

## 改良型 U-Net を用いた胸部 CT 画像からの肺腫瘍領域の自動識別

### Automatic Identification of Lung Tumor Regions from Thoracic CT Images Using Improved U-Net

高橋 礼生\*, 神谷 亨\*, 寺澤 岳\*\*, 青木 隆敏\*\*

\*九州工業大学, \*\*産業医科大学

Reo Takahashi\*, Tohru Kamiya\*, Takashi Terasawa\*\*, Takatoshi Aoki\*\*

\*Kyushu Institute of Technology, \*\*University of Occupational and Environmental Health

E-mail address: takahashi.reo828@mail.kyutech.jp

#### 1. はじめに

がんは体のあらゆる部位に発症する病気で、異常な細胞が分裂し、制御不能な状態で増殖を続ける。がんは世界的な死因の第一位であり、2020 年には約 1000 万人が死亡した。このうち 180 万人が肺がんによる死亡であり、がんの部位別死亡原因の第一位となっている[1]。肺がんの 5 年生存率は 18.6%で、他の主要ながん部位と比べて低い[2]。したがって、肺がんの早期発見と早期治療は重要な課題である。

肺がんが疑われた場合、まず胸部 X 線検査が行われ、異常が見つかれば CT 検査や気管支鏡検査(生検)が行われ、治療方針が決定される。主な治療法には、手術、放射線療法、薬物療法がある。薬物療法では、ドライバー遺伝子変異の有無により分子標的薬が使用できるかどうかの重要な判断材料となる。通常の抗がん剤治療では、がん細胞以外の正常細胞に影響を及ぼすという問題があるが、がん細胞の増殖や転移に関与するドライバー遺伝子に変異があれば、標的細胞を狙い撃ちする分子標的薬の使用が可能である。

ドライバー遺伝子変異の有無は、一般的に生検によって判定される。生検とは病変部から組織の一部を切り出し、顕微鏡で観察する検査である[3]。この検査には非効率性や身体的負担など多くの欠点があり、非侵襲的で迅速かつ低コストの生検に代わる検査法が求められている。

一方、前述の問題点を解決するために、コンピュータ支援診断(Computer Aided Diagnosis: CAD)が研究されている[4]。CAD とは、第二の意見として、放射線画像を含む医療画像をコンピュータで定量的に解析する医師支援診断システムである。前述の先行研究の流れを簡単に説明すると、まず胸部 CT 画像から医師と協力して手作業で腫瘍部分を抽出する。医師と協力して手作業で腫瘍部分を抽出することは、読影医師の負担が増える、腫瘍を見落とすなどの問題がある。

そこで本論文では、CAD システムの一つとして、胸部 CT 画像から深層学習により肺腫瘍領域を自動抽出する手法を提案する。従来手法[5]では、円形や楕円形といった腫瘍の抽出精度は高いが、小さい腫瘍に対しての抽出精度が低いという課題があった。そこで、本論文の提案手法は深層学習によるセグメンテーション手法の一つで

ある U-Net をベースに改良を行い、新たにアンサンブル学習を取り入れることで、小さい肺腫瘍領域に対しても精度の高いセグメンテーションを行う手法を提案する。本論文では、提案手法を胸部 CT 画像に適用し、モデルの評価を行い、結果を考察し、その有用性を示す。

#### 2. 手法

本論文では、肺腫瘍領域の自動抽出に改良型 U-Net を用いる。本手法の流れを簡単に説明する。まず、胸部 CT 画像の前処理により入力画像とラベル画像を作成する。次に、未知の画像から肺がんを抽出するために提案モデルを構築する。具体的な詳細は後述する。

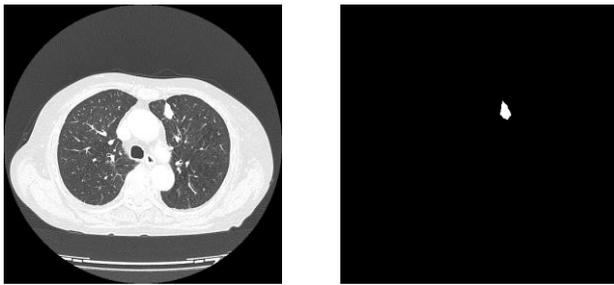
##### 2.1 画像生成

本論文では、産業医科大学病院で収集された DICOM(Digital Imaging and Communications in Medicine)の患者胸部 CT 画像を BMP 形式に変換した画像を入力画像とする。図 1(a)は実際に BMP 形式に変換された入力画像の例である。次に、入力画像からラベル画像を作成する。具体的には、入力画像から肺腫瘍部分に注釈をつけ、医師がその結果を確認し、必要であれば修正する。図 1(b)は、腫瘍領域にアノテーションを施して作成したラベル画像の例である。

