

びまん性肺疾患識別における Deep Convolutional Neural Network 特徴の解析

鈴木 聡志^{1,a)} 庄野 逸^{1,b)} 木戸 尚治^{c)}

概要: 画像診断を行う医師の負担は、X線 CT 装置の性能向上による撮像枚数の増加とセカンドオピニオンの普及による複数患者の診断によって、増加傾向にあり、計算機による診断補助を行う計算機診断支援 (Computer Aided Diagnosis: CAD) システムの構築が望まれている。本研究では、CAD システムのうち、びまん性肺疾患画像の特徴解析を行うサブシステムを Deep Convolutional Neural Network (DCNN) を用いて構築することを目的とした。DCNN は、階層型ニューラルネットワークを用いた手法で、データから特徴表現を学習することが可能であるが、特徴表現を取得するために十分な数の入力データが必要になる。その一方で医用画像の識別システムを構築するために学習データを十分確保することは困難な場合もある。前回の研究結果から、我々はデータセットに自然画像と CT 画像とを用いた半教師付き学習を行うことで、びまん性肺疾患画像の識別精度が向上することを示しているが、DCNN 内部での挙動は不明瞭であった。そこで本研究では、DCNN の中間層から抽出される特徴量を線形 Support Vector Machine を用いて解析した。

キーワード: DCNN, 半教師付き学習, びまん性肺疾患画像解析

Analysis for Deep Convolutional Neural Network feature with Diffuse Lung Disease classification

SATOSHI SUZUKI^{1,a)} HAYARU SHOUNO^{1,b)} SHOJI KIDO^{c)}

Abstract: The computer aided diagnosis (CAD) system is desired to develop for supporting physicians to diagnose the diffuse lung diseases (DLD). We apply a deep convolutional neural network (DCNN) into the CAD system for the classification of DLDs. DCNN is a kind of multi layer neural network which can automatically extract features description depending on the input data. Meanwhile, obtaining the effective DCNN features, it requires large amount of training data. In the field of medical image analysis, the number of acquired data sometimes is not enough to train. Thus, in our previous work, we introduce a kind of semi-supervised learning (SSL) based method for training the DCNN. At first, we apply massive natural images, which we can easily collect, for the unlabeled data. After that, we train the pre-trained DCNN with the small number of the DLD patterns as the labeled data. In this research, we analyze the intermediate layers of the DCNN in order to investigate the feature expression transition by use of the linear support vector machine (SVM).

Keywords: Deep Convolutional Neural Network, Semi-supervised Learning, Diffuse Lung Disease image analysis

1. まえがき

びまん性肺疾患とは、肺の広範囲にわたって異常な陰影が観察される病気の総称である。図 1 は、びまん性肺疾患と診断された患者の CT 画像例であり、右肺部 (図中左側) にびまん性肺疾患の症状が観察される。びまん性肺疾患の

¹ 電気通信大学大学院情報理工学研究所, 〒182-8585 東京都調布市調布ヶ丘 1-5-1

² 山口大学大学院応用理工学研究所 〒755-8611 宇部市常磐台 2-16-1

^{a)} s1530033@edu.cc.uec.ac.jp

^{b)} shouno@uec.ac.jp

^{c)} kido@ai.csse.yamaguchi-u.ac.jp




図1 びまん性肺疾患と診断された患者のCT画像例。向かって左側の右肺部分、枠線内に白い病変が広がっていることが分かる。

陰影は、淡い陰影パターンを呈し、広範囲にわたって観察されることが多く、陰影パターンが複雑多様であるため、医師の経験等によって診断が左右される場合がある。

本研究では、びまん性肺疾患画像の特徴解析に、階層型神経回路モデルの一種である Deep Convolutional Neural Network (DCNN) を用い、医用診断支援を行う計算機診断支援 (Computer Aided Diagnosis: CAD) システムへの適用を検討する。

