CT 画像における複数スライスを用いた小疾病領域検出*

後藤拓矢 ** 中野宏毅 *** 山下 淳† 淺間 一†

Small Tumor Segmentation Using Multi-Slices in CT Image

Takuya GOTO, Hiroki NAKANO, Atsushi YAMASHITA and Hajime ASAMA

This paper proposes a novel method to improve auto detection of small tumors in segmentation of computed tomography (CT) images. For medical images, there is a high bias in a dataset that most parts of images are non-tumor. For recent tumor auto detection, convolutional neural network (CNN) is used. In these methods, small tumors are hardly detected because it is difficult to detect from only single slice image. In the proposed method, sequential multi-slices including a target slice image are used as an input patch. For training CNN model, a loss function called Multi-Slices (MS) loss which is calculated with several annotations of sequential multi-slices is proposed. By using multi-slices for segmentation of CT images, the segmentation model gets to recognize a small tumor which exists in sequential several slices. Our proposed method using multi-slices improves 5.9% in DICE coefficient compared with a conventional method using a single slice. This paper presents that the proposed method is effective for detection of small tumors.

Key words: computer vision, medical image processing, computed tomography, convolutional neural network, tumor segmentation

1. 序 論

医用画像から疾病領域を検出することは切除手術や治療の経 過を把握する上で重要である¹⁾. 複数の剪断画像を組み合わせ た Computed Tomography (CT) 画像は単一の画像と異なり 3 次元の情報を含むため,単一のスライスでは判別が困難な疾病 領域の検出が可能である.しかし,人手によって CT 画像から 疾病領域を検出することは多くのスライスを処理する必要があ り,より多くの負担を要する¹⁾.

人手による負担軽減のため,疾病領域の自動検出手法につい ての研究が多くなされている.近年では Convolutional Neural Network (CNN) により画像認識の性能が飛躍的に向上したこ とを受け、医用画像からの疾病領域においても CNN の適用が 盛んである. CT 画像を対象とした研究においても,2次元の畳 み込みを用いた CNN (2D-CNN)を3次元の畳み込みを用いた CNN (3D-CNN)に拡張することで従来の画像処理を用いた手 法から大きく精度が向上している²⁾³⁾.しかし,医療業界にお いて診断支援システムとして実用化するための明確な数値基準 はなく,精度はより高いほど読影医師の労力低減につながると 期待される. 医用画像では疾病ではない領域に比べて疾病領域 は小さく、学習データには偏りがある. CNN を用いた自動検 出では過学習により本来疾病領域である部分が False-Negative として検出されない場合が多く、とりわけ小さな疾病領域の検 出率が低いことが課題となっている.また,2D-CNNに比べて 3D-CNN は計算量が多く、必要とするリソースが多いため適用 が困難であるという課題がある.

本研究は、単一のスライスからは検出が困難な小さな疾病

† 正 会 員 東京大学大学院

領域の検出精度を改善することを目的とする.目的達成のた めに,CT 画像からの疾病領域検出において複数のスライスを 入力に用いる.また,入力したスライス間の関係性を考慮し て学習することで,疾病領域を空間的に捉えることが可能と なり,小さな疾病領域の検出が容易になる.提案手法では3 次元成分の学習のために複数のスライスを用いて損失を計算 する Multi-Slice Loss (MS Loss)を導入する.また,領域検出 のモデルは3D-CNNと比べて必要とする計算リソースが少な い2D-CNNで構成する.ここで,領域検出 CNNにおける前半 の特徴抽出を担う部分は Back Born とよばれる.3D-CNN を 2D-CNN とすることでパラメータ数が減り,Back Born の性能 が低下する.Back Born に ImageNet⁴⁾で事前学習した性能の 高い,軽量のモデルを適用する.領域検出の CNN は UNet++⁵⁾ をもとに設計する.

