

令和 3 年度  
修士学位論文

# 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

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

1245113 東 聖

指導教員 吉田 真一

2022 年 2 月 28 日

高知工科大学大学院 工学研究科 基盤工学専攻  
情報学コース

# 要 旨

## 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

東 聖

本研究では、CNN による胸部 X 線画像からの塵肺検出の精度向上を目的とする。CNN への入力画像として、Haar wavelet によるウェーブレット変換を行った後の画像を用いる。胸部 X 線画像の肺野領域抽出を FCN モデルの U-Net で行っている。本研究におけるデータセットは、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、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は学習を行った U-Net モデルを用いて、肺野領域の抽出を行った。抽出した画像と胸部 X 線画像を Haar wavelet 変換により、3 つの高周波成分 (対角, 水平, 垂直方向) と低周波成分に分解する。そして、これらのデータを入力として塵肺検出を行う畳み込みニューラルネットワークモデルの VGG16 と ResNet50 で予測した。テストデータによるモデル検証では、抽出画像における対角方向高周波成分を入力とした VGG16 モデルにおいて、平均正解率, 平均 F 値共に 100.00% の精度であり、既存の手法 (97.3%) を上回ったことを示す。低周波成分を入力とした場合, VGG16 モデル, ResNet50 モデルの両方において、平均正解率, 平均 F 値共に精度が低下し、低周波成分が塵肺検出において有用な特徴でないことが示唆される。また、本研究において検証したモデルは、Grad-CAM を用いて推定モデルの着目している場所の可視化を行った。その結果、抽出画像における対角方向高周波成分を入力とした VGG16 モデルにおいて、学習結果の妥当性が確認できたことを示す。

**キーワード** 胸部 X 線画像, 畳み込みニューラルネットワーク, 塵肺, wavelet 変換, Grad-CAM

# Abstract

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

Hijiri AZUMA

In this study, we aim to improve the detection accuracy of Pneumoconiosis detection from chest X-ray images by CNN. The proposed model utilize Haar wavelet as image feature. The U-Net of the FCN model for extracting lung fields in chest X-ray images was trained. Three datasets were used in this study: the NIOSH chest X-ray image dataset, the chest X-ray image dataset collected at Kochi Medical school (KM), and the NIHCC chest X-ray image dataset. Using these datasets, we extracted the lung area regions with a trained U-Net model. The extracted images and chest X-ray images were decomposed into high-frequency components (diagonal, horizontal, vertical) and low-frequency components by Haar wavelet transform, respectively. These data for prediction by VGG16 and ResNet50, which are convolutional neural network models. Model validation using test data shows that the VGG16 model with the high frequency component (diagonal) of the extracted image as input has an accuracy of 100.00% for both the average accuracy and the average F-score, which is higher than the existing accuracy (97.3%). When the low-frequency component is used as an input, the accuracy of the average accuracy and the average F-score of the VGG16 and ResNet50 models decreases, indicating that the low-frequency component is not a useful feature in Pneumoconiosis detection. Grad-CAM study is also performed to visualize the region of interest of the estimated model. As a result, the validity of the training results was

confirmed for the VGG16 model using the high-frequency components (diagonal) of the extracted images as input. This validation demonstrates the usefulness of the Haar wavelet transform for pneumoconiosis detection.

***key words***     Chest X-ray image, Convolutional Neural Network, Pneumoconiosis, wavelet transform, Grad-CAM

# 目次

第 1 章	序論	1
第 2 章	関連研究	3
第 3 章	提案手法	5
3.1	wavelet 変換を用いた CNN による胸部 X 線画像からの検出手法 . . . . .	5
3.2	提案モデル全体の構造 . . . . .	6
第 4 章	実験	8
4.1	データセット . . . . .	8
4.1.1	画像の前処理 . . . . .	8
4.2	U-Net を用いた肺野領域抽出 . . . . .	9
4.2.1	データセット (U-Net) . . . . .	9
4.2.2	結果 (U-Net) . . . . .	10
4.3	Haar wavelet 変換 . . . . .	11
4.3.1	結果 (Haar wavelet 変換) . . . . .	11
4.4	実験設定 . . . . .	11
4.4.1	設定と学習率 . . . . .	11
4.4.2	Global Average Pooling(GAP) と Grad-CAM . . . . .	12
4.4.3	VGG16 と ResNet50 . . . . .	13
4.5	モデルの評価 . . . . .	14
第 5 章	結果と考察	16
5.1	肺野領域抽出の有無による比較 . . . . .	16
5.2	Haar wavelet 変換の有無による比較 . . . . .	20

## 目次

5.2.1	VGG16 . . . . .	20
5.2.2	ResNet50 . . . . .	24
5.2.3	Haar wavelet 変換と肺野領域抽出を合わせた比較 . . . . .	26
<b>第 6 章 結論</b>		<b>29</b>
<b>謝辞</b>		<b>31</b>
<b>参考文献</b>		<b>32</b>

# 目次

2.1 U-Net を使ったセグメンテーションの例 . . . . .	3
3.1 塵肺画像と No Finding 画像 . . . . .	6
3.2 提案する 4 種の識別モデル . . . . .	7
4.1 U-Net への入力と出力 . . . . .	10
4.2 U-Net による抽出 . . . . .	11
4.3 Haar wavelet を可視化 . . . . .	12
4.4 GAP の概要 . . . . .	15
5.1 VGG16 における元画像 (肺野領域外に注目) . . . . .	20
5.2 VGG16 における抽出画像 (境目に注目) . . . . .	20
5.3 ResNet50 における元画像の例 . . . . .	21
5.4 ResNet50 における抽出画像の例 . . . . .	21
5.5 VGG16:元画像における wavelet 変換 (ADH) の Grad-CAM 結果 . . . . .	22
5.6 VGG16:元画像における wavelet 変換 (V) の Grad-CAM 結果 . . . . .	23
5.7 VGG16:抽出画像 (A) における Grad-CAM の結果 . . . . .	24
5.8 VGG16:抽出画像 (D) における Grad-CAM の結果 . . . . .	24
5.9 VGG16:抽出画像 (H) における Grad-CAM の結果 . . . . .	25
5.10 VGG16:抽出画像 (V) における Grad-CAM の結果 . . . . .	25
5.11 ResNet50:元画像におけるデータセットによる違い . . . . .	26
5.12 VGG16 における元画像を入力した結果 . . . . .	27
5.13 VGG16 における抽出画像を入力した結果 . . . . .	27
5.14 Res50 における元画像を入力した結果 . . . . .	28
5.15 Res50 における抽出画像を入力した結果 . . . . .	28

# 表目次

4.1	データセット . . . . .	9
4.2	U-Net の学習に使用するデータセット . . . . .	10
4.3	実験条件 (VGG16) の学習率 . . . . .	13
4.4	実験条件 (ResNet50) の学習率 . . . . .	14
5.1	VGG16 の結果 . . . . .	18
5.2	ResNet50 の結果 . . . . .	19



# 第 1 章

## 序論

肺疾患には肺炎を始めとした様々な疾患が存在する。塵肺はそのような肺疾患の一つである。主な病因として長期間に渡って粉塵や微粒子を吸引し、肺胞に蓄積されることによって起こる。塵肺にはけい肺を始めとした 18 の種類が存在し、吸引した物質によって病種が変化する。これらの吸引物質には金属やガラス、ゴムや石炭などが存在し、多様な職業現場で吸引の危険性がある。そのため、塵肺は労働災害の一つとされている [15]。近年では世界的な人口増加や新興国の発展に伴うエネルギー需要により、鉱物資源の需要及び産出量が増加している。それに伴い、鉱物資源採掘の労働者を始めとした塵肺患者が世界的に増加している [18]。しかし、塵肺患者が増加していく中、現代の医療技術では治療法が確立されていない。また、職場を離れたとしても病気は進行し、元の肺に戻ることはない [3]。そのため、病気の早期発見が望まれている。

