

CT画像のfat strandingを特徴量とする人工知能を用いた大腸炎検出

Detection of colitis using artificial intelligence with fat stranding in computed tomography images as a feature value

江藤 芳浩^{1), 2)}, 恵谷 玲央³⁾, 品川 佳満⁴⁾, 小嶋 光明⁵⁾

1) 修士 (医科学) 医療法人慈恵会西田病院

2) 大分県立看護科学大学大学院 看護学研究科 健康科学専攻 博士後期課程

3) 博士 (保健学) 大分県立看護科学大学 看護学部 人間科学講座 環境保健学研究室

4) (大学教員) 博士 (医療情報学) 大分県立看護科学大学 看護学部 人間科学講座 健康情報科学研究室

5) (大学教員) 博士 (薬学) 大分県立看護科学大学 看護学部 人間科学講座 環境保健学研究室

Key words: computed tomography images, SVM classification model, colitis detection, fat stranding

[Abstract]

Previous studies on the use of artificial intelligence to assist in the diagnosis of colitis on CT images have used the thickness of the colon wall after the use of digestive tract contrast media as a feature, but the diagnostic accuracy was not always high.

In this study, we verified that the CT value of fat stranding of colitis (HU) is a useful feature in the colitis detection model.

From non-contrast colitis CT images of 187 cases, we created an original image in which the affected area was cut into a 128 × 128 matrix, a mask image in which structures other than the fat stranding were erased, and a threshold image in which only the fat stranding was displayed.

The SVM classifier output the classification accuracy of the original image, mask image, and threshold image, and the results showed that the accuracy of the mask image and threshold image improved over the original image.

This indicates that fat stranding is a feature for higher accuracy classification.

[要旨]

人工知能による大腸炎のCT画像診断支援に関するこれまでの研究は、消化管造影剤使用後の大腸壁の厚さを特徴量としていたが診断精度は必ずしも高くなかった。

本研究では、大腸炎のfat strandingのCT値 (HU) が大腸炎検出モデルの有用な特徴量になることを検証した。

187症例の非造影の大腸炎CT画像から、患部を128×128マトリクスに切り出した原画像、fat stranding以外の構造物を消去したマスク画像、fat strandingのみ表示した閾値画像を作成した。

SVM分類器で原画像・マスク画像・閾値画像の各分類精度を出力した結果、マスク画像・閾値画像の精度は原画像より向上した。このことから、fat strandingがより高精度に分類するための特徴量になることが分かった。

1. 緒言

Computed tomography (CT) 装置の目まぐるしい技術向上によって、多量かつ精密なデータを短時間

ETO Yoshihiro, M.S.^{1), 2)}, ETANI Reo, Ph.D.³⁾,
SHINAGAWA Yoshimitsu, Ph.D.⁴⁾,
OJIMA Mitsuki, Ph.D.⁵⁾

- 1) Medical corporation Jikeikai Nishida hospital
- 2) Doctoral Program, Health Sciences Graduate School, Oita University of Nursing and Health Sciences
- 3) Laboratory of Environmental Health Science, Department of Health Sciences, Oita University of Nursing and Health Sciences
- 4) Laboratory of Health Informatics and Biostatistics, Department of Health Sciences, Oita University of Nursing and Health Sciences
- 5) Laboratory of Environmental Health Science, Department of Health Sciences, Oita University of Nursing and Health Sciences

Received November 20, 2023; accepted December 17, 2023

に収集可能となったことから、CT画像診断の需要と期待はますます高まっている¹⁾。それに伴い、放射線科医師の読影件数は増加傾向であるが¹⁾、本邦におけるCTおよびmagnetic resonance imaging (MRI) 利用件数当たりの放射線科医師数は減少傾向にある²⁾。画像診断を専門とする放射線科医師は慢性的に不足しており、放射線科医師の負担増に拍車をかけている^{3, 4)}。こうした背景から、専門外の医師による画像診断がしばしば見受けられ、特に放射線科医師が不在の救急外来emergency room (ER) では画像診断に苦慮しているのが現状である^{5, 6)}。

ERにおける画像診断の主な対象疾患において、急性腹症はいずれの年齢層においても高い比率を占めている^{7, 8)}。姥名らは、ERでのCT画像診断において、急性腹症は実質臓器や管腔臓器に加え、血管系やfree air、腹水の有無まで注意深く観察しなくてはならないため、ER担当医師と放射線科医師の単位症例数当たりの画像診断の不一致数は頭部疾患より多く、ER担当医

師にとって急性腹症の画像診断はピットホールであると報告している⁹⁾。

こうした現状から、腹部CT画像診断における急性腹症などの検出において、artificial intelligence (AI) システムが放射線科医師のレベルでCT画像を診断できれば、病変の見落とし防止や読影精度の向上、読影時間の削減などの業務効率化が図れ、専門外医師の画像診断を支援し、放射線科医師の不在を補う手段になり得る⁶⁾。

しかしながら、江藤らのAIを用いた急性腹症疾患の検出に関する文献レビュー¹⁰⁾では、AIによる急性腹症のCT画像診断支援では、腹部臓器や病変の特徴から対象物を識別することが容易ではなく、臨床においては短時間に結果を出力する必要があることから、積極的に研究対象にされていないことが報告されている。急性腹症疾患の中でも特に大腸炎のAIを用いた診断に関する文献数は4件と少ない上^{11~14)}、いずれの研究も大腸壁の厚さを特徴量として識別しているため腹腔内臓器との誤分類が生じることや、大腸壁の肥厚が軽度の場合は偽陰性になりやすく、病変検出精度は腎・尿管結石や胆石などの他の急性腹症疾患よりも低いと報告されている。またいずれの文献も大腸と大腸壁の厚さを認識するために経口造影剤や経静脈性造影剤が使用されているが、造影剤使用は専門知識や患者の身体リスクを伴う。また造影剤が使用できない場合は大腸炎を認識することができない欠点があると報告している。

大腸炎における大腸の形態変化以外の特徴量として、Fig.1に示すような大腸炎周囲の脂肪組織への炎症波及によるfat strandingが挙げられる^{15~17)}。fat strandingの領域は周囲の正常脂肪よりCT値が上昇することから、造影剤を使用しないCT画像からfat strandingを検出することができれば、大腸炎の存在

