

2段階転移学習を用いた深層畳み込みニューラルネットワークによるびまん性肺疾患の識別と特徴表現の解析

鈴木 藍雅^{1,2,a)} 坂無 英徳^{2,1,b)} 木戸 尚治^{3,c)} 庄野 逸^{4,2,d)}

概要：転移学習は目的とは異なるタスクにおいて獲得した知識を転用することでモデルの汎化性能の向上を図る機械学習のテクニックである。多くの先行研究が深層畳み込みニューラルネットワークによる画像認識のタスクにおいて、学習に用いるデータ数が少ない場合に転移学習がモデルの性能を向上させることを示している。本稿では転移学習の一手法として、テキストチャ認識タスクに向けた2段階転移学習手法を提案する。提案手法は大量の自然画像に加え、テキストチャ画像を用いて2段階に渡るモデルの事前学習を行う学習則である。実験では2段階転移学習を胸部X線CT画像から、びまん性肺疾患の陰影を分類する問題に適用し、転移学習を行わない場合、従来の1段階の転移学習手法に比べ、モデルの性能が向上することを示した。また、学習に用いるデータ数の減少に対して、2段階転移学習は高い頑健性を示した。更に本稿では深層畳み込みニューラルネットワークの特徴表現を可視化する手法を用いて、転移学習によりモデルが事前学習に応じた特徴表現を獲得することを明らかにした。

キーワード：深層畳み込みニューラルネットワーク, 転移学習, 画像認識, テキスチャ認識, 医用画像

Feature Representation Analysis of Deep Convolutional Neural Network using 2-staged Transfer Learning -An Application for Diffuse Lung Disease Classification-

AIGA SUZUKI^{1,2,a)} HIDENORI SAKANASHI^{2,1,b)} SHOJI KIDO^{3,c)} HAYARU SHOUNO^{4,2,d)}

1. はじめに

深層畳み込みニューラルネットワーク (Deep Convolutional Neural Network; DCNN) は、Krizhevsky らによる AlexNet [7] が 2012 年に大規模画像分類コンペティションである ILSVRC において成功を収めて以来、コンピュータ

ビジョンの分野においてデファクトスタンダードとなりつつある。DCNN は Fukushima らの哺乳類初期視覚野を模した計算モデルであるネオコグニトロン [4], [5] をルーツに持つ、階層型ニューラルネットワークモデルの一種である。哺乳類における初期視覚野は視覚刺激の処理過程において階層構造を持つことが知られている [6]。DCNN はこの生理学的知見に倣い“畳み込み”、“空間プーリング”と呼ばれる処理を階層的に積み重ねることによって、入力から特徴表現を抽出するモデルである。DCNN の特筆すべき性質として、従来のパターン認識のモデルでは手作業により設計されていた適切な特徴表現を、End-to-End の学習によって自動的に獲得できることが挙げられる。

DCNN は画像認識において極めて高い性能を発揮する一方で、学習において大量のデータを必要とする欠点がある。Bengio らは深層ニューラルネットワークが良好な汎

¹ 筑波大学システム 情報工学研究科
305-8577, 茨城県つくば市天王台 1-1-1
² 産業技術総合研究所 人工知能研究センター
305-8568, 茨城県つくば市梅園 1-1-1 中央第 1
³ 山口大学 医学系研究科
755-8505, 山口県宇部市吉田 1677-1
⁴ 電気通信大学 情報理工学研究科
182-8585, 東京都調布市調布ヶ丘 1-5-1
a) ai-suzuki@aist.go.jp
b) h.sakanashi@aist.go.jp
c) kido@ai.csse.yamaguchi-u.ac.jp
d) shouno@uec.ac.jp

化性能を示すには、モデルの自由パラメータの10%の数の学習データが必要であると報告している [1]。一方で医用画像のようにデータの収集に多大なコストを要する応用においては、十分な数のデータを学習に用いることができない。一般に、こうした学習データの不足は、過学習などによりモデルの汎化性能の悪化を引き起こす。