胸部疾患の早期発見において、胸部 X 線検査は最も安価で簡便に行うことができる検査である [19]。しかし、胸部 X 線画像は三次元構造を二次元で表しているため、臓器や血管が重なって表示される。そのため、読影を行う医師に負担がかかり、読影を行う医師によって診断結果にばらつきがある。塵肺の読影を行う際は構成労働省塵肺標準 X 線写真をもとに 0(健康) から 4(重症) までの 5 段階で診断を行う。しかし、Zhang らの研究 [14] で、読影医師を 2 グループに分けて診断を行った結果、405 人中 101 人の患者で異なる診断結果になった。このような問題を解決するために、画像情報を定量化し医師の読影補助を行うコンピュータ支援診断 (CAD:Computer-Aided Diagnosis) の開発が活発化している [20][12]。

胸部 CAD の中でも、CNN(Convolutional Neural Network) を用いたものは、近年では最先端の性能を発揮している [1]。Zhang らの研究 [14] では U-Net を用いて胸部 X 線画像

の肺野領域抽出を行った。そして、彼らは肺野領域を上肺野、中肺野、下肺野に分割し、計 6 つの部位毎に ResNet モデルを用いて塵肺の分類を行った。また、塵肺の進行度を 0(健康) から 3(重症) の 4 段階に分け、4 クラスでの分類を行っている。塵肺の分類精度においては、正解率が 97.3%、感度、特異度共に 97%以上の結果が報告されている。また、4 クラスの分類では、正解率が 92.7%であった。また、Gaál らの研究 [4] では、U-Net ベースのモデルを用いて、入力画像の肺野領域抽出を行い、ダイス係数 0.975 となった。これらの研究のように、現在の CAD 開発において機械学習の入力画像の肺野領域抽出は有用であると言われている。

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、NF(No Finding=異常未発見) 画像と比べて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。画像特徴の抽出には様々な手法が存在するが、内海らの研究 [17] では顔認識において Haar wavelet が最も高い認識率を示した。そのため、塵肺における画像特徴抽出においても有用である可能性がある。

そのため、本研究では Haar wavelet による特徴抽出を行った後、CNN による胸部 X 線画像からの塵肺検出を行うことで、検出精度の向上を目指す。

## 第 2 章

# 関連研究

胸部 X 線画像からの塵肺検出において、先行研究として Zhang らの研究 [14] がある。Zhang らの研究では、入力画像の肺野領域抽出が行われている。肺野領域抽出において、これまで提案されてきた手法には画像の勾配特徴を抽出する手法 [16] やパターン認識や画像特徴量解析を用いた手法 [8] などがあげられる。最近では、肺野領域抽出において、U-Net などの CNN を使った手法で高い領域抽出精度が報告されている [6]。Zhang らの研究でも U-Net を用いた肺野領域抽出を行っており、既存の領域抽出手法と比較して U-Net は優れた領域抽出手法である。U-Net は FCN(Fully Convolution Network) の一つであり、画像のセグメンテーション (領域抽出) の推定を行う [9]。FCN は CNN の全結合層を畳み込み層に置き換えたものである。これにより、物体の種類を出力するのではなく、物体の場所を出力できるようになる。そのため、図 2.1 のように画像ピクセル毎に分類を行うことができる。




図 2.1: U-Net を使ったセグメンテーションの例

Zhang らの研究では、U-Net を用いて胸部 X 線画像の肺野領域を抽出し、肺野領域を上肺野、中肺野、下肺野に分割し、計 6 つの部位毎に塵肺の分類を行っている。また、塵肺の進行度を 0 から 3 の 4 段階に分け、4 クラスでの分類を行っている。実験に用いたデータセットは、医師に協力のもとラベル付けされている。塵肺の分類精度においては、正解率が 97.3%、感度、特異度共に 97%以上の結果が報告されている。また、4 クラスの分類では、正解率が 92.7%であった。

先行研究研究では、抽出した画像を入力として学習を行っている。しかし、塵肺には粒状のザラザラしたような磨りガラス状の白い陰影が見られる特徴がある。そのため、その特徴を抽出し、モデルの入力とすることでより良い塵肺 CAD の開発ができると考える。本研究では、特徴抽出に wavelet 変換を用いた。画像解析にはフーリエ変換 (Fourier transform) という手法もあるが、塵肺のような画像特徴が局在しているものに対しては、正弦波のような連続した波を用いるよりも、wavelet 変換のような局在した波を用いる方がより効果的に特徴を抽出できる [17]。wavelet 変換を用いた画像特徴の抽出手法において、内海らの研究 [17] がある。内海らの研究では、顔認識を目的とした様々な wavelet 変換による精度の比較を行っている。その結果、Harr wavelet が最も高い精度となった。そのため、塵肺における画像特徴抽出においても Harr wavelet が有用である可能性がある。

そこで本研究では、Haar wavelet での特徴抽出を用いて、CNN による胸部 X 線画像からの塵肺検出の精度向上を目的とした研究を行う。

## 第 3 章

# 提案手法


本研究では、CNN による胸部 X 線画像からの塵肺検出に対して、入力する画像を wavelet 変換を用いて高周波成分と低周波成分に分けることで検出精度の向上が可能であるか検証する。

また、本章では提案手法である Haar wavelet 変換を用いた CNN による胸部 X 線画像からの検出手法、提案モデルの全体構造について論じる。

### 3.1 wavelet 変換を用いた CNN による胸部 X 線画像からの検出手法

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、NF(No Finding) 画像と比べて図 3.1 のような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検出精度の向上が期待できると考える。そこで、本研究では特徴抽出に wavelet 変換を用いた。画像解析にはフーリエ変換という手法もあるが、塵肺のような画像特徴が局在しているものに対しては、正弦波のような連続した波を用いるよりも、wavelet 変換のような局在した波を用いる方がより効果的に特徴を抽出できると考える。wavelet 変換を用いた画像特徴の抽出手法において、内海らの研究 [17] がある。内海らの研究では、顔認識を目的とした様々な wavelet 変換による精度の比較を行っている。その結果、顔認識において Haar wavelet が最も高い認識率を示した。そのため、塵肺における画像特徴抽出においても有用である可能性がある。

### 3.2 提案モデル全体の構造



(a) No Finding 画像

(b) 塵肺画像

図 3.1: 塵肺画像と No Finding 画像

よって，本研究では Haar wavelet による特徴抽出を用いて，CNN による胸部 X 線画像からの塵肺検出の精度向上を目的とした研究を行う．

### 3.2 提案モデル全体の構造

本研究で提案する塵肺識別モデルの全体構成を図 3.2 に示す．本研究では，前処理として U-Net を用いた肺野領域セグメンテーションを行い，各画像のマスクを作成する．そして，元画像とマスクを用いて肺野領域の抽出を行い，抽出画像を作成する．次に，元画像と抽出画像を matlab を用いて Haar wavelet 変換し，高周波成分の各ベクトル (Vertical(V),Horizontal(H),Diagonal(D)) と，低周波成分の (Approximation(A)) に分解する．そして，元画像，元画像を Haar wavelet 変換した高周波成分と低周波成分，抽出画像，抽出画像 Haar wavelet 変換した高周波成分と低周波成分の計 10 種を VGG16[11] と ResNet50[5] に入力し，それぞれ学習を行う．