##### 2.2.1 U-Net

U-Net[6]は、医用画像分野におけるセマンティックセグメンテーションに有効であると考えられている CNN の一つであり、2015 年に MICCAI(Medical Image Computing Computer Assisted Intervention)で提案されたモデルである。U-Net は FCN(Fully Convolution Network)と同様に、エンコーダとデコーダから構成され、エンコーダが特徴抽出を行い、デコーダがアップサンプリングを行い、エンコーダで抽出された特徴を保持して画像の再構成を行う。この構造をスキップコネクションと呼ぶ。この構造により、同じ次元の特長マップを連結することができ、より正確なセグメンテーションのために、ダウンサンプリングによって失われた特徴を保持することができる。また、U-Net は end-to-end で学習されるため、少ないデータ数でも正確なセグメンテーションが可能である。U-Net は医療

あるのかについて焦点を当てることが可能となり、認識率が向上すると考え、本論文に採用した。



(a) 入力画像 (b) 正解画像

図 1 使用したデータの一部

分野で有効であるため、本論文の胸部 CT 画像に適した手法として用いる。

### 2.2.2 CBAM

CBAM(Convolutional Block Attention Module)[7]は 2018 年に提案されたモデルで、特徴マップから channel と spatial の 2 次元に沿った attention マップを推定し、特徴マップと attention マップを掛け合わせて新たな特徴マップを作成する。

CBAM は channel と spatial の二つの次元から特徴マップに重みをつけることで情報価値の高い有益な情報を強調することが可能となり、また他の無駄な情報を抑制できることが特徴である。さらに、二つの次元を用いることにより、入力画像に対して「何」があるのか、「どこに」

### 2.2.2 MultiRes Block

本論文で使用した胸部 CT 画像中の肺腫瘍は形も大きさも不規則であり、従来の固定スケールの CNN では受容野の範囲が限定されるため、十分な微量を抽出できない可能性がある。そこで、複数のスケールから特徴抽出が可能な MultiRes Block[8]を導入した。

MultiRes Block は  $3 \times 3$  の畳み込みが直列に接続された構造を持つ。入力から得られた特徴マップは、最初の  $3 \times 3$  畳み込みで保持され、2 番目の  $3 \times 3$  畳み込み層に渡される。  $3 \times 3$  の畳み込みは 2 回行なわれるので、畳み込みは実際には  $5 \times 5$  の畳み込みに近似する。次に、各スケールで得られた特徴マップを  $7 \times 7$  畳み込みに相当する 3 層目の  $3 \times 3$  畳み込みを通して連結し、最終出力を得る。

### 2.2.3 提案手法

本論文では、先行研究である Improved U-Net[5]を基本モデルとして、さらにそれらのモデルを大域的なセグメンテーションに特化した U-Net と局所的なセグメンテーションに特化した U-Net をアンサンブル学習[9]させた新たなネットワークを構築する。先行研究では、肺腫瘍のスケールの違いに対しては MultiRes Block によって対応しているが、それだけでは小さな肺腫瘍に対するアプローチとしては不十分であると考えた。そこで、新たに局所的なセグメンテーションに特化したモデルを構築す

