

## Deep CNN に基づく CT 画像からの乳腺濃度の自動分類法

加納 拓弥<sup>1</sup> 周 向荣<sup>1</sup> 子安 裕美<sup>2</sup> 横山 龍二郎<sup>1</sup> 原 武史<sup>1</sup>  
松尾 政之<sup>2,3</sup> 藤田 広志<sup>1</sup>

1 岐阜大学大学院医学系研究科再生医科学専攻知能イメージ情報分野 〒501-1194 岐阜県岐阜市柳戸 1-1

2 岐阜大学医学部附属病院放射線科 〒501-1194 岐阜県岐阜市柳戸 1-1

3 岐阜大学大学院医学系研究科腫瘍制御学専攻放射線医学分野 〒501-1194 岐阜県岐阜市柳戸 1-1

E-mail: 1 tkano@fjt.info.gifu-u.ac.jp,

**あらまし** 乳腺濃度は乳がんのリスク評価に用いられる重要な指標である。これまでに乳腺の濃度分類には主に 2 次元マンモグラフィが利用されているが、3 次元 CT 画像における乳腺濃度の測定と分類も期待される。本研究では、肺がん検診などで撮影される単純 CT 画像から乳腺濃度を自動的に分類する手法を提案し、他の目的で撮影された CT 画像を乳がんのリスク評価に活用する計算機支援診断システムを開発する。提案手法は乳腺周辺の解剖学的構造の認識に依存せず、CT 画像から直接的に乳腺濃度のカテゴリ分類を行う処理方式である。これには、畳み込みニューラルネットワーク (CNN) を中心的な構造とし、任意の CT 画像に CNN によって乳腺密度のカテゴリ番号に結びつくように、ネットワークパラメータを学習させる。全体の処理流れは、まず、入力 CT 画像から左右乳房領域 (乳房を囲んでいる最小な 3 次元ボックス) をそれぞれ自動的に検出する。そして、3 次元である左右乳房領域から大量な 2 次元断面画像 (標本) を生成し、それぞれの標本に対して CNN による乳腺濃度のカテゴリ分類を行う。全部の標本の分類結果を統計的に纏めた結果を最終的に出力する。実験では 40 例の CT 画像 (30 歳から 60 歳までの女性症例) を使用した。Holdout 法を用いた乳腺濃度の分類結果から、20 症例のうち 16 症例の分類に成功したことを確認した。これにより、CT 画像における乳腺濃度の自動分類の可能性が示された。

**キーワード** 3 次元 CT 画像, 乳房領域の検出, 乳腺密度の分類, 畳み込みニューラルネットワーク, 深層学習

### Automatic classification of breast density on CT images by using deep CNN

Takuya KANO<sup>1</sup> Xiangrong ZHOU<sup>1</sup> Hiromi KOYASU<sup>2</sup> Ryujiro YOKOYAMA<sup>1</sup> Takeshi HARA<sup>1</sup>

Masayuki MATSUO<sup>2,3</sup> and Hiroshi FUJITA<sup>1</sup>

1 Department of Intelligent Image Information, Division of Regeneration and Advanced Medical Sciences, Graduate School of Medicine, Gifu University, 1-1 Yanagido, Gifu 501-1194, Japan

2 Department of Radiology, Gifu University Hospital, 1-1 Yanagido, Gifu 501-1194, Japan

3 Department of Radiology, Graduate School of Medicine, Gifu University, 1-1 Yanagido, Gifu 501-1194, Japan

E-mail: 1 tkano@fjt.info.gifu-u.ac.jp,

**Abstract:** Breast density has been used as an important risk factor of breast cancer and routinely measured on 2D mammography. 3D CT images have been also expected as another image modality for breast density measurements. This research work proposed a novel method to classify a CT case directly into four categories of breast density by using an end-to-end mapping without any dependence on image segmentations. The deep convolutional neural network (CNN) was used as a core part for the classification and was trained on parameters by minimizing the classification errors to the human decisions. The processing flow of the proposed method can be described as localizing left and right breast regions on CT image firstly, and then, sampling a large number of 2D sections from the 3D breast regions for breast density classification based on the deep CNN, and making a final decision based on statistic of classification results of 2D sections. 40 CT cases from 30 to 60 years old women were used in the experiment. We used holdout validation to train and test the performance of the breast density classification, and confirmed that the breast density of 16 CT cases were classified correctly from total 20 test CT cases. In conclusion, the potential possibility of breast density classification on CT images was demonstrated.