### 3.2 提案モデル全体の構造

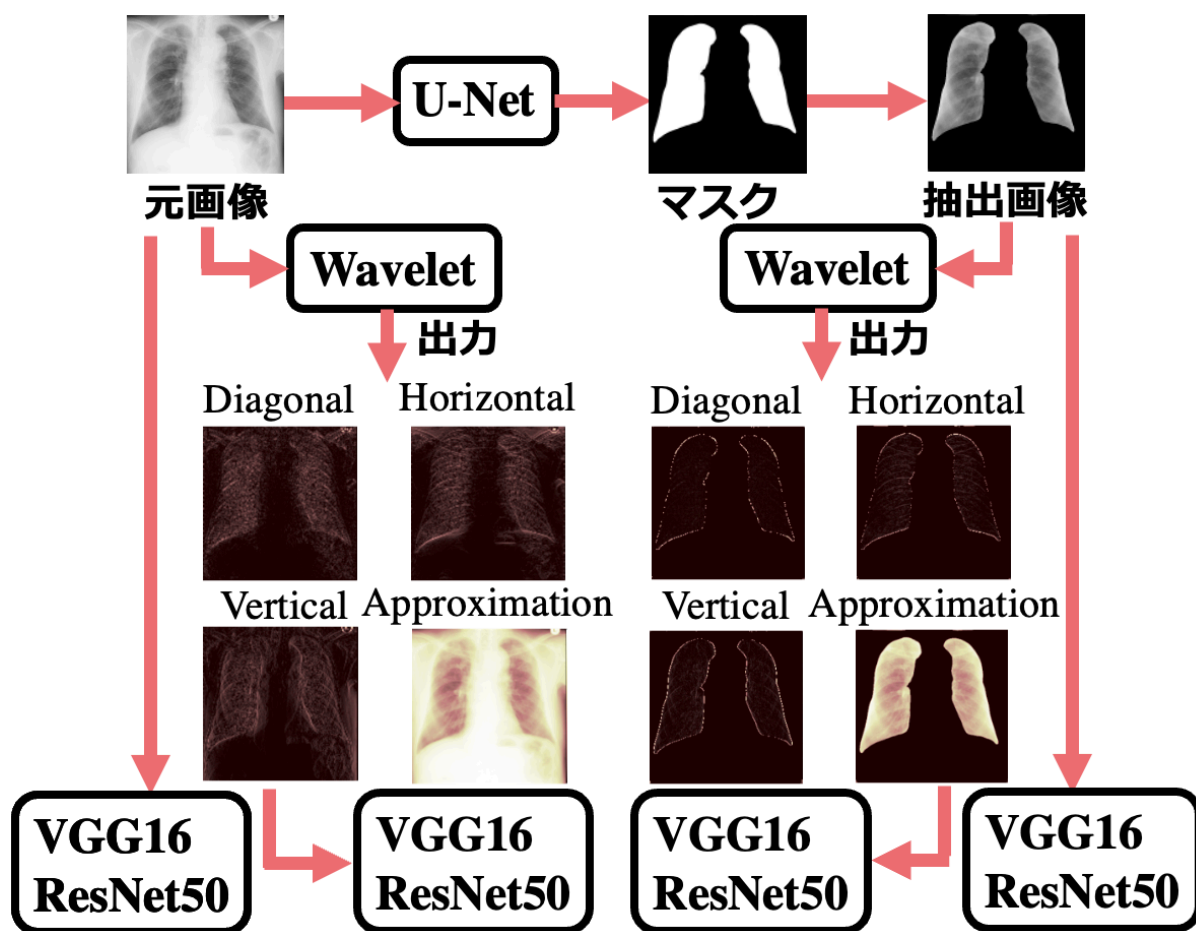


図 3.2: 提案する 4 種の識別モデル

## 第 4 章

# 実験

### 4.1 データセット

本研究では NIOSH(National Institute of Occupational Safety and Health) 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, NIHCC(National Institutes of Health Clinical Center) の胸部 X 線画像データセット [13] の 3 つを使用した. これらのデータセットの画像は NF(No Finding) 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 4.1 にデータセットを示す. 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学習データ (train), 検証データ (validation), テストデータ (test) に分割する.

#### 4.1.1 画像の前処理

各データセットの画像をグレースケールで読み込む. この時, 表 4.1 に示したように画像サイズがデータセット毎に異なるため, 512x512 にリサイズを行う.

機械学習において, 画像の前処理には標準化または正規化を行う必要がある. 画像のように 0 から 255 と最大値最小値が決まっている場合では正規化を使うことができる. しかし,



## 4.2 U-Net を用いた肺野領域抽出

表 4.1: データセット

	NF	塵肺	サイズ
NIOSH(米国立労働安全衛生研究所)	23	28	299x299
NIHCC(米国立衛生研究所)	90	0	1024x1024
KM(高知大学医学部)	4	91	299x299

正規化は外れ値が存在するデータには強く影響を受けるため、その場合は標準化を用いる。標準化はデータの分布が正規分布に近いほど効果的であるが、それ以外の場合でも標準化を用いることができる。そのため、機械学習においては標準化を使用することが一般的である。本研究のデータでは、元画像、抽出画像ともに 0 から 255 の値になっているが、Haar wavelet 変換を行ったデータでは、外れ値が存在するため、全てのデータを標準化する。

## 4.2 U-Net を用いた肺野領域抽出

これまでの肺野領域抽出において、画像の勾配特徴を抽出する手法 [16] やパターン認識や画像特徴量解析を用いた手法 [8] 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有用な手法と言われており、多くの胸部 CAD において用いられている [21]。最近では U-net などの CNN を使った肺野領域抽出において、高い領域抽出精度が報告されている [6][9][14][4]。そこで本研究では U-Net を使った肺野領域抽出を行う。

### 4.2.1 データセット (U-Net)

U-Net の学習には Montgomery County X-ray Set[7][2] を用いた。このデータセットの画像は、アメリカのメリーランド州モンゴメリー郡の保健福祉省から取得され、800 枚の胸部 X 線画像と 704 枚のマスク画像によって構成されている。このデータセットでは、全ての胸部 X 線画像に対してはマスク画像が存在していないため、今回は 704 枚の胸部 X 線

## 4.2 U-Net を用いた肺野領域抽出

表 4.2: U-Net の学習に使用するデータセット

Train データ	Test データ	Validation データ	合計	サイズ
569	64	71	704	2919x3000




図 4.1: U-Net への入力と出力

画像と 704 枚のマスク画像を使用した。そして、このうち 569 枚を Train データ, 64 枚を Test データ, 71 枚を validation データに分割する。表 4.2 にデータセットを示す。そして、データセットの画像をグレイスケールで読み込み、画像サイズを 512x512 にリサイズし学習を行う。

### 4.2.2 結果 (U-Net)

図 4.1 に、U-net に入力した元画像、生成したマスク画像、生成したマスク画像を用いて作成した抽出画像の例を示す。この時 NIHCC データセットの内 2 枚がマスクの生成に失敗している。この失敗した元画像はどちらも画像の輝度値が高く、それにより肺野領域とそれ以外の境目が曖昧になり、生成に失敗したと考える。図 4.2 に生成に失敗した画像とそのマスクを示す。

### 4.3 Haar wavelet 変換

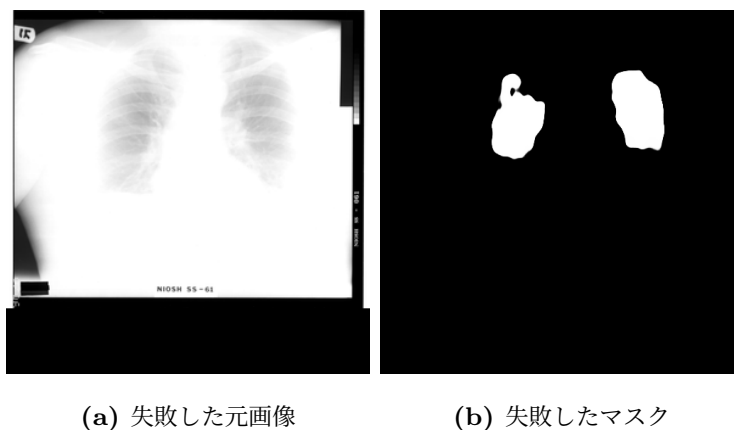


図 4.2: U-Net による抽出

### 4.3 Haar wavelet 変換

本研究では, wavelet 変換を行う. 画像を 512x512 にリサイズし, 高周波成分の各ベクトルと低周波成分を抽出した.

