

カルテ情報を加味した多断面 CT 画像からの結節状陰影の識別 Identification of Nodular Shadows from Multi-Section CT Images Incorporated Clinical Recording

西滝 裕人[†] 神谷 亨[†] 木戸 尚治[‡]
Yuto Nishitaki Toru Kamiya Shoji Kido

1. はじめに

1981 年以降, 日本における死亡原因の 1 位は悪性新生物である. その中でも, 肺がんによる死亡数は多く, 2022 年におけるがんの部位別死亡数は男性で 1 位, 女性で 2 位, 男女計では 1 位である[1]. 肺がんは進行速度が速く, ステージが進むにつれ生存率が著しく低下するため, 早期発見と早期治療が重要な課題となっている. 肺がんが疑われる場合, まず胸部 X 線検査が行われ, 異常が見られた場合にはより精密な検査として, 胸部 CT 検査が広く用いられている. しかし, 一回の検査で得られる CT 画像の枚数は膨大であり, 読影医の負担も大きい. また, 読影医の技能や経験の差により, 病変部の未検出が起こる可能性が懸念されている. そこで, 読影医の負担や未検出の低減を目的としたコンピュータ支援診断(CAD: Computer Aided Diagnosis)システムの導入が求められている. CAD とは, 検査によって得られた医用画像をコンピュータによって定量的に分析し, その結果を「第 2 の意見」として診断に利用することである.

従来の CAD システムは, 画像のみを利用した手法が一般的であった. しかし, 近年は画像情報に加え, 患者の年齢や性別, 既往歴, 喫煙歴などの患者に関する付加的情報を組み込んだ CAD システムの研究が推し進められている. 本稿では, 患者の年齢や性別, 既往歴などカルテに記載された情報を加味した多断面 CT 画像による肺結節状陰影の識別法を提案する. 画像情報のみを用いた手法や先行研究[2]との精度比較により, 提案手法の有効性を検証する.

2. 手法

全体の流れを図 1 に示す. まず, 多断面 CT 画像と患者のカルテ情報からそれぞれ特徴量を抽出する. 次に, これらの特徴量を統合し, 最終的に結節と血管の 2 クラス分類を行う.

2.1 画像特徴抽出

本稿では, 1 つの結節, 血管に対しアキシャル断面, コロナル断面, サジタル断面の 3 枚の画像をチャンネル方向に重ねたものを特徴抽出モデルに入力する. CT 画像からの画像特徴抽出には, 局所の特徴を捉える CNN と大域の特徴を捉える Self-Attention を組み合わせた CoAtNet[3]を採用する. 本稿では, CoAtNet-1 を基にした改良モデルを提案する. この改良では, 計算量を抑えつつ, 広い受容野を持つ畳み込みを利用し, モデルの前半部で対象の周辺領域も含めた特徴を捉えることを目指す. 具体的には, モデル前半部の MBConvolution を, ConvNext[4] で採用された

[†]九州工業大学 Kyushu Institute of Technology

[‡]大阪大学 Osaka University

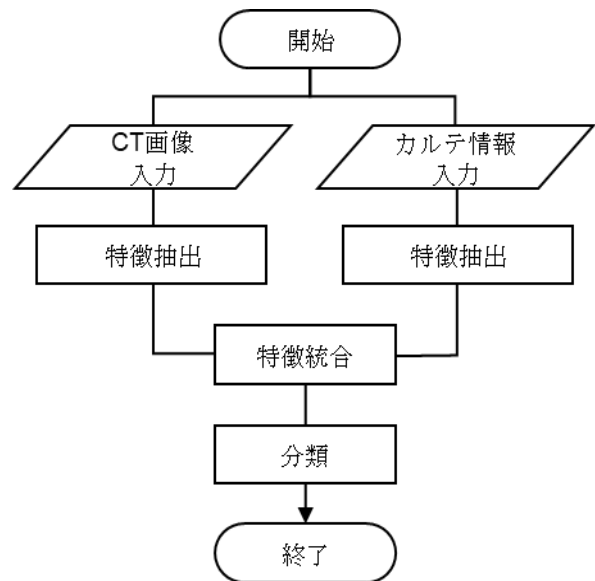


図 1 全体の流れ

ConvNext ブロックに置き換える. さらに, 画像特徴量を抽出するため全結合層を除き, 512 次元の画像特徴ベクトルを抽出する. 使用したモデルの概要を表 1, 図 2 に示す.