DCNN は、Fukushima の Neocognitron に代表されるように、画像認識システムとして有効な階層型神経回路モデルであるが、特徴抽出器としての性能を発揮するには十分なデータが必要となる [1][2][3]。一方、医用画像はその性質上、大量にデータを収集する事は難しい場合が多い。鈴木らは、取得が容易な自然画像と、ターゲットとなる CT 画像を用いた半教師付き学習を行う事で、識別精度が向上することを示し、また、中間層の挙動も調査した [4]。本研究では、先行研究で行われた DCNN 特徴の解析をより詳細に行い、先行研究では発見できなかった DCNN の性質を発見した。

2. 手法

本研究で用いる Deep Convolutional Neural Network (DCNN) は Fukushima の提唱した Neocognitron と同様な構造をもち、階層間の演算が畳み込み演算で記述できるのが特徴である。この DCNN は、顔や音声の認識手法として広く認知されつつある [5]。

2.1 DCNN モデルの概要と定式化

本研究で用いるのは中間層 10 層から成る DCNN である。ネットワークアーキテクチャの概要を図 2 に示す。このアーキテクチャは Krizhevsky らのと同様のものを用いており、学習により決定すべきパラメータ数は $O(10^7)$ である [6]。この DCNN は図 2 に示すように convolution 層 → ReLU 層 → pooling 層 → normalize 層 という処理を繰り返して行っており、各層は、複数の、画像状の平面構造を持つ素子から成り立っている。これらの層からなる処理単位を Neocognitron に倣い、段 (stage) と呼ぶことにする [1]。以

下では i 番目の段の各層について、 p 番目の入力を行った場合の定式化を行う。

convolution 層の演算は畳み込みであり、 k 番目の面の位置 \mathbf{x} における出力を $f_i^{\text{conv}}(k, \mathbf{x})$ と表すことにする:

$$f_{p,i}^{\text{conv}}(k, \mathbf{x}) = \sum_{l, \mathbf{u}} g_i(k, l, \mathbf{u}) f_{p,i-1}^{\text{pool}}(l, \mathbf{x} - \mathbf{u}), \quad (1)$$

ただし、 $g_i(k, l, \mathbf{u})$ は、前段 ($i-1$ 段) pooling 層の l 番目の面から、 i 段目の convolution 層 k 番目の層への結合係数で、畳み込み核に相当する。

次の ReLU 層では convolution 層の出力に対して非線形変調を施す。ここでは、活性化関数として、Rectified Linear Unit (ReLU: 半波整流) を用いている。ReLU 層での出力は以下の様に記述できる。

$$f_{p,i}^{\text{ReLU}}(k, \mathbf{x}) = \max[0, f_{p,i}^{\text{conv}}(k, \mathbf{x})] \quad (2)$$

次の pooling 層では、空間プーリングを行うことで情報圧縮と局所変形に対する応答の頑健性の向上を図る。ここでは、局所的な領域中の最大値を用いる max-pooling 演算を考える。 i 段目 k 番目の面の位置 \mathbf{x} の max-pooling 演算の出力を $f_{p,i}^{\text{pool}}(k, \mathbf{x})$ とすると

$$f_{p,i}^{\text{pool}}(k, \mathbf{x}) = \max_{\mathbf{u} \in N(\mathbf{x})} [f_{p,i}^{\text{ReLU}}(k, \mathbf{u})], \quad (3)$$

と書ける [7]。ただし、 $N(\mathbf{x})$ は、位置 \mathbf{x} に対応する局所領域を表す。以降の各段の特徴表現では、この pooling 層の出力を用いるが、これは pooling 層の k, \mathbf{x} に関する全ての要素を並べてベクトルとして扱ったものとする:

$$\mathbf{f}_{p,i}^{\text{pool}} = \{f_{p,i}^{\text{pool}}(k, \mathbf{x})\}_{k, \mathbf{x}} \quad (4)$$

図 2 に示したように、本研究で用いた Krizhevsky の DCNN アーキテクチャは fc6 層までは上述の演算を繰り返して特徴抽出を行うが、これ以降の層は、全結合型の多層型パーセプトロンを結合したような形になっている。