#### 4.3.1 結果 (Haar wavelet 変換)

抽出データはおよそ 0 から 2 の範囲に分布しており, ほとんどの値が 0 となっている. 抽出したデータをそのままでは表示できないので, 可視化の際は 0 から 255 にスケーリングしている. 実際のモデルに入力する場合には標準化を行っている. 可視化したものを図 4.3 に示す.

また, 抽出したデータをモデルに入力する際には, データの次元を増やす必要がある. 現在のデータでは 512x512 の二次元になっているため 512x512x1 の三次元に変換する.

### 4.4 実験設定

#### 4.4.1 設定と学習率

本研究では epoch 数が 100epoch, オプティマイザーには Adam を使用した. 学習率においては, 全 20 種の条件毎に,  $10^{-2}$  から  $10^{-6}$  の 5 パターンの学習率で学習を行い, 各条件

## 4.4 実験設定

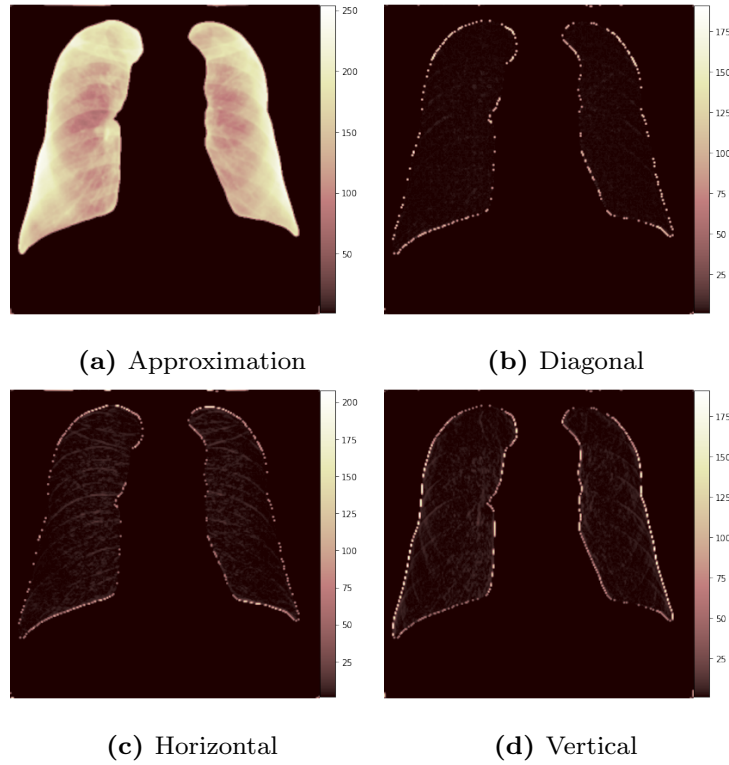


図 4.3: Haar wavelet を可視化

毎に最も validation accuracy の高かったものをその条件における学習率とした．各条件毎の学習率を表 4.3，表 4.4 に示す．

また，学習時には学習率減衰を行う．学習率減衰は学習の最適化に役立つ手法である．初期学習率を  $\lambda_0$ ，100epoch の内  $t$ epoch 時の学習率  $\lambda_t$  を式 4.1 に示す．

$$\lambda_t = \lambda_0(0.95)^t \quad (4.1)$$

### 4.4.2 Global Average Pooling(GAP) と Grad-CAM

図 4.4 に GAP の概要を示す．GAP では，最後の畳み込み層の出力の特微量マップをチャンネル毎に平均を取る．Grad-CAM[10] では，GAP で求めた各特微量マップの平均値と，予測結果の間の重みに着目することでモデルが画像のどこを注視しているか可視化することができる．そのため，本研究では Grad-CAM を用いて学習したモデルが肺野領域に注目しているか確認する．そして，学習結果に妥当性があるか確認する．

## 4.4 実験設定

表 4.3: 実験条件 (VGG16) の学習率

	マスク処理	周波数成分	最適学習率	Validation accuracy
VGG16			$10^{-3}$	$89.06 \pm 5.37$
VGG16		A	$10^{-4}$	$89.60 \pm 4.92$
VGG16		D	$10^{-4}$	$91.07 \pm 6.37$
VGG16		H	$10^{-5}$	$88.10 \pm 6.67$
VGG16		V	$10^{-3}$	$91.09 \pm 4.75$
VGG16	✓		$10^{-3}$	$88.59 \pm 6.36$
VGG16	✓	A	$10^{-5}$	$87.59 \pm 5.63$
VGG16	✓	D	$10^{-5}$	$87.57 \pm 4.14$
VGG16	✓	H	$10^{-2}$	$88.10 \pm 6.67$
VGG16	✓	V	$10^{-3}$	$91.04 \pm 5.40$

### 4.4.3 VGG16 と ResNet50

学習モデル VGG16 には Batch Normalization が搭載されていない。Batch Normalization は、レイヤ毎に input データを正規化する手法である。Batch Normalization を導入することで学習が安定する。また、高い学習率を設定することができるようになり、学習スピードが早くなる。そのため、近年使用されるモデルの多くで Batch Normalization が導入されている。そこで、本研究においても Batch Normalization の導入を行う。

また、本研究では全結合層を、Global Average Pooling(GAP)、全結合層、SoftMax に置き換えている。VGG16 の全結合層では最後の Max Pooling より  $16 \times 16 \times 512$  が出力され、それを  $1 \times 1 \times 2$  に全結合するため、膨大な量の重みパラメータになり、モデルのサイズが大きくなりすぎてしまう。Global Average Pooling では、最後の畳み込み層の出力の特徴マップをチャンネル毎に平均を取るため、512 を  $1 \times 1 \times 2$  に全結合する。それにより重みパラメータを減らすことができる。

## 4.5 モデルの評価

表 4.4: 実験条件 (ResNet50) の学習率

マスク処理		周波数成分	最適学習率	Validation accuracy
ResNet50			$10^{-3}$	$90.07 \pm 5.18$
ResNet50		A	$10^{-4}$	$89.59 \pm 5.69$
ResNet50		D	$10^{-4}$	$90.60 \pm 7.17$
ResNet50		H	$10^{-5}$	$88.12 \pm 7.77$
ResNet50		V	$10^{-3}$	$89.59 \pm 5.69$
ResNet50	✓		$10^{-3}$	$83.60 \pm 2.89$
ResNet50	✓	A	$10^{-5}$	$82.61 \pm 6.04$
ResNet50	✓	D	$10^{-5}$	$87.07 \pm 4.82$
ResNet50	✓	H	$10^{-2}$	$85.62 \pm 6.40$
ResNet50	✓	V	$10^{-3}$	$88.07 \pm 4.80$

学習モデル ResNet50 には Batch Normalization が既に搭載されている。しかし、本研究では Grad-CAM を用いるため、Global Average Pooling を使用する必要がある。そのため、本モデルでは、ResNet50 の全結合層を、Global Average Pooling, 全結合層, SoftMax に置き換えている。