本研究は、肺や肝臓などの臓器を対象とし、小さな疾病領域 の検出が重要となるような腫瘍などの疾病領域の検出を対象と する.また、使用する CT 画像は対象臓器の検査を目的として 撮影された CT 画像を用いる.本研究は、一般に公開されてい るデータを用いて行われており、倫理委員会等の承認は不要で ある.

2. 関連研究

医用画像からの疾病領域の自動検出において用いられてきた CNN 以外による手法として, CRF⁶⁾ や GrabCut⁷⁾,動的輪郭 モデル⁸⁾⁹⁾ などが挙げられる.

CNN を用いた医用画像からの疾病領域の自動検出手法では, **UNet**¹⁰⁾ や DeepLabV3¹¹⁾, Mask RCNN¹²⁾ などといった様々 な領域検出のための CNN のネットワーク構造を医用画像に応 用する研究がなされてきた^{2)3)5)10)13)14).}

Çiçek らは MRI からの臓器領域検出において 3D-CNN を適 用し 2D-CNN による結果より検出精度が高いことを示した²⁾. しかし, 3D-CNN は入力サイズが大きくパラメータ数が多いた

^{*} 原稿受付 令和2年5月20日

掲載決定 令和 2 年 8 月 20 日

^{**} 学生会員 東京大学大学院(東京都文京区本郷 7-3-1)

め,計算リソースの制約により複雑な構造を適用することは困 難である.また,公開されている 3D-CNN のモデルは少なく, Back Born に事前学習済みのモデルを適用した転移学習による 学習時間の短縮ができないため学習に時間がかかるという課題 がある.Li らは CT 画像からの肝臓領域と肝腫瘍領域の検出 において 3D-CNN と 2D-CNN を組み合わせて共通の特徴抽出 に事前学習した 2D-CNN を用いる手法を提案した³⁾.しかし, 3D-CNN を用いている上に 2D-CNN も併用しているため,必 要な計算リソースは増えている.

Chlebus らは 3D-CNN ではなく 2D-CNN による結果を位置 や CT 画像における数値などの固定の特徴量によって事後処理 を行うことで False-Positive を減らす手法を提案した¹³⁾.しか し、事後処理にはあらかじめ設定した固定の特徴量のみを用い ているため、設定していない特徴を持つ疾病には対応できない という課題がある. また, 過学習により False-Negative として 検出されなかった疾病領域は事後処理の対象とはならないた め小さな腫瘍は検出が困難であるという課題がある. Cai らは CT 画像の疾病領域検出において複数のスライスから予測する ために、予測対象のスライスに加えて隣接するいくつかのスラ イスを組み合わせて入力に用いる手法を提案した¹⁴⁾.入力の 次元が増えてはいるが、2D-CNN を用いているため必要な計 算リソースは 3D-CNN に比べて少ない. しかし, 2D-CNN で は入力のスライス間の関係性を学習に考慮されないという課 題がある. Roth らは 2D-CNN を用いて 3 次元的な情報を用い た疾病の検出を行うために、注目画素における axial, sagittal, coronal の3 断面を入力する手法を提案した¹⁵⁾.注目する画素 ごとに出力を得る手法であるため、疾病の領域検出に適用する ためには、少なくとも対象とする臓器が含まれる全ての画素に 対して 2D-CNN に入力処理を行う必要がある.本研究で対象 とする肺や肝臓などの大きな臓器の場合は、含まれる画素数が 非常に多く、実行時間が増大し、学習および予測の実行が困難 であるという課題がある.

以上,従来研究には3次元方向の特徴抽出が可能である 3D-CNNにおいて必要とされるリソースが多いという問題と, 2D-CNNではスライス間の関係性を学習できないという問題 がありスライスにおける小さな疾病領域の検出が困難である. また,画素ごとに出力を得る手法では疾病領域の予測を得るた めの実行回数が膨大となるという問題があり領域検出への適 用が困難である.そこで,本研究はパラメータが少なく軽量な 2D-CNNのモデルにおいて,入力に複数の連続したスライスを 用いた上でそれらのスライス間の関係性を学習するための手法 を提案する.