十分な学習データが存在しない元で、学習モデルの汎化性能を担保するための手法として転移学習 [9] が挙げられる。転移学習は“転移元ドメイン”と呼ばれるタスクにおける事前学習で得られた知識を転用し、目的のタスクにおけるモデルの性能を向上させる手法の総称である。例えば分類問題における転移学習では、モデルはまず転移元ドメインの分類を行うように学習された後、再度目的タスクの分類を行うように再学習される。DCNNにおける転移学習では、前述の“畳み込み”、“空間プーリング”からなる特徴抽出部の学習結果を再利用することでモデルの性能向上を図る。本稿ではしばしば混同される、DCNNにおける2つの転移学習の手法を明確に区別して扱う。一つは特徴抽出部を事前学習の状態に固定し、識別器のみを再学習するものである。言い換えれば、転移元タスクで事前学習されたDCNNを特徴抽出器として扱うもので、本稿ではこの手法を *fine-tuning* と呼ぶ。もう一つは事前学習により得られた状態をモデルの初期値とし、特徴抽出部をも含めて再学習を行う手法である。本稿ではこれを転移学習と呼ぶ。

画像認識のタスクにおける *fine-tuning* を含めた転移学習では、一般に転移元ドメインとして ImageNet [3] などの大規模自然画像データセットに対する分類問題が用いられることが多い [10], [12]。これはインターネットを通じた学習済みモデルの入手が容易なことに加え、自然画像により事前学習されたモデルは広範なタスクにおいて一定の性能を示すという経験則によるものと考えられる。しかしテキスト画像の認識タスクのように、自然画像データセットに陽に現れない構造をもつ目的タスクにおいて、転移元ドメインとしての自然画像の適切性には疑問が残る。

本稿ではDCNNによるテキスト画像の識別問題のための、2段階転移学習手法を提案する。提案手法では、はじめにDCNNを従来の転移学習手法と同様に、大量の自然画像を用いて学習する。自然画像による学習結果を初期状態とし、テキスト画像の分類問題を再度学習させた後、目的タスクの学習を行う。

実験では2段階転移学習を胸部X線HRCT (high resolution computed tomography) 画像から、びまん性肺疾患の陰影パターンを識別するタスクに適用し、転移学習を行わない場合、従来の1段階のみの転移学習を行った場合と識別性能を比較した。加えて、転移学習が学習データが減少した際の、モデル性能の頑健性に与える変化を検証した。実験結果に対する解析として、先行研究では積極的に議論されていなかった、転移学習のメカニズムについて、特徴

表現の可視化からの議論を行った。

2. 深層畳み込みニューラルネットワーク (DCNN)

DCNNはコンピュータビジョンにおいて広く用いられる階層型ニューラルネットワークの一種であり、近年ではディープラーニング (deep learning) のモデルの一つとしても広く知られている。DCNNの構造は、基本的に“畳み込み”、“空間プーリング”からなる特徴抽出部と、全結合層の積み重ねからなる識別部に大別される。図1に典型的なDCNNの概要図を示す。

特徴抽出部では、ネットワークの各層は一般に多チャンネルの2次元画像を入力とし、ある変換を通して多チャンネルの2次元画像を出力する。いまDCNNの*i*層のレイヤーの入力を $h_i(l, \mathbf{x})$ とする。ここで l は画像のチャンネル、 $\mathbf{x} \in \mathbb{Z}^2$ は画像の位置を表す。このとき畳み込み層の活性 (特徴マップ) は

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

と表される。ここで k は出力のチャンネル、 $g_i(k, l, \mathbf{u})$ はフィルタテンソルである。式1は畳み込み層において、特徴マップはフィルタテンソルにより、空間的に畳み込まれ出力されることを表している。この操作は画像処理における畳み込みフィルタリングと対応している。一般にニューラルネットワークにおける各層の出力は、活性化関数と呼ばれる非線形関数を通して変換される。我々は深層ニューラルネットワークにおいて一般的に用いられる *rectified linear function* (ReLU) をネットワークの活性化関数に用いた。畳み込み層の出力 $h_i^{\text{conv}}(k, \mathbf{x})$ はReLU関数を通して非線形変換され、その出力は

$$h_i^{\text{relu}}(k, \mathbf{x}) = \max(0, h_i^{\text{conv}}(k, \mathbf{x})) \quad (2)$$

と表される。

空間プーリング処理は畳み込み層で得られた特徴マップに対して、その次元数を削減するとともに微小変形に対する頑健性を与える処理である。特徴マップ $h_i(l, \mathbf{x})$ に対して、プーリング層の出力は

$$h_i^{\text{pool}}(k, \mathbf{x}) = \max_{\mathbf{r} \in N(\mathbf{x})} (0, h_i(k, \mathbf{r})), \quad (3)$$