診断ができる。しかしながら、専門外医師が腹部CT画像からfat strandingを指摘することは容易ではない。そこでAIが放射線科医師のレベルでfat strandingを検出することができれば、ERにおいて専門外医師の大腸炎診断を補うことができる。

本研究では、非造影CT画像における大腸炎診断において、fat strandingを機械学習 (machine learning: ML) モデルにおける大腸炎検出の有効な特徴量として、高精度で大腸炎を分類することができるかを明らかにした。

2. 方法

本研究における大腸炎は、憩室炎・感染性大腸炎・虚血性大腸炎・潰瘍性大腸炎など、大腸に炎症を生じる疾患の総称とした¹⁸⁾。

1) 大腸炎の画像収集

本院において、2013年1月から2021年12月末までの間で、腹痛を主訴として救急外来または一般外来を受診して大腸炎と診断された患者は345人であった。このうち非造影CT検査を施行し、経験年数35年と13年の放射線科専門医2人が大腸炎と診断したのは211人であった。この211人のうち、大腸周囲に脂肪層が全く見られない患者、全身性浮腫を伴う疾患の患者、体動や異物などによって画像アーチファクトが強かった24人を除外して、最終的に187人のCT画像を使用した。

187人の患者ごとに大腸炎患部の1画像を選択した。選択する画像は、放射線科医師が大腸炎の所見報告書に添付した画像と同一の画像とした。また所見報告書に画像が添付されていないものについては、CT検査経験年数18年の診療放射線技師が放射線科医師の所見を基に、大腸炎のfat strandingが特徴的な1画像を選択した。全ての画像データは画像サーバーからBitMap (bmp) 形式で抽出し、個人情報保護のため患者属性の表示を削除して収集した。

187人の患者の性別・年齢層・疾患名・発症部位の内訳をTable 1に示す。性別では男性がやや多く、年齢は40歳から60歳代が全体の約60%を占めた。また疾患は大腸憩室炎が約89%と大半を占め、発症部位は盲腸・上行結腸が約55%、下行結腸が約32%であった。大腸憩室炎症例が多いのは、消化管関連の入院で最も頻度の高い適応症の一つとされていることや¹⁹⁾、本来、罹患率が比較的高い上に^{20, 21)}、近年は発症数が増加傾向にある²²⁾ことを反映していると推察される。




Fig.1 CT image of fat stranding

Fat stranding increases CT values of adipose tissue around the colon.

Table 1 Breakdown of the 187 patients with colitis

Total number	187				
Sex	Male 102 / Female 85				
Age, years	10 ~	20 ~	30 ~	40 ~	50 ~
	2	8	27	39	37
Disease	Diverticulitis	Infectious colitis	Ischemic colitis	Other	
	166	7	10	4	
Site of inflammation	Ascending Cecum	Transverse	Descending	Sigmoid	Rectum
	102	6	60	18	1

Males were marginally more prevalent, and a significant portion, approximately 60%, were aged between 40 and 60 years. Most patients (about 89%) had been diagnosed with colonic diverticulitis, with the most common onset locations being the cecum and ascending colon (about 55%) and the descending colon (about 32%).

使用機器は、装置A: Activion16 (キヤノンメディカルシステムズ, 栃木, 16列MDCT: 2013年1月~2019年3月)ならびに装置B: Supria Grande (富士フイルムヘルスケア, 東京, 64列MDCT: 2020年3月~2021年12月)を使用した。大腸炎疾患187症例のうち装置Aで撮影した者は112人, 装置Bで撮影した者は75人であった。また正常画像データについて

は、大腸炎画像の取得装置, 撮影年月, 発症部位の数が同一になるように任意に抽出し, 大腸炎画像, 正常画像で374画像とした。

本研究は、医療法人慈恵会西田病院の倫理審査委員会 (No.202202-1) および公立学校法人大分県立看護科学大学の研究倫理・安全委員会 (No.21-72) の承認を得て実施した。

2) CT撮影装置の撮影条件

いずれの装置も撮影管電圧120 kVでCT線量自動露出機構 (auto exposure control: AEC) を使用し, 画像SD (standard deviation) は, Activion16が値8, Supria GrandeがSD値10に設定され, 患者体形によらず画像ノイズは一定とした。またいずれの装置もスライス再構成間隔は5 mmで, 標準再構成関数を使用し, 画像表示に任意のフィルター処理は加えていない。また装置や撮影時期に関わらずWindow Widthを300, Window Levelを15に統一した。