**Keywords:** 3D CT images, breast region localization, breast density classification, convolutional neural network, deep learning.

## 1. はじめに

近年、女性における乳がんの罹患率は増加傾向にある。乳がんは、女性が罹患するがんの中で最も罹患率が高く、早期発見が求められる。また、女性の乳腺の量は、長い間乳がんの危険度を予測する重要な要素として示唆されてきた。乳腺の量は、3次元CT画像から推定することができる。しかし、CT画像は、医療現場では多く扱われるが対象臓器の診断以外に利用されることが少ない。そのため、様々な用途で撮影されたCT画像からの乳がんのリスク評価への応用が期待される[1]。

これまでにマンモグラフィにおける乳がんの発症リスクに関わる要因として乳腺の濃度が用いられる。臨床では、各患者の乳腺濃度を4つのカテゴリ（1：脂肪性乳腺、2：散在性乳腺、3：不均一高濃度乳腺、4：高濃度乳腺）に分類される[2]。それぞれの例をFig.1に示す。脂肪性乳腺に近いほど、乳腺の密度が低く、量が少ない傾向にあり、高濃度乳腺に近いほど、乳腺の密度が高く、量が多い傾向にある。また、カテゴリ1と2は主にマンモグラフィ検査が勧められ、カテゴリ3と4はエコー検査が勧められる。そのため、事前に乳腺の濃度が推測可能であるなら、より効率的に検査することが可能である。

医療現場では多くのCT撮影が行われている。他の目的で撮影されたCT画像から乳腺濃度の推定が可能であるなら、乳がんのリスク評価や検査方法の選択に活用できる。そのため、CT画像から乳腺領域の濃度分類に関する研究が行われている。従来の研究では、画像処理で肺や胸筋などの解剖学的構造を自動的に認識

し、乳腺領域を抽出することによって、乳腺濃度を計測している[3]。しかし、乳腺の計測結果は解剖学的構造の抽出精度に大きく依存する。そのため、乳腺抽出の誤差によって正確な乳腺濃度の推定が困難である。そこで、CT画像から解剖学的構造の自動認識に必要としないアプローチが望まれる。

そこで、本研究では、CT画像から乳腺領域の抽出を行わず、乳腺濃度のカテゴリ分類を行う方法を提案する。基本的な考えとして、処理手順の構造を簡略化し、一つのニューラルネットワークでCT画像と乳腺濃度のカテゴリ分類結果を直接的に結びつける。そして、大量のCT画像を用いた学習を通してネットワークのパラメータを最適化する。計算コストを削減するため、乳房を囲んでいる最小なBounding-Box(以下BOXとする)を事前に検出を行い、乳房領域のみを用いて乳腺濃度を推定する。また、計算機の学習に必要な

