

---

一般口演B

## [OB10] 一般口演 B

2020年6月6日(土) 10:10 ~ 10:40 第2会場 (Zoom)

---

### [OB10-01] 画像診断レポートの所見位置情報による 画像 Bounding Box の自動作成

#### Machine-made creation of image annotations using image diagnostic reports

王 博文<sup>1</sup>、\*武田 理宏<sup>1</sup>、杉本 賢人<sup>1</sup>、和田 聖哉<sup>1</sup>、小西 正三<sup>1</sup>、真鍋 史朗<sup>1</sup>、松村 泰志<sup>1</sup> (1. 大阪大学大学院医学系研究科医療情報学)

Bowen Wang<sup>1</sup>, \*Toshihiro Takeda<sup>1</sup>, Kento Sugimoto<sup>1</sup>, Shoya Wada<sup>1</sup>, Shozo Konishi<sup>1</sup>, Shirou Manabe<sup>1</sup>, Yasushi Matsumura<sup>1</sup> (1. Department of Medical Informatics, Osaka University Graduate School of Medicine)

# 画像診断レポートの所見位置情報による 画像 Bounding Box の自動作成

王 博文<sup>\*1</sup>, 武田 理宏<sup>\*1</sup>, 杉本 賢人<sup>\*1</sup>, 和田 聖哉<sup>\*1</sup>,  
小西 正三<sup>\*1</sup>, 真鍋 史朗<sup>\*1</sup>, 松村 泰志<sup>\*1</sup>

<sup>\*1</sup> 大阪大学大学院医学系研究科医療情報学

## Machine-made creation of image annotations using image diagnostic reports

Bowen Wang<sup>\*1</sup>, Toshihiro Takeda<sup>\*1</sup>, Kento Sugimoto<sup>\*1</sup>, Shoya Wada<sup>\*1</sup>,  
Shozo Konishi<sup>\*1</sup>, Shirou Manabe<sup>\*1</sup>, Yasushi Matsumura<sup>\*1</sup>

<sup>\*1</sup> Dept. of Medical Informatics, Osaka University Graduate School of Medicine

近年、機械学習を用いたコンピュータ画像診断支援が取り組まれている。機械学習では画像に対するアノテーションが必要となるが、人手によるアノテーションは手間と時間がかかる。本研究では胸部レントゲン(CXR)画像を研究対象とし、CXR 画像診断レポートから抽出した部位と所見の情報から自動的に CXR 画像に Bounding Box を付ける手法を構築することを目的とした。2012 年から 2017 年に大阪大学医学部附属病院で実施された CXR 画像とそのレポートを解析の対象とした。最初に、DU-Net を用いて CXR レポートで記述される 8 つの部位に分割を行った。我々のモデルでは平均 IOU は 0.849 であった。次に DenseNet-121 を用い、左肺野と右肺野を、結節の有無で分類するモデルを構築した。AUC は左肺が 0.771、右肺が 0.788 であった。我々は Attention Map を作成し、CXR レポートで抽出された部位と一致した部位に Bounding Box を設定した。457 枚の CXR 画像に対し医師が付与した Bounding Box と比較すると、54.6% の医師が指摘した結節を指摘し、73.2% の Bounding Box は医師が作成した Bounding Box を含んでいた。最後に Faster-RCNN を用いて、作成した Bounding Box を教師データとした物体認識モデルを構築した。その結果、60.7% の医師が作成した結節を指摘することが可能となった。

キーワード: 胸部レントゲン検査, 画像診断レポート, 機械学習, アノテーション

## 1. はじめに

近年、機械学習を用いたコンピュータ画像診断支援が取り組まれている。機械学習では画像に対するアノテーションが必要となるが、人手によるアノテーションは手間と時間がかかる。

胸部レントゲン(CXR) 画像のデータセットでは、米国国立衛生研究所が公表する chest X-ray dataset of 14 common thorax disease categories (Chest X-ray 14)が知られる[1]。このデータセットは患者 30,805 人 112,120 枚の CXR 画像からなるデータセットで、画像レポートの自然言語解析により、画像に対し 14 種類の所見情報が付与されている。しかし、所見のアノテーション (Bounding Box) が付与されている画像は 1000 枚程度に限定されている。

我々は CXR レポートから機械学習により「部位」と「所見」の固有表現の抽出を行った[2]。この研究では、「部位」情報が F1=0.95、「所見」情報が F1=0.93 の精度で抽出可能であった。

大阪大学医学部附属病院では 1,00 万枚の CXR 画像と 40 万枚の CXR レポートが蓄積されている。そこで、CXR レポートから抽出される「部位」と「所見」情報から、CXR 画像の所見を認める部位に Bounding Box を付与することを研究の目的とした。本研究では結節影を検証の対象とした。

