

U-Netを用いた胸部X線画像からの解剖学的構造の領域抽出

Segmentation of anatomical structures in chest X-ray pictures using U-Net

近藤 堅司^{*1,*2} 小澤 順^{*1} 清野 正樹^{*2,*3}
Kenji Kondo Jun Ozawa Masaki Kiyono

藤本 真一^{*3} 田中 雅人^{*3} 安達 登志樹^{*3} 伊藤 春海^{*3} 木村 浩彦^{*3}
Shinichi Fujimoto Masato Tanaka Toshiki Adachi Harumi Ito Hirohiko Kimura

^{*1} 産業技術総合研究所 ^{*2} パナソニック株式会社 ^{*3} 福井大学
Advanced Industrial Science and Technology Panasonic Corporation University of Fukui

We report a segmentation process of multiple anatomical structures in chest X-ray pictures, which is a key element of computer-aided diagnosis (CAD) systems, and its evaluation results. The segmentation process utilizes U-Net, that is, a type of fully convolutional network. The segmentation targets are a small region such as a first thoracic vertebra and a line structure which is a boundary between anatomical structures. In the evaluation, we achieve Dice index 0.91 as the segmentation accuracy for the first thoracic vertebra, and Dice index 0.71 through 0.81 as the segmentation accuracy for the line structures.

1. はじめに

近年、医用画像を解析処理することで異常検出や所見疾患推定を行う装置／ソフトウェアが開発されている。それらを用いる診断はコンピュータ支援診断(Computer-Aided Diagnosis: CAD)と呼ばれ、医師の読影精度向上および負担軽減が期待されている。医用画像の中でも胸部X線画像は豊富な情報を含み、その撮影装置は安価で普及率も高いため、胸部X線撮影は胸部疾患診断の第一選択方法になっている。

胸部X線画像の CAD 技術としては、事前に機械学習した病変を検出するものが多く提案されている[Rajpurkar 17] [Wang 17]。しかしながら、胸部X線画像では奥行き方向に複数の解剖学的構造物が重なって描写され、さらに病変がそれらの解剖学的構造物と重なった場合は病変検出が困難になる。このような場合に、解剖学的構造の正常状態を基に、疾患による解剖学的構造の変化を検出することで異常検知を行う胸部X線画像 CAD システムが必要となる。この CAD の実現には、胸部 X 線画像から解剖学的構造の領域を正確に抽出する必要がある。

一方、深層学習を用いて医用画像から領域抽出を行う U-Net が提案されている[Ronneberger 15]。U-Net は encoder-decoder 型の Fully Convolutional Network (FCN) の一種であり、encoder 部で画像に対し convolution と downsampling を繰り返し適用して高次の特徴抽出を行い、decoder 部で convolution と upsampling を繰り返し適用して特徴マップの解像度を向上させ、目的とする領域抽出結果を得る。この時、同一解像度の特徴マップを encoder から decoder に受け渡すことで正確な位置精度を実現している。

本研究では、U-Net を用いて胸部 X 線画像から解剖学的構造の領域抽出を行い、正常胸部 X 線画像 697 症例を用いてその性能を評価した。

2. 関連研究

胸部X線画像から解剖学的構造の領域を抽出する先行研究としては、[Ginneken 06] や[Novikov 17]がある。

連絡先：近藤堅司、産業技術総合研究所人工知能研究センター、〒305-8560 茨城県つくば市梅園 1-1-1 中央第 1, kondo.kenji@aist.go.jp

[Ginneken 06]は、アプリケーションとして心胸比の自動計算を想定し、左右肺野、心臓、左右鎖骨の5つの解剖学的構造について active shape model (ASM), active appearance model (AAM), 及び pixel classification 法などの画像処理手法により領域抽出を行っている。肺野の領域抽出精度については、人(human observer)による抽出結果と同等、心臓については人より精度が低く、鎖骨については十分な精度を得ていない。実験に用いた胸部X線画像は、日本放射線技術学会(Japanese Society of Radiological Technology: JSRT)が公開した胸部X線画像データベース(JSRT database [Shiraishi 00])であり、この JSRT database に対し、評価に用いる領域マスク画像を手動作成し、Segmentation of Chest Radiograph (SCR) database として公開している。