この DCNN アーキテクチャを最適化するために損失関数として softmax 関数を用い、誤差逆伝播 (Back-propagation: BP) 法を学習に用いる。softmax 関数は分類を確率的な視点から考え、入力 \mathbf{f} がクラス k に分類される事後確率 $p(C_k|\mathbf{f})$ を

$$p(C_k|\mathbf{f}) = \frac{p(\mathbf{x}|C_k)p(C_k)}{\sum_j p(\mathbf{f}|C_j)p(C_j)} = \frac{\exp(a_k)}{\sum_j \exp(a_j)} \quad (5)$$

と定義した関数である。ただし、 a_k は $a_k = \ln(p(\mathbf{f}|C_k)p(C_k))$ である [8]。

2.2 DCNN を用いた半教師付き学習の医用画像応用

DCNN を物体認識に用いる場合、その学習には、ネットワークアーキテクチャに含まれるパラメータの規模に応じた学習セットが必要であることが知られている。LeCun

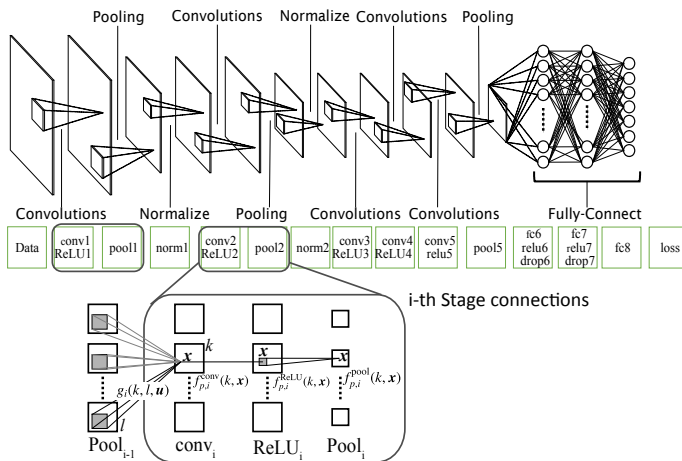


図2 本研究で用いた DCNN (図中上部) の概要と処理の詳細 (図中下部). DCNN は特徴抽出を行う中間層 10 層, 識別層 3 層から構成され, パラメータ数は $O(10^7)$ である. ニューロンの出力値を決定する活性化関数には Rectified Linear Unit (ReLU) を用いている. なお, ネットワーク下部の囲いは対応する階層・処理の名前を示す. DCNN は中間層で図中下部のような処理を繰り返す事で画像の特徴表現を学習する.

らは手書き数字文字認識を行わせるために 6 層の DCNN に対して $O(10^4)$ オーダーの MNIST データベースを用いている. Le らは 9 層の DCNN の特徴学習に $O(10^8)$ 枚の YouTube からサンプリングした自然画像をデータとして利用している [3].

その一方で, 本研究で取り扱うびまん性肺疾患画像のような医療データは, 診断に医師の判断が必要であり, 大量のラベル付きデータを収集するのが困難な場合がある. 鈴木らは, Krizhevsky らの DCNN の学習に $O(10^4)$ の CT 画像のみで学習を行った場合, DCNN 内部で過学習が生じる事を示し, 事前に $O(10^6)$ の自然画像を用いて学習を行う事で精度が向上する事を示した [4].

3. 実験

3.1 実験方法

3.1.1 交差検証法を用いた識別性能評価

比較としては, まず各 DCNN 特徴を用いた場合の識別性能について議論を行う. 識別器は線形 Support Vector Machine (SVM) を用いて識別スコアを算出した [9]. スコアには交差検証法を用いて Leave-One-Person-Out CV (LOPOCV) スコアを用いた. 本研究のような医療画像を識別評価に用いる場合, 患者一人のデータ除外した交差検証 (Leave One Person Out Cross Varidation: LOPOCV) 法を用いる. この手法は, 各患者一人から収集した画像データを評価データとし, 他患者からの画像データを学習データとする事で識別率を算出する手法である. X 線 CT 画像を用いてデータを収集する場合, 同一患者から複数のサンプルやパッチ画像を収集する場合があります, 単純に Leave-One-Out CV 法を用いて評価した場合, 同一患者から収集した画像データが,




図3 ROI 画像 7 種類の典型例. a, b, c, d がびまん性肺疾患の陰影クラスである.