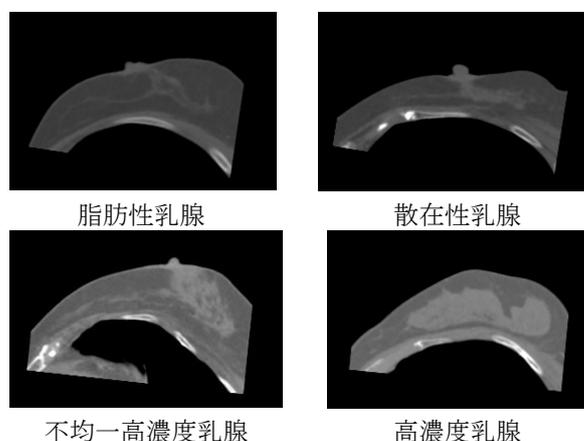


Fig.1 乳腺濃度によるカテゴリ分類例

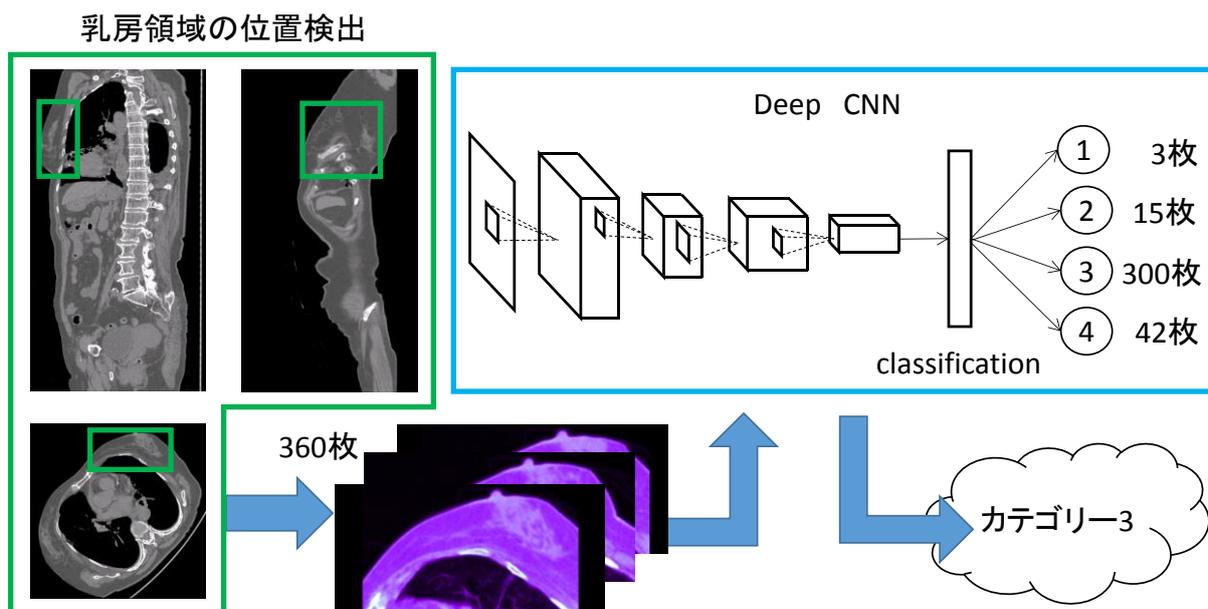


Fig.2 乳腺濃度によるカテゴリ分類の概要

とする学習サンプルを増やすため、各3次元のCT画像から大量の2次元スライスを生成する。そのスライス画像に基づくカテゴリ分類を先行し、最終的に複数の2次元分類結果を統合するアプローチを取る。これによって、数の少ないCT画像でも、安定的な学習結果が得られると考える。

## 2. 方法

提案法は、左右の乳房領域の位置検出と乳房領域画像から乳腺濃度の分類の2つの処理から構成される。全体の処理概要を Fig.2 に示す。まず、3次元CT画像から乳房領域を囲んでいるBOXを自動的に検出する[5]。この検出処理で、処理対象となる領域範囲をCT画像全体から左右の乳房領域という局所に限定する。次に、3次元画像である乳房領域を複数の2次元画像に分解し、Deep CNN を用いて乳腺濃度の分類を独立で行う。各2次元画像における分類結果を統合にして、3次元の乳房領域に対する最終的なカテゴリ番号を出力する。各乳房領域において、2次元断面画像のカテゴリ分類の結果に基づいてヒストグラムを作成する。断面画像が最も多く分類されているカテゴリは最終的な分類結果と出力する。

### 2.1 乳房領域の位置の自動抽出

CT画像における乳房領域の位置検出は、乳房領域の大きさと傾きと同じ程度の窓関数を全CT画像の範囲で走査し、最も関数の出力値の高い位置を乳房領域の中心位置とする。また、走査中に窓関数の大きさも変化させるため、乳房の大きさも同時に推定できる。

窓関数の作成には、教師ありの学習法を用いる。具体的には、学習標本(CT画像及び乳房領域のBOXの組)を複数用意し、乳房領域と背景を区別する特徴量空間及び分類規則を試行錯誤の形式で探索する。提案法では、特徴空間が Haar-like features と Local binary patterns, 分類規則は複数の線形分類機の重み結合、探索方法が AdaBoost アルゴリズムを用いる。

学習された特徴空間と分類規則を用いて、未知のCT画像に適用する。その際に特徴量と判定規則をCT画像の各画素に適用し、直方体のサイズを変化させながら乳房領域かどうかの判断を行う。その後、CT画像上に最も乳房らしい直方体の位置とサイズを出力する。なお、人体の解剖学的構造を考慮して、左右の乳房領域の直方体は体軸を中心とし $\pm 48.8$ 度をさせて設定する。

### 2.2 Deep learning による乳腺濃度の分類

Deep learning を用いて乳腺の濃度ごとに分類を行う。Deep learning とは、多層ニューラルネットワークを用いた機械学習の一種であり、多項分類や回帰分析などに対して用いられる。Deep learning では、多層ニューラルネットワークで識別に有効な特徴量を自動抽出すること

