

# ChestX-ray8を用いた構造適応型Deep Belief Networkにおける胸部疾患の分類と位置検出の試み

## Attempt to Classification and Localization of Thorax Diseases on ChestX-ray8 by Adaptive Structural Learning of Deep Belief Network

市村 匠

Takumi Ichimura

県立広島大学 高度人工知能プロジェクト研究センター長  
経営情報学部 経営情報学科

Email: ichimura @ pu-hiroshima.ac.jp

鎌田 真

Shin Kamada

広島市立大学大学院情報科学研究科  
日本学術振興会特別研究員 (DC2)

Email: da65002 @ e.hiroshima-cu.ac.jp

**Abstract**—Deep Learning has a hierarchical network architecture to represent the complicated feature of input patterns. We have developed the adaptive structure learning method of Deep Belief Network (DBN) that can discover an optimal number of hidden neurons for given input data in a Restricted Boltzmann Machine (RBM) by neuron generation-annihilation algorithm, and hidden layers in DBN. We examined to the learning method to medical open database: CXR8. The CXR8 is one of the most commonly accessible radiological examination for screening and diagnosis of many lung diseases. This paper describes our method accuracy of the classification and localization for the given bounding box(B-Box). The classification ratio for 8 diseases were almost 100% score. A new localization method for DBN is proposed here and the discrete heatmap, the likelihood map of pathologies, was automatically constructed.

### I. はじめに

Deep Learning とは大規模な階層構造を持ったニューラルネットワークにおける学習法 [1], [2] であり, 従来の階層型ニューラルネットワークとの最大の違いは事前学習にあると言われている. 最も知られた Deep Learning 学習法は, Convolutional Neural Network(CNN)[3] であろう. CNNには, Convolutional 層と Pooling 層を組み合わせながら, 複数のフィルタと呼ばれる検出器のパラメタを自動で学習する仕組みがあり, 畳み込み, 位置不変性, 合成性の3個の特徴を実現している. これらの層をうまく組み合わせながら, 独自の階層構造を構築するためには相当のスキルが必要であるため, 精度の高いネットワークとして知られている, AlexNet

[4], GoogLeNet [5], VGG16 [6], ResNet [7] など, 既存の学習済のネットワークを用いて, 再学習を行う転移学習と呼ばれる手法により, Deep Learning を応用している. しかしながら, 高精度なシステムを構築するためには, 転移学習よりも該当するデータのみを用いて学習する必要があるが, ネットワーク構造やパラメタ設定などは試行錯誤的に求めなければならなかった.

我々はこのような問題を解決するために, 入力データに応じて適切なネットワーク構造を探索する構造適応型学習法を, 尤度の概念を取り入れた Deep Learning 手法である Restricted Boltzmann Machine(RBM)[9], 及び事前学習した RBM を階層化し学習する Deep Belief Network(DBN)[10] において開発した [11]. 構造適応型学習法では, 入力データ空間に応じて適切な RBM の隠れニューロン数, 及び DBN の隠れ層数が学習中に自動で探索され, 画像ベンチマークデータセット CIFAR-10 及び CIFAR-100[12] に対し, 従来手法よりも高い分類精度が得られている [13], [14], [15].

本論文では, 医療データベースとして, 公開されている胸部 X 線画像のベンチマークテスト ChestX-ray8 (CXR8)[19] に対し, 構造適応型 DBN 学習法を適用した. データベースでは, 癌とその他の異常に分類されており, その形状等に応じてさらに細分化され, 結果として8個の疾患(癌を含む)に対する判定が行えるようになっている. 文献 [19] では, Caffe framework[8], AlexNet, GoogleNet, VGGNet-16, ResNet-50 などの手法に対して ROC 曲線が記載されていた. 構造適応型 DBN 学習法を適用した結果, これらのすべての CNN 手法よりも高い精度を示していた. さらに, 文献では,

“Bounding Box for Pathologies”が与えられている。これは、少数の病理を伴う画像に対してラベル付けされたもので、疾患の局所的な位置を評価するために利用する。病巣部分については、強い判定箇所は赤で、だんだんと色が黄色くなるように表示される Heatmap が表示される。しかしながら、文献では CNN による分類手法のみが適用されており、このままでは構造適応型 DBN 学習法に適用できない。本論文では、DBN 用に Heatmap を表示できるように改良し、病巣が発見されたレントゲン写真に対し、その部分を離散的 Heatmap として表示したので、ここに報告する。

