

# CNN, FCN, U-Net を用いたびまん性肺疾患の領域抽出の比較

## Comparison of extraction of diffuse lung disease areas using CNN, FCN and U-Net

村上 佳菜子\*<sup>1</sup>  
Kanako Murakami

橋本 典明\*<sup>1</sup>  
Noriaki Hashimoto

木戸 尚治\*<sup>1</sup>  
Shoji Kido

平野 靖\*<sup>1</sup>  
Yasushi Hirano

間普 真吾\*<sup>1</sup>  
Shingo Mabu

近藤 堅司\*<sup>2,3</sup>  
Kenji Kondo

小澤 順\*<sup>2</sup>  
Jun Ozawa

\*<sup>1</sup> 山口大学大学院創成科学研究科

Graduate school of Sciences and Technology for Innovation, Yamaguchi University

\*<sup>2</sup> 産業技術総合研究所  
Advanced Industrial Science and Technology

\*<sup>3</sup> パナソニック株式会社  
Panasonic Corporation

In recent years, a lot of analytical methods of medical images using deep learning are suggested. Especially, convolutional neural network (CNN) is a model generally used in image recognition. When we classify diffuse lung disease (DLD) patterns using CNN, it is necessary to set region-of-interests (ROIs) on CT images. However, detection is important on diagnosis of DLD as same as classification. So, we propose a method to detect DLD opacities and extract DLD areas without setting ROIs. In this study, we evaluated detection methods of DLD areas using CNN, FCN and U-Net.

## 1. はじめに

びまん性肺疾患とは、肺の広範囲に渡って病変が広がる疾患の総称である。CT(Computed Tomography)画像におけるびまん性肺疾患の異常陰影は非常に多彩であるため、疾患の診断は医師の経験や主観に左右される。また、CT装置の進歩に伴って、CT画像の枚数が増加し、診断する医師の負担が増加している。そのため、コンピュータ支援診断(Computer-aided Diagnosis:CAD)システムの必要性が高まっている。近年、CADシステムにおいてDeep Learningを用いる手法が多く提案されている[1][2]。Deep Learningの手法の一つにCNN(Convolutional Neural Network)がある。CNNは人間の脳の神経回路の仕組みを模したモデルであり、一般的に画像認識においてよく用いられる[3]。CNNを用いてびまん性肺疾患を分類する際、陰影ごとに興味領域を設定する必要がある。しかし、びまん性肺疾患の診断においては識別とともに検出が重要である。そこで本研究では、興味領域を設定せずに学習を行い、CT画像からびまん性肺疾患の領域を検出・抽出することを目的とした。本手法では、FCN(Fully Convolutional Network)[4]とU-Net[5]を用いて肺野領域から6つのびまん性肺疾患の陰影パターンの領域を抽出した。得られた結果に対して、CNNを用いた結果と比較を行った。

## 2. 手法

### 2.1 提案手法の概要

本手法では、図1と図2に示すFCNとU-Netを用いて肺野領域からびまん性肺疾患の領域抽出を行った。ここで、使用した陰影はびまん性肺疾患の代表的な陰影パターンである浸潤影(CON)、すりガラス状陰影(GGO)、蜂巣状陰影(HCM)、肺気腫陰影(EMP)、粒状影(NOD)の5つの陰影と、正常肺(NOR)を加えた合計6つの陰影である。

連絡先: 村上佳菜子, 山口大学大学院創成科学研究科電気電子情報系専攻, 〒755-8611 山口県宇部市常盤台 2-16-1, g094vg@yamaguchi-u.ac.jp




図1 本研究で用いたFCNの概要




図2 本研究で用いたU-Netの概要

### 2.2 データセットの作成

本研究では放射線科医の指導のもと、マニュアルでセグメンテーションした肺野領域画像を学習データとして使用し、透視変換・鏡映を用いてデータ数を増やし、各陰影をそれぞれ5800枚として学習を行った。