学習データと評価データの双方に存在する事になり, 評価にバイアスがかかる可能性がある. このようなバイアスを排除するため LOPOCV 法を用いて評価する必要がある.

3.2 実験データ

本研究で使用したデータは大阪大学の提供による, びまん性肺疾患を対象とした X 線 CT 画像であり, 医師の指導の下, 7 つのクラスに分類されている. まず, びまん性肺疾患を呈する陰影は 4 クラスで, それぞれ浸潤影 (consolidation: CON), すりガラス状陰影 (ground-glass opacity: GGO), 蜂巢状陰影 (honeycomb: HCM), 網状影 (reticular: RET) である. びまん性肺疾患以外の陰影は 2 クラスで, びまん性肺疾患と似た陰影を呈する肺気腫 (emphysema: EMP) と, 腫瘍などが呈する粒状影 (nodular: NOD) である. さらに, 正常状態 (Normal: NOR) を加えた合計 7 クラスで分類を行う. CT 画像から医師の指定した病変部分を 32×32 [pixel] の大きさのパッチ画像として切り出した. これを ROI (Region of Interest) 画像と呼ぶ. 病変部は必ずしも 32×32 [pixel] の正方形領域で切り出せるわけではないため, 領域内に病変部が 80 % 以上含まれるものを用いた. 各陰影パターンの典型例を図 3 に, CT 画像から切りだした ROI 画像の DCNN 特徴学習用のデータと, 識別実験における識別器の訓練用と評価用に分けた内訳を表 1 に示す. なおデータは Krizhevsky のネットワークを用いるため ROI 画像は 224×224 サイズに拡大したものを用了.

また, 表 1 において, "DCNN 特徴学習用" と "SVM 学習と評価用" の ROI 画像の枚数のオーダーが異なっているが, これは ROI 画像の採取の仕方に依存している. "DCNN 特徴学習用" データでは, DCNN の学習に用いる事を前提に ROI 画像の抽出の際, 画像の重なりを許容し, 8 [pixel] ずつラスタスキャンしながら ROI 画像を得ているのに対し, "SVM 学習と評価用" データでは重複を許容しないように抽出を行っているため抽出元の CT 画像の枚数は同数程度であるが, ROI 画像の枚数のオーダーが異なっている. また, それぞれの ROI 画像の抽出元の CT 画像の振り分けは医師の指導に従った.

4. 実験結果

表 2 は, DCNN の各階層から抽出した特徴量を用いて算出した LOPOCV スコアである. 階層を経るにつれて識別

表 1 CT 画像から切り出した各症例の ROI 画像の枚数.

症例	DCNN 特徴学習用	SVM 学習と評価用
Consolidation(CON)	143 枚	26 枚
GGO	609 枚	46 枚
Honeycomb (HCM)	282 枚	73 枚
Reticular (RET)	210 枚	66 枚
Emphysema (EMP)	4406 枚	296 枚
Nodular (NOD)	762 枚	65 枚
Normal (NOR)	5371 枚	355 枚
計	11783 枚	927 枚

精度が上昇している事が分かるが, pool 層で識別精度が大きく上昇している. この結果は, 中間層では Pool 層で識別精度を上昇させるような処理が施されていることを示唆しているが, 具体的に特徴空間でどのように特徴点が存在しているのか不明瞭である. そこで本研究では線形 SVM を用いて, 階層・DCNN 毎のクラス分離度を議論した.

