}_{\text{GAN}}(F, D_X) \quad (6)$$

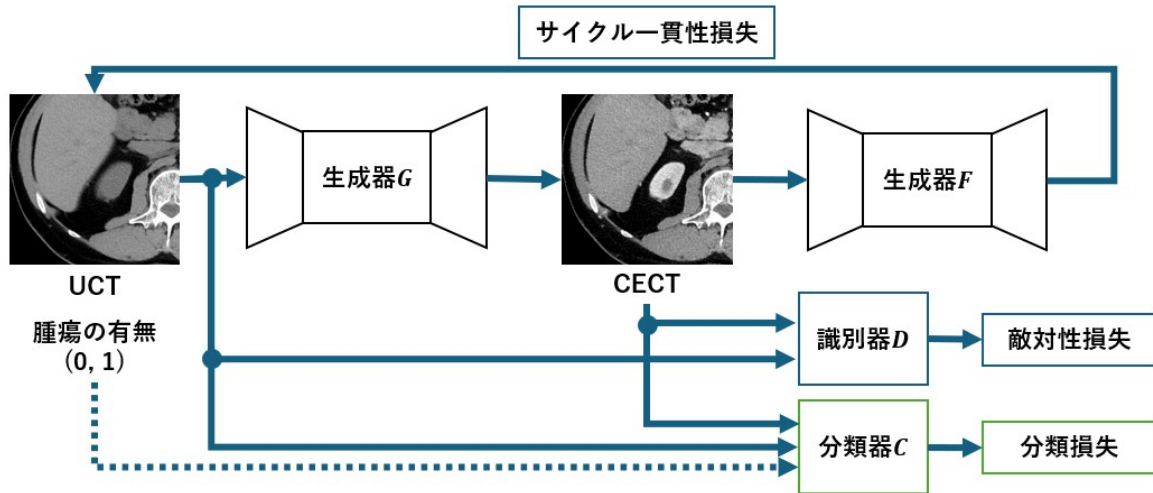


図 2: 提案手法のネットワーク構成

4.2 画像類似度評価手法

画像の類似度の評価指標として PSNR (Peak Signal to Noise Ratio)・SSIM (Structural Similarity Index Measure) [10]・ZNCC (Zero-mean Normalized Cross-Correlation) を使用する。本データセットでは UCT 画像と CECT 画像の枚数が異なるため、類似度の評価においては UCT・CECT のペアと人工 CECT・CECT のペアではペアの対応がとれた 1482 組で、人工 CECT・UCT のペアでは 1496 組で評価する。ZNCC の計測は、テンプレートマッチングのように、上下左右 16 ピクセルの範囲で比較対象の画像を移動した中で、得られる ZNCC が最大の値を使用している。

また、画像全体での評価に追加して、物体検出の学習用の BBox で囲われた腎臓領域部分のみで各評価指標で比較することで、腫瘍の特徴を考慮した人工 CECT 画像となっているかを確認する。UCT 画像と CECT 画像は完全なペアではないため、腎臓領域のサイズが異なることが多い。画像サイズを合わせるために腎臓領域が大きいドメインに画像サイズを揃えて計算することで、腎臓領域のみの評価を行う。

4.3 物体検出による腎腫瘍検出方法

物体検出による評価では、本研究で使用したデータセットで学習された SSD (Single Shot MultiBox Detector) [11] や RetinaNet [12], Transformer ベースの物体検出モデルである DETR (Detection Transformer) [13] を使用する。RetinaNet と DETR のバックボーンには ResNet50 を使用し、SSD は VGG16 を用いた。

今回の実験で用いる画像には必ず 1 つの腎臓が写っている

ため、それを前提として必ず 1 つの腎臓を検出し、陽性・陰性クラスに分類する。物体検出は陽性・陰性・背景の 3 種類のクラスに分けられた BBox とその確信度を出力する。そのため、陽性クラスを検出した BBox における最大の確信度を最大正確信度、陰性クラスを検出したボックスにおける最大の確信度を最大負確信度と定義して、各画像における最大正確信度と $(1 - \text{最大負確信度})$ との調和平均を、画像単位での陽性クラスの確信度とする [4]。