[Novikov 17]は、JSRT database および SCR database に対し、U-Net [Ronneberger 15]を適用し、肺野、心臓、鎖骨領域に対する multi-class segmentation 手法を提案した。[Novikov 17]の領域抽出精度として、肺野と心臓については人([Ginneken 06]での human observer)を上回り、鎖骨については人には及ばなかった。鎖骨のような小さい部位については、正則化手法を工夫したり、より多くの高レベル特徴を抽出することが必要であると結論付けた。

このように、従来までの胸部 X 線画像からの領域抽出においては、鎖骨のような小さい部位に対して十分な精度が実現されていない。

一方、胸部X線画像の異常検知に関する新たな取組として、[黒瀧 17]らは、生成モデルの一種である変分オートエンコーダ(variational autoencoder: VAE)を用いて正常胸部X線画像をモデル化し異常検知を行う手法を提案している。具体的には、入力画像に関する対数尤度の変分下界を利用して異常検知を行っているが、十分な定量評価については未報告である。

3. 解剖学的構造の正常状態に基づく胸部X線画像 CAD システム

解剖学的構造の正常状態に基づく胸部 X 線画像 CAD システムでは、局所的な解剖学的構造の正常状態をモデル化し、疾患による解剖学的構造の変化を検出することで、胸部 X 線画像の所見推定を行う(図1)。

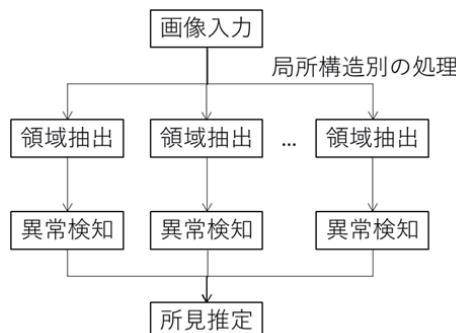


図1 解剖学的構造の正常状態に基づく
胸部X線 CAD システム

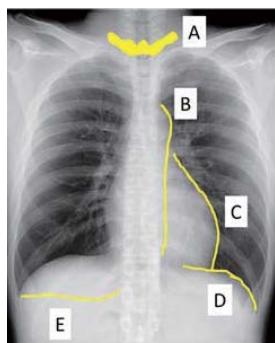
図1のCADでは、入力された胸部X線画像から、予め定めた複数の局所解剖学的構造の領域を抽出し、局所構造毎に事前に構築した正常モデルを基に異常検知を行い、最後に、それらの結果を総合して異常所見を推定する。次節以降で、U-Net を用いて実装した、図1における領域抽出部の詳細と、その評価について述べる。

4. U-Net を用いた解剖学的構造領域抽出

[Novikov 17]では、鎖骨のような小さい解剖学的構造に対して、人と同等な領域抽出精度は実現できていない。図1で示すCADシステムでは線状やより小面積の解剖学的構造を扱う必要がある。本節では、それらの解剖学的構造に関する領域抽出の取組結果を報告する。

4.1 評価対象の解剖学的構造

本稿では、図2に示す5個の解剖学的構造に対して、U-Net を用いた領域抽出の評価を行った。



	名称
A	第一胸椎
B	下行大動脈陰影
C	左室陰影
D	左横隔膜ドーム陰影
E	右背側横隔膜陰影

図2 対象とする解剖学的構造

Aは解剖学的構造そのものであるが、B,C,D,Eについては、正確には、X線吸収率が互いに異なる複数の解剖学的構造物によって胸部X線画像上に描出される、解剖学的構造間の境界線である。本稿では、この境界線を線構造と名付け、線構造も含めて解剖学的構造と呼ぶこととする。

4.2 U-Net を用いた解剖学的構造領域抽出

[Novikov 17]では、U-Netを胸部X線画像の解剖学的構造の領域抽出に適用し、肺野、心臓、鎖骨領域に対する multi-class segmentation 手法を提案している。オリジナルの U-Net に対し、①convolution 層の後に dropout 層を設けることで汎化性能を高める ②高解像層ほどフィルタ数(=特徴マップ数)を多く配置し、最適化すべきパラメータの総数を減らす、等の改良を加