4.1 線形 SVM を用いたクラス分離度

ここでは, DCNN の階層ごとに分離度がどのように変化しているのかを議論する. 分離度を示す指標として, 線形 SVM の分離境界に対して, 各クラスのデータを射影して得られるヒストグラムを用いる. 図 4 上段のように, SVM は特徴空間上に存在する入力データのうちからマージンを最大化するようなサポートベクトルから分離平面を構成する. このとき分離平面からの距離は, 分離平面を記述する法線ベクトルへの射影として定義できる. そこで, 表 1 の”SVM 学習と評価用” データをランダムに Train Data と Test Data に分割し, 図 4 のように Train Data で, 線形 SVM の学習を行い, Test Data で法線ベクトルへの射影を行いヒストグラムを作成する事で分離度の変化を議論する. 本研究では, conv1 層, pool1 層, conv2 層, pool2 層, conv3 層, conv4 層, conv5 層, pool5 層, fc6 層, の各階層から抽出した特徴量から SVM を構成し, 図 4 下段のようなヒストグラムを作成する事で, どのようにパターンの分離が進行していくかを観測した.

図 5 は, NOD クラスと GGO クラスにおけるクラス分離度のヒストグラムである. 各行はそれぞれ, 提案手法, CT 画像のみ, 自然画像のみで学習を行った DCNN, 各列は特徴を抽出した階層を示している. いずれの DCNN においても, 階層を経るごとにヒストグラムの重複部分は減少し, 識別精度が向上している事が分かる. また, 提案手法, 自然画像のみで学習した DCNN においては pool 層でクラス毎にヒストグラムが細長くなり, クラス内分散が減少していることが見て取れる. この事から, pool 層ではクラス内分散が減少するため識別精度が上昇するという可能性が示唆され, CT 画像のみで学習したネットワークは, この処理が正常に行われないうちに Pool 層での識別精度の上昇が少ないと考えられる. この仮説を検証するために, 各階

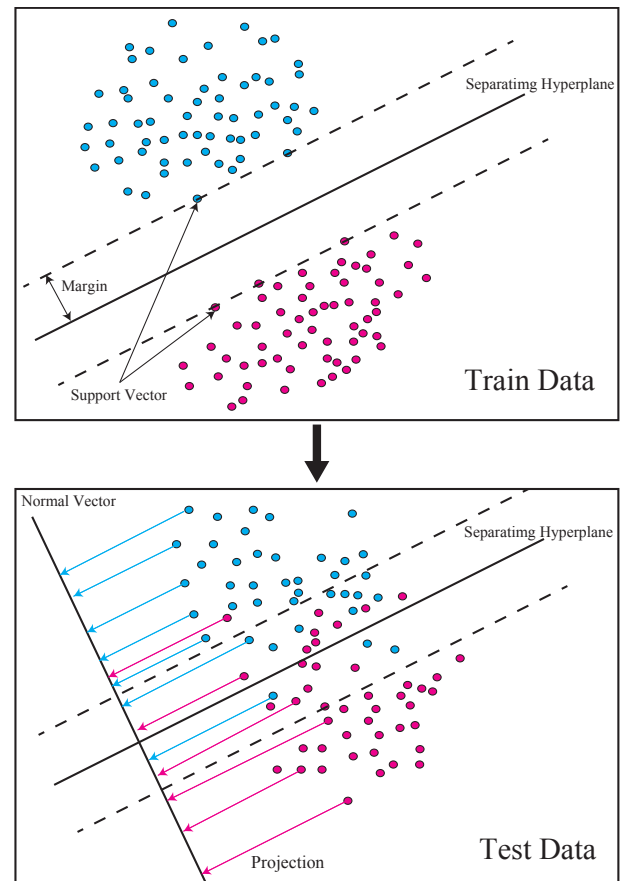


図 4 線形 SVM を用いたクラス分離実験の模式図. 上段 Train Data では, 線形 SVM の学習を行い, 下段 Test Data では法線ベクトルへの射影を行い分離度のヒストグラムを作成した.

層における SVM の分離境界までの距離のクラス内分散値を 7 クラス分類の 1 対 1 の組み合わせ 21 パターン全てで算出し, その平均値を表 3 にまとめた.