3) MLモデル構築プロセスの概要

MLモデル構築のためのプロセスの概要をFig.2に

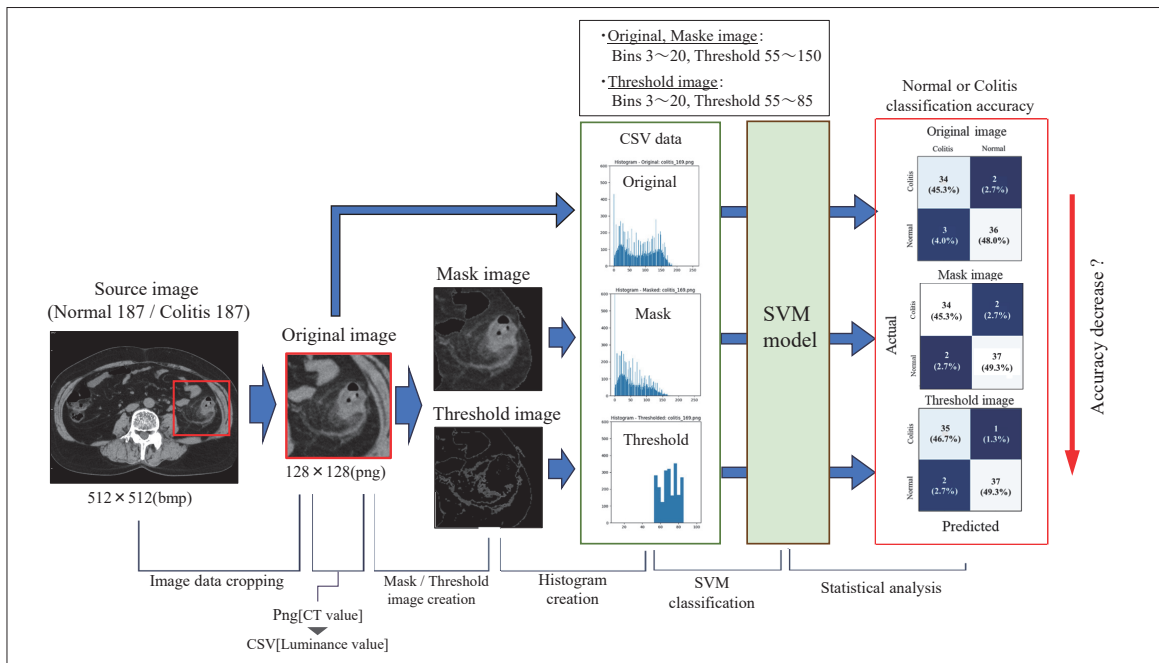


Fig.2 Overview of the process for the construction of a machine learning model

To verify that fat stranding around colitis was a feature, an original image was created by extracting the affected area of the original image into a 128x128 matrix. Normal images were also created in the same way. In addition, the original images were converted to csv data, and a total of three types of images were created: a mask image in which structures other than fat stranding were deleted from the original image, and a threshold image in which only the luminance of fat stranding was displayed. Histograms of these images were then developed, and through a combination of histogram bins, luminance thresholds, and hyperparameters, the SVM classifier was optimized for maximum classification accuracy. The accuracies of the mask and threshold images were compared with the original image to verify whether fat stranding had been captured as a feature.

示す。大腸炎周囲のfat strandingが特徴量になることを検証するため、元画像の患部を128×128マトリクスサイズに抽出した原画像を作成した。同様の方法で正常画像も作成した。さらに原画像をcsvデータに変換し、原画像からfat stranding以外の構造物を消去したマスク画像と、fat strandingの輝度のみを表示した閾値画像の計3種類の画像を作成した。3種類の画像のヒストグラムを作成し、ヒストグラムのbins・輝度閾値・ハイパーパラメーターの組み合わせを変えながらsupport vector machine (SVM) 分類器によって各画像での分類精度を出力し、原画像に対するマスク画像と閾値画像の精度比較を行うことで、fat strandingを特徴量として捉えられているかを検証した。

4) データセットの作成

①使用する画像データのトリミング

本研究は、fat strandingがMLによる大腸炎の検出に有用であるかを評価することが目的であることから、大腸とfat strandingが収まる画像サイズにトリミングした。元画像(マトリクスサイズ512×512)を全て観察して、大腸とfat strandingの領域が収まる最小範囲をマトリクスサイズ128×128に決定した。Fig.3に示すように全ての元画像をトリミングして原画像を作成した。トリミングは画像加工用のフリーソフトウェアを利用し、データ容量や管理上の利点から画像ファイル形式を「bmp」からportable network graphic (png)に変換して収集した。また正常画像についても同様に大腸を中心にトリミングし、画像ファイル形式の変換を行って収集した。




Fig.3 Image cropping

The minimum area where the colon and fat stranding areas fit was determined to be a matrix size of 128 x 128, and all source images were cropped to create the original image. In addition, the image file format was converted from "bmp" to "png" for collection.

②png画像のCT値をcsv(輝度値)へ変換

データセットをSVM分類器で分類するため、pythonの関数を使用し、Fig.4に示すように、正常と大腸炎の全ての原画像の128×128マトリクスを、8ビット256階調のcsvファイル形式の輝度値に変換した。

③fat stranding・臓器・組織の輝度値およびCT値の測定

fat strandingのcsv輝度値の範囲を決定するため、fat strandingが上行結腸にある画像10例、下行結腸6例、横行結腸2例、S状結腸2例の計20例について、大腸炎の原画像の中でfat strandingが比較的広範囲に及んでいる画像から輝度値の範囲を求めた。測定方法は、Fig.5のように大腸壁近傍から遠位方向に向かう3点の輝度値を読み取った平均から輝度値の範囲を決定した。また大腸壁・正常脂肪・骨・筋・腎臓につ




Fig.4 Convert CT values to csv

For all original images of normal and colitis, CT values in 128 x 128 matrix, 8-bit 256 gray scale were converted to luminance values in csv file format.

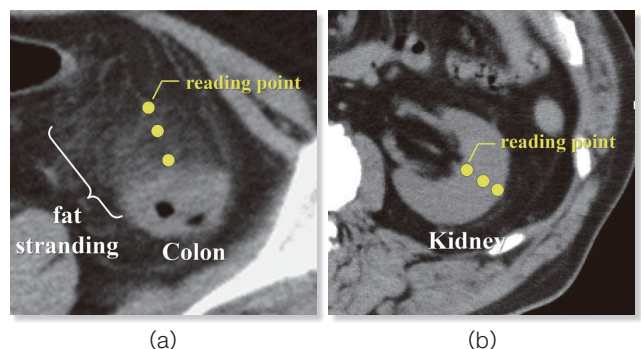


Fig.5 Fat stranding and organ luminance value measurements

(a) Luminance value of fat stranding: The luminance values of fat stranding at three points in the distal direction from the proximity of the colon wall were read, and the range of luminance values was determined from the average of these readings.

(b) Luminance values of organs: The luminance values of three points (inside, center, and outside of the organ) were read, and the range of luminance values was determined from the average values.