3. 提案 手法

図1の左側に入力するスライスの例,右側に肝腫瘍の画像 診断における経験が豊富な医師によって作成された疾病領域 のアノテーションの例を示す.疾病領域は肝腫瘍領域である. 図1(a),(c),(e)は1つのCT画像における連続する3枚のスラ イスである.図1(b),(d),(f)はそれぞれ図1(a),(c),(e)のス ライスに対するアノテーションである.図1(a),(c),(e)に示 したように含まれる疾病領域が小さい場合,単一のスライスを 見ただけでは疾病領域であるのか,そのスライスのみに発生し たノイズであるかの判断は困難である.これは熟練の医師にお いても同様に単一のスライスから判定することは困難である. しかし,人は提示されたスライスが同一のCT画像における連



Fig. 1 Samples of input slices (a, c, e) and annotations of tumor (b, d, f)

続したスライスであることがわかれば,隣接する複数のスライ スを見て同一の形状の物が同じ位置に確認することで小さな領 域が疾病であると判断できる.本提案手法は,人が通常行って いる隣接したスライスを参考にしながらの疾病検出をモデルの 学習において実現し小さな疾病領域の検出性能を向上を行う手 法である.

ここで、CT 画像は撮影方法によってスライス間の距離が一 定ではないため、連続したスライスであっても、隣接したスラ イスがどの程度参考になるかは異なる. 医師らは経験により臓 器の形や位置が分かっているため、隣接したスライスがどの程 度参考になるかの判断が暗黙的に行える.一方で、自動で領域 検出を行うモデルでは入力するスライスには位置情報は含まれ ていないため、単に隣接したスライスを同時に入力として用い た場合においても、隣接したスライスがどの程度参考になるか の判断は困難である.したがって、複数のスライスを入力した うえで、入力スライス同士の関係性を学習に付加することが領 域検出モデルの性能を高めると考えられる.本提案手法では、 入力したスライス間がどの程度近いかという、スライスの関係 性を学習に考慮することを目的とした損失関数を導入する.

CNN では入力および中間から最終までの出力における画像 平面に対して鉛直方向の次元をチャネルと呼ぶ. 2D-CNN で は畳み込みの際に同一フィルタによって出力先の1つのチャネ ルに集約される.したがって、入力スライスごとの特徴は畳み 込み計算によって消失していく.ここで、UNet¹⁰⁾は入力画像 から特徴抽出を行うエンコード部と、抽出した特徴から領域検 出を行うデコード部をもつエンコード-デコード型の CNN で ある. また, UNet はデコード部においてエンコード部のいく つかの中間出力を直前の層からの出力に連結して入力する構造 を持つ、したがって、UNetの構造は畳み込み計算によって消 失していった入力スライスごとの特徴を CNN の後半部分で再 利用することができるため、複数のスライスをもとに領域検出 を行う上で有効であると言える. また, UNet 型の 2D-CNN で は注目するスライスを含む連続した複数のスライスを入力し, スライスごとに疾病領域の予測が得られる.対象とする臓器が 含まれるスライス数は画素数に比べて非常に少ないため, 画素 ごとに予測を得る手法と比べて疾病領域の予測を得るための実 行回数を大きく削減できる.しかし, UNet を含めた 2D-CNN には入力スライス同士がどの程度近いかという、入力スライス 間の関係性を学習に考慮する機構はない. そこで本手法では 2D-CNN に複数のスライスを入力するだけではなく、学習時の 損失関数において複数のスライス間の関係性を加味して複数の アノテーションから計算される Multi-Slice Loss (MS Loss) を 導入することで複数のスライス間の関係性を考慮する. 医用画 像では疾病ではない領域に比べて疾病領域は小さく、学習デー タには偏りがある.したがって、疾病領域のアノテーションと の比較した学習と比べて疾病領域以外との比較した学習が支配 的となり、結果的に全てを疾病領域以外として予測するという 過学習が起きやすい. MS Loss を用いることで, 隣接スライス にも同様に疾病領域があった場合には隣接スライスのアノテー ションとも比較しその分多くの学習効果が得られる.また、小 領域があるスライスにおいては見落とされアノテーションが付 加されていない場合、通常の交差エントロピーを用いた学習の 際にはアノテーションとの比較がされずそのスライスによる学 習が行われないが、MS Loss を用いることで隣接スライスにお けるアノテーションによって比較され、学習効果を得られる. 以上から, MS Loss を一般的な交差エントロピー損失(BCE Loss)に加えて用いることで、損失関数に空間的に制約を設け ることで過学習を防ぐ効果が期待できる.