表 3 より, 提案手法と自然画像のみで学習した DCNN のクラス内分散が CT 画像のみで学習した DCNN と比較して小さくなっており, また, 全ての DCNN において pool 層でクラス内分散が減少している事から識別精度が向上している事が分かる. したがって, 提案手法と自然画像で学習した DCNN のように多数のデータサンプルで学習した DCNN は, CT 画像で学習した DCNN のようにデータサンプルが少数の DCNN と比較するとクラス内分散が減少するため, 識別精度が向上することが示唆される. しかし, この結果のみでは CT 画像の識別に自然画像を用いた事でクラス内分散が減少しているか, サンプル数が原因なのか不明瞭である. そこで, 自然画像のみで学習した DCNN から自然画像データセットである Caltech-101 のいくつかのクラスの特徴量を抽出し, 線形 SVM を用いて, 上記と同様のヒストグラムを作成した.

図 6 より, データサンプルが多量に存在するデータセットにおいて DCNN の学習を行うと, ヒストグラムのクラス内分散が減少し, 識別精度が向上するという我々の仮説の妥当性が示唆された.

表 2 各階層から抽出した特徴量を用いた線形 SVM の LOPO 識別スコア。

DCNN	conv1	pool1	conv2	pool2	conv3	conv4	conv5	pool5	fc6
Proposed	50.08%	70.07%	69.46%	70.24%	70.84%	72.67%	72.64%	75.55%	80.04%
CT	50.96%	66.04%	67.57%	74.38%	74.61%	75.25%	77.55%	77.85%	74.13%
Nat	52.27%	69.41%	68.15%	70.40%	66.79%	66.33%	69.38%	69.94%	75.78%

