

肺野 CT 画像における結節影検出のための分類モデルの構築

Construction of a Classification Model for Nodule Detection in Lung CT Images

李 拓宇^{*1}
Taku Ri

山崎 達也^{*1}
Tatsuya Yamazaki

^{*1} 新潟大学工学部
Faculty of Engineering, Niigata University

This paper proposes a method to detect nodules with cancer possibility from lung field CT images. In the proposed method, an image trimmed from the lung field is input to a classification model constructed by CNN (Convolutional Neural Network), and if it is judged to be a nodule, a mark is labelled on the lung field CT image at trimmed position. In this paper, in order to confirm the effectiveness of the classification model in the proposed method, we construct a model to classify into three classes of solid nodules, ground-glass nodules and non-nodules, and verify classification accuracy. As a result of the verification, for ground-glass nodule images and non-nodule images, the classification accuracy is 95% more. However, the classification accuracy of solid nodule images is 81.87%, and most of misclassified them have been classified as non-nodule.

1. はじめに

日本における 2017 年のがんによる死者数は 373,334 人である [国立]. このうち、肺がんによる死者数は 74,120 人であり、部位別で第 1 位である. 肺がんは発生から約 10 年から 15 年経過すると急激に成長し、生存率が低下する [北村 17]. そのため、早期発見して治療を開始すれば生存率の向上につながるの、死者数の減少のためには肺がんの早期発見が重要である. 現在、放射線科医師は撮影した肺野 CT (Computer Tomography) 画像を目視で診断し、肺がんの可能性のある結節影の有無を判断している. ところが日本における放射線科医師数は診療科別の平均の約 28% しかなく、不足している [日本放射線科]. また、放射線科医師の中でも診断能力に個人差があり、肺野 CT 画像におけるがんの可能性のある結節影の種類によって見落とし率に差が出る場合がある.

そうした中で、近年、医療分野における診断支援に関する研究が広く行われるようになってきている. その中でも、肺野 CT 画像をはじめとした医用画像を自動診断に活用するための手法として、深層学習における畳み込みニューラルネットワーク (CNN: Convolution Neural Network) が注目されていて、CNN を用いた医用画像内の病変検出に関する研究事例もある [Havaei 17]. 肺野 CT 画像に対しても CNN を適用して、「異常あり」と診断された部分だけを放射線科医師が確認するようになれば、診断の手間を削減できるようになると考えられている.

そこで本稿では、肺野 CT 画像からがんの可能性のある結節影を検出するシステムを提案する. 提案手法では、肺野 CT 画像における断面である二次元スライス CT 画像から、小領域画像をトリミングしていく. ただし、トリミングする範囲を肺野領域内に限定する. 次に、肺野 CT 画像からトリミングしてきた小領域画像を、CNN で構築した分類モデルに入力する. そして、トリミングした部分が結節影であると判定されたら、スライス CT 画像の該当部分にラベルをつける. 本稿では、提案手法における結節影の検出の精度を検証するために、実際の肺野 CT 画像を用いて、充実性結節影画像、すりガラス状

結節影画像と非結節影画像との分類実験を行い、精度の検証を行った.

2. 提案手法

本稿では、Anthimopoulos ら [Anthimopoulos 16] が提案した CNN を用いて学習を行い、分類モデルを構築する. この CNN の構造を簡潔に表したものを図 1 に示す.




図 1 CNN の構造

以下、本稿では図 1 の CNN を AnNet という. AnNet は、最初に畳み込み層が 5 層連続した後にただ 1 層だけプーリング層が配置され、最後に全結合層が 3 層続く構造となっている. AlexNet [Krizhevsky 12] のように、プーリング層が畳み込み層の途中にあると、医用画像における結節影の形状や境界部分などのきめ細かい特徴が失われる問題があるが、AnNet ではこの問題を解決している.

提案手法の概要を図 2 に示す. まず、肺野 CT 画像における断面である 512×512 画素の二次元スライス CT 画像を入力画像とする. 次に、肺野領域内で 32×32 画素の小領域画像をトリミングしていく. そして、トリミングした小領域画像を AnNet で構築した分類モデルに入力する. 分類モデルの出力は充実性結節影、すりガラス状結節影と非結節影の 3 クラスとする. そして、分類モデルの判定結果が充実性結節影またはすりガラス状結節影のどちらかであれば、二次元スライス CT 画像における小領域画像をトリミングした部分に矩形でラベルをつける.

本稿では、提案手法における結節影の検出の精度を確認することを目的として、実際に AnNet で分類モデルを構築し、このモデルに対する分類の精度を検証した.




図2 提案手法の概要

3. 分類実験

3.1 使用するデータセット

本稿では、分類実験に使用する画像として、二種類のデータセットを用いる。一つ目は LUNA16 (LUng Nodule Analysis 2016) [LUNA] からダウンロードした、充実性結節影に関する CT 画像のデータセット (LUNA データセット) である。始めに、LUNA データセットにおける 512×512 画素のスライス CT 画像から、医師によるアノテーションデータが示す座標を中心とした 32×32 画素の小領域画像を、結節影画像と非結節影画像それぞれについてトリミングした。その結果、結節影画像は 1,351 枚、非結節影画像は 537,624 枚用意できた。結節影画像と非結節影画像の例を図 3 に示す。