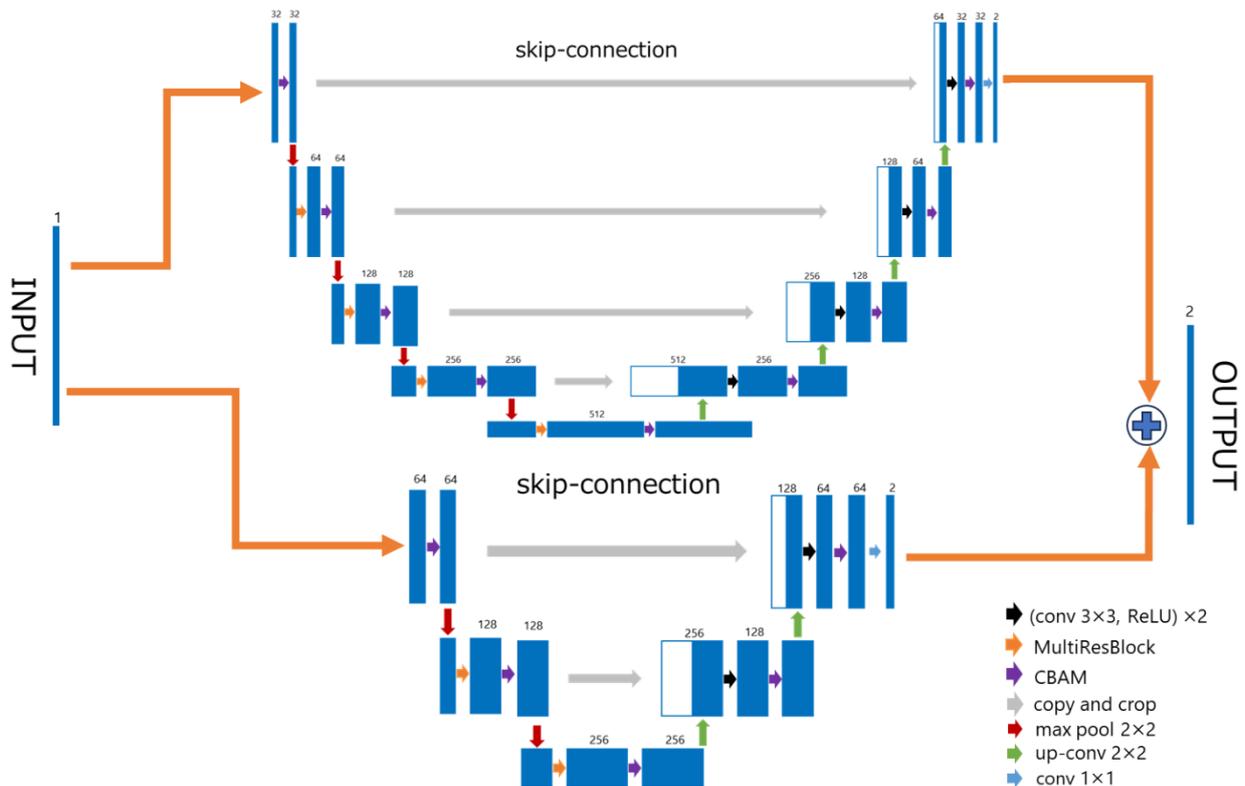


図 2 提案手法の全体構図

ることにより、小さな肺腫瘍の抽出精度が向上すると予測した。本論文では、図 2 のように大局的なセグメンテーションに特化した 5 層のモデルと、敢えて層を浅くした局所的なセグメンテーションに特化したモデルをアンサンブルしたモデルを提案し、どのようなスケールの腫瘍に対しても抽出精度が向上すると考えた。

### 3. 実験と結果

#### 3.1 評価方法

本論文で提案した深層学習モデルの検証のため、5 分割交差検証により、「Dice」と「IoU」を求め、その平均値を算出した。5 分割交差検証とは、データをランダムに 5 分割し、そのうち 1 組をテスト用、残りの 4 組を訓練用とし、テスト用の組を入れ替えながら 5 回の検証を行う。この検証方法により、汎化性能を評価することができる。本論文で使用した画像は産業医科大学病院で収集したもので、230 症例の CT 画像から得た 850 枚の画像を用いた。

#### 3.2 実験結果

U-Net をベースモデルとし、CBAM と MultiRes Block を追加した先行研究のモデルである improved U-Net、そして、両方追加したモデルと構造は同様で、局所的なセグメンテーションを行うために敢えて層を浅くしたモデルをアンサンブル学習させて得られた提案手法の評価実験を行う。各モデルの抽出精度を表 1~3 に示す。また、表 4 に平均値を求めた結果を示す。表 4 から Dice=0.899, IoU=0.832 を得た。