## II. 構造適応型 DEEP BELIEF NETWORK 学習

### A. Restricted Boltzmann Machine

RBM[9] は図 1 のように可視層と隠れ層の 2 層から構成されるネットワーク構造を持ち、確率分布に基づいて入力データに含まれる特徴を隠れニューロン上で学習することができる教師なし学習モデルである。

RBM では与えられた入力データに対して式 (1) のエネルギー関数を最小にするパラメタ  $\theta = \{\mathbf{b}, \mathbf{c}, \mathbf{W}\}$  が最尤推定により求められる。ここで、 $\mathbf{b} = \{b_1, \dots, b_i, \dots, b_I\}$ ,  $\mathbf{c} = \{c_1, \dots, c_j, \dots, c_J\}$ ,  $\mathbf{W} = \{W_{11}, \dots, W_{ij}, \dots, W_{IJ}\}$  である。

$$E(\mathbf{v}, \mathbf{h}) = -\sum_i b_i v_i - \sum_j c_j h_j - \sum_i \sum_j v_i W_{ij} h_j, \quad (1)$$

$$p(\mathbf{v}, \mathbf{h}) = \frac{1}{Z} \exp(-E(\mathbf{v}, \mathbf{h})), \quad (2)$$

$$Z = \sum_{\mathbf{v}} \sum_{\mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h})) \quad (3)$$

ここで、 $v_i$  は  $i$  番目の可視ニューロンの状態変数、 $h_j$  は  $j$  番目の隠れニューロンの状態変数である。 $b_i$  は  $v_i$  に対するパラメタ、 $c_j$  は  $h_j$  に対するパラメタ、 $W_{ij}$  は  $v_i$  と  $h_j$  間の重みである。 $\mathbf{v} \in \{0, 1\}^I$  と  $\mathbf{h} \in \{0, 1\}^J$  はそれぞれ可視層と隠れ層に含まれるニューロンの状態変数のベクトルであり、 $I$  と  $J$  は可視ニューロン数、隠れニューロン数である。式 (2) は入力  $\mathbf{v}$  と  $\mathbf{h}$  の確率分布である。式 (3) の  $Z$  は分配関数 (partition function) であり、 $\mathbf{v}$  と  $\mathbf{h}$  の全ての 2 値のパタンの組み合わせに対するエネルギーを示す。最適なパラメタ  $\theta$  は与えられた入力データの尤度  $p(\mathbf{v}|\theta)$  を最大化することで求められるが、モデルの尤度に含まれる分配関数  $Z$  の計算は現実的に困難である。そのため、この値を推定するために Contrastive Divergence(CD) 法 [20] のサンプリングによって近似が行われる。このサンプリングの過程で条件付き確率である連続値が 2 値に変換されてしまい、機械学習が収束するための条件である連続性を満たさない状態を生じることが考えられる。この問題に対して文献 [21], [22] では、RBM の各パラメタの変分がリップシツ連続で、その上限がシャッテンノルムにより与えられ、これを満たすことで学習が収束することが示されている。




図 1. RBM ネットワーク構造

### B. Deep Belief Network

Deep Belief Network(DBN) は、事前学習を行った RBM を複数積み重ねることで入力データの特徴を階層的に学習することができる Deep Learning 手法である [10]. 図 2 は 4 つの RBM を持つ DBN のネットワーク構造を示している。入力データを  $\mathbf{h}^0 = \mathbf{v}$  とすると、 $l(> 0)$  層目の RBM の  $j$  番目の隠れニューロンの発火確率は式 (4) のように定義される。

$$p(h_j^l = 1 | \mathbf{h}^{l-1}) = \text{sigm}(c_j^l + \sum_i W_{ij}^l h_i^{l-1}) \quad (4)$$

ここで、 $c_j^l$  と  $W_{ij}^l$  はそれぞれ  $l$  層目の RBM の  $j$  番目の隠れニューロンのパラメタと  $i, j$  番目の重みである。 $\text{sigm}()$  はシグモイド関数で、文献 [10] と同じ関数を使用している。DBN 自体は RBM を積み重ねたモデルであるため教師なし学習モデルであるが、最上位層に出力層を加え、ソフトマックス法等により計算された出力値と教師信号との誤差 (損失) を最小化することで、教師あり学習として適用できる (Fine-Tuning)。ソフトマックス法では、与えられた入力データがカテゴリ  $k$  に属する確率  $y_k$  が式 (5) により求められる。

