

# フラクタルデータベースを用いた胸部 CT 画像の肺炎識別器の事前学習

吉岡 雄健<sup>1</sup> 船津 朋和<sup>1</sup> 永岡 隆<sup>2</sup> 小塚 健倫<sup>3</sup> 根本 充貴<sup>4</sup>

山田 誉大<sup>5</sup> 木村 裕一<sup>6,7</sup> 石井 一成<sup>3,5</sup> 波部 斉<sup>6,7</sup>

近畿大学大学院総合理工学研究科<sup>1</sup> 近畿大学生物理工学部生命情報工学科<sup>2</sup>

近畿大学医学部 放射線医学教室 放射線診断学部門<sup>3</sup> 近畿大学生物理工学部医用工学科<sup>4</sup>

近畿大学高度先端総合医療センター PET 分子イメージング部<sup>5</sup> 近畿大学情報学部情報学科<sup>6</sup>

近畿大学情報学研究所<sup>7</sup>

## 1. はじめに

医師による画像診断は病気を早期発見する上で重要な検査の一つである。現在、画像診断の多くは医師による目視で行われているが、病変部の見落としによる治療の遅れが問題となっている。本研究では医師の負担を減らし病気の早期発見を補助するため、深層学習を用いた画像識別を行う。近年、事前学習用のデータセットは増加傾向にあり、データセットの作成には画像収集やアノテーションなど非常にコストがかかる。さらに、大規模データセットの中には倫理的、攻撃的内容を含む画像、ラベリングミス[1]が存在する。本研究では、既存の大規模データセットの代わりに、Kataoka らの手法[2]によって生成したフラクタルデータベース (FDB) を用いて事前学習を行う。

## 2. フラクタルデータベースの生成

Kataoka[2]の手順に従ったフラクタルデータベースの生成手順を以下に示す。

### 2.1 フラクタル画像生成

IFS (Iterated Function System) を用いて図形を構成する点群  $X = \{x_1, x_2, \dots, x_K\}$  を求めることにより生成する。IFS は完備距離空間  $X$  において変換  $\omega_i: X \rightarrow X$  とそれに対応する確率  $p_i$  の集合によって定義される (式(1))。この時の  $N$  は組  $(\omega_i, p_i)$  の数を表す。

$IFS = \{(\omega_1, p_1), (\omega_2, p_2), \dots, (\omega_i, p_i), \dots, (\omega_N, p_N)\}$  (1)  
二次元ユークリッド平面上のフラクタル画像生成時の変換  $\omega$  は、式(2)である。

$$\omega_i(x) = \begin{bmatrix} a_i & b_i \\ c_i & d_i \end{bmatrix} x + \begin{bmatrix} e_i \\ f_i \end{bmatrix} \quad (2)$$

$p_i$  は  $\sum_{i=1}^N p_i = 1$  の確率であり、式(3)によって求められる。

$$p_i = \frac{|\det A_i|}{\sum_{i=1}^N |\det A_i|} \quad \text{where } A_i = \begin{bmatrix} a_i & b_i \\ c_i & d_i \end{bmatrix} \quad (3)$$

以下の手順でフラクタル図形を構成する点群  $X$  を求める。

(I) 組  $(\omega_1, p_1)$  の数  $N$  を  $[2, \dots, 8]$  上の離散一様分布からランダムに決定する。

(II) 式(2)の変換  $\omega_i$  におけるパラメータ  $a_i - f_i$  を、 $[-1, 1]$  上の連続一様分布からそれぞれランダムに選択し確率  $p_i$  を式(3)により決定する。これを  $N$  回繰り返し  $N$  個のパラメータセットを用意する。

(III) 初期値を  $x_0 = (\mathbf{0}, \mathbf{0})^T$  とする。確率  $p_i$  に従って変換  $\omega_i$  とするアフィン変換 (式(2)) を座標  $x_{t-1}$  に適用し、新たな座標  $x_t$  を求める。

(IV) (III) を  $K$  回繰り返すことで、点群  $X = \{x_1, x_2, \dots, x_K\}$  を生成する。

フラクタル画像を生成する際は、求めた点群  $X = \{x_1, x_2, \dots, x_K\}$  が指す点を中心とする  $3 \times 3$  の 0 か 127 の値をランダムに持つ値とすることで描画を行う。任意のサイズの画像を生成するために点群の  $x$  座標と  $y$  座標の最大値と最小値を求め、それが画像サイズに合うようにスケールアップする。最後に、ピクセルの充填率を計算し、ある閾値以上であれば画像として採用する。

### 2.2 カテゴリの決定

採用された画像へのラベルの付与は、生成された順に割り当てられる。 $n$  クラスのデータセットを作成する際、点群  $X$  の生成からカテゴリの決定までの操作を  $n$  回繰り返す。今回使用する FDB は 1000 クラスにそれぞれ 1000 枚ずつ画像を含む。

## 3. 肺炎識別器の学習

フラクタルデータベースを用い事前学習を行う。ネットワークには ResNet50[5]を採用し、エポック数 90、バッチサイズ 64 で 1000 クラス分類を行

Pre-training of a pneumonia classifier for chest CT images using a Fractal Data Base.

†YUKEN YOSHIOKA, TOMOKAZU FUNATSU, Graduate School of Science and Engineering, Kindai University.