#### 3.2 考察

本論文では、胸部 CT 画像から得られる 2 次元画像に対し、肺腫瘍の自動抽出と評価を行った。その結果、表より、ベースモデルの U-Net とベースモデルに CBAM と MultiRes Block を追加した Improved U-Net、そして本論文の提案手法と比較した結果、提案手法では Dice, IoU とともに最も良好な結果を得た。図 3 は、提案手法によって抽出に成功したケースの一つである。赤色がアノテーション領域で、青色がモデルの抽出領域である。表 3(c)のベースモデルである U-Net に CBAM と MultiRes Block を導入した improved U-Net では、小さい腫瘍に対して全く抽出ができていない一方で、表 3(d)の今回の提案手法ではおおよその抽出に成功している。提案手法のみで抽出が成功した理由としては、新たに局所的なセグメンテーションに特化した層の浅いモデルを取り入れたことにより、ダウンサンプリングによる画像の解像度の低下が少なく、高解像度で詳細な情報が維持される。そのため、小さい肺腫瘍のような細かい情報を識別する際に有用な特徴を抽出することができ、提案手法のみで抽出に成功したと考えられる。次に提案手法を用いても抽出に失敗

表 1 U-Net の抽出結果

	Dice	IoU
dataset1	0.851	0.785
dataset2	0.806	0.718
dataset3	0.835	0.762
dataset4	0.801	0.739
dataset5	0.857	0.782
average	0.830	0.757

表 2 Improved U-Net[5]の抽出結果

	Dice	IoU
dataset1	0.878	0.807
dataset2	0.882	0.809
dataset3	0.904	0.835
dataset4	0.856	0.782
dataset5	0.896	0.830
average	0.883	0.813

表 3 提案手法の抽出結果

	Dice	IoU
dataset1	0.892	0.825
dataset2	0.881	0.812
dataset3	0.912	0.845
dataset4	0.902	0.836
dataset5	0.909	0.844
average	0.899	0.832

表 4 各モデルの平均抽出結果

	Dice	IoU
U-Net	0.830	0.757
Improved U-Net[5]	0.883	0.813
Proposed method	<b>0.899</b>	<b>0.832</b>

したケースを図 4 に示す。図 4(c), (d)のように、異形を有している肺腫瘍に対して、提案手法とその他のモデルを比較しても、どの手法でも精度の良い抽出ができていないことがわかる。これは主に原因として二つ考えられる。一つ目は、不規則な形状を持つ肺がんは、一般的な円形や楕円形のような容易な形状よりも特徴が複雑であるため、学習が難しいことが考えられる。二つ目は、このような形状のデータが不足していることである。一般的にはデータが多いほど精度が向上するが、不規則な形状の肺がんがデータセット内に十分に含まれておらず、このようなケースに対する精度が低下したと考えられる。そこで、複雑な形状の抽出精度を向上させるために、敵対的生成ネットワークにより新たに画像を生成し、データの偏りを無くしたいと考えている。また、それぞれの腫瘍の形状(nodule, specula, ggo)に対してそれぞれの学習