$$y_k = \frac{\exp(z_k)}{\sum_{j=1}^M \exp(z_j)} \quad (5)$$

ここで、 $z_j$  は出力層における  $j$  番目のニューロン出力活性化値である。 $M$  は出力層のニューロン数である。

### C. ニューロン生成/消去アルゴリズム

階層型ニューラルネットワークでは、入力データに対して十分な隠れニューロン数があれば学習が進むにつれて重みの変分は小さくなり、ある一定の値に収束すると考えられる。一方、この条件を満たさず重みが収束しない場合は、学習データに対するネットワークの表現能力が不足しており、データのパターンを隠れニューロン上で表現できていないことが原因だと考えられる。このような場合、関連する位置に十分な数の隠れニューロンを挿入することでデータのパターンを表現できると考えられる。文献 [23] では学習中における重みの変分ベクトルを Walking Distance(WD) と定義している。WD は式 (6) により、 $\tau - 1$  回目までの学習によるパラメタの変分と  $\tau$  回目の学習のパラメタの変分の和によ




図 2. DBN ネットワーク構造

り計算される.

$$WD_j[\tau] = \gamma_W WD_j[\tau - 1] + (1 - \gamma_W) Met(\mathbf{W}_j[\tau], \mathbf{W}_j[\tau - 1]) \quad (6)$$

ここで、 $\mathbf{W}_j[\tau]$  は  $\tau$  回目の学習における隠れニューロン  $j$  に関連する重みである。  $Met$  はベクトル間の距離を計算する関数で、本論文ではユークリッド距離  $Met(\mathbf{a}, \mathbf{b}) = \sum_{i=1}^N \sqrt{(a_i - b_i)^2}$  を用いる。  $\gamma_W$  は  $\tau - 1$  回目までの変分と  $\tau$  回目の変分の影響度を調整するパラメタで  $0 < \gamma_W < 1$  である。文献 [23] ではある一定回数の訓練後、隠れニューロン  $j$  の  $WD_j[\tau]$  の値が予め定められた閾値よりも大きい場合、その隠れニューロンの重みを 2 分割し、新しく隠れニューロンを追加する手法が提案されている。

階層型ニューラルネットワークと異なり、RBM には 3 種類の学習パラメタ  $\theta = \{\mathbf{b}, \mathbf{c}, \mathbf{W}\}$  がある。我々の調査では、RBM 学習における 3 つのパラメタは、隠れニューロンに関するパラメタ  $\mathbf{c}$  と重み  $\mathbf{W}$  が隠れニューロンの学習状況によって変化し、入力に関するパラメタ  $\mathbf{b}$  が入力データの分布に応じて変化することが分かった [24]。各パラメタの WD は式 (6) の  $WD_j[\tau]$  の計算方法により求めた。すなわち、 $\tau - 1$  回目までの学習による変分と、 $\tau$  回目の学習の変分の和に基づいて、各パラメタの変分が計算される。本論文では、 $\mathbf{b}$  は入力に関するパラメタであるため考慮せず、 $\mathbf{c}$  と  $\mathbf{W}$  は隠れニューロンの学習状況に依存するパラメタであるため、この 2 つの変分の積空間を用いた指標を考え、ニューロン生成の条件を式 (7) に示すように定義した。

$$WD_{c_j} \cdot WD_{W_j} > \theta_G, \quad (7)$$

$$WD_{c_j} = \gamma_c WD_{c_j} + (1 - \gamma_c)(|c_j[\tau] - c_j[\tau - 1]|), \quad (8)$$

$$WD_{W_j} = \gamma_W WD_{W_j} + (1 - \gamma_W) Met(\mathbf{W}_j[\tau], \mathbf{W}_j[\tau - 1]) \quad (9)$$

ここで、 $WD_{c_j}$ 、 $WD_{W_j}$  はそれぞれ  $j$  番目の隠れニューロンに関するパラメタと重みに関する学習の変分であり、0 以上の値をとる。これらは、式 (6) と同様の計

算方法で求められ、隠れニューロン  $j$  に関連する  $c_j$  と  $\mathbf{W}_j$  の変分が観察される。  $\theta_G$  はニューロン生成に関する閾値であり  $\theta_G > 0$  の値をとる。  $\theta_G$  の値が小さくなるに従って、ニューロン生成条件は満たされやすくなる。学習中に式 (7) を満たす隠れニューロンがある場合、該当する隠れニューロンの属性を継承したニューロンが式 (10) のように生成され、図 3(a) のように隣接する位置に挿入される [11]。

$$c_j^{new} = c_j + N(0, \sigma^2), W_{ij}^{new} = W_{ij} + N(0, \sigma^2) \quad (10)$$