2.2 カルテ情報特徴抽出

本稿では, カルテ情報として性別, 年齢, 既往歴を採用する. 採用した既往歴は, 大腸がん, 胃がん, その他のがん, 結核, 肺炎, その他の肺に関する疾患の 6 つである. 前処理として, 性別は男性を 1, 女性を 0 とする one-hot ベクトルに変換する. 既往歴も同様に, 該当疾患が存在する場合は 1, 存在しない場合は 0 の one-hot ベクトルに変換する. また, 年齢は他の説明変数とスケールを合わせるため, 年齢の値を 10^{-2} 倍して使用する. これらのカルテ情報から 256 次元の特徴ベクトルを抽出するため, 3 層からなる多層パーセプトロンを用いる. 使用したモデルの概要を表 2 に示す.

2.3 マルチモーダル

画像とカルテ情報から得られた特徴ベクトルを統合し, 768 次元の特徴ベクトルを形成する. この特徴ベクトルを 4 層からなる多層パーセプトロンに入力し, 結節と血管の 2 クラス分類を行う. 使用したモデルの概要を表 3 に示す.




図 2 画像特徴抽出モデルの概要

表 1 画像特徴抽出モデル

Layer	Component	Channel	Block
Stage1	Conv 3 × 3	64	2
Stage2	DConv 7 × 7	96	3
	Pointwise Conv		
	Pointwise Conv		
Stage3	Conv 3 × 3	128	4
	Pointwise Conv		
Stage4	Self-Attention	256	6
	Feed Forward		
Stage5	Self-Attention	512	3
	Feed Forward		
Stage6	GAP	512	1

表 2 カルテ情報特徴抽出モデル

Layer	Input	Output	Activation function
Input	8		-
Dropout.1	-	-	-
Linear.1	8	150	ReLU
Dropout.2	-	-	-
Linear.2	150	280	ReLU
Dropout.3	-	-	-
Linear.3	256	256	softmax
Output		256	-

表 3 分類モデル

Layer	Input	Output	Activation function
Input	768		-
Dropout1	-	-	-
Linear1	768	4400	ReLU
Dropout.2	-	-	-
Linear.2	4400	2600	ReLU
Dropout.3	-	-	-
Linear.3	2600	1000	ReLU
Dropout.4	-	-	-
Linear.4	1000	2	softmax
Output		2	-

3. 実験と結果

3.1 入力画像

本稿では、計算量を抑えつつ、対象の 3 次元特徴を取得するため、胸部 CT 画像からアキシャル断面、サジタル断面、冠状断面の 3 つの画像を使用する。入力画像として、結節が 20mm 以下の CT 画像を採用した。アキシャル断面については、胸部 CT 検査によって得られた一連の CT 画像データの中から、結節が最も大きいスライス面を選択する。結節の領域は手動でセグメンテーションを行い、医師の指導の下、修正を行った。さらに、関心領域が小さいため、512×512 pixel から、112×112 pixel にトリミングを行った。そして、冠状断面、サジタル断面については、アキシャル断面から関心領域の中心座標を取得し、それを基に各画像を 112×112pixel にトリミングを行った。血管の

画像についても同様の手順で画像を生成した。陽性画像として、73 症例 157 枚の結節画像を使用し、陰性画像として、73 症例 327 枚の血管画像を使用する。画像を図 2, 3 に示す。

3.2 データ拡張


深層学習はデータ量が少ない場合、過学習に陥りやすい。そのため、データ拡張による汎化性能の向上が必要である。本稿では、学習データを対象に、15 度から 345 度まで 15 度刻みで回転処理を行い、また上下反転および左右反転を施してデータ量を 23 倍に増加させた。ただし、これらのデータ拡張により生成された画像は学習用データとしてのみ使用し、テストデータとしては使用しない。



(a) アキシャル断面




(b) コロナル断面



(c) サジタル断面

図 3 データセット (結節)



(a) アキシャル断面



(b) コロナル断面



(c) サジタル断面

図 4 データセット (血管)

3.3 評価指標

評価指標として、全データにおける正しく分類された割合を示す正解率 (Accuracy), 正解が陽性の画像に対して正しく陽性と識別された割合を示す真陽性率 (TPR: True Positive Rate), および正解が陰性の画像に対して誤って陽性と識別された割合を示す偽陽性率 (FPR: False Positive Rate) を用いる。

3.4 結果と考察

アキシャル断面画像および 3 断面画像のみで分類を行った場合と、画像とカルテ情報を組み合わせて分類を行った場合の分類結果を表 4, 表 5 に示す。手法 1 では、入力画像としてアキシャル断面のみを使用し、画像特徴抽出モデルとして先行研究[2]で採用された ResNet34[5]に Residual Block[6]の直前に畳み込みオートエンコーダを追加し、