と表される。ここで $N(\mathbf{x})$ は、特徴マップの位置 \mathbf{x} におけるチャンネルにまたがる空間近傍である。式3のような、ある領域における最大値を代表値とするプーリング処理は最大値プーリング (max-pooling) と呼ばれる。

これらの処理において、モデルの調整可能パラメータとなるのは、フィルタテンソル g_i のみである。DCNNの前の特徴抽出部においては、この g_i を学習することによって、入力パターンの縮約表現を獲得し、特徴抽出を行う。




図 1 上: 本研究において用いた DCNN の概要図 . AlexNet[7] と同様の構造である . 下: 特徴抽出部における特徴マップの変換処理の概要 .

図 1 の後段において “Fc n ” で表される部分はネットワークの識別部である . 識別部は全結合層 (fully-connected layer) の積み重ねからなり , 特徴抽出部によって変換された特徴表現の識別を行う . DCNN の特筆すべき特徴のひとつとして , ネットワーク全体を誤差逆伝搬 (back-propagation) アルゴリズムにより , 特徴抽出部と識別部を End-to-End に最適化する過程において前段の特徴抽出部が , 与えられたタスクに適切な特徴表現を獲得することが挙げられる .

3. 手法

3.1 2 段階転移学習

本稿では DCNN におけるテクスチャ認識の性能を向上させるための 2 段階転移学習手法を提案する . 図 2 に提案する 2 段階転移学習の概要図を示す .

本稿における DCNN の転移学習のプロセスでは , モデルを転移元ドメインで学習した後 , 畳み込み層・プーリング層からなる特徴抽出部を保持し , 識別層 (Fc7, Fc8) を新たに初期化する . その後 , 保持された特徴抽出部のパラメータを初期値とし , ネットワーク全体を目的タスクで再学習させる .

提案する 2 段階転移学習では , はじめに大量の自然画像を用いてネットワークを学習する . この段階において , DCNN に自然画像に頻出するエッジ構造などの特徴表現を獲得させる . さらに自然学習での学習結果を初期状態とし , 大量のテクスチャ画像の分類問題を学習させる . これは , 自然画像に陽に現れないテクスチャ構造に関する特徴表現を獲得させるためである . これらの逐次的な 2 段階の事前学習を経て , 目的タスクの分類を行うように DCNN を再学習させる一連のプロセスを , 2 段階転移学習として提案する .

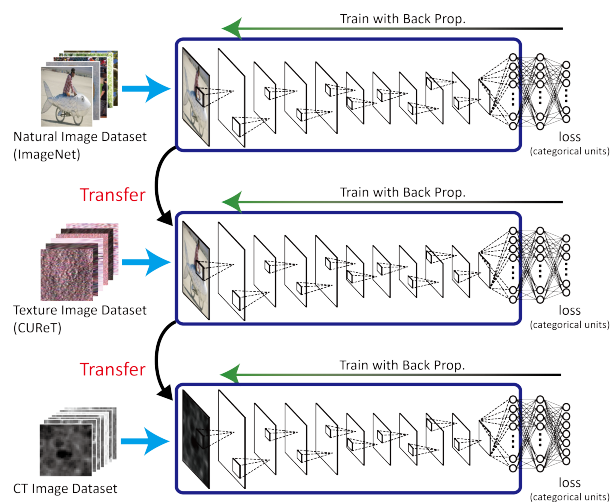


図 2 提案する 2 段階転移学習の概要図 . はじめに DCNN を大規模自然画像データセットを用いて学習し , ネットワークの初期状態とする . その後 , ネットワークの特徴表現をテクスチャ画像に適した形式に変化させるために , 大量のテクスチャ画像により学習させる . これら 2 段階の転移学習を経た後 , 目的タスクの学習を行う .

3.2 特徴表現の可視化

転移学習によって DCNN の特徴表現がどのように変化するかを明らかにするため , DCNN が獲得した特徴表現を可視化する手法を用いる . 可視化の手法には Mahendran らの提案している DeSaliNet を用いた [8] . DeSaliNet は , 入力のどのような成分が特徴表現に影響を与えているかを , 入力空間の画像として可視化する手法である . 図 3 に DeSaliNet による特徴表現の可視化の流れ図を示す .