一方、入力データに対して十分な数の隠れニューロンが生成された後、そのうち出力に寄与していない、すなわち冗長な値を出力する隠れニューロンが存在する場合がある。構造適応型 RBM では、一定の学習の後、式 (11) を満たす隠れニューロンが存在すれば、該当する隠れニューロンを図 3(b) のように消去する。式 (11) ではすべての入力データに対する隠れニューロンの出力値の平均を観察し、その値が一定の閾値以下のニューロンを冗長なニューロンとみなし、削除する。

$$\frac{1}{N} \sum_{n=1}^N p(h_j = 1 | \mathbf{v}_n) < \theta_A \quad (11)$$

ここで、 $p(h_j = 1 | \mathbf{v}_n)$  は  $n$  番目の入力データ  $\mathbf{v}_n$  を与えた際の隠れニューロン  $h_j$  の発火確率を示している。  $\theta_A$  はニューロン消去に関わる閾値であり、 $0 < \theta_A < 1$  の値をとる。

#### D. 層の生成条件

事前学習において学習が適切に行われれば、上位層ほど与えられた入力データに対するエネルギーやパラメタの変化が小さくなることを用いて、DBN における層の生成条件を提案した。

構造適応型 RBM におけるニューロン生成アルゴリズムでは学習中の WD (パラメタ  $\mathbf{c}$  と  $\mathbf{W}$  の変分) を観察したが、構造適応型 DBN [13] では個々の RBM ではなくネットワーク全体の WD とエネルギーを式 (12) と式 (13) を用いて観察した。