## 4.5 モデルの評価

本研究ではモデルの評価として、平均正解率、平均再現率、平均適合率、平均 F 値を用いる。そして、学習した結果の妥当性を確認するために、Grad-CAM を用いて判断根拠の可視化を行う。

## 4.5 モデルの評価

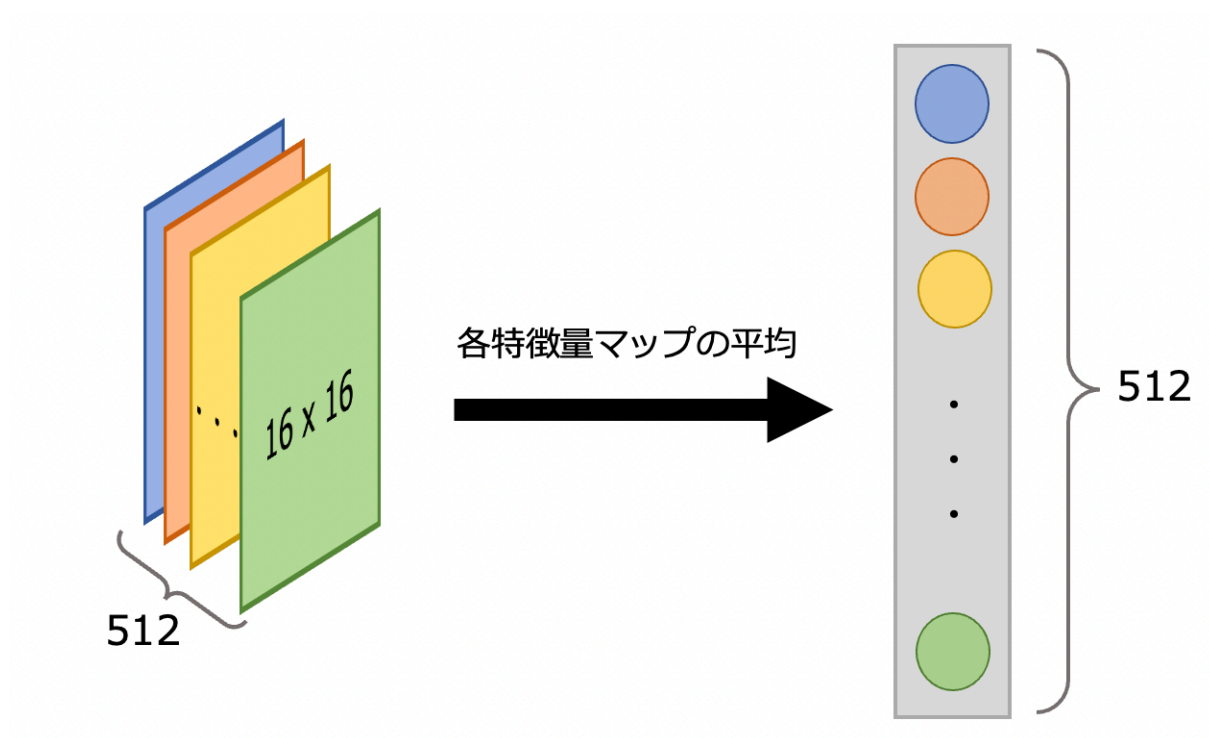


図 4.4: GAP の概要

## 第 5 章

# 結果と考察

本章では、本研究で行った 20 種の実験についての結果と考察を述べる．VGG16 を用いた推定結果を表 5.1，結果とその標準偏差をまとめたグラフを図 5.12, 図 5.13 に示す．ResNet50 を用いた推定結果を表 5.2 に示す．結果とその標準偏差をまとめたグラフを図 5.14, 図 5.15 に示す．

### 5.1 肺野領域抽出の有無による比較

VGG16 の表 5.1 では，抽出画像が元画像を平均正解率平均 F 値共に 2 ポイント程度上回った．Grad-CAM で可視化した画像を確認すると，図 5.1 などの元画像では肺野領域以外に注目しており，特に画像端や，角に書かれている文字に注目している．抽出画像では，肺野領域に注目しているものもあったが，図 5.2 などの肺野領域とマスクの境目に注目しているものが多く見られた．この結果から，肺野領域以外の場所への注目を矯正するためにも肺野領域抽出は有用であると確認できた．

ResNet50 の表 5.2 では，元画像が抽出画像を平均正解率，平均 F 値共に 10 ポイント程度上回った．しかし，元画像の方がどちらも 2.5%程度標準偏差が高く，結果にばらつきが見られた．Grad-CAM で可視化した画像を確認すると，元画像では，肺野領域以外に注目するようなヒートマップと画面端に注目するヒートマップの 2 種類が形成された．その図を図 5.3 に示す．この違いとして，画像の輝度が高い場合は肺野領域を除いた全体にヒートマップが形成され，輝度が低い場合は画像の端にヒートマップが形成されている．これはデータセットによって画像の輝度値に差が生じている可能性がある．そのため，画像の平坦化用い



## 5.1 肺野領域抽出の有無による比較

ることで学習の改善になるのではないかと考える．抽出画像では，全体的に肺野領域に注目しているが，一部の画像中央下に注目しているものを確認した．その図を図 5.4 に示す．

## 5.1 肺野領域抽出の有無による比較

表 5.1: VGG16 の結果

	マスク処理	周波数成分	平均正解率	平均再現率	平均適合率	平均 F 値
VGG16		normal	94.86 $\pm$ 1.10	97.65 $\pm$ 2.90	92.33 $\pm$ 2.30	94.85 $\pm$ 0.012
		Approximation	93.71 $\pm$ 2.14	100.00 $\pm$ 0.00	88.68 $\pm$ 3.51	93.96 $\pm$ 0.020
		Diagonal	95.43 $\pm$ 2.91	100.00 $\pm$ 0.00	91.68 $\pm$ 5.12	95.58 $\pm$ 0.028
		Horizontal	95.43 $\pm$ 2.91	100.00 $\pm$ 0.00	91.68 $\pm$ 5.12	95.58 $\pm$ 0.028
		Vertical	96.00 $\pm$ 6.66	100.00 $\pm$ 0.00	93.67 $\pm$ 10.11	96.43 $\pm$ 0.058
	✓	normal	97.14 $\pm$ 1.81	97.65 $\pm$ 2.88	96.60 $\pm$ 2.78	97.07 $\pm$ 0.019
	✓	Approximation	95.43 $\pm$ 2.29	92.94 $\pm$ 5.76	97.71 $\pm$ 2.80	95.10 $\pm$ 0.026
	✓	Diagonal	100.00 $\pm$ 0.00	100.00 $\pm$ 0.00	100.00 $\pm$ 0.00	100.00 $\pm$ 0.000
	✓	Horizontal	97.14 $\pm$ 2.56	100.00 $\pm$ 0.00	94.68 $\pm$ 4.71	97.21 $\pm$ 0.025
	✓	Vertical	93.71 $\pm$ 4.57	97.65 $\pm$ 2.88	91.00 $\pm$ 7.63	93.97 $\pm$ 0.041

## 5.1 肺野領域抽出の有無による比較

表 5.2: ResNet50 の結果

	マスク処理	周波数成分	平均正解率	平均再現率	平均適合率	平均 F 値
ResNet50			95.43±3.88	97.65±2.88	93.60±5.97	95.49±0.038
		Approximation	92.57±3.43	98.82±2.35	87.71±4.68	92.88±0.032
		Diagonal	92.00±4.57	100.00±0.00	86.42±6.99	92.57±0.040
		Horizontal	97.14±3.13	100.00±0.00	94.78±5.48	97.24±0.030
		Vertical	97.71±3.33	100.00±0.00	95.89±5.85	97.81±0.032
	✓		84.57±1.40	82.35±3.72	85.68±4.06	83.83±0.013
	✓	Approximation	87.43±2.29	85.88±6.00	88.16±3.04	86.82±0.027
	✓	Diagonal	97.14±2.56	97.65±2.88	96.72±4.28	97.11±0.026
	✓	Horizontal	91.43±5.11	92.94±2.35	90.44±8.30	91.51±0.049
	✓	Vertical	91.43±4.04	94.12±6.44	89.18±4.95	91.40±0.042