DeSaliNet による特徴表現の可視化のベースとなる考え方は , 順伝搬で得られた特徴マップの入力空間への逆伝搬である . DeSaliNet においては DCNN の各層の変換を写像と捉え , DCNN 全体を単一の合成写像とみなす . すなわ

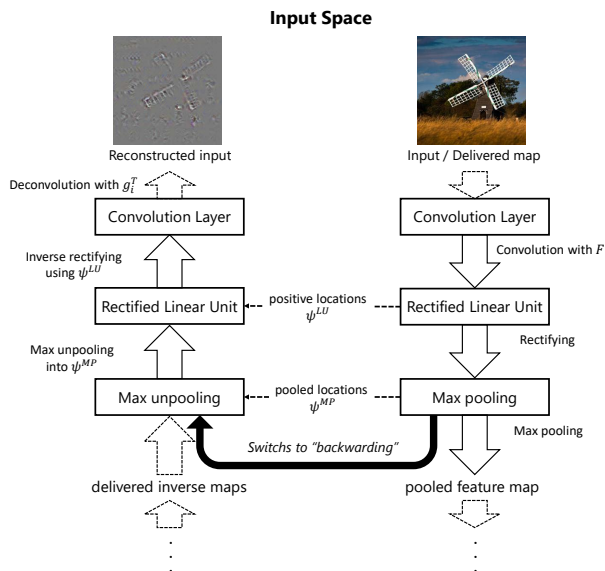


図 3 DeSaliNet による特徴表現の可視化処理の流れ図。可視化を行う入力画像を右側の通常の順伝搬処理によって、解析を行う特徴表現まで伝搬した後、得られた特徴表現に各々の層の逆写像からなる逆伝搬を行い、入力空間に復元する。DeSaliNet では ReLU・max-pooling の順伝搬において、伝搬された特徴の位置情報 ψ^{MP} , ψ^{LU} を保存し逆伝搬の際の情報復元に用いている。

ち h^{L_k} を DCNN の k 層目における操作 L_k による、入出力関係を表す写像とするならば、DCNN の i 層目に現れる特徴表現への写像は

$$\phi^{(i)} = h_i^{L_i} \circ \dots \circ h_1^{L_1}, \quad (4)$$

と各々の合成写像の形で表現できる。ここで L_k は DCNN の層の種類と対応しており、本研究では畳み込み、max-pooling, ReLU のいずれかである場合を考慮する。入力 x に対して得られた特徴表現 $\phi^{(i)}$ の可視化は、 $\phi^{(i)}$ の逆写像、すなわち

$$\phi^{(i)\dagger} = h_1^{L_1\dagger} \circ \dots \circ h_i^{L_i\dagger}, \quad (5)$$

の適用により得られる。各々の逆写像 $h^{L_i\dagger}$ については、[8] で詳しく述べられている。

4. 実験に用いたデータ

4.1 目的タスク

実験では提案する 2 段階転移学習の有効性について、胸部 X 線 HRCT 画像におけるびまん性肺疾患の陰影パターンの識別問題を対象に検証を行った。びまん性肺疾患は、肺の広範囲に病巣が広がる疾患の総称であり、その早期発見には X 線 HRCT による診断が有効とされている。これらは CT 画像上で特徴的な陰影パターンとして観察される。本研究では、これらの陰影パターンを病態・進行度に応じて、浸潤影 (consolidations; CON), すりガラス状陰影 (ground-glass opacities; GGO), 網状影 (reticular opacities; RET), 蜂巢状陰影 (honeycombing; HCM), 肺気




図 4 典型的なびまん性肺疾患の陰影パターン: 左からそれぞれ浸潤影 (CON), すりガラス状陰影 (GGO), 網状影 (RET), 蜂巢状陰影 (HCM), 肺気腫陰影 (EMP), 粒状影 (NOD)

表 1 実験における肺 X 線 CT 画像のパッチ数

	クラス						
	CON	GGO	HCM	RET	EMP	NOD	NOR
訓練	169	655	355	276	4,702	827	5,726
テスト	26	46	73	66	296	65	355
計	195	700	428	342	4,998	892	6,081

