

リアルタイム大腸内視鏡画像診断支援システムのための CNN特徴とSVM分類を用いた識別手法

岡本 拓巳^{1,a)} 小出 哲士¹ 玉木 徹² Bisser Raytchev² 金田 和文² 吉田 成人³
三重野 寛³ 田中 信治⁴

概要: 本稿では大腸 Narrow Band Imaging (NBI) 拡大内視鏡がん診断支援実現のため、Convolutional Neural Network (CNN) の処理結果を特徴量と見做し、Support Vector Machine (SVM) による病理タイプ識別を行う手法を提案する。提案手法は研究グループで提案している Bag-of-Features (BoF) に基づく診断支援の特徴量抽出処理を、学習済み CNN の結果を用いることで実現する。これにより、一般物体認識のために抽出された局所特徴量が、SVM による病理タイプ分類に有効な特徴量として利用できることが期待できる。提案手法の組み込みシステム化を考慮して識別精度の検証を行い、その結果非腫瘍・腫瘍の識別において医療現場からの要求性能である 90% 以上の識別精度を確認した。

Classification Method for Real-Time NBI Colorectal Endoscopic Images with CNN features and SVM

TAKUMI OKAMOTO^{1,a)} TETSUSHI KOIDE¹ TORU TAMAKI² BISSER RAYTCHEV² KAZUFUMI KANEDA²
SHIGETO YOSHIDA³ HIROSHI MIENO³ SHINJI TANAKA⁴

Abstract: This paper introduce a classification method for real-time Narrow-Band Imaging (NBI) colorectal endoscopic images with Convolutional Neural Network (CNN) and Support Vector Machine (SVM) as a Computer-Aided Diagnosis (CAD) system. The proposed method using the result of pre-learned CNN as a feature extraction module on BoF framework and SVM inputs the result for classification. We estimated identification accuracy compare with the BoF framework and the proposed method. As an estimation result, we achieved that the proposed method can identify cancer or not with about 90% accuracy.

1. はじめに

近年、国内外において大腸ガンの罹患数は年々増加傾向にある。しかし、大腸ガンは早期ステージで発見、治療ができれば完治はほぼ可能である。そのための大腸内視鏡検

査方法として、NBI(Narrow Band Imaging) システムを用いた大腸拡大内視鏡による画像検査が行われている。大腸 NBI 拡大内視鏡診断では、医師が大腸内壁の血管等の微細模様構造から腫瘍の有無やガン深達度を診断する。この診断を行う医師には専門知識と経験が必要となり、診断できる医師に限られる。

そこで、コンピュータ画像解析を用いた症状の客観的な判断による診断の正確度向上や、定量的な指標提示による若手医師に対する教育支援を目指したコンピュータ診断支援 (Computer-Aided Diagnosis: CAD) システムが必要とされている。我々研究グループでは、佐野分類 [1], [2], 広島分類 [3], 昭和分類 [4], 慈恵分類 [5] といった日本国内で提唱されている NBI 拡大観察所見分類をコンセンサスを

¹ 広島大学 ナノデバイス・バイオ融合科学研究所
Research Institute for Nanodevice and Bio Systems, Hiroshima University

² 広島大学 工学研究院
Graduate School of Engineering, Hiroshima University

³ JR 広島病院 消化器内科
Department of Gastroenterology Hiroshima General Hospital of West Japan Railway Company

⁴ 広島大学大学院 医歯薬保健学研究科 内視鏡医学
Department of Endoscopy and Medicine Graduate School of Biomedical and Health Science, Hiroshima University

a) koide-lab-info@ml.hiroshima-u.ac.jp

経て統合された, JNET 分類 [6] に基づき, 大腸内視鏡画像を図 1 に示す 4 タイプのうち, 3 つの病理タイプ (Type 1, Type 2A, Type 3) に分類する大腸 NBI 拡大内視鏡画像診断支援システムの実現を目指している。

	Type 1	Type 2A	Type 2B	Type 3
Vessel pattern	● 認識不可	● 口径整 ● 均一な分布 (網目・らせん状)	● 口径不同 ● 不均一な分布	● 疎血管野領域 ● 太い血管の途絶
Surface pattern	● 規則的な黒色 または白色点 ● 周囲の正常粘膜 と類似	● 整(管状・樹枝状・ 乳頭状)	● 不整または不明瞭	● 無構造領域
Endoscopic image				

図 1 JNET 分類 [6].

診断支援システムに求められる医療現場からの要求性能として, (I) 高速性と即応性 (スループット 1~5 fps かつ, レイテンシ 1 秒以内), (II) 高い識別精度 (腫瘍部位か, あるいは非腫瘍部位であるかの診断結果が, 医師による診断結果と 90%以上一致すること) が求められている. これまでに我々研究グループはソフトウェア実装による診断支援システムを開発しており, 大腸 NBI 拡大内視鏡画像中央の 120×120 pixel 領域に対し処理速度 14.7 fps を達成し, 正診率約 97%を達成している [7]. また, システムの主要処理部に関して FPGA への実装に向けたハードウェアアルゴリズムの提案, 実装評価を行いリアルタイム処理が可能であることを示している [8], [9], [10].

