

Deep Convolutional Neural Network の転移学習による乳房 X 線 画像上の腫瘍検出

Detecting Masses in Mammograms Based on Transfer Learning of A Deep Convolutional Neural Network

○鈴木真太郎, 張暁勇, 本間経康, 吉澤 誠

○Shintaro Suzuki, Xiaoyong Zhang, Noriyasu Homma, Makoto Yoshizawa

東北大学

Tohoku University

キーワード: ニューラルネットワーク (Neural networks), 画像処理 (Image processing),
深層学習 (Deep learning), 転移学習 (Transfer learning), マンモグラム (Mammogram),
コンピュータ支援診断・検出 (Computer-aided diagnosis/detection)

連絡先: 〒980-8579 仙台市青葉区荒巻字青葉 6-6-05
東北大学 サイバーサイエンスセンター 吉澤(誠)・杉田研究室
鈴木真太郎, Tel.: (022)795-7130

E-mail: shintaro.suzuki.r4@dc.tohoku.ac.jp

1. はじめに

近年, 乳がんは日本人女性における部位別がん罹患率の第 1 位を占めており¹⁾, 今後も増加傾向にある。対策として, 乳がんの早期発見を目的とした乳房 X 線撮影 (マンモグラフィ) による検診が普及しつつある。しかしこれに伴い, 乳房 X 線画像の読影を行う医師の負担も増加し, 疲労による病変の見落としといった読影精度の低下が懸念されている。この問題の解決のため, コンピュータを用いて乳房 X 線画像上の病変を自動検出し, 第 2 の意見として提示することで医師の診断を補助する, コンピュータ支援診断 (computer-aided diagnosis: CAD) システムの開発が行われている²⁾。

乳房 X 線画像上で観察される乳がんの主要な画像所見のひとつとして, 腫瘍と呼ばれる病変

がある。Fig. 1 に示すように, 腫瘍は乳房 X 線画像上では高輝度な類円形の領域として観察されることが多い。従来の CAD システムでは, このような病変の画像的特徴や医師の読影論理を参考に設計者が与えた基準で特徴量を算出し, それをもとにサポートベクターマシンやニューラルネットワーク等の分類器を用いて病変の検出を行うものが多い。このため, この特徴量設計の良し悪しが最終的な病変検出性能に大きく影響する。

しかし, 実際の腫瘍の形状や特徴は多種多様であり, 正常組織と腫瘍を適切に識別できる特徴量の設計は極めて難しく, 検出性能向上の課題となっていた。

一方で自然画像認識の分野においては近年, 深層学習 (deep learning) の手法のひとつである deep convolutional neural network (DCNN) が




Fig. 1: 乳房 X 線画像上の腫瘍

従来法を大きく上回る性能を示し、注目を集めている。その最大の特徴は、与えられた入力データから、対象の識別に有効な特徴量を学習によって自動で獲得する点である。そのため、DCNN を乳房 X 線画像上の病変の検出に応用することができれば、病変の多様性を網羅しつつ対象を適切に識別するような特徴量を自動的に獲得し、従来より高い識別性能を実現できる可能性がある。本稿では、DCNN の乳房 X 線画像上の病変検出への応用可能性を検証することを目的とし、医師の診断例を基に学習した DCNN を用いて病変の識別を試みた。一般に DCNN の学習には大量の学習データが必要となる一方、医用画像の場合には十分な数の画像データを用意することは難しいという問題がある。そこで、DCNN の学習に転移学習の手法を導入し、大量に入手可能な自然画像で事前学習した DCNN に対し、少量の乳房 X 線画像により病変識別を学習することでこの問題の克服を試みた。

2. 提案手法

2.1 DCNN の基本構造

本稿で用いた DCNN は、Krizhevski らによる *AlexNet*³⁾ と同じ構造を持つものである。Fig. 2 に示すように、この DCNN は 5 層の畳込み層

と 3 層の全結合層をもつ。DCNN への入力として 3 チャンネル (R,G,B) の画像の輝度値を与え、DCNN の出力層 (*fc8*) は、入力画像が *ImageNet*⁴⁾ における 1000 種類のクラスそれぞれに属する確率を出力する。

Fig. 2 における *conv1-5* 層は特徴抽出を担う畳込み層、*pool1,2,5* 層は次元と計算量の削減および特徴の位置変動に対するロバスト性の獲得を担うプーリング層、*fc6-8* 層はクラス識別を行う全結合層である。なお、*AlexNet* の詳細は参考文献³⁾ を参照されたい。