$$\sum_{l=1}^k WD^l > \theta_{L1}, \quad (12)$$



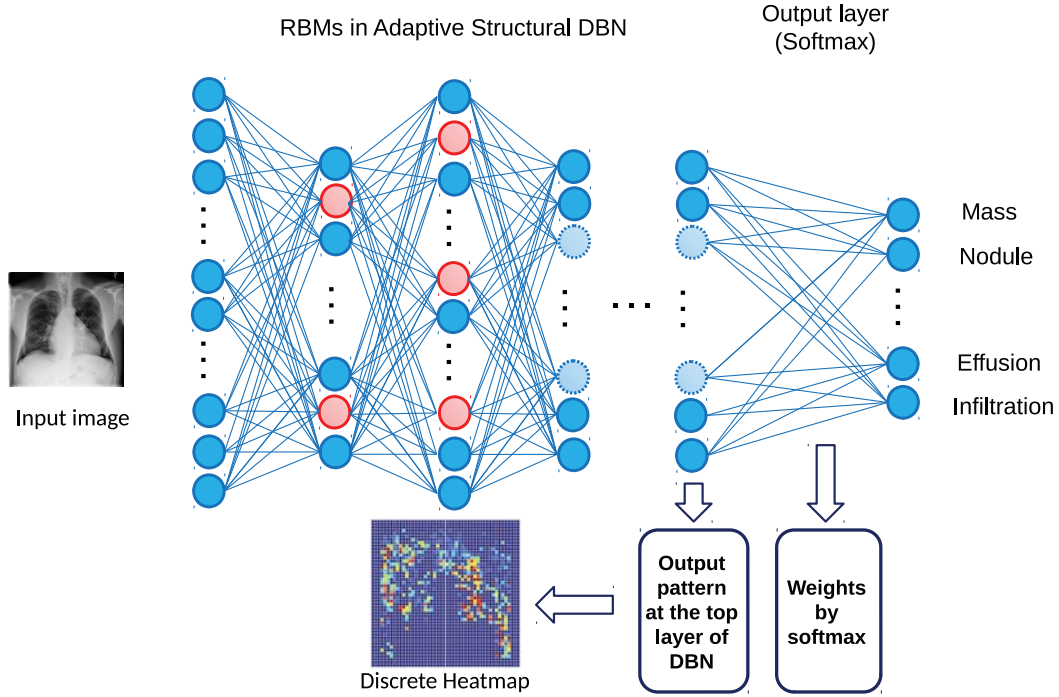


図 4. 離散的ヒートマップ計算の概要

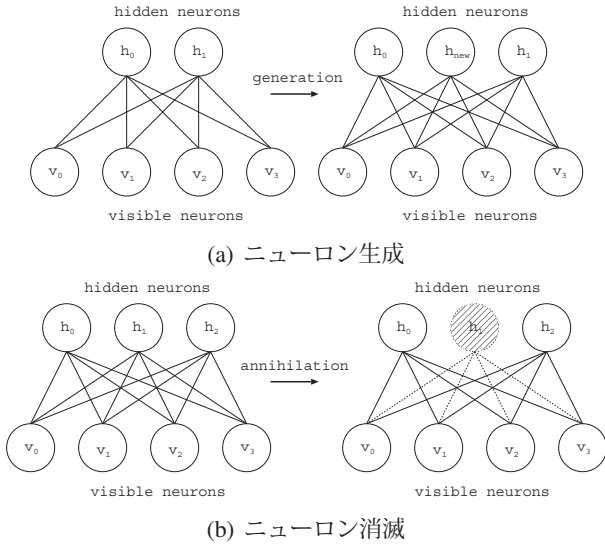


図 3. 構造適応型 RBM 学習法

$$\sum_{l=1}^k E^l > \theta_{L2} \quad (13)$$

ここで、 $WD^l = \sum_{j=1}^J (WD_{c_j}^l \cdot WD_{W_j}^l)$  であり、 $WD_{c_j}^l$  と  $WD_{W_j}^l$  はそれぞれ  $l$  層目の RBM における  $c_j$  と  $W_j$  に関する WD を示している。  $E^l$  はエネルギー関数である。  $\theta_{L1}$ 、  $\theta_{L2}$  は予め与えられる閾値である。 ある  $k$  層目の RBM の学習中に式 (12) 及び式 (13) を同時に満たす場合、入力データに対するネットワーク全体の表

現能力が不足していると考え、  $k$  層目の学習が終了した時点で、  $k+1$  層目の RBM を生成し学習を行う。 ここでも RBM のニューロン生成アルゴリズムと同様に、  $k+1$  層目の RBM のパラメタ  $b$ 、  $c$ 、  $W$  の初期値が  $k$  層目の RBM から継承される。

### III. 構造適応型 DBN に対する離散的ヒートマップ計算

文献 [19] で述べられている CNN では、最終層の Pooling 層や全結合である予測層において、単純に分類するだけでなく、疾病の可能性を表現可能な「ヒートマップ」を出力していた。ヒートマップは温度表示のように、高い確率であれば赤色で、低い確率であれば青色で表示する。 Pooling 層までの重みと最終層である全結合層の重みの積によって、ヒートマップを形成している。文献 [19] では、一般的な Max Pooling 手法や Average Pooling 手法の他に、式 (14) で定義される、Log-Sum-Exp(LSE) Pooling 手法を利用している。

$$x_p = \frac{1}{r} \cdot \log \left[ \frac{1}{S} \cdot \sum_{(i,j) \in \mathcal{S}} \exp(r \cdot x_{ij}) \right] \quad (14)$$

ここで、  $x_{ij}$  は、プーリング領域  $\mathcal{S}$  の局所的な位置である  $(i, j)$  の活性化値であり、  $S$  は  $\mathcal{S}$  の位置の総数である。ハイパーパラメタ  $r$  を制御することで、プールされる値は、  $r$  を無限大に近づけた時の  $\mathcal{S}$  の最大値から  $r$  を 0 に近づけた時の平均値までの範囲で定められる。

LSE 関数は計算上の問題点から式 (15) に変形される.

$$x_p = x^* + \frac{1}{r} \cdot \log \left[ \frac{1}{S} \cdot \sum_{(i,j) \in S} \exp(r \cdot (x_{ij} - x^*)) \right] \quad (15)$$

さらに, 文献 [19] では, Convolutional 層から Pooling 層への接続において, 画像の部分的な特徴を示す複数種類のフィルタが与えられ, 学習によって更新される. 2 種類の層からなる CNN で最終的に出力層への写像を求めるとき, 教師信号に対する学習が行われる. 一般的な CNN では, Softmax などの手法が利用されている. 文献 [19] では, この計算に基づいて, 入力画像のフィルタに対する活性・不活性を定め, 教師信号に対する一致度として, ヒートマップを積和によって表現していると考えられる. ヒートマップの強度は,  $[0, 255]$  の範囲で与えられるが, 閾値  $\{60, 80\}$  によって変換された分布により表現している.

DBN においては, このヒートマップを最終層の RBM の隠れニューロンと, 出力層の Softmax による学習によって作成する. 一般的な CNN においては, フィルタと画像は, 行列計算により行われているが, DBN においては一次元の配列で表現されたニューロンに並び替えるときに, 同じ方向 (軸) の配列の情報のみを保持するだけで, 他方の軸に関する情報は保持されておらず, 画像の位置とニューロンの位置に明確な関係はない. この問題を解決するために, 文献 [25], [26] で提案したマルチモーダルな異種データ学習手法により, データ配列を最小のブロックに分割し, そのブロック内ではデータの順序を保ちながら構造適応型学習を実現する手法を適用した. この手法は, RBM の計算時間を短縮するために, 入力データ間の類似性に基づいて入力の並びをソートする手法であるが, この過程で, 隠れニューロンの出力パターンに関し, 高い類似性を持つ隠れニューロンを見つけ, 高い類似性をもつニューロン同士を並び替えることができる. 隠れニューロンが発火する入力パターンを発見することで, 高次元や複数種類のデータにおいて, 類似する (同時に発火する) パターンを同一ブロックとして表現することができる.