二つ目は新潟大学医学部の PACS (Picture Archiving and Communication Systems) で収集された、すりガラス状結節影に関する CT 画像のデータセット (PACS データセット) である。結節影画像については LUNA データセットと同様に、 512×512 画素のスライス CT 画像から、アノテーションデータが示す座標を中心とした 32×32 画素の小領域画像をトリミングし、524 枚用意できた。非結節影画像についてはアノテーションデータが存在しないので、スライス CT 画像における、肺野領域内で任意の座標を中心とした 32×32 画素の小領域画像をトリミングした。結節影画像と非結節影画像の例を図 4 に示す。




図3 LUNA データセットの画像の例




図4 PACS データセットの画像の例

3.2 分類精度の検証

本稿では、分類モデル構築のために用意したデータを 10 個のサブセットに分割して、一つずつテストデータとし、残りの 9 個のサブセットを訓練データとする 10 分割交差検証により分類精度の検証を行う。始めに、訓練データ数を合わせるために LUNA データセットに対してダウンサンプリングを行った。ダウンサンプリング後のデータは、充実性結節影画像、すりガラス状結節影画像それぞれ 524 枚である。また、結節影は向きについて無関係であることから、訓練データに対して回転及び反転によるデータ拡張を施す。非結節影画像については二つのデータセットから合わせて 524 枚を交差検証の対象にする。また、用意できた非結節影画像数は十分にあるので、この 524 枚とは別

の非結節影画像を訓練データとして追加で用いる。データ拡張後の、検証に用いる画像数をまとめたものを表 1 に示す。但し括弧内は画像数が各クラス 56 枚のサブセットをテストデータとした場合の数である。

表 1 検証に用いる画像数

	充実性 結節影画像	すりガラス状 結節影画像	非結節影 画像
訓練データ	3,776 (3,744)	3,776 (3,744)	3,776 (3,744)
テストデータ	52 (56)	52 (56)	52 (56)

表 1 に示す画像数で学習して 3 クラスに分類するモデル構築を行い、10 回分それぞれについてテストデータに対する分類を行った。

3.3 結果と考察

表 2 に分類の結果をまとめた混同行列を示す。但し、分類精度は 10 回の平均値である。また、表 2 の各項目における画像の例を表 3 に示す。表 2 より、すりガラス状結節影画像と非結節影画像については 95% 以上の高い分類精度となっており、CT 画像を基にした自動診断を正確に行える面で分類モデルの有効性が確認されている [松尾 18]。一方で、充実性結節影画像に対する分類精度は 81.87% であり、他の 2 クラスに比べて 10% 以上低くなった。さらに、正しく充実性結節影と分類できなかった画像のうち、87.37% は非結節影と分類された。このような結果になった理由として、表 3 のように、非結節影と誤分類された充実性結節影画像は、正しく充実性結節影と分類されたものに比べて結節影が小さい傾向にあることが考えられる。LUNA データセットでは、1,351 枚の結節影画像のうちの 165 枚は結節影の大きさが 3mm 以下であるとされている [LUNA]。この大きさの場合にはがんである可能性は低い、0% というわけではない。そのため、このような画像をデータセットから除外したり、優先して訓練データとしたりするかどうかについては検討すべき事項であると考えている。

表 2 分類結果

正解 \ 予測	充実性 結節影	すりガラス状 結節影	非結節影
充実性 結節影	81.87%	2.29%	15.84%
すりガラス 結節影	0.76%	98.47%	0.76%
非結節影	3.24%	1.53%	95.23%

表 3 画像の例

正解 \ 予測	充実性 結節影	すりガラス状 結節影	非結節影
充実性 結節影			
すりガラス状 結節影			
非結節影			

4. おわりに

本稿では、肺野 CT 画像からがんの可能性のある結節影を検出するシステムを提案し、そのシステムにおける分類モデルについて分類精度の検証を行った。今後は、データセットに用いる画像や CNN の層の数などについて変更した場合で分類精度の検証を行って、最適な分類モデルの条件についてさらに検討する。また、提案手法の実装を進めていく。

参考文献

- [国立] 最新がん統計,
https://ganjoho.jp/reg_stat/statistics/stat/summary.html,
 国立がん研究センター, 参照 Jan.15, 2019.
- [北村 17] 北村茂三: 肺がん検診による早期発見の重要性, 医療保健学研究, No. 8, pp. 77-81, 2017.
- [日本放射線科] 放射線科医の現状と将来について,
<http://www.jcr.or.jp/kensyui/syourai/syourai.html>,
 日本放射線科専門医会, 参照 Feb. 6, 2019.
- [Havaei 17] Mohammad Havaei, Axel Davy, David Warde-Farley, Antoine Biard, Aaron Courville, Yoshua Bengio, Chris Pal, Pierre-Marc Jodoin, Hugo Larochelle: Brain tumor segmentation with Deep Neural Networks, Medical Image Analysis, vol. 35, pp. 18-31, 2017.
- [Anthimopoulos 16] M. Anthimopoulos, S. Christodoulidis, L. Ebner, A. Christe, S. Mougiakakou: Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network, IEEE transactions on medical imaging, Vol. 35, No. 5, pp. 1207-1216, May 2016.
- [Krizhevsky 12] A. Krizhevsky, I. Sutskever, G. Hinton: ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems, p. 9, 2012.
- [LUNA] LUNg Nodule Analysis 2016,
<https://luna16.grandchallenge.org>
- [松尾 18] 松尾豊: 人工知能は人間を超えるかーディープラーニングの先にあるもの, 角川書店, 2018.