2.2 DCNN の転移学習

転移学習とは、あるタスクで学習した「知識」を別のタスクに転用する手法である⁵⁾。本稿では、大量に収集可能な自然画像で DCNN を学習し、獲得した知識すなわち特徴量や識別規則を、対象タスクである乳房 X 線画像上の病変識別に転用し、病変の識別を学習する。具体的な学習の手順は以下のとおりである。まず Fig. 3(a) に示すように、約 120 万枚の自然画像からなる *ImageNet*⁴⁾ データセットを用いて DCNN を学習する。この手順を事前学習と呼ぶ。次に、DCNN の出力層を腫瘍識別タスクにおける分類クラス (腫瘍, 正常組織) に対応する 2 つのニューロンからなる新たな全結合層で置換する。続いて Fig. 3(b) に示すように、乳房 X 線画像より作成した ROI 画像を用いて病変の識別を学習する。これを fine-tuning と呼ぶ。

この手順により、自然画像認識で獲得した基本的な知識 (エッジ等の基本的な特徴量, 識別規則) を病変識別に転用することができ、少量の医用画像でも病変の特徴の獲得, 識別が可能になると期待される。

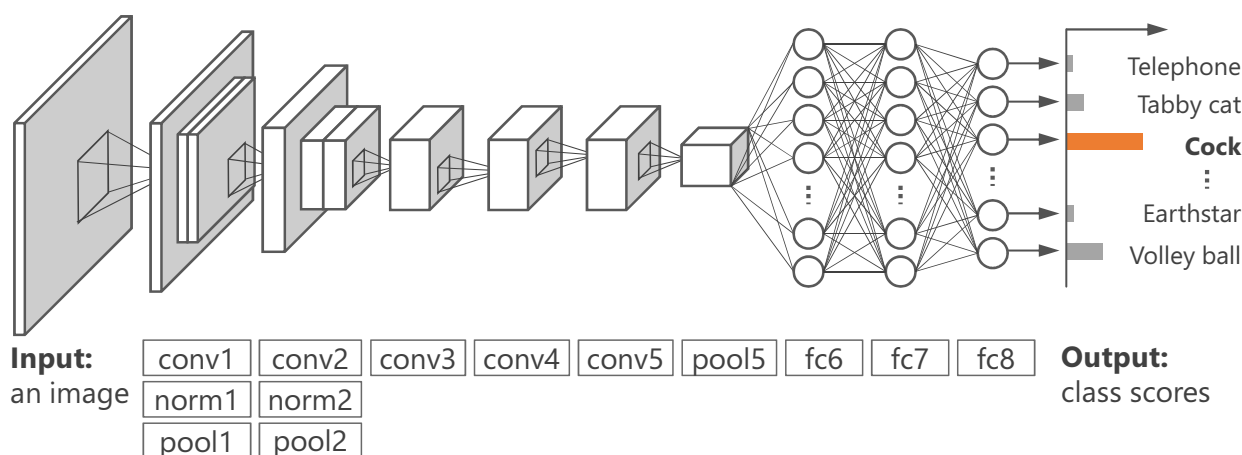


Fig. 2: 本稿で用いた DCNN の構造

3. 実験結果

3.1 実験データセット

学習 (fine-tuning) および識別テストでは、乳房 X 線画像のデータベースである *Digital Database for Screening Mammography (DDSM)* ⁶⁾ より切り出した region of interest (ROI) 画像を用いた。腫瘍を含む画像としては医師の指定した病変領域を中心として、また正常組織としては病変をもたない患者の乳房領域内よりそれぞれ 454 画素四方で切り出し、計算コスト削減のため 227 画素四方に縮小した ROI 画像を用いた。腫瘍を含む 885 枚、正常組織 969 枚の計 1,854 枚を用意し、9 分割交差検証により腫瘍の識別精度を評価した。

3.2 腫瘍識別性能の評価

学習 (fine-tuning) に伴う分類誤差の推移を Fig. 4 に示す。学習データに対する誤分類率は学習の初期に急速に低下し、その後も緩やかに低下を続け、50 回学習後に約 6% まで減少した。テストデータに対する誤分類率は学習に伴い緩やかに低下し、最終的に 10% 前後となった。

50 回学習後の DCNN を用いてテスト画像を分類させた際の混合行列を Table 1 に示す。真陽性率は約 92.5%，偽陽性率は約 12.3% となり、腫瘍を有意に識別することができた。