## 2.3 FCN を用いた学習

FCN はセグメンテーションモデルであり、全ての層が畳込み層で構成されたネットワークモデルのことである。また、全結合層がないため、入力画像のサイズに制約がないという特徴がある。

## 2.4 U-Net を用いた学習

U-Net は FCN と同様、セグメンテーションを行うためのモデルであり、医用画像を学習対象とする Deep Learning の手法の一つである SegNet[6] で提案されているような Encoder-Decoder 構造であり、Encoder 部分と Decoder 部分の対応した特徴マップをつないでいるため、画像を復元する際に位置情報も含めることができるという特徴がある。

## 3. 実験と結果

### 3.1 実験データ

実験には山口大学医学部附属病院にて撮影された胸部 CT 画像 406 症例を用いた。実験に使用した陰影ごとのスライス数の内訳を表 1 に示す。また、CT 画像において 3 人の医師がそれぞれ病変部をマークし、そのうち 2 人以上のマークが一致した領域を正解データとした。CT 画像から放射線科医の指定した病変部を  $32 \times 32$  pixel の大きさの ROI 画像として切り出した。病変部は  $32 \times 32$  pixel の正方形領域で切り出せるとは限らないため、中心座標が病変部に含まれているものを各陰影 500 枚ずつとした。回転・鏡映を用いて水増しした ROI 画像は各陰影 4000 枚ずつであった。また、透視変換・鏡映を用いて水増しした CT 画像は各陰影 5800 枚ずつであった。

表 1 使用した陰影ごとのスライス数

症例の種類	スライス数
浸潤影(CON)	150 枚
すりガラス状陰影(GGO)	114 枚
蜂巣状陰影(HCM)	129 枚
肺気腫陰影(EMP)	163 枚
粒状影(NOD)	34 枚
正常肺(NOR)	55 枚

### 3.2 評価方法

本手法によって抽出した異常陰影の領域と正解データの領域との類似度を Dice 係数によって評価を行った。Dice 係数は以下の式によって算出した。A は CNN, FCN, U-Net によって抽出した異常陰影の領域、B は正解データの異常陰影の領域を表す。

$$\text{Dice 係数} = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (1)$$

### 3.3 実験結果

表 2 は、CNN, FCN, U-Net を用いて陰影ごとに病変部を抽出し、Dice 係数によって類似度を求めた。このときの FCN と U-Net を用いて抽出した場合の結果画像を図 3 に示す。陰影ご

の正解データと FCN と U-Net を用いて病変部の抽出を行った結果画像である。

本研究での入力画像は、FCN と U-Net では  $512 \times 512$  pixel の CT 画像であり、ネットワークへの入力の際に FCN では  $32 \times 32$  pixel, U-Net では  $96 \times 96$  pixel に圧縮して使用した。また、CNN では  $32 \times 32$  pixel の大きさを切り出した ROI 画像を使用した。

表 2 CNN, FCN, U-Net の抽出結果

症例の種類	Dice 係数		
	CNN	FCN	U-Net
CON	$0.999 \pm 0.001$	$0.609 \pm 0.034$	$0.836 \pm 0.063$
GGO	$0.777 \pm 0.154$	$0.700 \pm 0.069$	$0.470 \pm 0.337$
HCM	$0.941 \pm 0.032$	$0.228 \pm 0.267$	$0.177 \pm 0.250$
EMP	$0.868 \pm 0.010$	$0.250 \pm 0.060$	$0.812 \pm 0.131$
NOD	$0.914 \pm 0.011$	$0.008 \pm 0.011$	$0.639 \pm 0.242$
NOR	$0.939 \pm 0.031$	$0.351 \pm 0.133$	$0.904 \pm 0.003$
平均	$0.906 \pm 0.070$	$0.358 \pm 0.235$	$0.640 \pm 0.252$