腎腫瘍検出精度の評価では、UCT・CECT・SynCECT・SynCECT*画像それぞれをテストデータとして与えて、検出精度を陽性 (腫瘍を含む) クラスに対する適合率、再現率、F 値、AUROC で評価することによって、人工 CECT 画像が CECT 画像と同様の腫瘍の特徴があるまま生成されたか比較する。本研究で使用するデータセットは腫瘍ありのデータが少ないクラス不均衡であるので画像単位では AUROC の差がつきにくい。そのため、画像単位では F 値、患者単位では AUROC を主に参照する。

決定閾値は検証データにて最大の F 値をとる閾値を使用する。そのため、人工 CECT 画像が CECT 画像と類似しているなら人工 CECT 画像を用いた検出精度は CECT 画像による検出精度に近い値になる。

また、臨床的には患者単位での検出に意味があるため、画像単位・患者単位の 2 つの観点から検出精度を比較する。患者単位での検出は、画像単位での陽性クラスの確信度を各患者の複数スライス上で移動平均をとった時の最大値を患者単位での陽性クラスの確信度とする。

$$\mathcal{L}_{\text{cls}}(G, F, C_X, C_Y) = -\mathbb{E}_{x \sim p_{\text{data}}(X)}[\log C_Y(G(x))] - \mathbb{E}_{y \sim p_{\text{data}}(Y)}[\log C_X(F(y))] \quad (7)$$

$$\begin{aligned} \mathcal{L}_G(G, F, D_X, D_Y, C_X, C_Y) &= \mathcal{L}_{\text{GAN}}(G, D_Y) + \mathcal{L}_{\text{GAN}}(F, D_X) \\ &+ \lambda_{\text{cyc}} \mathcal{L}_{\text{cycle}}(G, F) + \lambda_{\text{idt}} \mathcal{L}_{\text{identity}}(G, F) + \lambda_{\text{cls}} \mathcal{L}_{\text{cls}}(G, F, C_X, C_Y) \end{aligned} \quad (8)$$

$$\begin{aligned} \mathcal{L}_C(C_X, C_Y, G, F) &= -\mathbb{E}_{x \sim p_{\text{data}}(X)}[\log C_Y(G(x))] - \mathbb{E}_{x \sim p_{\text{data}}(X)}[\log C_X(x)] \\ &- \mathbb{E}_{y \sim p_{\text{data}}(Y)}[\log C_X(F(y))] - \mathbb{E}_{y \sim p_{\text{data}}(Y)}[\log C_Y(y)] \end{aligned} \quad (9)$$

5 実験結果

5.1 人工 CECT 画像の生成

図 3 は陰性クラス, 図 4 は陽性クラスの CT 画像から生成された良好な例である. 図 3 (a), 図 4 (a) は実在する UCT 画像である. 図 3 (d), 図 4 (d) は実在する CECT 画像であり, 人工 CECT 画像はこれらに類似するように生成されるのが望ましい. SynCECT, SynCECT* どちらの人工 CECT 画像も腎臓領域を白く強調していることから, どちらのモデルも腎臓の位置を捉えている. SynCECT 画像は腎臓全体を白く強調するが, 提案手法により生成された SynCECT* 画像は腎臓の模様を捉えた生成をする傾向がある.

5.2 人工 CECT 画像の類似度評価

表 3 は画像全体を使用して PSNR, SSIM, ZNCC で評価した結果である. UCT・CECT のペアと人工 CECT・UCT のペアにて各評価指標で大きな差があるが, UCT・CECT のペアは厳密なペアではなく大きくずれているペアを含んでいることから差が発生している. そのため, 類似度評価では主に UCT・CECT, SynCECT・CECT, SynCECT*・CECT の 3 つのペアで相対的に比較する.

SynCECT・CECT ペアと SynCECT*・CECT ペアを比較すると, すべての評価指標で SynCECT*・CECT ペアが優れている. しかし, UCT・CECT ペアと SynCECT*・CECT ペアを比較すると, SSIM では UCT・CECT ペアの方が類似度が高い. SynCECT・UCT ペアと SynCECT*・UCT ペアを比較すると, PSNR と ZNCC で SynCECT・UCT ペアの方が類似度が高い.

表 4 は腎臓領域を使用して PSNR, SSIM, ZNCC で評価した結果である. SynCECT・CECT ペアと SynCECT*・CECT ペア, UCT・CECT ペアと比較すると, すべての評価指標で SynCECT*・CECT ペアが類似度が高い. SynCECT・UCT ペアと SynCECT*・UCT ペアを比較すると, SSIM と ZNCC で SynCECT・UCT ペアの方が類似度が高い.