本研究では,領域検出ネットワークとして 2D-CNN である UNet++ ⁵⁾をもとに作成する.UNet++ は 2D-CNN で構成さ れるため 3D-CNN に比べて必要な計算リソースは少ない.ま た,Back Born 部分には事前学習した EfficientNet ¹⁶⁾を用いる. EfficientNet は Zhou ら ⁵⁾が Back Born に用いた ResNet ¹⁷⁾よ りパラメータ数が少ないためより軽量な 2D-CNN である.ま た,ImageNet における性能は ResNet より高い.

図2に2D-CNNの学習における損失の計算方法の比較を示 す.一般的な学習手法では予測対象となる単一のスライスを入 力し,出力される疾病領域の予測と予測対象のスライスに対す る教師データにおけるアノテーションを比較することで損失を 計算する. Cai ら¹⁴⁾による複数のスライスを入力する手法で は予測対象のスライスと隣接するスライスの複数のスライスを 入力し,出力される対象のスライスに対する疾病領域の予測と 対象のスライスの教師データにおけるアノテーションを比較し 損失を計算する.一方で提案手法では予測対象のスライスと隣 接するスライスの複数のスライスを入力し,対象のスライスに 対する疾病領域の予測と対象のスライスおよび隣接するスライ スに対する複数の教師データにおけるアノテーションを比較す



Fig. 2 Comparison of methods to calculate training loss

ることで損失を計算する.したがって,提案手法では 2D-CNN においても複数のスライスを用いて 3 次元的に損失を計算する ことができる.単一のスライスにおいて疾病領域が小さい場合 にも,複数のスライスにまたがって存在している疾病領域と比 較することでバイアスをかけて学習できる.

以上を踏まえ,本研究では式 (1), (2) によってスライス X_i に対する疾病領域の予測 $\hat{Y_i}$ を得る.

$$\hat{Y}_i = f(\mathbf{X}_{i,s}, \theta), \tag{1}$$

 $\mathbf{X}_{i,s} = \{X_{i-s}, X_{i-s+1}, \dots, X_i, \dots, X_{i+s-1}, X_{i+s}\},$ (2) ここで $f(\mathbf{X}_{i,s}, \theta)$ はスライスの集合 $\mathbf{X}_{i,s}$ を 2D-CNN に入力し 出力としてスライス X_i に対する疾病領域の予測 \hat{Y}_i を得る処 理を示し, θ は 2D-CNN において学習によって調節されるパラ メータを示す. X_i は CT 画像における最初のスライスを 0 と し, 順に数えた際の *i* 番目のスライスを示す.

また, Multi-Slice Loss を式 (3), (4), (5) によって定義する.