ができるため、画像に対する専門的な知識が不要であり、原画像のみで学習することが出来る。

2次元の断面画像を Deep CNN を用いて乳腺濃度の分類を行う。本研究では、自然画像分野で大きく成功を収めた AlexNet[6]と GoogLeNet[7]の構造をそのまま利用し、CT画像を用いて新たにネットのパラメータを訓練する。具体的には、位置検出で生成した乳房画像と専門医師による分類結果を AlexNet と GoogLeNet にそれぞれ入力し、学習は非同期確率勾配降下法(Stochastic gradient descent) でモーメント係数 0.9, 学習係数は 8 エポック毎に 0.04 減少させた。学習画像には、自然画像に近いカラー画像を用いて行う。

CT画像上の乳房領域は、画像の座標軸に基づく3次元の画素行列である。本研究は先ほどの画素行列を乳頭に通過する乳房表面の法線ベクトルを軸とする円柱座標系に変換する。その上に円柱座標系の中心軸を通る2次元の平面を360度回転して、3次元である乳房領域を360枚の2次元断面画像にリサンプリングする。この処理によって、乳頭に集中してくる乳腺領域の広がり具合を最も均等に2次元で表現できる。また、CT画像の画素値を16bitsの濃淡から24bitsのカラーに拡張し、自然画像と類似するように加工する。各条件による画像とカラー画像を Fig.3 に示す。

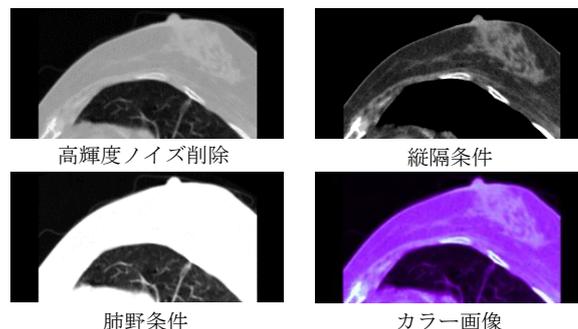


Fig.3 異なるウィンドウ処理によるCT画像のカラー化

## 3. 実験

乳房領域の位置の自動検出は、岐阜大学附属病院で撮影された体幹部CT画像データベースを用いて行った。データベースは、GEヘルスケア社製の LightSpeed16 で撮像された体幹部画像であり、濃度分解能は 12[bit], 画像のマトリクスサイズは 512×512[voxel], 解像度は 0.508-0.977 [mm], スライス間隔は 0.508-0.977 [mm]の等方性画像である。また、造影と非造影が混在している。

学習症例には右乳房領域 300 症例と左乳房症例 300 症例用い、テスト症例には右乳房症例 100 症例と左乳房領域 100 症例用いた。評価基準は目視による評価と手入力との誤差による定量的評価を行った。目視によ

る評価は、自動検出された BOX の中心位置の Axial 断面、Coronal 断面、Sagittal 断面の画像を目視で確認し、BOX 内に対象臓器領域の 2/3 以上が収まり、かつ BOX の中心位置と対象臓器領域の中心位置とのずれが対象臓器領域の大きさの 1/2 より小さい症例を検出成功とした。また、乳腺領域をすべて検出できていない場合は検出失敗とした。誤差による定量的評価は、手入力した Bounding-Box と自動検出された Bounding-Box との体積誤差と中心位置誤差を利用した。臓器の形状などで変化するため、正規化を行い誤差が臓器の大きさに依存しないためである。式は以下の通りである。

$$\text{体積誤差} : \frac{|V2-V1|}{V1} \quad (1)$$

(手入力の体積 : V1, 自動検出の体積 : V2)

$$\text{中心位置誤差} : \frac{\sqrt{(P2x-P1x)^2+(P2y-P1y)^2+(P2z-P1z)^2}}{\sqrt{(xx-x)^2+(yy-y)^2+(zz-z)^2}} \quad (2)$$

(手入力の中心位置 : P1(x,y,z), 自動検出の中心位置 P2(x,y,z), 手入力の BOX の 2 点(x,y,z)(xx,yy,zz))