腫陰影 (emphysematous changes; EMP), 粒状影 (nodular opacities; NOD), 正常陰影 (normal; NOR) の 7 クラスに分類し、DCNN を用いて分類を行った。それぞれのクラスについて典型的な陰影パターンを図 4 に示す。

本研究が対象とするびまん性肺疾患のデータは、大阪大学医学部附属病院から提供された CT データを元で作成している。これらは 117 患者から得られた 512×512 [px] のグレースケール画像であり、医師の指導の下、前述の 7 クラスにラベル付されている。データセットとしては、これらの画像からクラスごとに 32×32 [px] の小領域パッチに分割したものをを用いた*1。このパッチは実際の肺実質において、およそ 2[cm] 角の領域と対応しており、この分割は医師の指導によるものである。モデルの性能評価のため、各々の ROI 画像を DCNN の学習用とモデルの性能検証のためのテスト用に、それぞれに同一の患者から得られたパッチが混在しないよう、表 1 に示すように分割し用いた。

4.2 転移元ドメイン

2 段階転移学習では、DCNN の事前学習に自然画像とテクスチャ画像を用いる。自然画像データセットには ImageNet に含まれる ILSVRC2012 データセットを用い、ネットワークの学習は [7] と同様に行った。テクスチャデータセットには Columbia-Utrecht Reflectance and Texture Database (CURET)[2] を用いた。CURET は 61 クラスの物体に関して、様々な撮影環境下における表面テクスチャを撮影したデータベースである。それぞれのクラスごとに 200 枚ずつのカラー画像が含まれている。実験ではこれらの画像を CT 画像と同様に 224×224 [px] にリサイズし、DCNN の入力として用いた。

5. 実験

5.1 学習プロセス

転移学習による DCNN の性能の変化を検証するため、学

*1 DCNN に入力する際には、これらの ROI 画像をバイキュービック補完を用いて 224×224 [px] に拡大し用いた。

表 2 Classification accuracies for test data

	(1)	(2)	(3)	(4)
転移学習	なし	1 段階		2 段階
正答率	0.9277	0.9558	0.9201	0.9601
精度	0.9583	0.9484	0.9412	0.9739
再現率	0.9590	0.9471	0.9417	0.9719
F1 スコア	0.9583	0.9470	0.9411	0.9724

表 3 Variations of model performances in each process

	(1)	(2)	(3)	(4)
正答率の傾き	1.3560	0.9920	0.9475	0.7479
交差エントロピ誤差の傾き	-0.5054	-0.4938	-0.3221	-0.2230

習のプロセスを以下のように変化させたモデルについて比較を行った。

- (1) 転移学習を行わない場合 (ランダム初期値から学習)
- (2) 自然画像による 1 段階の転移学習
- (3) テクスチャ画像による 1 段階の転移学習
- (4) 自然画像 → テクスチャ画像による 2 段階転移学習 (提案手法)

はじめに、それぞれのモデルにおけるテストデータの識別性能について評価を行った。性能指標には、正しいクラスに分類された割合である正答率 (accuracy), 偽陽性・義陰性それぞれに関する指標である精度 (precision) と再現率 (recall), また精度と再現率の調和平均である F1 スコアを用いた。表 2 において、2 段階転移学習はいずれの性能指標においても、最も高い性能を示している。

更に、転移学習が学習データの減少に対するモデルの頑健性を与えることを検証するために、学習データを $r = 20\%$ から $r = 100\%$ まで変化させた際の、テストデータに対する正答率と、Fc8 層における softmax 出力の交差エントロピ誤差の変化を検証した。それぞれのモデルにおける変化のグラフを図 5 に示す。転移学習を行ったモデル (2), (3), (4) は転移学習を行わない (1) に比べて、データ数が少ない場合において高い識別性能を示しており、特に 2 段階転移学習を行った (4) は、従来の 1 段階の転移学習を行う (2), (3) に比べて、その変化が緩やかである。この変化の大きさを定量化し評価するために、性能の変化が学習データ数の割合 r に対して線形と仮定した際の回帰式 $y = Ar + b$ における傾きの大きさ A を比較した。ここで A の絶対値が小さいほど、モデルはデータ数の減少に対して頑健であると言える。表 3 の結果からも転移学習によって、モデルがデータ数の減少に対する頑健性を獲得していることがわかる。更に、(4) の 2 段階転移学習は (2), (3) の従来の 1 段階の転移学習に比べ、より頑健であることが傾きの値からわかる。