文献 [19] では, ヒートマップは連続的な色の変化として見ることができるが, 本論文の手法は, Pooling 層による代表値表現方法を用いていないため, 強度をそのまま  $[0, 255]$  の範囲で表現し, これを「離散的ヒートマップ」として用いる. 図 4 は, 「離散的ヒートマップ」の作成の概要を示している. 与えられた入力パターンに対し前向き計算を行い, 最終層の RBM の出力パターンと Softmax 層の重みの積を計算する. ヒートマップを作成するために, 積の演算により得られたパターンから入力層に向けて逆向きの計算を行い, 入力画像における各位置の発火確率を求める. 発火確率が高いほど, 濃い赤色で表示するヒートマップを作成することができる. 疾患の局所的な位置を評価するために利用するために, “Bounding Box for Pathologies” が文献 [19] には用意されている. 本論文では, この Bounding Box を用いて疾病の位置検出を試みた.

表 I  
CXR8 のカテゴリ

分類		データ数	
正常	正常: No Finding	60,361	
異常	癌	形状大: Mass 形状小: Nodule	5,782 6,331
	その他	肺拡張不全: Atelectasis	11,559
		心肥大: Cardiomegaly	2,776
		胸水: Effusion	13,317
		肺浸潤: Infiltration	19,894
		肺炎: Pneumonia	1,431
	気胸: Pneumothora	5,302	
合計		112,120	




図 5. ROC 曲線

## IV. 実験

### A. 構造適応型 DBN による CXR 胸部 X ベンチマーク画像の分類

「ChestX-ray8 (CXR8)」は, 文献 [19] によって公開されている胸部 X 線画像のベンチマークテストである. 30,805 人の患者から収集した 112,120 枚の胸部 X 線画像が含まれており, 表 I に示すように, 各画像は, 正常ラベル及び 8 種類の異常ラベルに分類される. これらの 8 種類の異常ラベルの中には, 癌に関連する症状として, “Mass” と “Nodule” が定義されている. なお, 全 112,120 個のデータは, 訓練データ 86,524 個とテストデータ 25,596 個に予め分割されている.

提案手法の構造適応型 DBN を用いて CXR8 の学習を行った. 提案手法の学習パラメタとして, 勾配の学習手法を Stochastic Gradient Descent (SGD), 学習係数を 0.01, バッチサイズは 100, 学習の最大反復回数を 500 回, 初期隠れニューロン数を 300 とした. 構造適応型 RBM のパラメタとして,  $\theta_G = 0.050, \theta_A = 0.100$  とし, 構造適応型 DBN のパラメタとして,  $\theta_{L1} = 0.1, \theta_{L2} = 0.1$  とした. これらのパラメタの値は, 予備実験の結果による最良の組み合わせである.

表 II は, テストデータの各症状に対する分類精度を

表 II  
CXR8 の分類精度


分類		Accuracy			
		ResNet-50	DBN	改良 FT 法 DBN	
正常	正常: No Finding	-	90.0%	97.7%	
異常	癌	形状大: Mass	56.0%	96.3%	98.6%
		形状小: Nodule	71.6%	97.2%	98.1%
	その他	肺拡張不全: Atelectasis	70.6%	94.5%	98.5%
		心肥大: Cardiomegaly	81.4%	98.1%	99.2%
		胸水: Effusion	73.6%	97.2%	98.7%
		肺浸潤: Infiltration	61.2%	96.0%	99.4%
		肺炎: Pneumonia	63.3%	99.9%	99.9%
気胸: Pneumothora	78.9%	98.1%	99.3%		

示している。表 II の“ResNet-50”は ResNet[7] と呼ばれる深層学習モデルを用いた精度である。この数値は文献 [19] に記載されているが、ResNet と比較して、提案手法は全ての症状ラベルに対して高い分類精度を示すことができた。表 II の“改良 FT 法 DBN”は、文献 [27] で述べられている Fine Tuning 法を用いた結果である。Fine Tuning 法とは、誤判定を生じるケースに対する特徴的なパスを抽出し、その一部分の重みを修正することで、正しい計算結果を得る手法である。この数値は文献 [19] に記載されている CNN 手法のなかで最も良い精度を示したものである。ResNet と比較して、提案手法は全ての症状ラベルに対して高い分類精度を示すことができた。