Residual Block の内部に SE-Block を導入したモデルを使用している。手法 2 では、入力画像としてアキシャル断面のみを使用し、画像特徴抽出モデルとして CoAtNet-1 を使用した。手法 3 では、入力画像としてアキシャル断面を使用し、画像特徴抽出モデルとして CoAtNet-1 に ConvNeXt ブロックを採用したモデルを使用している。提案手法では、入力画像として 3 断面画像を使用し、画像特徴抽出モデルとして CoAtNet-1 に ConvNeXt ブロックを導入したモデルを使用している。

表 4 より、画像のみを用いた実験では、提案手法が他の手法と比較して高い精度を達成している。これは、ConvNext ブロックの導入により、対象の周辺情報を含む特徴を捉えられるようになったこと、及び 3 断面画像を用いることにより、球状の結節と、細長い管状や分岐構造を持つ血管という異なる形状特徴を正確に識別できるようになったためと考えられる。

表 5 より、患者に関する付加的情報を画像情報と組み合わせ学習した場合、全体の精度が低下したことがわかる。この精度の低下は、画像のみを用いた分類で非常に高い精度が得られたことから、カルテ情報がこの分類タスクにおいて冗長な情報であったことが考えられる。また、画像情報とカルテ情報の特徴量が適切に統合されていないことも、精度低下の一因として挙げられる。今後の課題として、画像とカルテ情報から得られた特徴量を効果的に統合する手法の導入や、カルテ情報特徴量の選定と前処理の改善が求められる。

また、提案手法により誤分類された結節と血管の例をそれぞれ図 5, 図 6 に示す。これらの図から、画像内の血管や結節以外の肺組織が占める割合が大きく、対象の形状特徴を正確に捉えることが困難であったため、誤分類が発生したと考えられる。さらに、使用されたデータセットにおいて、対象が他の肺組織に侵食した画像データが少ないことも誤分類の原因であると考えられる。今後の課題として、異なるタイプの侵食を示す画像データの増加が必要である。これにより、モデルはより多様な病理状態に対応する形状特徴を学習し、その結果、より複雑な対象を理解し汎化性能を向上させることが期待される。

表 4 実験結果 (画像情報のみ)


model	Accuracy	TPR	FPR
手法1	0.944	0.917	0.051
手法2	0.938	0.923	0.061
手法3	0.952	0.949	0.048
提案手法	0.979	0.980	0.022

表 5 実験結果 (画像情報+カルテ情報)

model	Accuracy	TPR	FPR
手法3	0.950	0.955	0.051
提案手法	0.975	0.980	0.027

参考文献

- [1] 公益財団法人 がん研究振興財団, “がんの統計 <2024 年度版>” (2024).
- [2] Honda N, Kamiya T, Kido S, “Identification of abnormal tissue from CT images using improved ResNet34”, 2022 22nd International Conference on Control, Automation and Systems, pp. 532-536, (2022).
- [3] Z. Dai, H Liu, Q. V. Le, M. Tan, “CoAtNet: Marrying Convolution and Attention for All Data Sizes”, Advances in Neural Information Processing Systems 34, (2021).
- [4] Z. Liu, H. Mao, C. Wu, C. Feichtenhofer, T. Darrell, S Xie, “A ConvNet for the 2020s”, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.11976-11986, (2022).
- [5] K. He, X. Zhang, S. Ren, J. Sun, “Deep residual learning for image recognition”, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp.770-778, (2016).
- [6] J. Hu, L. Shen, S. Albanie, G. Sun, E. Wu, “Squeeze-and-excitation networks”, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp.7132- 7141, (2018).



(g) アキシナル断面




(h) コロナル断面




(i) サジタル断面


図 5 誤分類した画像例
(正解：結節, 予測：血管)



(d) アキシナル断面



(e) コロナル断面



(f) サジタル断面

図 6 誤分類した画像例
(正解：血管, 予測：結節)

4. まとめと今後の展望

本稿では、患者の年齢や性別、既往歴などカルテに記載された情報を加味した多断面 CT 画像による肺結節状陰影の識別法を提案した。提案手法による画像情報のみを用いた実験結果は、Accuracy=0.979, TPR=0.980, FPR=0.022 と非常に高い精度を達成し、提案手法の有効性を確認した。また、画像情報にカルテ情報を追加して学習した場合は、Accuracy=0.975, TPR=0.980, FPR=0.027 であり、Accuracy と FPR が低下した。そのため、今後の課題として、画像とカルテ情報から得られた特徴量を効果的に統合する手法の導入や、カルテ情報特徴量の選定と前処理の改善が求められる。