## 4. 考察

各陰影の平均 Dice 係数は、FCN を用いた場合では  $0.358 \pm 0.235$ , U-Net を用いた場合では  $0.640 \pm 0.252$ , CNN を用いた場合では  $0.906 \pm 0.070$  という結果になった。FCN と U-Net では入力画像の圧縮を行っているが、CNN では圧縮を行っていない。そのため、解像度の違いが原因で FCN と U-Net での抽出精度が低下したと考えられる。すりガラス状陰影と蜂巣状陰影においては、FCN と U-Net を用いた場合に全く領域を抽出できない症例を含んでいた。そこで、領域を抽出できた画像のみで評価を行った結果、すりガラス状陰影では FCN が  $0.700 \pm 0.069$ , U-Net が  $0.706 \pm 0.070$  となり、蜂巣状陰影では FCN が  $0.604 \pm 0.003$ , U-Net が  $0.530 \pm 0.010$  となった。この結果から、学習は適切に行えていると考えられる。

また、粒状影において FCN と U-Net を用いた場合の抽出精度が低下した原因として、入力画像の圧縮を行ったために小結節が見えなくなり、学習が十分にできていないと考えられる。今後、入力画像を片肺ずつに切り出した画像とするなどの処理により、圧縮率を小さくすることで改善が見込まれる。

## 5. まとめ

本稿では、関心領域の設定を行わずに CT 画像からびまん性肺疾患の異常陰影を抽出する方法として FCN と U-Net を用いた方法を提案した。今後の課題として、圧縮率の改善と臨床現場での利用を考慮して、複数陰影での領域抽出への適応が挙げられる。