$$\mathcal{L}_{ms} = \sum_{t} w(X_i, X_{i+t}) \operatorname{bce}(\hat{Y}_i, Y_{i+t}),$$
(3)

$$t \in \{-d, -d+1, \cdots, -1, 1, \cdots, d-1, d\},$$
(4)

$$w(X_i, X_{i+t}) = \exp(-\lambda \operatorname{dis}(X_i, X_{i+t})), \tag{5}$$

ここで $w(X_i, X_{i+t})$ は、 $X_i \ge X_{i+t}$ から式(3)によって定義さ れるスライス間の関係性を表す重みである. Y_i はスライス X_i に対応する教師データのアノテーションを示す. Yi は,疾病領 域であれば1それ以外であれば0で定義される. bce(\hat{Y}_i, Y_{i+t}) はスライス画像 X_i に対する予測 \hat{Y}_i とアノテーション Y_{i+t} から計算される交差エントロピー損失関数を示す. ここで $dis(X_i, X_{i+t})$ はスライス X_i, X_{i+t} の類似度を示す.対象臓 器を目的とした CT 画像の場合,検査精度を高くするために対 象となる臓器に関して隣接するスライスにおける変化が小さく なるようなスライス厚で撮影されると考えられる. したがっ て、スライスの距離が比較的近いスライスにおいては含まれる 臓器の位置は変化せず,大きさが変化することが多い. 臓器の 大小によって類似度を変化させるために、類似度の計算の際に スライスを Oriented FAST and Rotated BRIEF (ORB)¹⁸⁾を用 いてベクトル化する. ORB はベクトルの各要素が2値となる ベクトル化であるため、類似度はベクトル間のハミング距離を 用いる.ハミング距離は2値のベクトルに対して値の異なる要

素数を距離としたものである.また,総当たりマッチングによる最小のハミング距離をスライス間の類似度とする. λ は距離の正規化パラメータを示す. λ が大きいほどスライスの距離に対する感度が大きくなる.学習時には式(6)で示した MS Lossに予測対象のスライス X_i に対する予測 \hat{Y}_i と, X_i に対応する教師データのアノテーション Y_i との交差エントロピーを加えた損失関数を最小化するように 2D-CNN の重みを更新する.

$$\mathcal{L} = \operatorname{bce}(\hat{Y}_i, Y_i) + \alpha \mathcal{L}_{ms},\tag{6}$$

ここで α は全体の損失関数における MS Loss の重みを示す. MS Loss は予測として出力される対象スライスのアノテーショ ンではなく,隣接するスライスに対するアノテーションと比較 して計算する.したがって,αが大きすぎると教師データにお ける真のアノテーション部分の学習を妨げる恐れがある.この 重みはハイパーパラメータであり,適切な値を選択する必要が ある.本研究では BCE Loss と MS Loss の影響を同程度となる 値を用いる.

4. 評価実験と結果

4.1 評価実験の設定

本研究は LiTS Challenge¹⁾ で一般に公開されている LiTS データセットを用いる.LiTS データセットは腹部 CT 画像と 肝臓および肝腫瘍の領域のアノテーションを含む.それぞれ の縦横の画素数は 512 × 512 で空間分解能は 0.56mm から 1.00mm である.スライス厚は 0.45mm から 6.00mm である. 本研究では LiTS データセットにおける肝腫瘍を含む 118 セッ トの肝臓部分のみを用いる.さらに含まれる肝腫瘍の画素数の 分布が均一になるようにトレーニング用,テスト用に分割し, 学習にはトレーニング用のデータセットのみを用いる.表1 に トレーニング用,テスト用に分割したデータセットそれぞれに おける CT 画像数,スライス数,最大肝腫瘍画素数,最小肝腫 瘍画素数,平均画素数を示す.また,本研究では LiTS データ セットにおける肝腫瘍のアノテーションのみを用いる.

Back Born である EfficientNet には ImageNet データセット によって事前学習した EfficientNet B4* を用いる. トレーニン グ用データセットは肝腫瘍の画素数の分布が均一になるように トレーニング用とバリデーション用に4:1の割合で分割し, 5-fold の交差検証を行う. 学習はミニバッチで行い, バッチサ イズは8とし, 50 エポック行う.

提案手法の式 (2), (4), (5), (6) におけるパラメータはs = 1, d = 2, $\lambda = 0.5$, $\alpha = 0.25$ とする.また,入力するスライスに は学習時ランダムな上下の平行移動,拡大,回転などの処理を 加え,対応するアノテーションにも同様に処理を加える.