‡TAKASHI NAGAOKA, TAKENORI KOZUKA, MITSUTAKA NEMOTO, TAKAHIRO YAMADA, YUICHI KIMURA, KAZUNARI ISHII, HITOSHI HABE, Kindai University.

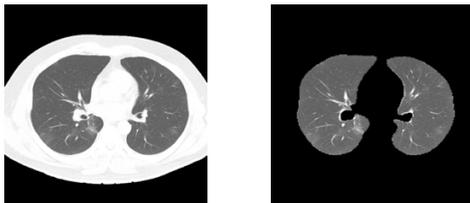


図 1 肺野抽出前(左)、肺野抽出後(右)

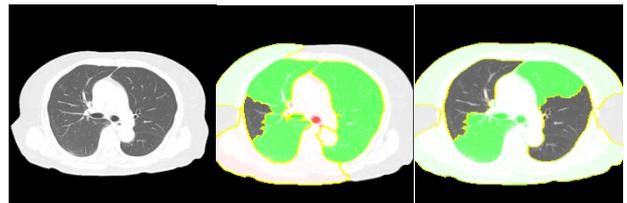


図 2 肺野抽出前

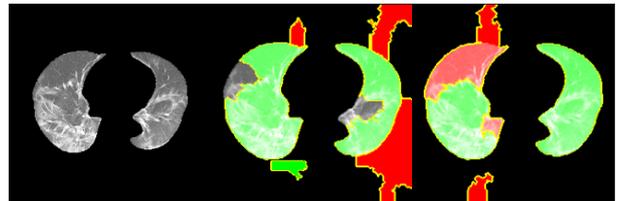


図 3 肺野抽出後

う。比較には、ImageNetVersion2(以下 IN\_V2)を用いる。IN\_V2はネットワークにResNet50を用いた 1000 クラス分類の事前学習済みモデルである。次に、FDB と IN\_V2 それぞれの事前学習済みモデルに対して肺炎識別器用にファインチューニングを行う。識別するのは COVID-19 肺炎と通常肺炎の 2 クラス識別である。ファインチューニングの条件は、エポック数 90、バッチサイズ 64、学習率 0.01 である。

#### 4. 実験

上述したデータセットを用い、肺炎識別における精度検証を行う。

##### 4.1 検証

近畿大学医学部から提供された、図 1(左)、の様な通常肺炎と、COVID-19 肺炎の 2 種のラベルを持つ CT 画像を検証に使用する。また Hofmanninger が作成した U-Net のパラメータ[6]を使用し、図 1(左)の様な画像を、図 1(右)の様に肺に対し肺野のみを切り出したデータを使用する。検証には 10 分割交差検証を用いる。それぞれ使用する枚数は、COVID-19 肺炎が 6621 枚、通常肺炎が 7092 枚である。

##### 4.2 結果

10 分割交差検証の結果を表 1 に示す。数値は 90 回の試行の中でテストデータの一番正診率の高い結果とその時の感度の平均を表している。肺野抽出前の正診率は IN\_V2 が 5.31%高く、肺野抽出後は IN\_V2 が 5.90%高い結果となった。

表 1 FDB と IN\_V2 の 10 分割交差検証(%)

	肺野抽出前		肺野抽出後	
	FDB	IN_V2	FDB	IN_V2
正診率	85.53	90.84	82.49	88.39
感度	85.70	90.19	80.75	87.18

次に、識別に大きく寄与した部分を調べるため LIME[7]を用い、判断根拠を可視化した様子を図 2, 3 に示す。画像は左から元画像、FDB、IN\_V2 による識別結果であり、画像の緑色の部分と赤色

の部分がそれぞれ正解ラベルの予想確率を上昇させている部分と低下させている部分である。

#### 5. まとめ

現在の FDB の肺炎識別に対する精度は IN\_V2 より劣っているが、図 2、3 より IN\_V2 における肺炎識別の正診率は高いものの、FDB よりも注目領域が正確でないことがわかる。今後の課題としては、FDB の生成画像を CT 画像に適したものに変更する工夫や、ハイパーパラメータ調整による識別精度向上、FDB 生成時の効率向上などが挙げられる。

本研究の一部は科研費 JP21H05302 の補助を受けて行った。

#### 参考文献

- [1] Beyer et. al., “Are we done with ImageNet?”, arXiv, 2020.
- [2] Kataoka et. al., “Pre-Training Without Natural Images”, IJCV, 2022.
- [3] 中村 他, “カテゴリあたり 1 枚の生成画像で視覚特徴を学習できるのか?”, 第 25 回 画像の認識・理解シンポジウム(MIRU), 2022.
- [4] 船津 他, “学習時の注目領域重視度の動的調整による画像分類精度の改善”, 情報処理学会第 84 回全国大会, 2022.
- [5] He et. al., “Deep Residual Learning for Image Recognition”, CVPR, 2016.
- [6] Hofmanninger et. al., “Automatic lung segmentation in routine Imaging is primarily a data diversity problem, not a methodology problem.” Eur Radiol Exp4, 50 (2020).
- [7] M. Ribeiro et. al, ““Why Should I Trust You?”: Explaining the Predictions of Any Classifier”, NAACL, 2016.