画像全体を使用して計算した SSIM では UCT・CECT ペアが人工 CECT・CECT ペアより高いが, 腎臓領域に絞った SSIM では UCT・CECT ペアより人工 CECT・CECT ペアの方が高くなることから人工 CECT 画像は本来なら強調が不要な腎臓領域以外の部分まで変化している可能性がある.

また, 人工 CECT 画像は UCT 画像を元に画像変換モデルで生成したものであるため, 人工 CECT 画像と UCT 画像の類似度が低下するということは人工 CECT 画像が UCT 画像から変化したことを意味する. SynCECT・UCT ペアと SynCECT*・UCT ペアの ZNCC による比較において, 画像全体・腎臓領域両方で SynCECT・UCT ペアの方が類似度が高いことから, SynCECT*の方がより多くのピクセルで変化していると考えられる.

5.3 物体検出による腎腫瘍の検出結果

図 5 は DETR による人工 CECT からの腎腫瘍検出が良好な例である. どちらも腎臓領域を囲っており, 陽性の確




図 3: 腫瘍なし CT 画像の生成例

表 3: 画像全体の品質評価

画像ペア	PSNR	SSIM	ZNCC
UCT・CECT	14.0	0.342	0.746
SynCECT・CECT	14.2	0.302	0.764
SynCECT*・CECT	14.4	0.334	0.770
SynCECT・UCT	20.8	0.864	0.952
SynCECT*・UCT	20.5	0.881	0.947

信度は 1 である. 表 5 は画像単位での腎腫瘍検出精度の結果である. 適合率と F 値において SynCECT はすべての物体検出モデルで UCT に劣る結果となった. SynCECT は腎臓領域全体を白く強調することで, 腎臓領域全体が腫瘍部分に類似することになるので誤検出につながり, 適合率が低くなると考えられる. SynCECT*ではすべての物体検出モデルで UCT より優れた F 値を示した. このことから, 提案手法は CycleGAN と比べて, 腎臓の構造や腫瘍に考慮した生成をしていると考えられる. 一方で, SynCECT*を用いた場合の検出精度が CECT を用いた場合に匹敵するとは言えない.

表 6 は患者単位での腎腫瘍検出精度の結果である. AUROC では SynCECT は SSD と RetinaNet で UCT に劣るが, SynCECT*はすべての物体検出モデルで UCT を上回る結果となった. 一方で, 画像単位同様に SynCECT*は CECT に匹敵するとは言えない.

表 4: 腎臓領域の品質評価

画像ペア	PSNR	SSIM	ZNCC
UCT・CECT	10.2	0.228	0.692
SynCECT・CECT	12.8	0.277	0.712
SynCECT*・CECT	13.0	0.297	0.717
SynCECT・UCT	13.0	0.722	0.927
SynCECT*・UCT	13.5	0.639	0.887




図 4: 腫瘍あり CT 画像の生成例

表 5: 画像単位でのモデル間比較結果

物体検出	使用画像	適合率	再現率	F 値	AUROC
SSD	UCT	0.567	0.462	0.510	0.819
	SynCECT	0.374	0.428	0.399	0.730
	SynCECT*	0.711	0.468	0.564	0.810
	CECT	0.794	0.682	0.734	0.920
RetinaNet	UCT	0.505	0.572	0.537	0.801
	SynCECT	0.315	0.538	0.397	0.746
	SynCECT*	0.573	0.520	0.545	0.773
	CECT	0.714	0.677	0.695	0.878
DETR	UCT	0.506	0.468	0.486	0.817
	SynCECT	0.277	0.595	0.378	0.743
	SynCECT*	0.488	0.601	0.539	0.808
	CECT	0.679	0.828	0.746	0.947