続いて、各クラスに分類された画像の一例を Fig. 5 に示す。各画像下にクラススコアと正解クラス (MAS: 腫瘍, NOR: 正常組織) を示しており、テスト画像の一部をスコアの高い順に掲載した。Fig. 5(a) を見ると、比較的不整形で不明瞭な腫瘍であっても高いスコアで正しく分類できていることがわかる。一方 Fig. 5(b) より、輝度変化の少ない画像、変化の緩やかな画像が、高いスコアで正常組織と判定されていることが読み取れる。

続いて、テスト画像のうち誤分類されたものを Fig. 6 に示す。正常組織を腫瘍と誤分類した偽陽性分類 Fig. 6(a) は、正常な組織によるパターンが腫瘍に類似しているものが多い。一方で、腫瘍を誤って正常としてしまった偽陰性分類 Fig. 6(b) は、腫瘍陰影のコントラストが特に低いものや、腫瘍が大きいため本来識別すべき対象が ROI からみ出してしまうものが多い。これら誤分類された画像はいずれも、小さな ROI 内の情報だけでは人間でも判断が難しい例と考えられる。腫瘍周辺の、より広い領域の情報を用いることによって、これらの例を適切に分類できる可能性がある。

一般に、腫瘍と正常の判定の閾値を変更することで真陽性率は変化するが、真陽性率と偽陽性率は互いにトレードオフの関係にある。この関係を表したのが、Fig. 7 の receiver operating




Fig. 3: 自然画像と医用画像を用いた DCNN の転移学習

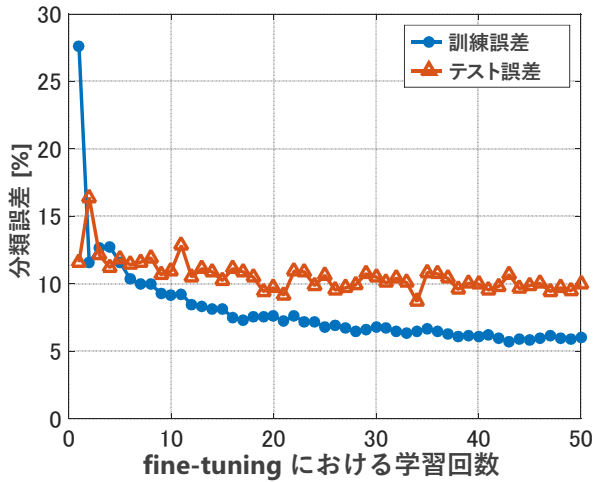


Fig. 4: fine-tuning の学習進行における分類誤差の推移

characteristic (ROC) 曲線であり、真陽性率が高く偽陽性率が低いほど、曲線が左上方になり曲線下面積 (area under the curve: AUC) が1に近いほど、識別性能が優れていることを表す。提案法との比較のため、自然画像を用いた事前学習を行わず、医用画像のみで学習を行った場合の結果も示す。曲線下面積 AUC は、提案法では 0.97 となった。これは、Kom *et al.*⁷⁾ の AUC = 0.93, Sahier *et al.*⁸⁾ の AUC = 0.87 と比較して大幅に優れた病変識別性能である。また真陽性率が 90% となると、偽陽性率は提案法で 9.0%, 医用画像のみによる学習で 24.5%, 真陽性率が 95% となるとそれぞれ 18.7%, 48.0% となり、転移学習により偽陽性を半分以下に抑え、病変識別性能を向上できることが確認された。

Table 1: 50 回学習後の分類結果 (枚)


		真のクラス		
		腫瘍	正常	計
推定 クラス	腫瘍	819	119	938
	正常	66	850	916
計		885	969	1854

4. おわりに


本稿では、乳房 X 線画像上の病変検出に対する DCNN の応用可能性を検証した。腫瘍識別実験の結果、従来の手法を上回る識別性能を達成し、DCNN の病変識別への有効性が確認された。特に、学習用の医用画像の不足を補うため、自然画像にて事前学習を行った DCNN を用いて転移学習を行った工夫が有効であった。今後は、学習法や DCNN への入力方法を改良することによりさらなる性能の向上が期待されるほか、乳房 X 線画像上から DCNN に与える ROI を検出する手法についても研究を進め、病変の有無だけでなくその位置情報も提示するなど、より高度な支援システムの開発を行う予定である。

参考文献

- 1) A. Matsuda et al., "Cancer Incidence and Incidence Rates in Japan in 2008: A Study of 25 Population-based Cancer Registries for the Monitoring of Cancer Incidence in Japan (MCIJ) Project,"



(a)



(b)