評価時には予測値 \hat{Y}_i における閾値 p 以上である領域を予測 領域とする.評価指標にはスライスごとの Precision, Recall, F 値および DICE 係数を平均した, Mean Average Precision (MAP), Mean Average Recall(MAR), Mean Average F1(MAF), mean DICE coefficient (mDICE) を用いる.評価時における閾 値 p は学習した 2D-CNN にバリデーションデータセットを入 力し mDICE が最も大きくする p を選択する.

実験はオープンソースとして公開されている TensorFlow** および Keras*** を用いて実装し,NVIDIA Titan RTX 上で実行 する.

Table 1 Statistical information of dataset

	Training	Test
Number of CT images	98	20
Number of slice images	8065	1478
Max. tumor size in a slice (pixels)	1.91×10^6	1.45×10^6
Min. tumor size in a slice (pixels)	298	98
Mean tumor size in a slice (pixels)	1.61×10^{5}	1.45×10^{5}

Table 2 Results of experiment

Method	MAP	MAR	MAF	mDICE
2D input with BCE Loss	0.783	0.618	0.558	0.558
3D input with MS Loss (ours)	0.840	0.614	0.591	0.591

4.2 実験結果

実験結果を表 2 に示す. 2D input は単一スライス入力を示 し, 3D input は予測対象のスライスとその隣接する前後 1 ス ライスを加えた 3 スライスを入力することを示す. BCE Loss は学習時に損失関数に交差エントロピーを用いたことを示し, MS Loss は提案手法における式 (4) を用いたことを示す. 2D input with BCE Loss は一般的な 2D-CNN における手法のため, 従来手法である.

MAR 以外の評価手法において提案手法による結果が高く なっていることがわかる.実験結果における MAP を比較す ると,3D input with MS Loss では 0.840 となっており,およ そ7.2% の改善がみらた.一方で,MAR については従来手法 では 0.618 に対して,提案手法では 0.614 と 0.7% の精度の低 下がみられたが,MAP の精度改善の割合が大きい.実際に, Precision, Recall の総合的評価基準である F1 値の平均の MAF は従来手法で 0.558 であるのに対して,提案手法では 0.591 と およそ 5.9% 改善している.領域検出の確からしさを測るため に広く用いられている DICE 係数の平均値である mDICE に関 しても,従来手法では 0.558 であるのに対して,提案手法では 0.591 となっており,およそ 5.9% の精度の改善がみられた.

図 3 にテストデータセットにおけるそれぞれの手法における予測結果の一部を示す.図 3(a) は予測対象のスライス, 図 3(b) は LiTS データセットにおける図 3(a) の肝腫瘍領域を 示す Ground Truth,図 3(c) は予測対象のスライスのみを入力 し BCE Loss を用いて学習したモデルによる図 3(a) に対する予 測結果,図 3(d) は予測対象のスライスと隣接する前後の 2 枚 のスライスを入力し MS Loss を用いて学習したモデルによる 図 3(a) に対する予測結果を示す.スライスに対する予測結果 を見ると提案手法では従来手法に比べて予測している領域が大 きいことがわかる.また,従来手法では検出できなかった小さ な肝腫瘍領域が提案手法では検出できていることがわかる.

5.考察

MS Loss を導入することによる小さな疾病領域の検出におけ る効果を考察する.