## 6. 謝辞

本研究は JPS 科研費 JP26108009, JP17H02110 による助成を受けた。

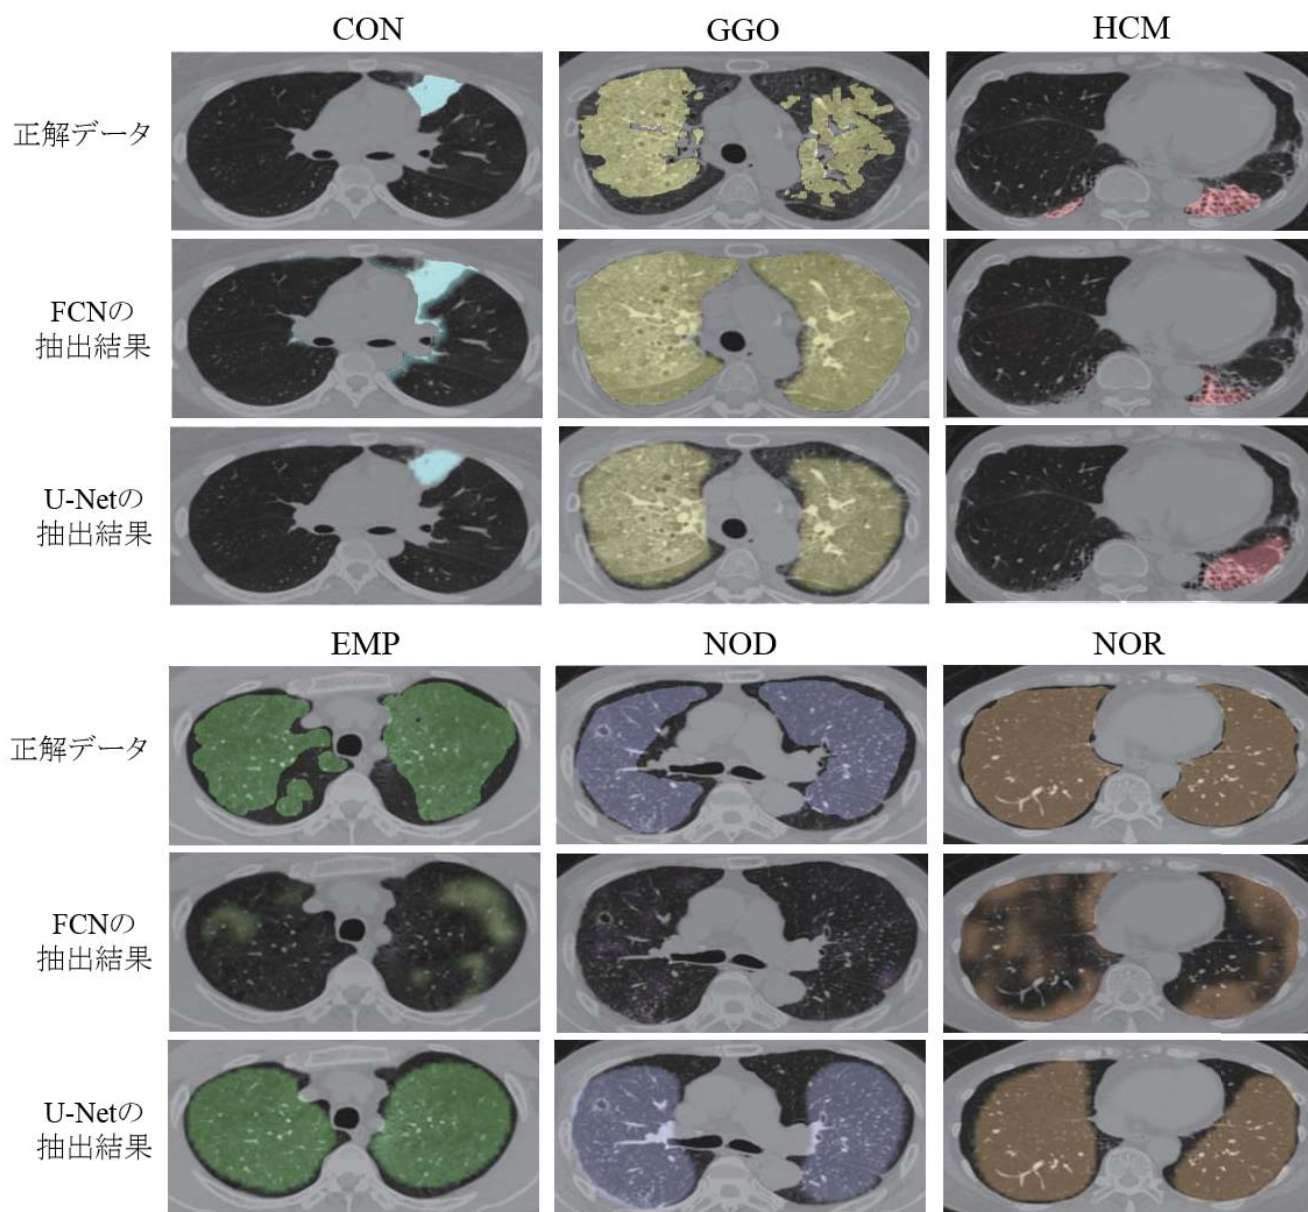


図3 FCNとU-Netを用いて抽出した結果画像

## 参考文献

- [1] Mingchen Gao, Ziyue Xu, Le Lu, et al., "Segmentation label propagation using deep convolutional neural networks and dense conditional random field", Proceedings-International Symposium on Biomedical Imaging, pp. 1265-1268, 2016
- [2] M. Anthimopoulos, S. Christodoulidis, et al., "Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network", IEEE Transactions on Medical Imaging, Vol. 35, pp. 1207-1216, 2016
- [3] A. Krizhevsky, I. Sutskever, and G. Hinton, "ImageNet classification with deep convolutional neural networks", Advances in Neural Information Processing Systems, Vol. 2, pp. 1097-1105, 2012
- [4] E. Shelhamer, J. Long, and T. Darrell, "Fully Convolutional Networks for Semantic Segmentation", IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016
- [5] O. Ronneberger, P. Fischer, T. Brox, "U-net: Convolutional networks for biomedical image segmentation", Lecture Notes in Computer Science, Vol. 9351, pp. 234-241, 2015
- [6] V. Badrinarayanan, A. Handa, R. Cipolla, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Robust Semantic Pixel-Wise Labelling", CVPR, 2015