## 5.2 Haar wavelet 変換の有無による比較




図 5.1: VGG16 における元画像 (肺野領域外に注目)

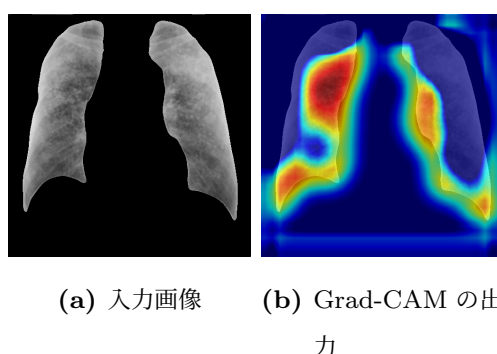


図 5.2: VGG16 における抽出画像 (境目に注目)


## 5.2 Haar wavelet 変換の有無による比較

### 5.2.1 VGG16

表 5.1 より, VGG16 の元画像では, Approximation を除き Haar wavelet 変換を行った方が平均正解率, 平均 F 値共に高い値となった. この結果から, Haar wavelet 変換を用いることで精度の向上が確認できた. そして, 低周波成分の Approximation には塵肺検出における重要な特徴が他のものよりも少ないと考えられる. また, VGG16 の元画像の中でも Vertical が最も高い数値となった. しかし, 標準偏差が他のものと比較して平均正解率では 3 ポイント程度, 平均 F 値では 5 ポイント程度高くなっている. そのため, 他の条件よりも結果にばらつきが見られる.

これらの結果を Grad-CAM で確認すると, Approximation は肺野領域外に注目しており, 肺野領域に注目していない. また, 元画像の Diagonal は肺野領域に注目しているもの


## 5.2 Haar wavelet 変換の有無による比較



(a) 肺野領域以外に注目する  
目するようなヒートマップ  
トマップ

(b) 画面端に注目する  
ヒートマップ

図 5.3: ResNet50 における元画像の例



(a) 肺野領域に注目する  
るようなヒートマップ  
ップ

(b) 画像中央下に注目  
するヒートマップ

図 5.4: ResNet50 における抽出画像の例

も半数程存在したが、ほとんどの画像が角のマークに注目していた。元画像の Horizontal は、大まかに肺野領域を型取ってヒートマップを形成しているが、うっすらと画面全体にも注目している。そして、画像端のマークに注目しているものも確認できた。Vertical では、KM データセットの多くは肺野領域を注目していたが、それ以外のデータセットでは、画像端を注目しているものが多かった。そのため、この条件においてもデータセットによる差が見られた。以上のことから、Horizontal のモデルを除き判断根拠に妥当性があるとは言えない。以上の Approximation, Diagonal, Horizontal の Grad-CAM の結果を図 5.5 に示す。Vertical の Grad-CAM の結果を図 5.6 に示す。

それに対し、VGG16 の抽出画像では、Diagonal が最も高い数値となった。予測精度 100%について、過学習や不適切な特徴 (例えば画像中の ID タグのような、病変ではない情

## 5.2 Haar wavelet 変換の有無による比較

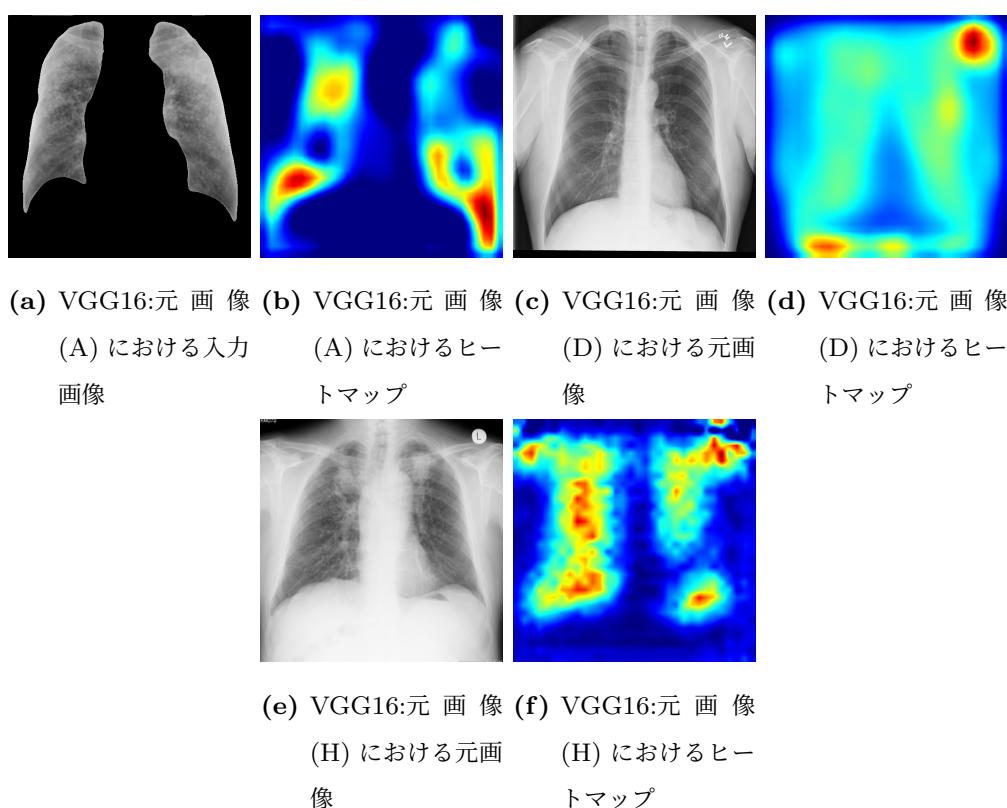



図 5.5: VGG16:元画像における wavelet 変換 (ADH) の Grad-CAM 結果

報) の危険性が考えられる。医用画像は画像に多くの情報が埋め込まれるため、マスクをしていない元画像についてはその可能性も考えられる。しかし、この条件では抽出画像を入力としているため、この条件で精度が 100% になるならば、ほかの条件においても同様の結果になるはずである。そのため、予測精度 100% については問題ないとする。本研究で用いたテストデータは 35 枚であり、枚数が少ないことから 100% の精度が実現したのではないかと考える。その他の Haar wavelet 変換したものは、抽出画像と同等かそれよりも低い値となった。

VGG16 の抽出画像の Grad-CAM を確認すると、図 5.7 の Approximation は、肺野領域の輪郭部をヒートマップで形成しているが、逆に肺野領域の中心部に対しては、あまり注目していないものが多く確認できた。しかし、図 5.5 の元画像の Approximation よりも肺野領域を注視しているため、肺野領域抽出の必要性を確認できた。図 5.8 の Diagonal は、肺野領域の中心部以外に注目しているものもあったが、概ね肺野領域に注目した。ま

## 5.2 Haar wavelet 変換の有無による比較




(a) VGG16:元 画 像 (b) VGG16:元 画 像 (c) VGG16:元 画 像 (d) VGG16:元 画 像  
(V) における肺野 (V) における肺野 (V) における肺野 (V) における肺野  
領域に注目した元 領域に注目した 領域外に注目した 領域外に注目した  
画像 ヒートマップ 元画像 ヒートマップ