いては任意の画像10例を選択し、各臓器などの外側・中央・内側の任意の3点の輝度値を読み取った平均から範囲を決定した。輝度値の読み取りは各点の周囲9マトリクスの平均値とした。

CT値はpicture archiving and communication systems (PACS) の測定機能を利用し、csvの測定点と同じ位置で臓器などの形状に合わせた任意サイズのROIを設定して平均値を求めた。脂肪の測定点は血管や結合組織などがない任意の部位とした。

Table 2に、fat strandingおよび各組織・臓器のCT値およびcsv輝度値の範囲を示す。マトリクスごとの輝度値はバラツキがあるため、測定した値を5単位で表示した。測定の結果、fat strandingの輝度値とCT値は、脂肪や臓器とは明らかに隔たりがある特徴的な値を示した。

④ マスク画像と閾値画像およびヒストグラムの作成

SVM分類器がfat strandingを特徴量としているかを確認するため、原画像からfat stranding以外の構造物を消去した2種類の画像を作成した。

まず、原画像の全ての正常と大腸炎のcsvデータセットについてpythonの関数を使用してヒストグラムを作成した。次いで、画像処理ライブラリのOpenCVを利用して、Otsuの方法²³⁾による画像の二値化と、面積フィルタリングの組み合わせによるマスク処理を行い、腹腔内臓器を消去してfat strandingを強調する「マスク画像」を作成した。また原画像内のfat strandingの輝度値「55~85」のみを表示する「閾値画像」を作成した。さらに全ての正常と大腸炎のマスク画像と閾値画像のcsvデータのヒストグラムを作成した。

5) SVM分類器による分類

SVM分類器のトレーニングデータとテストデータの分割は、python関数を利用してランダムに分割した。

SVM分類器のハイパーパラメーターは、原画像において最高精度となるハイパーパラメーターを決定し、同じハイパーパラメーターでマスク画像・閾値画像の最高精度を求めて原画像からの精度変化を評価した。

まず、原画像の分類が最高精度となるハイパーパラメーターを決定するため、ヒストグラムのbins、csv輝度閾値とハイパーパラメーターの「kernel」「C」「gamma」の各候補の組み合わせを変えながら分類精度を算出した。ヒストグラムのbinsは特徴量の細か

Table 2 CT and luminance values for fat stranding and each tissue and organ

	CT value (HU)	CSV luminance range
Bone	200 - 900	200 - 255
Muscle	40 - 80	140 - 160
Colon	15 - 50	120 - 150
Kidney	15 - 50	120 - 150
Fat stranding	-30 - 5	55 - 85
Fat	-70 - 120	0 - 10

CT and luminance values of fat stranding are separated from those of fat and organs.

さと計算負荷のバランスを考慮して「3, 5, 8, 10, 12, 15, 18, 20」とした。輝度閾値はTable 2に示すfat strandingの下限値から実質臓器の上限までの「55~150」とした。ハイパーパラメーターの各候補はkernelを「linear, poly, rbf」、Cを「0.1, 1, 10」、gammaを「0.001, 0.01, 0.1, 1, 10, 100」とした。ハイパーパラメーターの探索手法であるScikit-learnのグリッドサーチを用いて、binsごとに出力された精度の中から最高精度を出力したkernel, C, gammaを決定した。なお、マスク画像の輝度閾値は原画像と同じ「55~150」とし、閾値画像についてはTable 2のfat strandingの輝度範囲「55~85」とした。

6) 統計解析

統計解析はpythonライブラリを用いて行った。原画像・マスク画像・閾値画像で最高精度を出力したbinsについて、それぞれ混同行列を作成し、精度・感度・特異度を求めた。

7) 誤判定画像の特徴評価

正常と大腸炎にラベル付けされた原画像187画像と閾値画像187画像を、それぞれ学習済みSVM分類器で分類し、誤判定として出力された画像に共通する特徴について評価した。

3. 結果

1) マスク画像と閾値画像のヒストグラム

原画像・マスク画像・閾値画像と各csvデータのヒストグラムの例をFig.6に示す。原画像・マスク画像共に、脂肪領域を中心とした輝度範囲と実質臓器を中心とした輝度範囲の二峰性の形態を示した。

マスク画像では実質臓器が消去されたことによっ

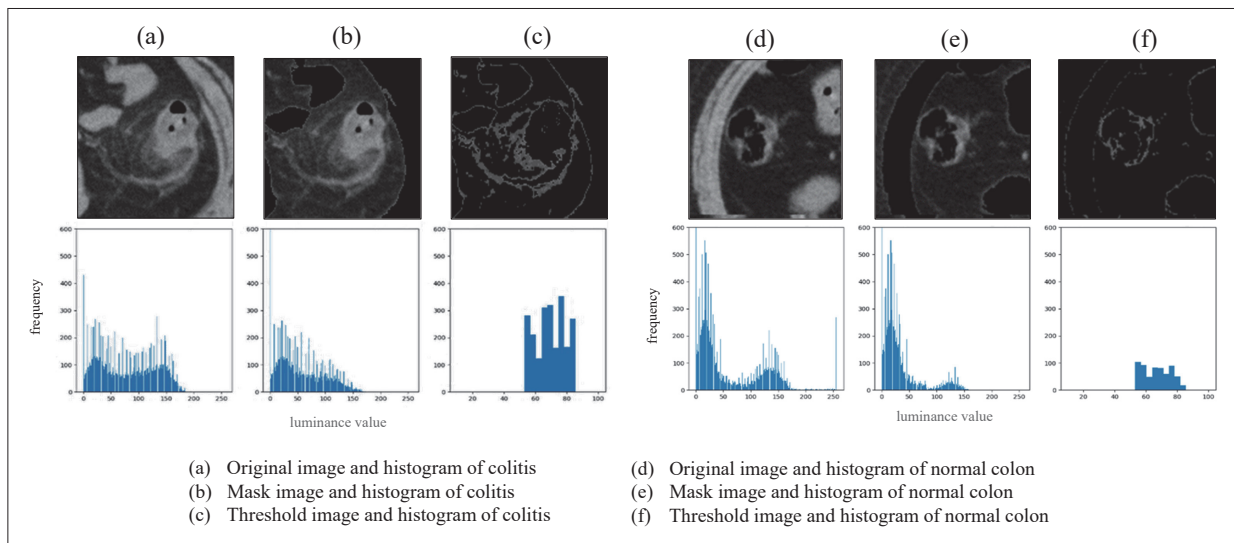


Fig.6 Histograms of the original, mask, and threshold images for colitis and normal

Both the original and masked images showed a bimodal morphology, with luminance centered on the fat region and luminance centered on the parenchymal organs. Histograms of the threshold images showed a trend toward higher frequencies for colitis images than for normal images.