## 2. 方法

### 1) 肺野の分割

CXR 画像の肺野を左右の肺尖部、上肺野、中肺野、下肺野の 8 つの領域に分割するモデルを構築した。250 枚の CXR 画像を人手で 8 領域に分割し、学習データとして用いた。学習モデルは分割モデルとして知られる U-Net を用いた。モデル精度は予測領域とアノテーション領域の重なり (IOU: Intersection over Union) で評価した。

### 2) 左右肺野の結節影の認識

2-1) で分割した領域を活用し、左肺野、右肺野の結節影の有無を判別するモデルを構築した。用いた画像は、左肺野は結節影ありが 4,330 画

像, 結節影なしが 7,918 画像, 右肺野は結節影ありが 5,451 画像, 結節影なしが 6,797 画像であった. 分類モデルとして, DenseNet-121 を用いた.

### 3) Attention Map から Bounding Box の作成

2-2)で構築した分類モデルの判断根拠を class activation map (CAM) アルゴリズムを用いて可視化した. 作成された Attention Map で定義された領域と, CXR レポートに記述される結節影の位置 (2-1)で分割した領域で定義)が重なった領域を結節影領域と仮定して Bounding Box (Machine-made Bounding Box)を作成した. 作成した Bounding Box は, 医師が 457 枚の画像の結節影に対して目視で作成した Bounding Box (Manual Bounding Box)と比較を行った.

### 4) 結節影の物体認識モデルの構築

2-3)で作成した Machine-made Bounding Box を用いて, 結節影の物体認識モデルを構築した. 学習モデルとして Faster-RCNN (Regions with Convolutional Neural Networks) を用いた. 予測された Bounding Box (Predicted Bounding Box) は, Manual Bounding Box と比較し, その精度を検証した.

## 3. 結果

### 1) 肺野の分割

U-Net (U), DU-Net (DU), DU-Net with a larger size input (LDU), Loss function として cross entropy (CE), dice loss (DC), focal loss (FL)を用いて比較検討を行った. 平均 IOU は U+CE: 0.821, DU+CE: 0.842, DU+DC: 0.746, DU+FL: 0.849, LDU+FL: 0.843 と DU-Net+focal loss のモデルが最も精度が高かった. また, 左右ともに中肺野の IOU が低かった(DU+FL: 右 0.828, 左 0.827).

### 2) 左右肺野の結節影の認識

左肺野は Area under ROC: 0.772, 真陽性 378 例, 真陰性 1,026 例, 擬陽性 193 例, 偽陰性 271 例で, Precision: 0.661, Recall:0.582, F1: 0.619 であった. 右肺野は Area under ROC: 0.788, 真陽性 522 例, 真陰性 834 例, 擬陽性 202 例, 偽陰性 310 例で, Precision: 0.720, Recall:0.627, F1: 0.670 であり, 右肺野の方が予測精度は高かった.

### 3) Attention Map から Bounding Box の作成

457 枚の画像から 1483 個の Manual Bounding Box が定義された. 一方, Machine-made Bounding Box は 627 個であった. Manual Bounding Box 809 個 (54.6%)は Machine-made Bounding Box と領域と重なっていた. 一方, Machine-made Bounding Box のうち 459 個 (73.2%)は, 結節影が含まれていた.

### 4) 結節影の物体認識モデルの構築

Manual Bounding Box が 1,444 個定義された 441 枚の画像に対し, 物体認識モデルにより 1,306 個の Predicted Bounding Box が予測された. Manual Bounding Box のうち 877 個 (60.7%)を物体認識モデルで予測することが可能であった. 一方, Predicted Bounding Box のうち 603 個 (46.2%)は結節影が含まれていた.

## 4. 考察

CXR レポートから作成した Machine-made Bounding Box の 73.2%に医師が確認した結節影が含まれており, 本提案手法の妥当性を示すことができた. Predicted Bounding Box の精度は, Machine-made Bounding Box の精度を上回っており, Predicted Bounding Box を学習データとして学習を繰り返すことで, Bounding Box の精度をさらに上げることができる可能性を示唆している.

## 5. 結語

CXR レポートの部位, 所見情報から, CXR 画像のアノテーションを自動作成する手法を提示することができた.

## 参考文献

- [1] Wang X, Peng Y, Lu L, Lu Z, Bagheri M, Summers RM. ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases. IEEE CVPR 2017
- [2] 杉本 賢人, 和田 聖哉, 島井 良重, 山畑 飛鳥, 武田 理宏, 真鍋 史朗, 松村 泰志 画像診断レポートから部位表現と所見表現の抽出手法の開発 第 38 回医療情報学連合大会 38th JCFI(Nov.2018) 718-72