

# 胸部 X 線画像からの機械学習を用いた塵肺検出に関する研究

1245113 東 聖 【 知能情報学研究室 】

## A Study on Pneumoconiosis Detection Using Machine Learning from Chest X-ray Images

1245113 Hijiri AZUMA 【 Intelligent Informatics Laboratory 】

### 1 はじめに

塵肺は肺疾患の一つであるが、鉱物資源採掘の労働者に多い労働災害の一つである。肺疾患のうち塵肺の画像診断は難しく、AI 診断アルゴリズムも研究途上である。そこで本研究では、塵肺の早期発見や医師の診断支援につながる塵肺 CAD(Computer-Aided Diagnosis) を構築する。

### 2 提案手法

本研究では、ウェーブレット変換を用いた CNN による胸部 X 線画像からの塵肺検出を提案する。胸部 X 線検査において、X 線は気体の部分はそのまま通過し黒く映るため、異常がある場合は白い陰影ができる特徴がある。そのため塵肺では、胸部 X 線画像に粒状のザラザラしたような白い陰影が見られる。塵肺 CAD において、その特徴を取得することで精度の向上が期待できると考える。すなわち、本研究では胸部 X 線画像と肺野領域を抽出した画像、上記2つをそれぞれウェーブレット変換し、抽出した各ベクトル (Vertical(V),Horizontal(H),Diagonal(D)) の高周波成分と、低周波成分 (Approximation(A)) を CNN の入力とし、それぞれで学習を行う。

また、肺野領域の抽出では、画像の勾配特徴を抽出する手法やパターン認識や画像特徴量解析を用いた手法 [2] などの様々なアプローチが行われており、その結果精度の向上が報告されている。そのため現在では肺野領域の抽出は必要な前処理と言われており、多くの胸部 CAD において用いられている。最近では U-Net などの CNN を使った手法において、高い領域抽出精度が報告されている [1]。U-Net を使った肺野領域抽出を行う。

提案手法についての具体的な手順を図 1 に示す。

### 3 実験

#### 3.1 データセット

本研究では National Institute of Occupational Safety and Health(NIOSH) の胸部 X 線画像データセット、高知大学医学部 (KM) で収集された胸部 X 線画像データセット、National Institutes of Health Clinical Center(NIHCC) の胸部 X 線画像データセットの 3 つを使用した。これらのデータセットの画像は NF(No Find-

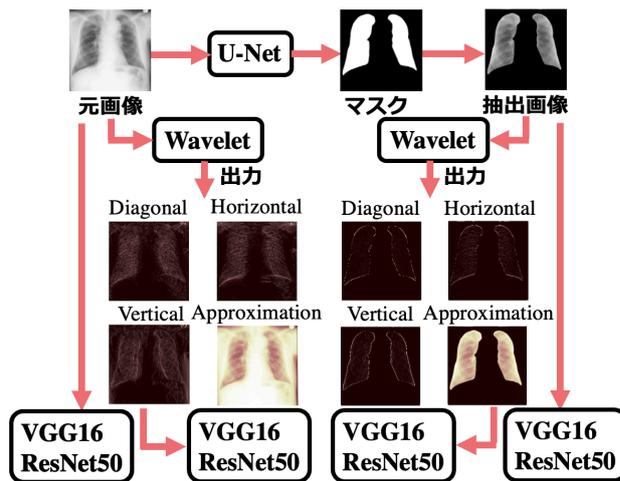


図 1: 提案する 4 種の識別モデル

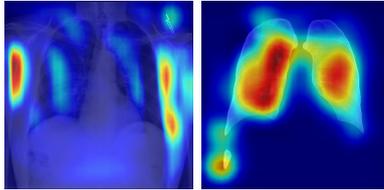
表 1: データセット

	NF	塵肺
NIOSH(米国立労働安全衛生研究所)	23	28
NIHCC(米国立衛生研究所)	90	0
KM(高知大学医学部)	4	91

ing) 画像と塵肺画像のいずれかにラベル付けされている。NIOSH データセットは NF 画像 25 枚、塵肺画像 28 枚の計 53 枚。NIHCC データセットは NF 画像 90 枚、塵肺画像 0 枚。KM データセットは NF 画像 4 枚、塵肺画像 91 枚である。そして、NIHCC データセットは NF 画像のみで構成されている。これは他のデータセットでは塵肺画像のデータが多く、学習を行う上で塵肺画像と NF 画像の割合を合わせるためである。また、U-Net で肺野領域抽出を行った段階で、NIOSH データセットの内 2 枚がマスクの作成に失敗したため取り除いている (表 1)。これらのデータセットで 5-交差検証法を行うために層化抽出法を用いて train,test,validation に分割する。