4 章における従来手法である 2D input with BCE Loss で学習 したモデルと,提案手法である 3D input with MS Loss で学習

^{*} https://github.com/qubvel/efficientnet

^{**} https://www.tensorflow.org/

^{***} https://keras.io/



(c) 2D input with BCE Loss

Fig. 3 Segmentation results

したモデルそれぞれによるテストデータに対する疾病領域の検 出の結果を, Ground Truth における疾病領域の大きさごとに比 較する.図4にスライスにおける疾病の領域面積が1000 画素 以下の疾病領域に対して面積ごとに検出率を集計した結果を示 す. 集計時には Ground Truth の疾病領域と予測領域が一致し た部分があれば検出したとみなす.疾病対象のスライスに対す るアノテーションのみから計算する BCE Loss を用いて学習し た場合より、複数のスライスを入力し、複数のアノテーション 画像から計算する MS Loss を用いて学習した場合の方が大き さによらず検出率が高い.また、疾病領域の面積が100 画素以 下のスライスに対しては BCE Loss を用いた場合には全く検出 できていないため、小さな疾病領域は単一スライスからでは検 出が困難であることがわかる.一方で、MS Loss を用いること で面積が100 画素以下の疾病領域も検出できている. 使用し た LiTS データセットにおけるスライスの分解能は最大 1mm であるため、領域面積が100 画素の疾病領域は断面積が1 cm² 以下の腫瘍である.

以上より, MS Loss を導入することによって単一のスライ スからは検出が困難な小さな疾病領域を検出できるように なった.

6. 結 論

本論文では、単一のスライスからは検出が困難な小さな疾病 領域の検出精度を改善した.提案手法では小さな疾病領域を検 出するために複数のスライス画像を入力として用いた.また、 CT 画像からの疾病領域検出において 2D-CNN である UNet++ を用いて 3 次元情報を学習するために MS Loss を提案した. 肝腫瘍のセグメンテーション用データセットである LiTS デー タセットを用いた実験では、従来の単一のスライスのみを用い た手法と比べて、提案手法を適用することで DICE 係数の平均 が 5.9% 改善することを確認し、疾病領域の検出精度が向上す ることを示した.従来手法から大きく領域検出の精度が向上 したことから、医師のための診断支援システムの実用化の一 助となると考えられる.一方で、Chlebus らによると、複数の 熟練の読影医師らによって CT 画像に対して肝腫瘍のアノテー ションを実施し教師データと比較したところ DICE 係数の平均 が従来手法からおよそ 37% 高いという調査結果が得られてい



Fig. 4 Detection rate per range of tumor size

る¹³⁾.本研究における実験とは比較した従来手法,テストデー タおよび評価手法が異なるため,直接比較することはできない が,提案手法による疾病の領域検出と熟練の読影医師による診 断とではまだ精度に開きがあると考えられる.したがって,医 師の診断支援として実用化のためにはにはより一層の精度改善 が必要である.

今回,提案手法の導入により予測が可能となった小さな疾病 領域は,形状の面では依然として読影医師の作成した疾病領域 と乖離がある.疾病の有無を医師に提示する目的の場合には, 検出精度が高い本手法は有用な診断支援ができる.しかし,疾 病の大きさを測る目的の場合には,予測領域をより精緻化す る必要がある.また,提案手法には入力するスライス数,MS Loss の計算に用いるスライス数,および MS Loss における正 規化パラメータ λ や全体の損失関数における MS Loss の重み αといった調節可能なパイパーパラメータが含まれる.これら のハイパーパラメータを調節することは,学習時間が大きく増 加するため実現が困難である.効率的なハイパーパラメータの 調節が今後の課題である.

また, Roth ら¹⁵⁾ による方向の異なる複数の断面を入力する 手法との定量的な精度の比較は,実行時間が膨大であることか ら行っていない. Roth らによる手法を領域検出が実用可能な 時間内で行えるように改善した上での精度比較が課題である.