ることにより、胸部X線画像の領域分割においてオリジナルの U-Net よりも高い性能を得ている。特に、鎖骨のような位置変動が少なく、かつ、サイズが小さい構造では、高次特徴をそれ程必要としないため、特に②の効果により、オリジナルの U-Net を上回る抽出性能を得ている。

我々の今回の評価実験においては、①②の改善を取り入れた U-Net を single-class segmentation タスクで用いる。領域抽出処理のデータフローを図3に示す。処理対象の胸部X線画像を共通の入力とし、5 個の U-Net が、図2におけるA～Eの各解剖学的構造物の領域確率画像をそれぞれ出力する。

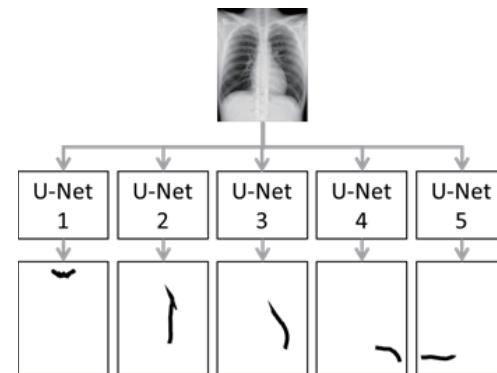


図3 領域抽出処理のデータフロー

5. 評価実験

5.1 実験データ

実験データとして、福井大学病院の正常胸部X線画像697症例(DICOM format)を用いた。図2の5つの解剖学的構造の領域マスク画像については、胸部X線画像読影に関する教育を受けた作業者が手作業で作成し、診療放射線技師が最終確認・修正を行った上で使用した。なお、本実験は、福井大学倫理審査委員会の承認を得て実施している。

U-Net へ入力する胸部X線画像は次のように加工して用いた。

- ・画像の幅と高さが異なる DICOM 画像について余白を付加して正方形状に変換後、256×256 画素、または、512×512 画素に縮小
- ・輝度値に関しては、DICOM header の WW,WL を利用して正規化を行った後、float に変換
- ・領域マスク画像も胸部X線画像と同様の方法で縮小

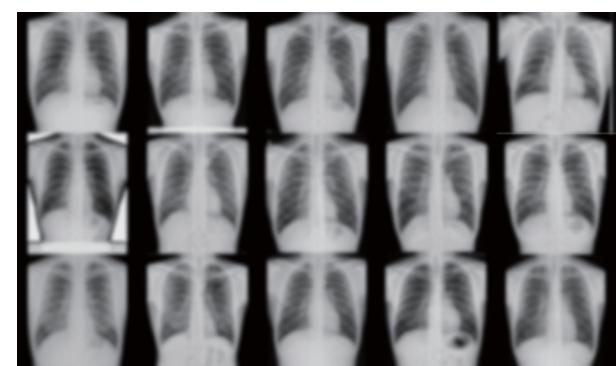


図4 実験に用いた胸部X線画像の一部

訓練用として 697 症例のうちの 9 割(627 症例)を無作為に選定して用い、評価用として残りの 70 症例を用いた。

図4に、今回の実験に用いた胸部X線画像の一部を示す。図4では、個人情報保護の観点から、意図的に平滑化を適用した画像を掲載している。実験で用いた画像は、平滑化を適用していないため、より高周波成分を含んでいる。

5.2 U-Net の構造

実験に用いた U-Net の構造を図5に示す。この構造は、[Ronneberger 15]の構造、及び、我々が実験に用いた GPU のメモリ量、計算時間を考慮して決定した。