表 2: 元画像と抽出画像の結果

	マスク処理	平均正解率	平均 F 値
VGG16		94.86±1.10	94.85±1.20
VGG16	✓	97.14±1.81	97.07±1.86
ResNet50		95.43±3.88	95.49±3.79
ResNet50	✓	84.57±1.40	83.83±1.34



(a) 元画像 (b) 抽出画像

図 2: NF 画像と抽出画像の Grad-CAM

### 3.2 実験設定

学習モデルには VGG16 と ResNet50 を用いる. VGG16 では Batch Normalization を導入し, 全結合層を GlobalAveragePooling, 全結合層, SoftMax に置き換える. また, ResNet50 は全結合層を GlobalAveragePooling, 全結合層, SoftMax に置き換える. オプティマイザーには Adam を用い, epoch 数は 100, 学習率 ( $\lambda_0$ ) は各条件毎に  $10^{-2}$  から  $10^{-6}$  の中で最も検出精度の高いものを使用する. 学習時には学習率減衰を行う. 100epoch の内の  $t$  epoch 時の学習率  $\lambda_t$  を式 (1) に示す.

$$\lambda_t = \lambda_0(0.95)^t \quad (1)$$

### 3.3 モデルの評価

モデルの評価として, 平均正解率と平均 F 値を用いる. そして, 学習した結果の妥当性を検証するために, Grad-CAM を用いて判断根拠の可視化を行う.

## 4 結果・考察

### 4.1 元画像と抽出画像の比較

元画像と抽出画像を用いて精度の比較を行い (表 2), VGG16 においては抽出画像が平均正解率, 平均 F 値ともに元画像を上回り, ResNet50 においては元画像が平均正解率, 平均 F 値ともに抽出画像を上回った. しかし, Grad-CAM で可視化を行った結果, 抽出画像は肺野領域を主に注視したのに対して, 元画像は肺野領域外のポイントを中心に注視していた (図 2). 元画像が画像右上の文字や画像端を注視していることから, 肺野領域外に着目し判別していることが分かる. このことから, 元画像と抽出画像での単純な精度の比較はできないと考えられる.

### 4.2 抽出画像における高周波成分と低周波成分の比較

抽出画像の高周波成分, 低周波成分を用いて精度の比較を行い, 表 3 の結果が得られた. 表 3 より, VGG16 と

表 3: 高周波成分と低周波成分の比較

	周波数成分	平均正解率	平均 F 値
VGG16	A	95.43±2.29	95.10±2.64
VGG16	D	100.00±0.00	100.00±0.00
VGG16	H	97.14±2.56	97.21±2.48
VGG16	V	93.71±4.57	93.97±4.07
ResNet50	A	87.43±2.29	86.82±2.72
ResNet50	D	97.14±2.56	97.11±2.56
ResNet50	H	91.43±5.11	91.51±4.87
ResNet50	V	91.43±4.04	91.40±4.17

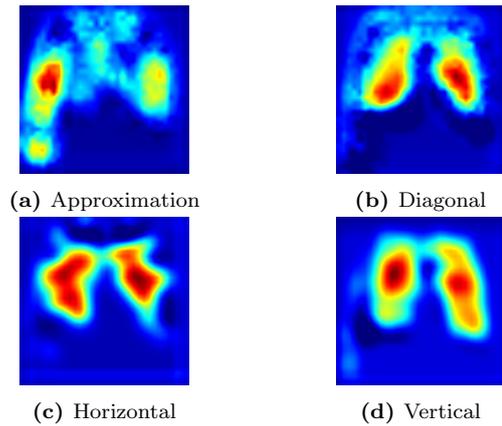


図 3: 高周波成分と低周波成分の Grad-CAM

ResNet50 において, どちらも Diagonal が最も高い精度となった. そして, VGG16 においては, Vertical が最も精度が低くなり, ResNet50 においては Approximation が最も低い精度となった. また, Grad-CAM の結果において高周波成分を用いた場合, 肺野領域に着目していることが確認できたため, VGG(D) の判断根拠に妥当性があると考えられる (図 3).

## 5 まとめ

本研究では, ウェーブレット変換を用いた CNN による胸部 X 線画像からの塵肺検出を提案した. その結果, ウェーブレット変換により得られた高周波成分である Diagonal では, 100% の精度で塵肺を検出できた. また, Grad-CAM での検証においても肺野領域に着目しており, モデルの妥当性を確認できた.

## 参考文献

- [1] J. Hofmanninger et al. Automatic lung segmentation in routine imaging is primarily a data diversity problem, not a methodology problem. *European Radiology Experimental*, 4(1):1–13, 2020.
- [2] L. Li et al. Improved method for automatic identification of lung regions on chest radiographs. *Academic Radiology*, 8(7):629–638, 2001.