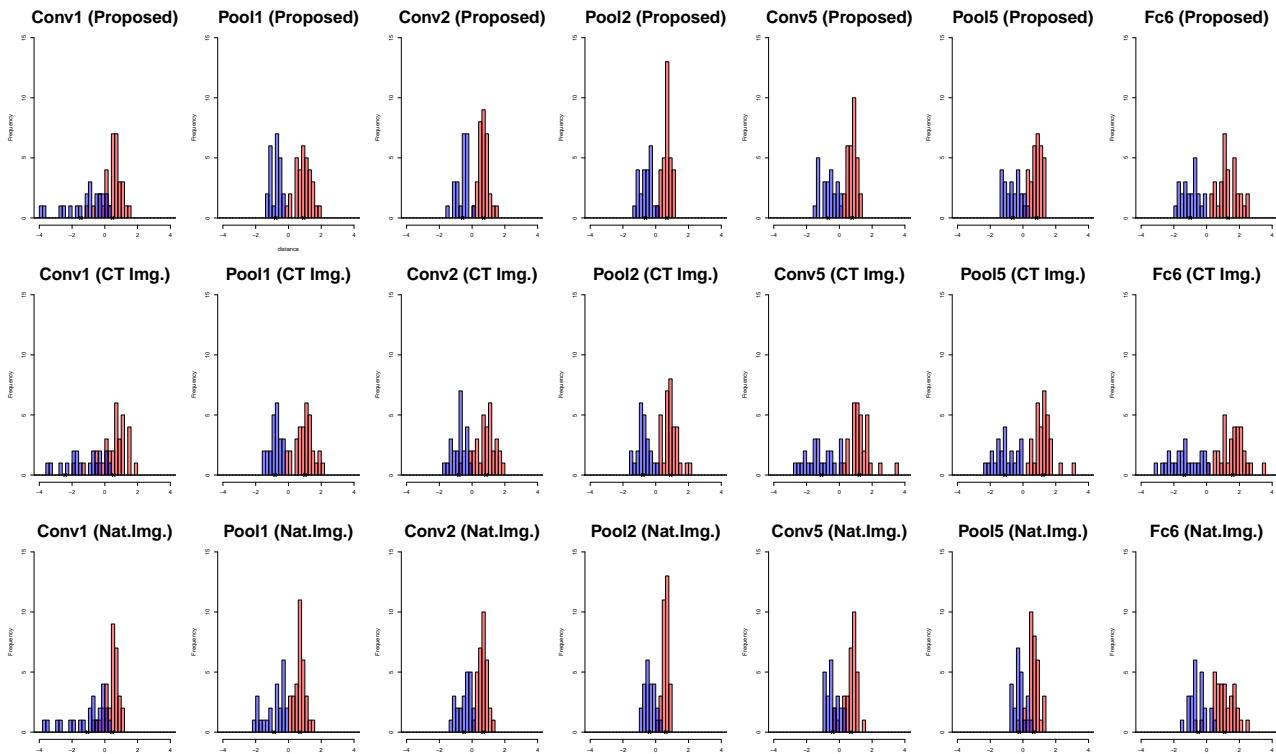


図 5 Nodular と GGO の 2 クラスにおける, SVM の分離超平面からの距離ヒストグラム. 右側のヒストグラムが Nodular, 左側のヒストグラムが GGO を示しており, それぞれ 1 と -1 がサポートベクトルの位置である. 各列は, 左から conv1 層, pool1 層, conv2 層, pool2 層, conv5 層 pool5 層, fc6 層で抽出した特徴を用いて学習したヒストグラムとなっており, 各段は, 上から提案手法, CT 画像のみ, 自然画像のみで学習したネットワークで抽出した特徴を用いている. 1, 3 段目の提案手法と自然画像を用いて学習した DCNN ではヒストグラムが階層を経るごとに徐々に細くなっている事が見て取れる.

4.2 特徴点の特徴空間における cos 類似度

4.1 節は, DCNN の中間層では各クラスの特徴のクラス内分散を減少させる処理が行われる事を示唆しているが, 4.1 節は, 線形 SVM の法線ベクトルへの射影を評価しているため, 特徴空間上で各特徴点が互いに近づいているかは不明瞭である. そこで, 中間層の表現を式 (3) のようなベクトル表現として考え, 中間層のベクトル表現が, 同一クラス内でどの程度類似しているかどうか, cos 類似度を用いて調べた [10]. cos 類似度は基準となるパターン p に対応する表現 $f_{p,i}$ と, 変形させたパターン q に対応する表現 $f_{q,i}$ との間の距離で, $s = f_{p,i} \cdot f_{q,i} / \|f_{p,i}\| \|f_{q,i}\|$ で定義される. ここでは, 提案手法で得た DCNN の各階層から抽出した特徴量において, クラスごとに総当たりで cos 類似度を算出し, その平均値を表 4 にまとめた. 表 4 より, DCNN の階層を経る毎に特徴空間上で各クラスの特徴点のクラス内分散が減少し, それぞれの特徴点が近づいていくという,

我々の仮説が正しい事を示唆される. また, 興味深いのは表 4 の pool5 層において大きく cos 類似度が低下している点である. この結果は, 表 3 の結果と相違があり, 特徴空間上と線形 SVM の距離の射影での性質が必ずしも一致しない事を示唆している.

5. 考察・結論

本研究では, びまん性肺疾患の識別における DCNN 特徴の解析を行った. 先行研究では行われていない階層ごとの識別精度の算出を行い, 加えて階層ごとのクラス分離度を議論することで DCNN の中間層で特徴点がどのような挙動を示すか, 解析することに成功した. 本研究の実験結果は, 多量のデータサンプルで DCNN を学習した場合, 中間層では各クラスのクラス内分散を小さくする処理が行われている事を示唆している.