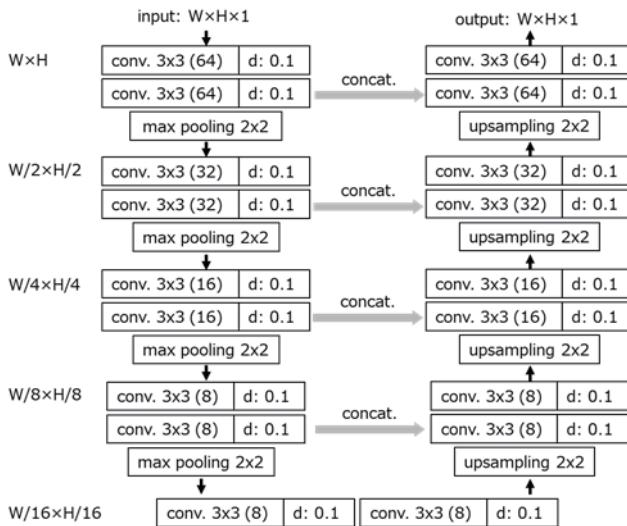


図 5 U-Net の構造

図5の記載法について補足する。”conv. $3 \times 3(64)$ ”はサイズ 3×3 (\times 前層の特徴マップ数) のフィルタを 64 個用いる convolution 層を、”d: 0.1”は確率 0.1 の dropout 層を、左端の ”W×H” 等は入出力の画像サイズが W×H 画素である時の特徴マップの画像サイズを表している。図5の U-Net では 2×2 の max pooling を 4 回行うことで、最も低解像の特徴マップは入力画像の 1/16 のサイズとなっている。

5.3 実装および計算機

領域抽出の評価指標を、教師データとしての領域マスク画像とネットワーク出力としての領域マスク画像間の Dice 係数とし、学習時の損失関数を、Dice 係数 \times (-1)とした。

U-Net の実装には、python2.7 と keras を用いた。最適化には Adam を用い、学習率を 10^{-5} とした。計算機のスペックは、OS: Ubuntu14.04, GPU: GeForceGTX1080Ti 11GB, CPU: Core i7-6850K, memory: 64GB である。

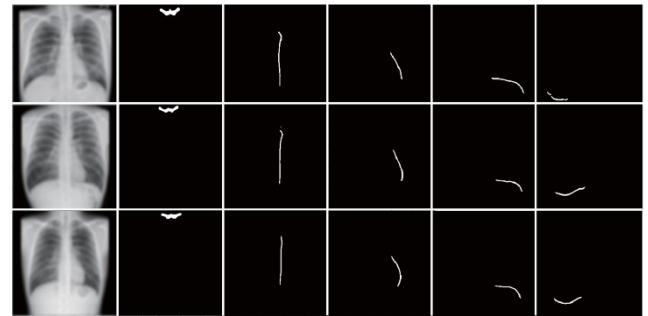
5.4 評価結果と考察

表1にDice係数での評価結果を、図6に評価データから無作為に選んだ3症例に対する領域抽出結果を示す。表中の数字は、入力画像解像度が 256×256 画素および 512×512 画素である場合それぞれの、学習終了後の訓練／テストデータに対するDice係数の平均値である。

解剖学的構造そのものである第一胸椎については、両解像度ともテストデータに対する Dice 係数が約 0.91 となった。[Novikov 17]においては 256×256 画素の解像度時に、鎖骨に対する Dice 係数が 0.902 であった。データセットやデータ数が

表 1 評価結果 (Dice 係数)

画像サイズ	第一胸椎	下行大動脈	左室	左横隔膜ドーム	右背側横隔膜
256	訓練データ	0.932	0.833	0.821	0.821
	テストデータ	0.909	0.796	0.763	0.769
512	訓練データ	0.929	0.827	0.810	0.816
	テストデータ	0.908	0.807	0.709	0.770



(a) 入力画像と出力画像



(b) 入力画像と抽出結果の重畠表示

図 6 評価データ(3例)に対する領域抽出結果

異なるため厳密な比較はできないが、今回の我々の実験では、鎖骨よりも小さく形状が微細な第一胸椎に対する Dice 係数が 256×256 画素の解像度時で 0.909 であり、良好な性能が確認できた。

一方、下行大動脈、左室、左横隔膜ドーム、右背側横隔膜という線構造については Dice 係数が 0.71～0.81 となった。但し、目視で領域抽出結果を見る限り、ほぼ正しく領域抽出できていた。Dice 係数が低くなった理由としては、Dice 係数が本来領域間のオーバラップを評価する指標であり、線構造の場合、位置が正しくても線の太さが異なれば値が低下するためと考えられる。今後は、線構造に対する損失関数及び評価指標を改良する必要がある。