乳腺濃度の分類は、BOX 検出された画像を用いて行った。学習症例は 20 症例、テスト症例は各濃度 5 症例ずつ計 20 症例を用いて行った。学習症例とテスト症例は症例ごとで前後軸を基準に 1 度ずつ回転を行った 360 枚の画像を作成し、学習またはテストを行った。学習画像は 6800 枚、Validation 画像は 700 枚の計 7200 枚を使用した。テスト画像は、20 症例 360 枚より計 7200 枚である。評価基準は、1 症例で 1 度ずつ回転を行った 360 枚の 2 次元画像から判断を行う。360 枚の画像のうち最も多くに分類されたものを分類結果とした。

#### 4. 結果

CT 画像から乳房領域の位置検出結果の 1 例を Fig.4 に示す。乳房領域の位置検出結果は、目視による評価と定量的評価を Table 1 または Table 2 に示す。乳房領域を含みかつ乳腺を全て含んでいる症例を成功症例、乳房領域の未検出または乳腺領域の未検出がある症例を失敗症例、BOX 作成に失敗した症例を検出失敗症例とする。

AlexNet と GoogLeNet における学習結果を Fig.5 に示す。30 回の学習の繰り返しで、高い精度と低い損失となっている。乳房領域における濃度分類結果を、Table 3 に示す。AlexNet と GoogLeNet では、GoogLeNet の方が 5 症例多く分類に成功した。また、GoogLeNet では、20 症例のうち 16 症例で分類に成功した。

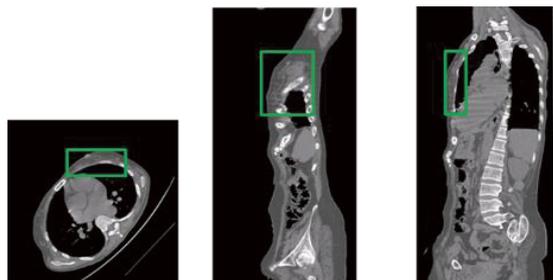
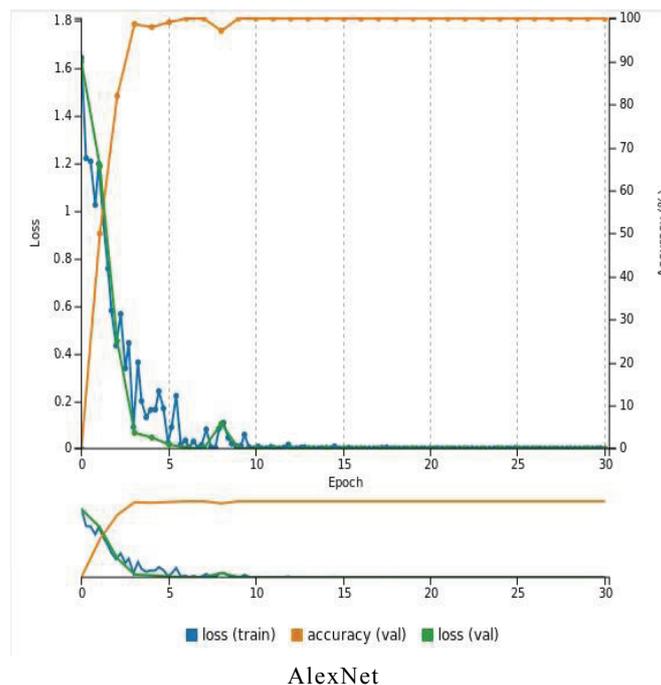
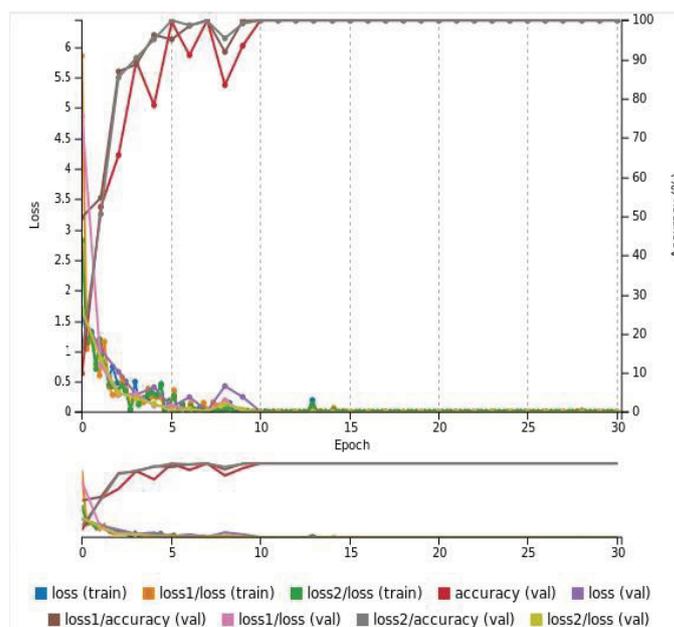