しかしながら, 4.1 節の結果と 4.2 節の結果には相違があ

表3 びまん性肺疾患7クラスの1対1分類の全組み合わせにおける、各階層から抽出した特徴量を用いて学習した線形SVMの分離境界への距離のクラス内分散の平均値。

DCNN	conv1	pool1	conv2	pool2	conv3	conv4	conv5	pool5	fc6
Proposed	1.093	0.4509	0.4064	0.2469	0.3676	0.3308	0.3350	0.2778	0.6524
CT	2.080	0.7172	0.9964	0.7168	1.273	1.413	1.332	0.9894	1.465
Nat	0.7695	0.4312	0.3565	0.2147	0.3158	0.3161	0.3254	0.2564	0.6273

表4 提案手法で得たDCNN特徴の各クラスにおけるcos類似度。pool5層を除き、階層を経るにつれてcos類似度が大きくなっていることが分かる。

	NOD	EMP	HCM	CON	GGO	NOR	RET
conv1	0.0234	0.1204	0.0362	0.7917	0.1425	0.0346	0.2861
pool1	0.5024	0.5081	0.5422	0.7819	0.5435	0.4833	0.6249
conv2	0.6955	0.7078	0.6904	0.9084	0.7261	0.7003	0.7964
pool2	0.7188	0.6667	0.7286	0.8227	0.7381	0.6933	0.7873
conv3	0.7249	0.6719	0.7464	0.8734	0.7626	0.6913	0.8161
conv4	0.7432	0.7275	0.7440	0.8603	0.7663	0.7218	0.8037
conv5	0.8608	0.8381	0.8415	0.9148	0.8785	0.8511	0.8920
pool5	0.6109	0.6210	0.5863	0.7250	0.6226	0.6108	0.7173
fc6	0.8663	0.8670	0.8731	0.8816	0.8794	0.8747	0.8965




図6 Caltech-101のMotorbikesクラスとAirplanesクラスのヒストグラム。中間層で、ヒストグラムが細くなっており、データサンプルを多量に用いて学習を行った場合、ヒストグラムのクラス内分散が減少するという、仮説の妥当性を示唆している。

り、pool5層では特徴点間のcos類似度が大きく減少している。この相違の原因を調査し、pool5層から抽出できる特徴空間上でどのような現象が起こっているのかを把握することを今後の課題としたい。

謝辞 実験に際し、貴重なデータを提供していただいた、大阪大学附属病院に深く感謝いたします。

参考文献

- [1] K. Fukushima, *Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position*, Biological Cybernetics, Vol. 36, No. 4, pp. 193-202, 1980.
- [2] H. Shouno, *Recent Studies around the Neocognitron*, in Proc. Lecture Notes in Computer Science, Springer, Vol. 4985, pp. 1061-1070, 2007.
- [3] Quoc V. Le, Marc'Aurelio Ranzato, Rajat Monga, Matthieu Devin, Kai Chen, Greg S. Corrado, Jeff Dean, Andrew Y. Ng, *Building High-level Features Using Large Scale Unsupervised Learning*, Acoustics, Speech and Signal Processing, pp. 8595-8598, 2013.
- [4] 鈴木 聡志, 庄野 逸, 木戸 尚治, *Deep Convolutional Neural Network* を用いたびまん性肺疾患画像の特徴解析, 信学技報, vol. 114, no. 515, NC2014-114, pp. 259-264, 2015.
- [5] Li Deng, Dong Yu, *Deep Learning: Methods and Applications*, Microsoft Research, 2014.
- [6] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, *ImageNet Classification with Deep Convolutional Neural Networks*, Advances in Neural Information Processing Systems 25, 2012.
- [7] Dominik Scherer, Andreas Müller, and Sven Behnke, *Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition*, Artificial Neural Networks ICANN 2010 Lecture Notes in Computer Science Volume 6354, 2010, pp 92-101.
- [8] C. M. Bishop 著, 監訳: 元田浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田昇, *Pattern recognition and machine learning-パターン認識と機械学習*, シュプリンガー・ジャパン, 2007-2008.
- [9] Chih-Chung Chang, Chih-Jen Lin, *LIBSVM: a library for support vector machines*, ACM Transactions on Intelligent Systems and Technology (TIST), Vol. 2, No. 3, pp. 27, 2011.
- [10] 吉塚武治, 庄野逸, 宮本弘之, 岡田真人, 福島邦彦, *ネオコグニトロンによる視覚腹側経路のモデル化*, 神経回路学会論文誌, 14(4), pp.266-272, 2007.