図 5.6: VGG16:元画像における wavelet 変換 (V) の Grad-CAM 結果


た, Grad-CAM により可視化されたヒートマップは, データセットの種類によって特徴が見える. NIH データセットの画像では, はっきりと肺の形にヒートマップが形成されている. それに対し, KM データセットと NIOSH データセットの画像では, 概ね肺の形にヒートマップが形成されているが, NIH データセットのものと比較すると, まばらにヒートマップが形成されている. これは, 元々の画像の画質, ラベルの違いが原因であると考ええる. NIH データセットは 1024x1024 の画像であるが, KM データセットと NIOSH データセットは 299x299 の画像である. そのため, 画像に含まれる情報量に差が生じていた可能性がある. また, NIH データセットは全て NF 画像であり, KM, NIOSH データセットの多くは塵肺画像である. その結果がヒートマップに影響を及ぼした可能性がある. 次に, 図 5.9 の Horizontal は, NIH データセットの画像は概ね肺野領域に注目していたが, それ以外のデータセットの画像は出鱈目なヒートマップが形成されていた. また, NIH データセットの画像でも上手くヒートマップを形成できていないものもあったが, これは他の画像に比べて遠距離から撮られたように, 少し小さくなっていることが原因であると考ええる. 図 5.10 の Vertical では, 上手く肺野領域にヒートマップを形成できなかったが, 概ね肺野領域に近いヒートマップを形成した.

## 5.2 Haar wavelet 変換の有無による比較



(a) VGG16:抽出画像 (b) VGG16:抽出画像 (A) における入力画像 (A) におけるヒートマップ

図 5.7: VGG16:抽出画像 (A) における Grad-CAM の結果



(a) VGG16:抽出画像 (b) VGG16:抽出画像 (c) VGG16:抽出画像 (d) VGG16:抽出画像 (D) における入力画像 (D) における NIH データのヒートマップ (D) における NIOSH データの入力画像 (D) における KM データのヒートマップ


図 5.8: VGG16:抽出画像 (D) における Grad-CAM の結果

### 5.2.2 ResNet50

表 5.2 より, ResNet50 の元画像では, Horizontal, Vertical は元画像よりも平均正解率, 平均 F 値が高い値となった. これらを Grad-CAM で確認すると, 元画像では, 図 5.3 のような肺野領域以外に注目するようなヒートマップと画面端に注目するヒートマップの 2 種類が形成された. この違いとして, 画像の輝度が高い場合は肺野領域を除いた全体にヒートマップが形成され, 輝度が低い場合は画像の端にヒートマップが形成されている. そのため, 画像の平坦化用いることで学習の改善になるのではないかと考える. Approximation, Diagonal, Horizontal, Vertical では, 図 5.11 のように, NIH データセットは全体に注目したヒートマップ, KM データセットと NISOH データセットはうっすらと肺




## 5.2 Haar wavelet 変換の有無による比較



(a) VGG16:抽出画像 (H) における入力画像 (b) VGG16:抽出画像 (H) におけるヒートマップ (c) VGG16:抽出画像 (H) における失敗例の入力画像 (d) VGG16:抽出画像 (H) における失敗例のヒートマップ

図 5.9: VGG16:抽出画像 (H) における Grad-CAM の結果



(a) VGG16:抽出画像 (V) における入力画像 (b) VGG16:抽出画像 (V) におけるヒートマップ

図 5.10: VGG16:抽出画像 (V) における Grad-CAM の結果

野領域に注目したヒートマップが形成された。この結果から、これらのモデルでは塵肺を検出しているのではなく、データセットの検出を行っている可能性がある。本研究で使用した NIH データセットが全て NF 画像であることが原因として考えらる。

ResNet50 の抽出画像では、Haar wavelet 変換を行ったものは、全て抽出画像よりも高い平均正解率、平均 F 値となった。また、Diagonal は ResNet50 の抽出画像の中で最も高い値になった。以上のことから、肺野領域抽出は、ResNet50 における抽出画像では、有用である可能性がある。

これらの結果を Grad-CAM で確認すると、抽出画像は図 5.4 のような一部画像の中央下を注目しているものもあったが、概ね肺野領域を注目している。それに対して、Approximation, Diagonal, Horizontal, Vertical では、図 5.11 のように、元画像と同様なヒートマッ

## 5.2 Haar wavelet 変換の有無による比較

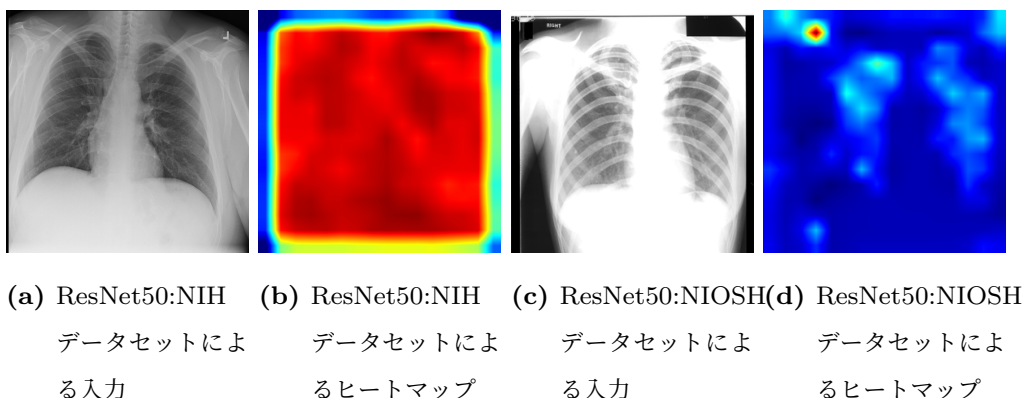


図 5.11: ResNet50:元画像におけるデータセットによる違い

プが形成された。以上の結果から、ResNet50 の抽出画像では塵肺検出の判断根拠に妥当性があると考えるが、その他の Haar wavelet 変換を行ったものについては、妥当性がないと考える。

### 5.2.3 Haar wavelet 変換と肺野領域抽出を合わせた比較

VGG において最も高い値であった、抽出画像の Diagonal は ResNet50 においても平均正解率 97.14%，平均 F 値 97.11%と高い値となった。そのため、抽出画像の Diagonal は VGG16，ResNet50 のどちらにおいても高い平均正解率と平均 F 値が確認できたため、高周波成分の中でも特に、塵肺の特徴が現れているのではないかと考える。また、VGG16 では低い平均正解率，平均 F 値だった Approximation は ResNet50 においても低い値と確認できた。これにより、低周波成分は高周波成分と比較して、塵肺検出において重要な特徴をあまり持っていないと考える。

## 5.2 Haar wavelet 変換の有無による比較




図 5.12: VGG16 における元画像を入力した結果




図 5.13: VGG16 における抽出画像を入力した結果

## 5.2 Haar wavelet 変換の有無による比較




図 5.14: Res50 における元画像を入力した結果




図 5.15: Res50 における抽出画像を入力した結果

## 第 6 章

# 結論

本論では、Haar wavelet による特徴抽出を行った後、CNN による胸部 X 線画像からの塵肺検出を行うことで、検出精度の向上を目指した。その結果、VGG16 モデルにおける抽出画像の Diagonal を入力とした場合において、平均正解率、平均 F 値共に 100%と高い識別率を持つ結果となった。そして、Grad-CAM による推定モデルの着目している場所の可視化においては、肺野領域に着目しており、学習結果の妥当性が確認できた。また、VGG16 モデルにおける元画像と抽出画像の両方の Approximation において、高周波成分と比較して、元画像では平均正解率 93.71%、抽出画像では、平均正解率 95.4%という低い識別率を持つ結果となった。この結果から、Approximation は高周波成分と比較して、塵肺検出に有用な特徴があまり含まれていないと考える。