て、その輝度範囲の度数が低下した。マスク画像の正常と大腸炎の各187画像のうち、fat stranding以外の構造物が全て消去されていたのは正常24画像、大腸炎84画像で、それ以外の画像は大腸のみが残存していた。

fat strandingの輝度範囲(55~85)だけを表示した閾値画像のヒストグラムでは、大腸炎画像の度数は正常画像より高い傾向を示した。

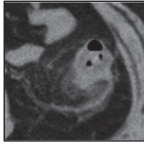
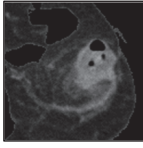
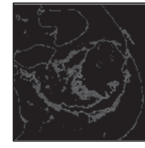
2) SVM分類器による分類

原画像・マスク画像・閾値画像の各374画像のうち、Python関数によってトレーニング用に約80%、299画像(正常148画像、大腸炎151画像)、テスト用に約20%、75画像(正常39画像、大腸炎36画像)がランダムに選択された。

原画像の分類精度は、binsが10または12、ハイパーパラメータはグリッドサーチによってkernel: linear, C: 1, gamma: 0.01が選択され、最高精度が0.933であった。

マスク画像・閾値画像は原画像のハイパーパラメータを基にkernel: linear, C: 1として分類精度を求めた。3種類の画像データセットについて、binsご

Table 3 Comparison of the accuracy of the original, mask, and threshold images

	Original image	Masked image	Threshold image	
Image				
Hyper parameter	kernel : linear C : 1 gamma : 0.01	kernel : linear C : 1 gamma : scale	kernel : linear C : 1 gamma : scale	
Luminance range	55~150	55~150	55~85	
Bins	3	0.906	0.920	
	5	0.906	0.920	
	8	0.920	0.947	0.906
	10	0.933	0.933	0.920
	12	0.933	0.906	0.933
	15	0.906	0.880	0.960
	18	0.920	0.933	0.933
	20	0.890	0.866	0.920

After a grid search, the hyperparameters selected were: kernel (linear), C (1), and gamma (0.01). This configuration yielded a maximum accuracy of 93.3%. For the mask and threshold images, the hyperparameters were determined based on the original images. The mask image achieved a peak accuracy of 94.7% with 8 bins, while the threshold image reached 96.0% accuracy with 15 bins.

との精度の一覧をTable 3に示す。マスク画像の最高正解率はbinsが8で94.7%、閾値画像ではbinsが15で96.0%であった。

3) 統計解析

テストにおける75画像の原画像・マスク画像・閾値画像の最高精度を示したbinsとハイパーパラメーターにおける混同行列をそれぞれFig.7に示す。原画像では感度94.4%、特異度92.3%、マスク画像はそれぞれ94.4%と94.9%、閾値画像については97.2%と94.9%であった。

今回作成したSVM分類モデルは原画像でも93.3%

の高い分類精度を示した。マスク画像と閾値画像の精度は原画像よりそれぞれ1.4%、2.7%上昇し、原画像からfat stranding以外の構造物を消去しても精度は低下しないことが分かった。

4) 誤判定画像の特徴評価

誤判定画像の特徴について評価を行うため、原画像の正常と大腸炎の各187画像と、閾値画像の正常と大

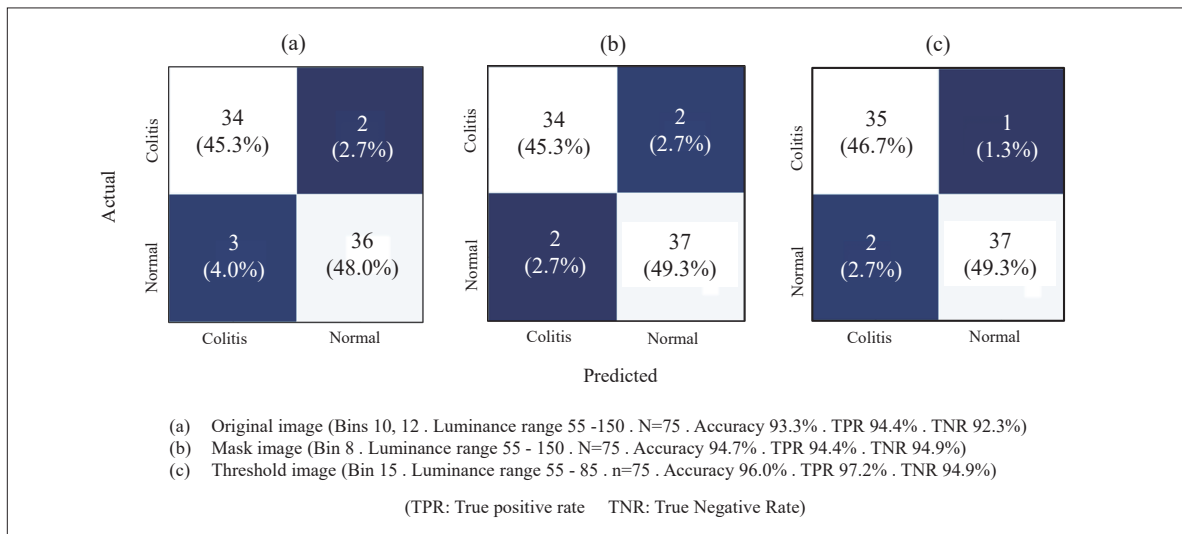


Fig.7 Confusion matrices in showing the highest accuracy in the original, mask, and threshold images

The sensitivity and specificity of the original images were 94.4% and 92.3%, mask images 94.4% and 94.9%, and threshold images 97.2% and 94.9%.The original image also showed a high accuracy of 93.3%, while the accuracy of the mask and threshold images increased by an additional 1.4% and 2.7%.