参考文献

- P. Bilic, P.F. Christ, E. Vorontsov, G. Chlebus, H. Chen, Q. Dou, C.W. Fu, X. Han, P.A. Heng, J. Hesser et al.: The Liver Tumor Segmentation Benchmark (LiTS), arXiv preprint arXiv:1901.04056, (2019).
- 2) Ö.Çiçek, A. Abdulkadir, S. Lienkamp, T. Brox, O. Ronneberger: 3D U-net: Learning Dense Volumetric Segmentation from Sparse Annotation, In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, (2016) 424.
- X. Li, H. Chen, X. Qi, Q. Dou, C. W.Fu, P.A. Heng: H-DenseUNet: Hybrid Densely Connected Unet for Liver and Tumor Segmentation from CT Volumes, IEEE Transactions on Medical Imaging, 37, 12 (2018) 2663.
- 4) J. Deng, W. Dong, R. Socher, L. Li, K. Li, L. Fei-Fei: ImageNet: A large-scale hierarchical image database, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, (2009) 248.
- 5) Z. Zhou, M.M. Rahman Siddiquee, N. Tajbakhsh, J. Liang: Unet++: A Nested U-net Architecture for Medical Image Segmentation, In Proceedings of Deep Learning in Medical Image Analysis and Multimodal

Learning for Clinical Decision Support, 11045, (2018) 3.

- 6) P. Krähenb, K. Krähenbühl, V. Koltun: Efficient Inference in Fully Connected CRFs with Gaussian Edge Potentials, In Proceedings of Advances in Neural Information Processing Systems, (2011) 109.
- C. Rother, V. Kolmogorov, A. Blake: GrabCut: Interactive Foreground Extraction Using Iterated Graph Cuts, ACM Transactions on Graphics, 23, 3 (2004) 309.
- 8) 清水 昭伸, 松坂 匡芳, 長谷 川純一, 鳥脇 純一郎, 鈴木 隆一郎: 動的輪 郭モデルを用いた輪郭線抽出手順の自動構成と胸部 X 線像上の肺輪 郭線抽出への応用, コンピュータ支援画像診断学会論文誌, 1, 1 (1997) 1
- S. Dai, K. Lu, J. Dong, Y. Zhang, Y. Chen: A Novel Approach of Lung Segmentation on Chest CT Images Using Graph Cuts, Neurocomputing, 168, (2015) 799.
- O. Ronneberger, P. Fischer, T. Brox: U-Net: Convolutional Networks for Biomedical Image Segmentation, In Proceedings of the International Conference on Medical Image Computing and Computer Assisted Intervention, (2015) 234.
- L.C. Chen, Y. Zhu, G. Papandreou, F. Schroff, H. Adam: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, In Proceedings of the European Conference on Computer Vision, (2018) 801.
- K. He, G. Gkioxari, P. Dollár, R. Girshick: Mask R-CNN, In Proceedings of the IEEE International Conference on Computer Vision, (2017)

2961.

- 13) G. Chlebus, A. Schenk, J. H. Moltz, B. van Ginneken, H. K. Hahn, H. Meine: Automatic Liver Tumor Segmentation in CT with Fully Convolutional Neural Networks and Object-Based Postprocessing, Scientific Reports, 8, 15497 (2018).
- 14) J. Cai, Y. Tang, L. Lu, A. P. Harrison, K. Yan, J. Xiao, L. Yang, R. M. Summers: Accurate Weakly Supervised Deep Lesion Segmentation on CT Scans: Self-Paced 3D Mask Generation from RECIST, arXiv preprint arXiv:1801.08614, (2018).
- 15) H. R. Roth, L. Lu, A. Seff, K. M. Cherry, J. Hoffman, S. Wang, J. Liu, E. Turkbey, R. M. Summers: A New 2.5D Representation for Lymph Node Detection Using Random Sets of Deep Convolutional Neural Network Observations, In Proceedings of the International Conference on Medical Image Computing and Computer Assisted Intervention, (2014) 520.
- 16) M. Tan, Q. Le: EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, In Proceedings of the International Conference on Machine Learning, (2019) 6105.
- 17) K. He, X. Zhang, S. Ren, J. Sun: Deep Residual Learning for Image Recognition, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, (2016) 770.
- 18) E. Rublee, V. Rabaud, K. Konolige, G. Bradski: ORB: An Efficient Alternative to SIFT or SURF, In Proceedings of the IEEE International Conference on Computer Vision, (2011) 2564.