図 5 は、提案手法の各症状ラベルの分類結果に対する ROC(Receiver Operating Characteristic) 曲線を示している。ROC 曲線とは、縦軸に、陽性を陽性と正しく予測する率である Sensitivity、横軸に、陰性を誤って陽性と予測する率である 1-Specificity をプロットした曲線である。ROC 曲線と縦軸と横軸で囲まれた面積ができるだけ大きいものほど良いモデルである。文献 [19] に記載されている ResNet の ROC 曲線と比較して、図 5 の ROC 曲線の方が、各症状に対して良い精度を示している。

### B. 離散的ヒートマップの表示

“改良 FT 法 DBN”のネットワーク構造を用いて、離散的ヒートマップの抽出を試みた。疾患の局所的な位置の評価に利用するために、“Bounding Box for Pathologies”が文献 [19] には用意されている。文献には 983 個の Bounding Box があると記載されていたが、ダウンロードしたデータには、985 個の Bounding Box が提供されていた。図 6(a) は、1 つの Bounding Box に対し行なった実験である。CXR8 のある胸部 X 線画像に対し、与えられた Bounding Box の矩形を描画した図を示しており、図 6(b) は、III 節で述べた方法により、この画像から抽出された離散的ヒートマップを示している。図 6(a) と図 6(b) は同じ大きさの画像であり、図 6(a) において句形で囲まれている領域は、図 6(b) においても、濃い赤色で描画されていた。実験は 985 個に対して離散的ヒートマップとレントゲン写真の位置検



(a) 元の画像



(b) 離散的ヒートマップ

図 6. Bounding Box との比較

出が一致しているかどうかを調査した。離散的ヒートマップにおいて、濃度が一定以上 (256 分の 170) を示すすべての位置が、すなわちすべての赤色の位置が、該当する Bounding Box に含まれているものを正答とし、この数を数えたところ、763 個 (77.6%) となった。ここで用いた Bounding Box は手で与えられた指標を用いている。文献 [19] では、Appendix において学習結果から自動で領域の特定を行っていた。厳密な精度の比較のためには、今後同様に領域の自動特定を検討する必要がある。



## V. おわりに

本論文では、胸部 X 線画像のベンチマークテスト CXR8 を用いて構造適応型 DBN 学習を行った。さらに、学習した深層学習モデルを用いて、知識獲得を行った。CXR8 で学習した深層学習モデルは、Fine Tuning 前では 90%以上、Fine Tuning 後では 97%以上の高い確率で癌の有無を分類できている。ベンチマークテストを用いたシステムによる評価の結果、判定は概ね一致していた。また、予め用意されている Bounding Box を用いた結果、病巣の位置を検出できたと考える。今後は、学習後に自動で Bounding Box のルール検出につながるよう、知識獲得手法の改良が求められるところである。