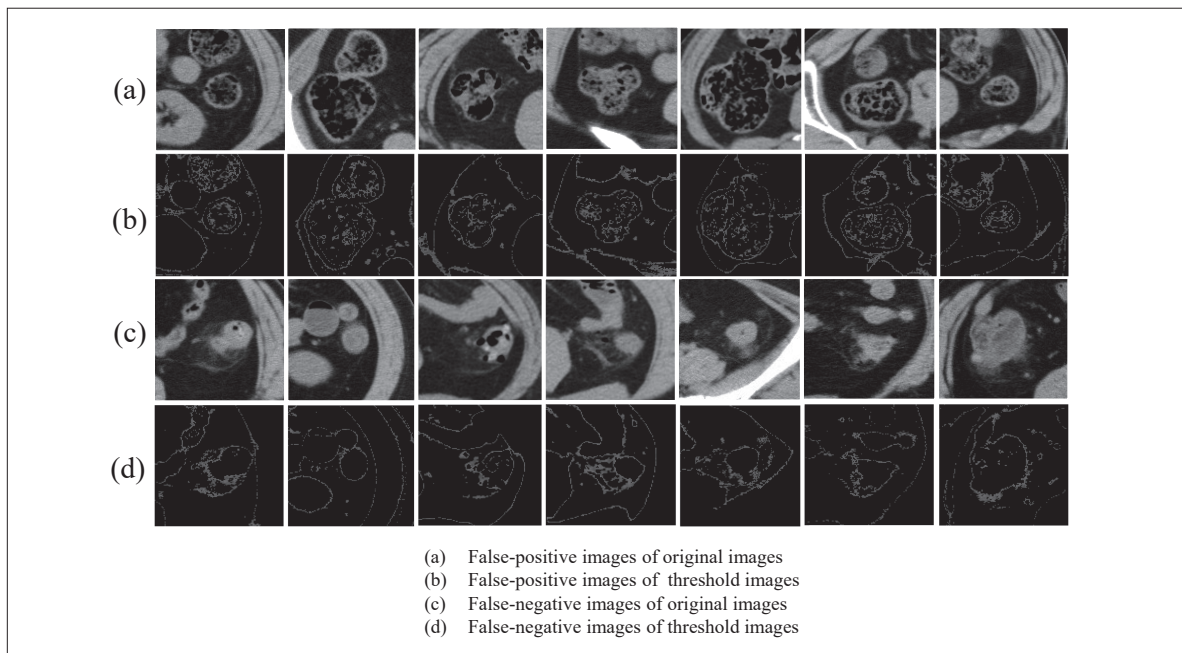


Fig.8 Characteristics of false-positive and false-negative images

In cases where normal images were misidentified as colitis, the colon was dilated and there were many fecal masses with the same luminance as the fat stranding. The images in which colitis was misidentified as normal were characterized by small fat stranding areas.

腸炎の各187画像を、今回作成した学習済みSVM分類器で分類した。誤判定となった画像の中から、原画像と閾値画像共に誤判定となった正常と大腸炎の各7画像をFig.8に示す。正常画像で誤判定した画像は大腸が拡張し、内腔にfat strandingの輝度と同等の便塊が存在することが特徴であった。また大腸炎を正常と誤判定した画像はfat strandingの領域が比較的小さいことが特徴であった。

4. 考察

過去に報告された人工知能を用いた大腸炎検出の研究¹¹⁻¹⁴⁾では、全て消化管造影剤を使用し、大腸炎による大腸壁の浮腫性肥厚を特徴量にして大腸炎を分類していた。いずれの研究もディープラーニングベースのアルゴリズムで識別しているものの、精度0.7~0.73、感度0.73~0.94、特異度0.73~0.95と性能評価は必ずしも高くなかった。またこれらの研究の課題として、結腸の形態や個人差により炎症領域を検出することは困難であること、結腸以外の臓器の誤検出対策が必要であること、画像スライス厚が検出に影響すること、壁肥厚が明確でない場合や病変のサイズが小さい場合に偽陰性が生じること、便を伴う結腸や腎臓・肝臓は大腸炎と類似しているため、誤検出する可能性があることが挙げられていた。本研究は、過去の研究での課題を克服するため、大腸の形態ではなく大腸炎CT検査の副所見であるfat strandingの検出に着目し、原画像・マスク画像・閾値画像をSVM分類器で分類することで、90%以上の高精度で分類できた。高精度であった要因については、過去の研究では元画像から大腸をローカライズしてから大腸壁の厚さを計測する複雑なアルゴリズムを用いる必要があったのに対し、本研究では大腸炎患部を手動で切り出した画像を使用したことと、fat strandingの特徴的な輝度値のヒストグラムをSVM分類器によって分類するシンプルなアルゴリズムであることが理由であると考えられる。また今回使用したSVM分類器は、1992年に発表された教師ありの分類アルゴリズムであり、分類・回帰などに広く利用され、医療画像処理などの分野で強力な分類器であるとされている²⁴⁻²⁶⁾。ランダムフォレスト²⁷⁾や多層パーセプトロン分類²⁸⁾など、広く使用されている他のパターン認識手法よりも高い分類精度を提供することが可能で、少数のトレーニングデータしか利用できない環境で有利とされており²⁵⁾、そうしたSVM分類器の特長が生かされた結果であると推察された。

本研究では、原画像においてもテストデータで93.3%の精度を出し、大腸やその他の臓器などを消去したマスク画像と閾値画像の分類精度が原画像の精度から低下することなく、それぞれ1.4%と2.7%向上した。マスク画像と閾値画像が原画像よりも高い精度を示したのは、これらの処理によってfat strandingの特徴がより明確になり、ノイズの低減が影響したものであると考えられる。つまりマスク処理によって関連性の低い背景情報が取り除かれ、さらに閾値処理によりfat strandingの輝度が強調されたことにより、SVM分類器のパフォーマンスが向上したと推察される。このことから、構築したSVMモデルがfat strandingを主な特徴量として捉えていることが証明され、fat strandingの有無を分類することによって大腸炎を高精度に検出することが可能であるという結論を得た。fat strandingに着目した本研究の成果は、AIを利用した大腸炎CT診断支援の今後の研究に有益であると考えられる。またfat strandingを伴う疾患は大腸炎だけではないため²⁹⁻³¹⁾、fat strandingを特徴量とする手法は大腸以外の腹腔内臓器などの炎症疾患や、一部のがん³²⁻³⁴⁾の検出にも応用できる可能性がある。