Fig. 5: 各クラスに分類された画像例. 正解ラベル (MAS:腫瘍, NOR:正常) と各クラスのスコアを付記. (a) 腫瘍に分類された画像例と腫瘍クラススコア (b) 正常組織に分類された画像例と正常クラススコア

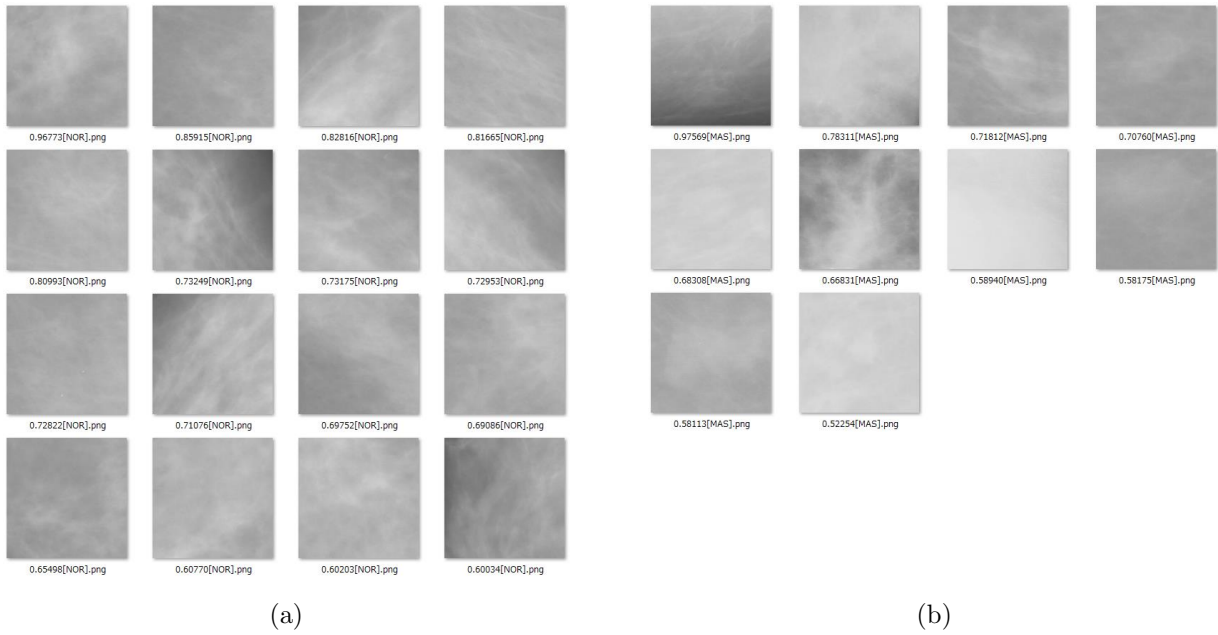


Fig. 6: 誤分類された画像例. (a) 偽陽性分類例, (b) 偽陰性分類例




Fig. 7: 腫瘍識別における ROC 曲線の比較

Japanese Journal of Clinical Oncology, **44-4**, 388/396 (2013)

- 2) J. Tang et al, “Computer-Aided Detection and Diagnosis of Breast Cancer With Mammography: Recent Advances,” IEEE Trans. Inf. Technol. Biomed, **13-2**, 236/251 (2009)

- 3) A. Krizhevski et al., “ImageNet Classification with Deep Convolutional Neural Networks,” In Proc. NIPS (2012)
- 4) J. Deng et al., “ImageNet: A Large-Scale Hierarchical Image Database,” In CVPR09, 248/255 (2009)
- 5) S. J. Pan and Q. Yang: A Survey on Transfer Learning, Knowledge and Data Engineering, IEEE Trabsaction, **22-10**, 1345/1359 (2010)
- 6) M. Heath et al, “The Digital Database for Screening Mammography,” In Proceedings of the Fifth International Workshop on Digital Mammography, M.J. Yaffe, ed., pp. 212-218, Medical Physics Publishing, 2001.
- 7) G. Kom, A et al., “Automated detection of masses in mammograms by local adaptive thresholding,” Comput. Biol. Med., **37-1**, 37/48 (2007)
- 8) B. Sahiner et al, “Classification of mass

and normal breast tissue: A convolutional neural network classifier with spatial domain and texture images,” *IEEE Trans. Med. Imag.*, **15**-5, 598/610 (1996)

- 9) N. R. Mudigonda et al, “Gradient and texture analysis for the classification of mammographic masses,” *IEEE Trans. Med. Imag.*, **19**-10, 1032/1043 (2000)