VGG16 モデルにおける、Harr wavelet 変換を行った抽出画像と元画像を入力としたものをそれぞれ比較すると、抽出画像の Vertical を除いた全ての抽出画像が元画像よりも高い識別率となった。また、唯一元画像よりも低い識別率となった抽出画像の Vertical と元画像の Vertical を Grad-CAM で比較すると、抽出画像の Vertical では、ある程度塵肺に着目しているが、元画像の Vertical ではほとんど肺野領域に注目していない。そのため、結果としての識別率は元画像の Vertical の方が高い値となったが、塵肺をより識別しているモデルは抽出画像の Vertical であると考え。以上の結果から、VGG16 モデルにおいては抽出画像を入力とした場合の方が優れていると考える。

また、ResNet50 モデルにおける、元画像と抽出画像においても、モデルの結果を比較すると元画像が平均正解率 10 ポイント程度高い結果となった。しかし、Grad-CAM で比較を行うと、元画像のモデルではあまり肺野領域に着目していないが、抽出画像のモデルでは、

概ね肺野領域に着目していた．そのため，元画像のモデルには妥当性があるとは言えない．また，ResNet50 においては，抽出画像と抽出画像の Approximation 以外のモデルでは，全てのモデルが肺野領域に着目しておらず，データセットによって Grad-CAM の結果が変化する結果となった．この原因として，NIHCC データセットには健常画像しか含まれていないことが考えられる．これによって，塵肺の検出をしているのではなく，データセットの検出をしている可能性がある．また，データセットの輝度値が異なっていることや，元々の画像サイズが NIHCC のみ 1024x1024 であり，他のデータセットが 299x299 であるため，情報量に違いがあった可能性がある．そのため，今後，新しいデータセットを入手することや，画像の平滑化で改善する可能性がある．

# 謝辞

本研究を進めるにあたり、4年間ご指導して頂いた吉田真一教授に心から感謝いたします。研究に行き詰まった時には的確なアドバイスを頂き、常に研究の指針を示していただきました。先生のお力添えにより、無事修士論文の執筆を終えることができました。また、研究活動以外においても、様々な技術に造詣が深く、多くのことをご教授していただきました。そして、お忙しい中本研究の副査を引き受けて下さった敷田幹文教授、並びに妻鳥貴彦准教授にも心から感謝いたします。研究を進めるにあたって適切なご指摘をしていただきました。お二人には学部の頃から講義を含め多くのことを学ばせていただきました。これまで学ばせて頂いたことが研究活動においても大いに役立ちました。敷田先生には、課題のために徹夜で研究室にお邪魔した際にも笑顔で対応してくださり、大変居心地良く過ごすことができました。改めて深く感謝申し上げます。妻鳥先生には、研究室合同の飲み会や新歓など、非常に多くの場面でご指導いただきました。飲み会の場でも夜遅くまで一緒にさせていただきました。多くのことを学ばせていただき大変感謝しております。また、四宮友貴助教には夜遅くまで研究相談に乗ってくださりました。研究活動以外においても多くのことをご教授していただき大変感謝しております。一緒に休憩に行くことも多く、充実した研究室生活を送ることができ、大変感謝しております。そして、データを提供してくださった高知大学医学部にも深く感謝申し上げます。また、研究室の皆様のおかげで研究生活が有意義なものになったことを心から感謝いたします。特に同期の4人とは苦楽を共にし、研究室生活が豊かなものになりました。

また、これまで支えていただいた家族にも感謝いたします。最後に、大学・大学院生活に関わった全ての方に感謝申し上げます。

## 参考文献

- [1] Md Zahangir Alom, Chris Yakopcic, Mahmudul Hasan, Tarek M Taha, and Vijayan K Asari. Recurrent residual u-net for medical image segmentation. *Journal of Medical Imaging*, 6(1):014006, 2019.
- [2] Sema Candemir, Stefan Jaeger, Kannappan Palaniappan, Jonathan P Musco, Rahul K Singh, Zhiyun Xue, Alexandros Karargyris, Sameer Antani, George Thoma, and Clement J McDonald. Lung segmentation in chest radiographs using anatomical atlases with nonrigid registration. *IEEE transactions on medical imaging*, 33(2):577–590, 2013.
- [3] Paul Cullinan and Peter Reid. Pneumoconiosis. *Primary Care Respiratory Journal*, 22(2):249–252, 2013.
- [4] Gusztáv Gaál, Balázs Maga, and András Lukács. Attention u-net based adversarial architectures for chest x-ray lung segmentation. *arXiv preprint arXiv:2003.10304*, 2020.
- [5] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778, 2016.
- [6] Johannes 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.
- [7] Stefan Jaeger, Alexandros Karargyris, Sema Candemir, Les Folio, Jenifer Siegelman, Fiona Callaghan, Zhiyun Xue, Kannappan Palaniappan, Rahul K Singh, Sameer Antani, et al. Automatic tuberculosis screening using chest radiographs. *IEEE transactions on medical imaging*, 33(2):233–245, 2013.



## 参考文献

- [8] Lihua Li et al. Improved method for automatic identification of lung regions on chest radiographs. *Academic Radiology*, 8(7):629–638, 2001.
- [9] Olaf Ronneberger et al. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer, 2015.
- [10] Ramprasaath R Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, and Dhruv Batra. Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE international conference on computer vision*, pages 618–626, 2017.
- [11] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [12] Youbao Tang, Yuxing Tang, Jing Xiao, and Ronald M. Summers. XLSor: A Robust and Accurate Lung Segmentor on Chest X-Rays Using Criss-Cross Attention and Customized Radiorealistic Abnormalities Generation. *arXiv:1904.09229 [cs]*, April 2019. arXiv: 1904.09229.
- [13] Xiaosong Wang, Yifan Peng, Le Lu, Zhiyong Lu, Mohammadhadi Bagheri, and Ronald M Summers. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2097–2106, 2017.
- [14] Liuzhuo Zhang et al. A deep learning-based model for screening and staging pneumoconiosis. *Scientific reports*, 11(1):1–7, 2021.
- [15] Ran Zheng, Lanlan Zhang, and Hai Jin. Pneumoconiosis identification in chest x-ray films with cnn-based transfer learning. *CCF Transactions on High Performance Computing*, 3(2):186–200, 2021.
- [16] 永田 亮一 et al. 胸部 X 線像における肺尖から肋骨横隔膜角までの肺境界検出. *Medical*

## 参考文献

- imaging technology*, 27(5):341, 2009. Publisher: 日本医用画像工学会.
- [17] 内海ゆづ子 et al. 顔認識のためのウェーブレット特徴量の評価. volume 19, pages 476–487. 日本知能情報ファジィ学会, 2007.
- [18] 労災病院じん肺研究グループ 編集委員会. よくわかる じん肺健康診断. 2018.
- [19] 近藤 堅司, 小澤 順, 清野 正樹, 藤本 真一, 田中 雅人, 安達登志樹, 伊藤 春海, and 木村 浩彦. U-Net を用いた胸部 X 線画像からの解剖学的構造の領域抽出. volume JSAI2018, pages 2J404–2J404, 2018.
- [20] 平山一希, 陸慧敏, 金亨燮, 橘理恵, 平野靖, and 木戸尚治. DCNN による LIDC データからのすりガラス状陰影の検出. volume 34, pages 70–74, 2017. Publisher: 医用画像情報学会.
- [21] 春日 魚住 et al. Mask R-CNN を用いた小児胸部 X 線画像における肺領域の自動抽出. *Medical Imaging Technology*, 38(3):126–131, 2020.