図 5: 人工 CECT から DETR による腎腫瘍検出例

表 6: 患者単位でのモデル間比較結果

物体検出	使用画像	適合率	再現率	F 値	AUROC
SSD	UCT	0.591	0.667	0.627	0.762
	SynCECT	0.608	0.795	0.689	0.721
	SynCECT*	0.839	0.667	0.743	0.825
	CECT	0.854	0.897	0.875	0.951
RetinaNet	UCT	0.750	0.846	0.795	0.810
	SynCECT	0.522	0.897	0.660	0.765
	SynCECT*	0.681	0.821	0.744	0.811
	CECT	0.729	0.897	0.805	0.913
DETR	UCT	0.815	0.564	0.667	0.756
	SynCECT	0.583	0.897	0.707	0.706
	SynCECT*	0.674	0.795	0.729	0.817
	CECT	0.841	0.949	0.891	0.933

6 おわりに

本論文では、腎臓の腫瘍部分を考慮した人工 CECT 画像を生成することを目的に、分類損失を導入した CycleGAN を提案した。実験では、画像全体だけでなく腎臓領域に焦点を当てた画質評価と、人工 CECT 画像を用いた物体検出による腎腫瘍の検出を行った。その結果、提案手法で生成された人工 CECT 画像は使用したすべての物体検出モデルで検出精度にて UCT 画像と CycleGAN で生成された人工 CECT 画像を上回り、人工 CECT 画像生成において分類損失の有効性を示した。

今後の課題として Transformer や拡散モデルを導入した CycleGAN ベースの画像変換モデル [15] [16] に対して分類損失を導入することや、分類損失の代わりに物体検出の損失を組み込むことによる人工 CECT 画像のさらなる品質向上や、類似度評価のために UCT と CECT 画像の厳密なペアの作成、複数の専門医による評価が挙げられる。

参考文献

- [1] 鈴木淳晟ほか: 多相 CNN と人工造影 CT 画像を利用した腎腫瘍検出, 第 36 回人工知能学会全国大会予稿集 (2022)
- [2] N. Sassa et al.: Creation of Synthetic Contrast-Enhanced Computed Tomography Images Using Deep Neural Networks to Screen for Renal Cell Carcinoma. Nagoya Journal of Medical Science, Vol. 85, No. 4, pp. 713–724 (2023)

- [3] T. Tanaka et al.: Kidney Cancer Detection from CT images by Transformer-Based Classifiers. Proc. of IIAI-AAI 2023 (2023)
- [4] 深沢貴希ほか: 物体検出モデルによる造影・非造影 CT 画像からの腎腫瘍の検出. 情報処理学会第 86 回全国大会講演論文集 (2024)
- [5] S. Pavarut et al.: Improving Kidney Tumor Classification With Multi-Modal Medical Images Recovered Partially by Conditional CycleGAN, IEEE Access, Vol. 11, pp. 146250–146261 (2023)
- [6] V. Sandfort et al.: Data Augmentation Using Generative Adversarial Networks (CycleGAN) to Improve Generalizability in CT Segmentation Tasks. Scientific Reports, Vol. 9 (2019)
- [7] P. Russo et al.: From Source to Target and Back: Symmetric Bi-directional Adaptive GAN, Proc. of CVPR 2018, pp. 8099–8108 (2018)
- [8] J.-Y. Zhu et al.: Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks. Proc. of ICCV 2017 (2017)
- [9] I. L. Xi et al.: Deep Learning to Distinguish Benign from Malignant Renal Lesions Based on Routine MR Imaging. Clinical Cancer Research, Vol. 26, pp. 1944–1952 (2020)
- [10] Z. Wang et al.: Image Quality Assessment: From Error Visibility to Structural Similarity. IEEE Trans. on Image Processing. Vol. 13, No. 4 (2004)
- [11] W. Liu et al.: SSD: Single Shot MultiBox Detector, Proc. of ECCV 2016 (2016)
- [12] T. Lin et al.: Focal Loss for Dense Object Detection, Proc. of ICCV 2017 (2017)
- [13] N. Carion et al.: End-to-End Object Detection with Transformers, Proc. of ECCV 2020 (2020)
- [14] K. He et al.: Deep Residual Learning for Image Recognition, Proc. of CVPR 2016, pp. 770–778, (2016)
- [15] N.-C. Ristea et al.: CyTran: A Cycle-Consistent Transformer with Multi-Level Consistency for Non-Contrast to Contrast CT Translation. Neurocomputing, Vol. 538 (2023)
- [16] M. Ozbey et al.: Unsupervised Medical Image Translation with Adversarial Diffusion Models. IEEE Trans. on Medical Imaging, Vol. 42, No. 12, pp. 3524–3539 (2023)