転移学習によるモデル性能の向上について、その動作機序を明らかにするために、識別層に入力される特徴表現 (図 1 における Fc6 の入力) の可視化を行った。その結果を図 6 に示す。(1) の転移学習を行わないモデルでは、可視化

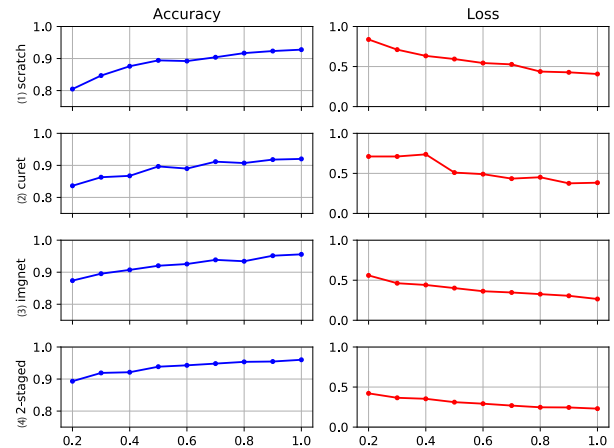


図 5 データ数の変動に対するモデル性能の変化の比較: (左) テストデータに対する正答率; (右) 交差エントロピ誤差。

結果に顕著な活性が見られない。これは転移学習を行わない場合、データ数の不足から DCNN は適切な特徴抽出を行うように学習されていないことを示唆している。(2) の自然画像を用いた転移学習の例では、入力において急峻な変化を伴う、エッジ構造に対応する部分が活性していることがわかる。自然画像において、こうした成分の特徴表現が獲得されることは多くの特徴表現の可視化手法において報告されている [8], [11], [13]。対症的に (3) のテクスチャ画像を用いた転移学習においては、入力において平坦な模様を持つ部分に活性を示している。そして (4) の自然画像・テクスチャ画像を用いた 2 段階転移学習においては、(2), (3) それぞれに見られるエッジ構造、テクスチャ構造の両方に対して活性が見られる。これは逐次的な 2 段階転移学習において、DCNN がそれぞれのドメインに頻出する特徴表現を加法的に獲得することを示唆している。2 段階転移学習における顕著な性能向上は、両方の転移元ドメインに対応した特徴表現がびまん性肺疾患の陰影パターンにおいていずれも有効であったためと考えられる。

6. 結論

本稿では、DCNN によるテクスチャ認識の性能を向上させるための学習則である、2 段階転移学習手法を提案した。提案手法は大量の自然画像・テクスチャ画像を用いて、DCNN に段階的な事前学習を施すことで、適切な特徴表現を獲得させ、識別性能の向上を図る手法である。我々は 2 段階転移学習を胸部 X 線 HRCT 画像における、びまん性肺疾患陰影の識別問題に適用し、モデルの識別性能が転移学習を行わない場合、従来の 1 段階の転移学習に比べて向上することを示した。また、転移学習が学習データ数の減少に対する、モデルの識別性能の頑健性を与えることを示した。さらに DCNN の特徴表現を可視化する手法を用い、今まで議論されてこなかった転移学習の動作原理についての解析を行った。その結果 DCNN は転移学習によって、転移元ドメインに頻出する特徴表現を加法的に獲得し