Fig.4 乳房領域の位置検出結果



AlexNet



GoogLeNet

Fig.5 Deep learning における学習結果

Table 1 学習症例における検出結果(300 症例)

臓器	右乳房領域	左乳房領域
成功症例数	292	296
失敗症例数	8	4
検出失敗数	0	0

臓器	右乳房領域	左乳房領域
体積誤差	0.060	0.052
中心位置誤差	0.166	0.353

Table 2 テスト症例における検出結果(100 症例)

臓器	右乳房領域	左乳房領域
成功症例数	92	97
失敗症例数	6	3
検出失敗数	2	0

臓器	右乳房領域	左乳房領域
体積誤差	0.087	0.059
中心位置誤差	0.064	0.121

Table 3 乳腺濃度分類結果

	AlexNet	GoogLeNet
成功症例数	11	16
失敗症例数	9	4

## 5. 考察

乳房領域の位置の自動検出は高い精度を示した。成功症例は乳腺領域を中心に検出され、乳腺の量などでは影響が少ないと考える。検出に失敗した症例は、異常症例の 2 例に見られた。一つは、肝臓が肥大している症例であった。もう一方は、肺水腫であった。これより、本来は肺が存在する領域に別の臓器があったからと推測する。

乳腺領域における濃度分類では、乳腺濃度は乳腺の量で分類されているため、乳腺が多いカテゴリ 3 やカテゴリ 4 では非常に分類性能が高かった。しかし、乳腺の量が少ないカテゴリ 1 や 2 での分類成功症例が少なかった。

今回は学習症例における偏りが多くカテゴリ 1 と 4 の症例が少なくカテゴリ 3 が学習症例の半分を占めていた。しかし、乳腺量が多いカテゴリ 4 での分類は全て成功しており、カテゴリ 1 の症例での分類は 3 症例失敗した。これより、乳腺の量が多い症例は比較的分類することが容易であり、乳腺の量が少ない症例では分類が困難と考える。また、今回は学習症例が少なく、数による偏りが大きいため、分類時に偏りが出たと考える。そのため、カテゴリ 1 や 2 の症例を追加すれば、分類の精度が上がると思われる。

## 6. まとめ

体幹部 CT 画像から乳房領域の位置検出と乳腺濃度の分類を行った。乳房領域の位置検出に関しては、97% 以上の症例で検出に成功した。また、乳腺領域の濃度分類では 8 割の症例で分類に成功した。今後は、学習症例の数の偏りを減らし、分類を行う必要がある。

## 7. 謝辞

本研究の一部は、文部科学省科学研究費・新学術領域研究(課題番号 26108005),及び JSPS 科学研究費補助金(基盤研究(C) 26330134)によって行われました。

## 文 献

- [1] 藤田広志, "肺がん CT 検診 CAD システムの現状と今後の展望. 解説", 医学物理, 35(2), 163-166, (2015)
- [2] "診断の基本 乳がん検診", 日産婦誌 58 巻 4 号, (2013).
- [3] X.Zhou, M.Han, et al., "Automated segmentation of mammary gland regions in non-contrast X-ray CT images", Computerized Medical Imaging and Graphics, 32, 699-709, (2008).
- [4] 守田翔一, 周 向榮, et al., "機械学習に基づく大規模な CT データベースからの複数臓器位置の自動検出と性能評価", 電子情報通信学会技術報告, 113(410), 37-41, (2014).
- [5] X. Zhou, S. Morita, et al., "Automatic anatomy partitioning of the torso region on CT images by using multiple organ localizations with a group-wise calibration technique", Proc. of SPIE Medical Imaging 2015: Computer-Aided Diagnosis, edited by L.M.Hadjjiiski and G.D.Tourassi, Vol.9414, 94143K-1 . 94143K-6, (2015).
- [6] Krizhevsk et al., "ImageNet Classification with Deep Convolutional Neural Networks", NIPS2012
- [7] Christian Szegedy, Wei Liu, et al., "Going Deeper With Convolutions", The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1-9,(2015)