本研究の限界としては、大腸周囲に脂肪層がない患者についてはfat strandingを検出できない。また全身性浮腫を伴う疾患により軟部組織のCT値が上昇している患者では、精度が低下する可能性がある。これらの問題を解決するためには、多様な症例を含むデータセットを用いる、あるいはfat strandingの検出方法を改善する必要がある。一方、本研究では大腸炎の検出を目的としているが、fat strandingには体網の虚血変化や近傍臓器の炎症によるものなどさまざまなパターンがあるため¹⁶⁾、炎症を検出することはできるが、大腸炎としては偽陽性となる可能性がある。

大腸炎の偽陽性の要因としては、fat strandingの輝度に相当する便塊の占める領域が比較的大きいことが原因であることが推察された。通常、大腸炎の患部は大腸内腔が虚脱するため³⁵⁾便塊の影響を受けずfat strandingを分類しやすいが、内腔が虚脱した正常大腸の近傍に便塊が滞留した大腸がある場合は偽陽性と判定される可能性がある。また偽陰性については、fat strandingの領域が軽度の場合に生じる可能性がある。これらの問題を解決するための方策として、分類アルゴリズム自体の改善に加えて、より高度な前処理や特徴抽出手法の開発、さらには多様な症例を含むデータセットを使用することが考えられる。例えばCNNによる特徴量の抽出とSVM分類技術を組み合わせた

アプローチによって、より多様な症例に対して高性能な分類精度を実現できる可能性が考えられる²⁵⁾。また本研究は、アーチファクトがなく、特定のノイズレベル、一定のWindow Width/Level (WW/WL)、さらに放射線科医師2人によって診断された大腸炎CT検査画像の患部を、128×128マトリクスに切り出した画像を使用してSVM分類器のトレーニングとテストを行った。しかし、臨床での実用性を高めるためには、ノイズレベルやWW/WLの変化に対する精度の検証を行う必要がある。またCT検査の元画像からfat strandingを自動的にローカライズして分類するアルゴリズムの研究が必要である。

5. 結 語

本研究は、MLによる大腸炎のCT画像診断支援において、fat strandingをSVM分類器の特徴量とするこ

とは有効であり、消化管造影剤を使用しない腹部CT画像から大腸炎を高精度で分類することができることを示した。これにより、ERにおける専門外医師による大腸炎の早期診断に貢献できると期待される。

今後の研究では、より高い精度と汎用性を持つモデルの開発を目指し、さまざまな症例にも対応できる手法の開発を進める。

謝 辞

本研究に際し、ご協力いただきました医療法人慈恵会西田病院 放射線部の皆さまに感謝申し上げます。

利益相反

筆頭著者および共著者全員に開示すべき利益相反はない。

表の説明

Table 1	大腸炎患者187人の内訳 男性がわずかに多く、約60%の患者が40~60歳であった。ほとんどの患者(約89%)は大腸憩室炎と診断されていた。最も多い発症部位は盲腸と上行結腸(約55%)と下行結腸(約32%)であった。
Table 2	fat strandingおよび各組織、臓器のCT値と輝度値の範囲 fat strandingのCT値と輝度値は、脂肪や臓器の値とは隔たりがある。
Table 3	原画像・マスク画像・閾値画像の精度比較 グリッドサーチの結果、選択されたハイパーパラメータは、カーネル (linear), C (1), ガンマ (0.01)であった。この構成で最大93.3%の精度が得られた。マスク画像と閾値画像については、ハイパーパラメータは元画像に基づいて決定された。マスク画像は8 binsで94.7%のピーク精度を達成し、閾値画像は15 binsで96.0%の精度を達成した。

図の説明

Fig.1	fat strandingのCT画像 fat strandingは大腸周囲の脂肪組織のCT値が上昇する。
Fig.2	機械学習モデル構築プロセスの概要 大腸炎周囲のfat strandingが特徴量であることを確認するため、原画像の患部を128×128マトリクスに抽出して原画像を作成した。正常画像も同様に作成した。さらに原画像をcsvデータに変換し、原画像からfat stranding以外の構造を削除したマスク画像、fat strandingの輝度のみを表示した閾値画像の計3種類の画像を作成した。各画像のヒストグラムを作成し、ヒストグラムのbins・輝度閾値・ハイパーパラメータの組み合わせにより、SVM分類器の分類精度が最大になるように最適化した。マスク画像と閾値画像の精度を元の画像と比較

し、脂肪鎖が特徴として捉えられているかどうかを検証した。

Fig.3	画像のトリミング 大腸とfat strandingの領域が収まる最小範囲をマトリクスサイズ128×128に決定して、全ての元画像をトリミングして原画像を作成した。また画像ファイル形式を「bmp」から「png」に変換して収集した。
Fig.4	CT値からCSVへの変換 正常と大腸炎の全ての原画像について、128×128マトリクス・8ビット256階調のCT値をcsvファイル形式の輝度値に変換した。
Fig.5	fat strandingと臓器の輝度値測定 (a) fat strandingの輝度値：大腸壁の近傍から遠位方向に3点のfat strandingの輝度値を読み取り、その平均値から輝度値の範囲を求めた。 (b) 臓器などの輝度値：臓器の内側・中央・外側の3点の輝度値を読み取り、その平均値から輝度値の範囲を求めた。
Fig.6	大腸炎と正常の元画像・マスク画像・閾値画像のヒストグラム 原画像・マスク画像共に脂肪領域を中心とした輝度と実質臓器を中心とした輝度の二峰性の形態を示した。閾値画像のヒストグラムは、大腸炎画像の頻度が正常画像よりも高い傾向を示した。
Fig.7	原画像・マスク画像・閾値画像の最高精度における混同行列 原画像の感度と特異度は94.4%と92.3%、マスク画像は94.4%と94.9%、閾値画像は97.2%と94.9%であった。原画像でも93.3%の高い精度を示し、マスク画像と閾値画像の精度はさらに1.4%と2.7%上昇した。
Fig.8	偽陽性画像と偽陰性画像の特徴 正常画像を大腸炎と誤認識したものは大腸が拡張し、fat strandingと同じ輝度の便塊が多く存在することが特徴であった。大腸炎を正常と誤認識した画像はfat strandingの領域が小さいことが特徴であった。