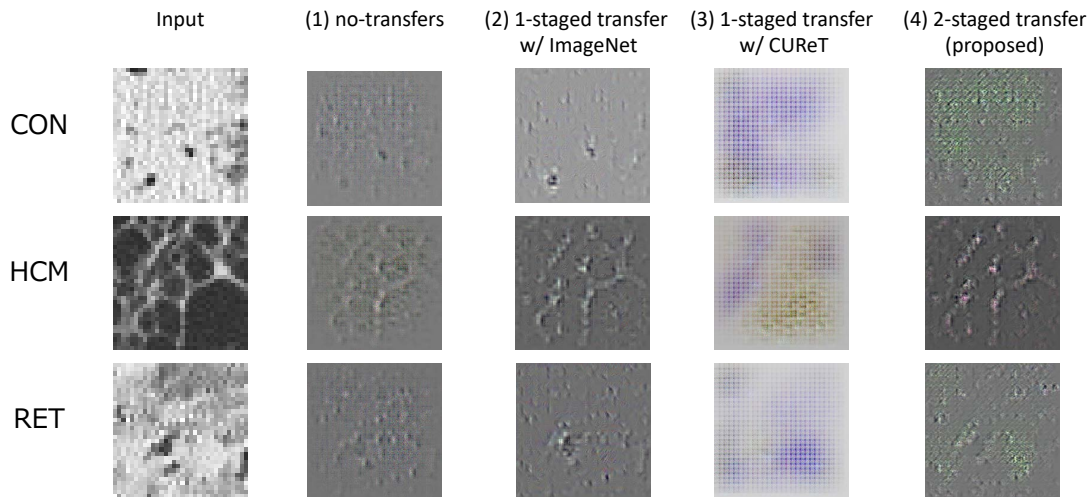


図 6 DCNN が獲得したびまん性肺疾患画像に対する特徴表現の可視化結果．左が可視化対象の ROI 画像；それぞれの列が各々のモデルにおける特徴表現の可視化結果．可視化結果において顕著な場所に対応する入力画像の成分が特徴表現に大きな影響を与えている．

ていることが明らかになった．2 段階転移学習ではびまん性肺疾患の識別に有用である，エッジ構造とテクスチャ構造の両方に対して適切な特徴表現を獲得することで，性能向上が行われているものと考えられる．この結果は転移学習における，転移元ドメインの選択の重要性を示唆するものである．

謝辞 本研究の一部は，科学研究費補助金 16K00328 および 16H01542 の補助を受けて実施されたものです．また，実験で用いた胸部 X 線 HRCT 画像のデータをご提供頂きました，大阪大学医学部附属病院の本多修先生と富山憲幸先生に深く感謝申し上げます．

参考文献

- [1] Bengio, Y. and Delalleau, O.: On the expressive power of deep architectures, *International Conference on Algorithmic Learning Theory*, Springer, pp. 18–36 (2011).
- [2] Dana, K. J., Van Ginneken, B., Nayar, S. K. and Koenderink, J. J.: Reflectance and texture of real-world surfaces, *ACM Transactions on Graphics (TOG)*, Vol. 18, No. 1, pp. 1–34 (1999).
- [3] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. and Fei-Fei, L.: Imagenet: A large-scale hierarchical image database, *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, IEEE, pp. 248–255 (2009).
- [4] Fukushima, K.: 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).
- [5] Fukushima, K.: Neocognitron: A hierarchical neural network capable of visual pattern recognition, *Neural networks*, Vol. 1, No. 2, pp. 119–130 (1988).
- [6] Hubel, D. H. and Wiesel, T. N.: Receptive fields, binocular interaction and functional architecture in the cat's visual cortex, *The Journal of physiology*, Vol. 160, No. 1, pp. 106–154 (1962).
- [7] Krizhevsky, A., Sutskever, I. and Hinton, G. E.: Im-

- genet classification with deep convolutional neural networks, *Advances in neural information processing systems*, pp. 1097–1105 (2012).
- [8] Mahendran, A. and Vedaldi, A.: Salient deconvolutional networks, *European Conference on Computer Vision*, Springer, pp. 120–135 (2016).
- [9] Pan, S. J. and Yang, Q.: A survey on transfer learning, *IEEE Transactions on knowledge and data engineering*, Vol. 22, No. 10, pp. 1345–1359 (2010).
- [10] Shouno, H., Suzuki, S. and Kido, S.: A transfer learning method with deep convolutional neural network for diffuse lung disease classification, pp. 199–207 (2015).
- [11] Simonyan, K., Vedaldi, A. and Zisserman, A.: Deep inside convolutional networks: Visualising image classification models and saliency maps, *arXiv preprint arXiv:1312.6034* (2013).
- [12] Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B. and Liang, J.: Convolutional neural networks for medical image analysis: Full training or fine tuning?, *IEEE transactions on medical imaging*, Vol. 35, No. 5, pp. 1299–1312 (2016).
- [13] Zeiler, M. D. and Fergus, R.: Visualizing and understanding convolutional networks, *European Conference on Computer Vision*, Springer, pp. 818–833 (2014).