線構造のうち、特に、右背側横隔膜陰影について Dice 係数が他よりも低い値となったが、この右背側横隔膜陰影は、濃淡差が微妙な陰影であることに依ると考えられる。

入力画像解像度 256×256 画素の場合と 512×512 画素の場合との比較においては、左室を除き、Dice 係数に差は見られなかった。左室については、入力画像解像度が 512×512 画素の場合に 256×256 画素の場合と比べ Dice 係数が約 0.05 低下していた。抽出結果を目視した結果、 512×512 画素の入力画像の場合のみで、真の左室陰影以外の位置に過抽出が生じているものがテストデータ70症例のうち6割程度あり、さらにその半分が図7のように下行大動脈陰影の一部を含めた状態での過抽出であった。その理由を以下のように考えた。



図 7 左室陰影に関する過抽出の例

図5のU-Netのネットワーク構造を、仮想的な1つの畳み込みフィルタとして考えた場合、その受容野の大きさを計算すると 204×204 画素になる。入力画像解像度が 256×256 画素の場合、理論上は、辺の長さで入力画像の約8割の正方領域を基に判断を下せることになる。しかし、入力画像解像度が 512×512 画素の場合には、辺の長さで入力画像の約4割の正方領域しか考慮することができず、そのため図7のような過抽出が生じたと考えられる。今後は、領域抽出対象の解剖学的領域のサイズ、および、その位置変動範囲等に応じたネットワーク構造の最適化を行う。

フィルタ受容野の問題を除けば、今回用いた5個の解剖学的構造の領域抽出では、解像度が 256×256 画素で十分と考えられる。

6. 結び

局所的な解剖学的構造の正常状態をモデル化し、疾患による解剖学的構造の変化を検出することで異常検知を行う、胸部X線画像 CAD の概要について述べた。さらに、その構成要素である、胸部X線画像からの解剖学的構造の領域抽出に対して、U-Net を用いて実装し、その評価結果について述べた。領域抽出対象として、第一胸椎のような小面積の解剖学的構造や、下行大動脈陰影などの解剖学的構造間の境界線である線構造を扱った。第一胸椎の領域抽出精度として、Dice 係数 0.91、線構造の領域抽出精度として Dice 係数 0.71～0.81 を確認した。

今後は、線構造に適した損失関数の設計、及び、領域抽出対象に応じたネットワーク構造の最適化などにより、解剖学的構造領域抽出の更なる改善を行い、さらに、異常検知手法の開発に取り組む。

参考文献

- [Ginneken 06] B. Ginnaken, M. Stegmann, and M. Loog, “Segmentation of anatomical structures in chest radiographs using supervised methods: a comparative study on a public database,” *Medical Image Analysis*, vol. 10, pp. 19–40, 2006.
- [Novikov 17] A. Novikov, D. Lenis, D. Major, J. Hladuvka, M. Wimmer, and K. Buhler, “Fully Convolutional Architectures for Multi-Class Segmentation in Chest Radiographs”, arXiv:1701.08816v3, 2017
- [Rajpurkar 17] P. Rajpurkar, J. Irvin, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, R. Ball, C. Langlotz, K. Shpanskaya, M. Lungren, A. Ng, “CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning”, arXiv:1711.05225v3, 2017.
- [Ronneberger 15] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation”. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 234–241. Springer, 2015.
- [Shiraishi 00] J. Shiraishi, S. Katsuragawa, J. Ikezoe, T. Matsumoto, T. Kobayashi, K. Komatsu, M. Matsui, H. Fujita, Y. Kodera, and K. Doi, “Development of a digital image database for chest radiographs with and without a lung nodule: receiver operating characteristic analysis of radiologists’ detection of pulmonary nodules,” *American Journal of Roentgenology*, vol. 174, no. 1, pp. 71–74, 2000.
- [Wang 17] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, R. Summers, “ChestX-ray8: Hospital-scale ChestX-ray Database and Benchmarks on Weakly-Supervised Classification and

Localization of Common Thorax Diseases”, CVPR2017, 2017.

[黒滝 17] 黒滝紘生、中山浩太郎、上原雅俊、山口亮平、河添 悅昌、大江和彦、松尾豊、”深層学習による胸部X線写真から診断補助”, 第31回人工知能学会全国大会, 2017