## 謝辞

本研究開発は JSPS 科研費 (課題番号: JP17J11178) の助成を受けたものです。

## 参考文献

- [1] Y.Bengio: *Learning Deep Architectures for AI*, Foundations and Trends in Machine Learning archive, vol.2, no.1, pp.1-127 (2009)
- [2] V.Le.Quoc, R.Marc's Aurelio, et.al.: *Building high-level features using large scale unsupervised learning*, Proc. of 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp.8595-8598 (2013)
- [3] Y.LeCun, et.al.: *Backpropagation applied to handwritten zip code recognition*, Neural Computation, vol.1, no.4, 541/551 (1989)
- [4] A.Krizhevsky, I.Sutskever, G.E.Hinton, *ImageNet Classification with Deep Convolutional Neural Networks*, Proc. of Advances in Neural Information Processing Systems 25 (NIPS 2012) (2012)
- [5] C.Szegedy, W. Liu, Y.Jia, P.Sermanet, S.Reed, D.Anguelov, D.Erhan, V.Vanhoucke, A.Rabinovich, *Going Deeper with Convolution*, Proc. of CVPR2015 (2015)
- [6] K.Simonyan, A.Zisserman, *Very deep convolutional networks for large-scale image recognition*, Proc. of International Conference on Learning Representations (ICLR 2015) (2015)
- [7] K.He, X.Zhang, S.Ren, J.Sun, J, *Deep residual learning for image recognition*, Proc. of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.770-778 (2016)
- [8] Y.Jia, E.Shelhamer, J.Donahue, S.Karayev, J.Long, R.Girshick, S.Guadarrama, and T.Darrell, *Caffe: Convolutional architecture for fast feature embedding*, arXiv preprint arXiv:1408.5093 (2014)
- [9] G.E.Hinton: *A Practical Guide to Training Restricted Boltzmann Machines*, Neural Networks, Tricks of the Trade, Lecture Notes in Computer Science (LNCS, vol.7700), pp.599-619 (2012)
- [10] G.E.Hinton, S.Osindero and Y.Teh: *A fast learning algorithm for deep belief nets*, Neural Computation, vol.18, no.7, pp.1527-1554 (2006)
- [11] S.Kamada and T.Ichimura: *An Adaptive Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Proc. of 2016 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2016), pp/1273-1278 (2016)
- [12] A.Krizhevsky: *Learning Multiple Layers of Features from Tiny Images*, Master of thesis, University of Toronto (2009)
- [13] 鎌田真, 市村匠: *忘却機能を持った Deep Belief Network による構造適応型学習*, 計測自動制御学会第 9 回コンピュータショナル・インテリジェンス研究会講演論文集, pp.92-97 (2016)
- [14] S.Kamada and T.Ichimura: *A Structural Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Neural Information Processing, Lecture Notes in Computer Science (LNCS, vol.9950), pp.372-380 (2016)
- [15] S.Kamada and T.Ichimura: *An Adaptive Learning Method of Deep Belief Network by Layer Generation Algorithm*, Proc. of 2016 IEEE Region 10 Conference (TENCON), pp.2971-2974 (2016)
- [16] 鎌田真, 市村匠: *構造適応型 Deep Belief Network からの知識獲得に関する一考察*, 2016 IEEE SMC Hiroshima Chapter Young Researchers WorkShop, pp.61-66(2016)
- [17] 鎌田真, 市村匠, *リカレント構造適応型 Deep Belief Network 学習における事前知識の分析*, 第 44 回知能システムシンポジウム講演論文集, SY004/17/B2-2 (2017)
- [18] S. Kamada and T.Ichimura, *Fine Tuning of Adaptive Learning of Deep Belief Network for Misclassification and its Knowledge Acquisition*, International Journal Computational Intelligence Studies, Vol.6, No.4, pp.333-348(2017)
- [19] X.Wang, Y.Peng, L.Lu, Z.Lu, M.Bagheri, R.M.Summers, *ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases*, Proc. of IEEE Computer Vision and Pattern Recognition, pp.3462/3471 (2017)
- [20] G.E.Hinton: *Training products of experts by minimizing contrastive divergence*, Neural Computation, vol.14, no.8, 1771/1800 (2002)
- [21] D.Carlson, V.Cevher and L.Carlin: *Stochastic Spectral Descent for Restricted Boltzmann Machines*, Proc. of the Eighteenth International Conference on Artificial Intelligence and Statistics, 111/119 (2015)
- [22] 鎌田真, 藤井哲崇, 市村匠: *Lipschitz 連続による Restricted Boltzmann Machine のエネルギー安定性に関する一考察*, 2015 IEEE SMC Hiroshima Chapter Young Researchers WorkShop, pp.53-56 (2015)
- [23] T.Ichimura, S.Oeda, Ma.Suka, and K.Yoshida: *A learning method of immune multi-agent neural networks*, Neural Computing and Applications, vol.14, no.2, 132/148 (2005)
- [24] 鎌田真, 市村匠, 原章: *ニューロン生成/消滅アルゴリズムによる構造適応型 Restricted Boltzmann Machine*, 計測自動制御学会第 8 回コンピュータショナル・インテリジェンス研究会講演論文集, pp.90-96 (2015)
- [25] S.Kamada, T.Ichimura, *Shortening Time Required for Adaptive Structural Learning Method of Deep Belief Network with Multi-Modal Data Arrangement*, Proc. of IEEE 10th International Workshop on Computational Intelligence and Applications (IW-CIA2017), pp.97-102(2017)
- [26] S.Kamada, T.Ichimura, *Fast Training of Adaptive Structural Learning Method of Deep Learning for Multi Modal Data*, International Journal Computational Intelligence Studies (to appear in 2018)
- [27] 市村匠, 鎌田真, *構造適応型 Deep Belief Network 事前学習を考慮した知識獲得の検討*, 2017 IEEE SMC Hiroshima Chapter Young Researchers WorkShop (to appear in 2018)

## 問い合わせ先

〒 734-8558  
広島県広島市南区宇品東一丁目 1 番 71 号  
県立広島大学  
高度人工知能プロジェクト研究センター長  
市村 匠