参考文献

- 1) Nakajima Y, et al.: Radiologist supply and workload: international comparison. *Radiation medicine*, 26(8), 455-465, 2008.
- 2) Matsumoto M, et al.: Geographic distribution of radiologists and utilization of teleradiology in Japan: a longitudinal analysis based on National Census Data. *PLoS One*, 10(9), 2015.
- 3) 川本誠一: 画像診断とAI (人工知能). *大阪急診医誌*, 41(1), 3-19, 2019.
- 4) 藤田広志: AI画像診断の全体像と将来の展望—医師を助ける“第三の目”—. *情報処理*, 62(2), 1-8, 2021.
- 5) 高本聖也, 他: 診療放射線技師による時間外救急CTの緊急所見報告の効果. *日臨救急医学会誌*, 22(5), 703-708, 2019.
- 6) Jin JP, et al.: Convolutional-neural-network-based diagnosis of appendicitis via CT scans in patients with acute abdominal pain presenting in the emergency department. *Scientific Reports*, 10, 9556, 2020.
- 7) 恩田秀賢, 他: 当院高度救命救急センターにおける高齢者医療の現状. *日医大医学会誌*, 9(2), 129-134, 2013.
- 8) 加藤博之: 高齢者に多い救急疾患. *日老医誌*, 48(4), 312-316, 2011.
- 9) 蛸名正智, 他: ER型救命センターでのCT画像診断における診断精度の現状と質向上の試み. *日臨救急医学会誌*, 18, 1-4, 2015.
- 10) 江藤芳浩, 他: 救急医療におけるAIを用いた腹部CT画像診断支援の現状と課題に関する文献レビュー. *日放技誌*, 70(9), 21-29, 2023.
- 11) Liu J, et al.: Detection and diagnosis of colitis on computed tomography using deep convolutional neural networks. *Med Phys*, 44(9), 4630-4642, 2017.
- 12) Liu J, et al.: Colitis detection on abdominal CT scans by rich feature hierarchies. In: *Medical Imaging 2016: Computer-Aided Diagnosis*, SPIE, 9785, 423-429, 2016.
- 13) Liu J, et al.: Colitis detection on computed tomography using regional convolutional neural networks. In: *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*, IEEE, 863-866, 2016.
- 14) Wei Z, et al.: Computer-aided detection of colitis on computed tomography using a visual codebook. In: *2013 IEEE 10th International Symposium on Biomedical Imaging (ISBI)*, IEEE, 141-144, 2013.
- 15) Thorisson A, et al.: Diagnostic accuracy of acute diverticulitis with unenhanced low-dose CT. *BJS Open*, 4(4), 659-665, 2020.
- 16) Thornton E, et al.: Patterns of Fat Stranding. *Am J Roentgenology*, 197, 1-14, 2011.
- 17) Lin HA, et al.: Periappendiceal fat-stranding models for discriminating between complicated and uncomplicated acute appendicitis: a diagnostic and validation study. *World J Emerg Surg*, 16(1), 52, 2021.
- 18) Thoeni RF, et al.: CT imaging of colitis. *Radiology*, 240(3), 623-38, 2006.
- 19) Deery SE, et al.: Management of Diverticulitis in 2017. *J Gastrointest Surg*, 21(10), 1732-1741, 2017.
- 20) Warner E, et al.: Fourteen-year study of hospital admissions for diverticular disease in Ontario. *Can J Gastroenterol*, 21, 97-99, 2007.
- 21) Etzioni DA, et al.: Diverticulitis in California from 1995 to 2006: increased rates of treatment for younger patients. *Am Surg*, 75, 981-985, 2009.
- 22) Strate LL, et al.: Epidemiology, Pathophysiology, and Treatment of Diverticulitis. *Gastroenterology*, 156(5), 1282-1298, 2019.
- 23) Otsu N: A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66, 1979.
- 24) Boser BE, et al.: A training algorithm for optimal margin classifiers. *Proceedings of the fifth annual workshop on Computational learning theory*, 144-152, 1992.
- 25) Melaku BH, et al.: Detection and classification of gastrointestinal disease using convolutional neural network and SVM. *Cogent Engineering*, 9(1), 2084878, 2022.
- 26) Paoletti ME, et al.: A new GPU implementation of support vector machines for fast hyperspectral image classification. *Remote Sensing*, 12(8), 1257, 2020.
- 27) Belgiu M, et al.: Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, 114, 24-31, 2016.
- 28) Noriega L: Multilayer perceptron tutorial. *School of Computing. Staffordshire University*, 4.5, 444, 2005.
- 29) Song X, et al.: Relative CT number of periappendiceal fat stranding may be an applicable index for estimating the severity of acute appendicitis. *Br J Radiol*, 94(1120), 20200437, 2021.
- 30) Mehta P, et al.: A case report of mesenteric panniculitis. *Cureus*, 12(1), 2020.
- 31) Das JP, et al.: Imaging findings of immune checkpoint inhibitor associated pancreatitis. *European journal of radiology*, 131(109250), 2020.
- 32) Bai X, et al.: Rim Enhancement and Peripancreatic Fat Stranding in Preoperative MDCT as Predictors for Occult Metastasis in PDAC Patients. *Acad Radiol*, S1076-6332(23)00119-8, 4 Apr, 2023.
- 33) Chung JW, et al.: Prognostic impact of perirenal fat stranding on oncologic outcomes in ureteral urothelial carcinoma. *Investig Clin Urol*, 62(1), 23-31, 2021.
- 34) Damgaci L, et al.: Diagnostic value of MDCT in determining the perinephric fat tissue and renal sinus invasion in patients with clear cell renal cell carcinoma. *Niger J Clin Pract*, 24(4), 489-495, 2021.
- 35) Horsthuis K, et al.: Detection of inflammatory bowel disease: diagnostic performance of cross-sectional imaging modalities. *Abdom Imaging*, 33(4), 407-416, 2008.