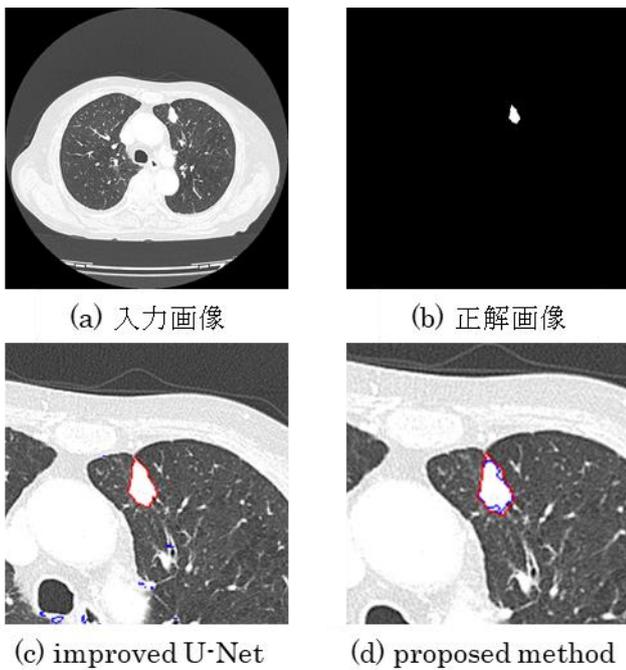


表 3 抽出の成功例

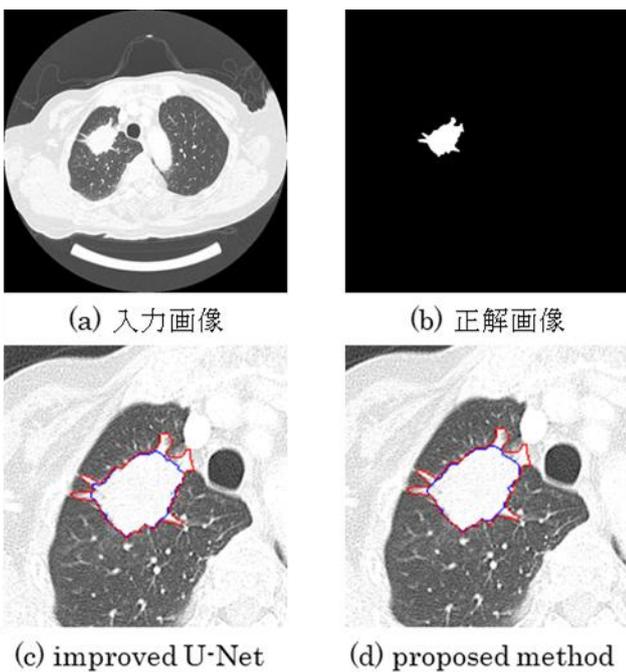


表 4 抽出の失敗例

機を構築しそれらをアンサンブル学習させることで、さらなる精度の向上が期待される。

#### 4. おわりに

本論文では、CAD による肺腫瘍領域の自動抽出を可能とするため、改良型 U-Net による胸部 CT 画像からの肺腫瘍領域のセグメンテーション手法を提案した。

認識手法として、U-Net に CBAM と MultiRes Block を追加し、この構造の 5 層と 3 層の U-Net をアンサンブル

学習させ、新たなモデルを構築した。層数の異なるモデルをアンサンブルさせることで、大局的なセグメンテーションと局所的なセグメンテーションに特化したモデルを構築することができ、小さい腫瘍に対しての抽出精度が向上すると考えた。評価には Dice と IoU を用い、5 分割交差検証を行った。その結果、Dice=0.899、IoU=0.832 となり、提案手法が最も精度の良い抽出が可能となった。

今後の課題としては、データセットの拡大とネットワークの改良を考えている。現在の課題として、異形を有した肺腫瘍に関しては抽出精度が低いことが挙げられる。そこで、敵対的生成ネットワークによるデータ拡張や、それぞれの腫瘍の形状に特化したネットワークを構築することにより、抽出精度を向上させたいと考える。

#### 参考文献

- [1] Cancer, <https://www.who.int/news-room/fact-sheets/detail/cancer> (2023/09/12/access).
- [2] Survival Rates <https://www.lung.org/lung-health-diseases/lung-disease-lookup/lung-cancer/resource-library/lung-cancer-fact-sheet#:~:text=The%20five-year%20survival%20rate,rate%20is%20only%205%20percent> (2023/09/12/access).
- [3] General Biopsy <https://www.radiologyinfo.org/en/info/biopsen> (2023/09/12/access).
- [4] S. Watanabe et al., “Detection of Driver Gene Mutations from Thoracic CT Images Based on Light GBM with Radiomics Features”, International Conference on Control, Automation and Systems, pp.542-545, 2022.
- [5] R. Takahashi et al., “Extraction of Lung Tumor Regions from Thoracic CT Images Using An Improved U-Net”, International Conference on Control, Automation and Systems. pp.1489-1493, 2023.
- [6] O. Ronneberger et al., “U-Net : Convolutional networks for biomedical image segmentation”, International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer, Cham, pp.234-241, 2015.
- [7] S. Woo et al., “Cbam : Convolutional block attention module”, European Conference on Computer Vision, pp.3-19, 2018.
- [8] N. Ibtihaz et al., “MultiResUNet : Rethinking the U-Net architecture for multimodal biomedical image segmentation”, Neural Networks, Vol.121, pp.74-87, 2020.
- [9] H. Tang et al., “Automatic Lumbar Spinal CT Image Segmentation with a Dual Densely Connected U-Net”, IEEE Access, Vol.8, pp.89228-89238, 2020.