以下, 2 節にてこれまで研究グループで提案されている, Bag-of-Features (BoF) に基づいた診断支援システムの概要について説明する. 3 節にて Convolutional Neural Network (CNN) の計算結果を特徴量として利用した Support Vector Machine (SVM) による大腸 NBI 拡大内視鏡画像がん診断支援を提案する. 4 節で提案手法の識別精度検証について述べ, 5 節で結論を述べる.

2. Bag-of-Features に基づく 内視鏡画像診断支援システム

本節では, これまでに研究グループで提案されてきた, Bag-of-Features (BoF) に基づいた大腸 NBI 拡大内視鏡画像診断支援システムについて述べる.

システムの概要を図 2 に示す. オフラインで行う学習, 学習結果を基にオンラインで実行する識別の 2 つのフェーズが存在する. システムは (1) 特徴抽出部, (2) 特徴変換部, (3) タイプ識別部の 3 つのモジュールに大きく分けることができる. システムは Bag-of-Features (BoF) と呼ばれる手法に基づいて識別を行っている. BoF とは文書検索を画像に応用した手法で, 画像の局所特徴量によって得られる特徴量ベクトルを 1 つの単語と見做し, その出現頻度

によって識別を行う.

学習フェーズでは, 学習用に準備した画像と, 画像に対応したラベル (病理タイプの情報) を用いて学習を行う. 画像から特徴量を抽出し, 各タイプ 256 (= 2^8) 個のクラスタにクラスタリングを行い, 各クラスタの中心を Visual-Word (VW) として保存しておく. そして, 学習用画像から抽出した特徴量から VW の出現頻度である VW ヒストグラムを作成する. 作成した VW ヒストグラムをタイプ識別部の Support Vector Machine へと入力し, 識別フェーズで必要な Support Vector (SV) を決定する.

識別フェーズでは入力された内視鏡映像のフレームから特徴量を抽出し, 得られた特徴量群を VW と照合して出現頻度によるヒストグラムを作成し, ヒストグラムデータに対してタイプ識別を行い, 結果を表示する.

研究グループによりシステムアルゴリズムの有用性に関する評価を行った結果, 腫瘍・非腫瘍の識別に有用性が確認できている [11]. 図 3 にその評価結果を示す. SVM の学習に Type 1 (非腫瘍) の画像 504 枚, Type 2A と 3 (腫瘍) の画像 1743 枚を使用し, 病理組織診断が得られた 118 症例の内視鏡観察時の画像をテストとして用いた. 識別結果は SVM の出力値 (SVM output value) によって得られ, 現在のシステムカットオフ値である 0.5 を境に腫瘍・非腫瘍の識別が可能であることが確認できている.




図 2 BoF に基づく大腸 NBI 拡大内視鏡画像がん診断支援システム.

2.1 Support Vector Machine (SVM)

Support Vector Machine (SVM) は, 教師あり学習により 2 クラス分類アルゴリズムの一つである. SVM は学習を行うことで, 識別空間において正と負の 2 タイプの距離 (マージン) が最大となるような識別超平面を決定する. その後新たに入力されるデータが識別超平面を境界として正と負のどちら側に位置するのかを識別関数を計算することにより判断する. 特徴として, 入力空間を高次元特徴空間に写像することにより線形分離不可能な問題にも適用可能であることが挙げられる (カーネルトリック). 本稿にお




図 3 SVM を用いた大腸腫瘍・非腫瘍の識別有用性評価 [11].

いて用いる SVM の識別関数を，式 (1) に示す．式 (1) は入力データである 1000 次元の CNN の出力値が Type 1 か $\bar{1}$ かを判断する際の例である．

$$f_{1:\bar{1}}(\vec{x}) = \sum_{i=1}^{N_1+N_{\bar{1}}} \text{coef}_i \times (s\vec{v}_i \cdot \vec{x}) + \rho_{1:\bar{1}} \quad (1)$$

ここで, $s\vec{v}_i$ は学習時に決定されるサポートベクトル (Support Vector (SV)) であり, 識別超平面を構成する. BoF に基づくアプローチでは, $s\vec{v}_i$ および $\vec{x}$ は 512 次元の Visual Word ヒストグラムデータである.

また, $coef_i$ は各 sv の係数を, $\rho_{1:\bar{1}}$ は識別器の係数を示しており, これらも学習時に決定される. N_1 , $N_{\bar{1}}$ はそれぞれクラス 1, クラス $\bar{1}$ の SV の数を示す.

SVMのためのライブラリとして、複数のカーネル関数やマルチクラス識別に対応した LIBSVM ライブラリ [12], 線形カーネルの識別のみに対応し処理高速化を図った LIBLINEAR ライブラリ [13] が公開されており、本稿ではこの両者のライブラリを用いて識別精度検証を行う。

3. CNN 特徴を適用した SVM 分類手法

本節では、これまで研究グループで提案してきた BoF に基づいた分類手法において、内視鏡画像を Convolutional Neural Network (CNN) に入力した時の処理結果を特徴量として利用し、SVM への入力データとして診断支援を行うことを提案する。

図4に BoF に基づく大腸がん診断支援システムと、CNN 特徴を適用した SVM 分類手法の概念図を示す。

図 8 に本稿で用いる CNN である, AlexNet のネットワーク構成概要図を示す [14]. 本稿で特徴抽出器として用いる AlexNet は, 一般物体認識コンテストの Large Scale Visual Recognition Challenge 2012(ILSVRC2012) で提供された ImageNet のデータセット 1000 カテゴリーを出力と




図 4 大腸がん診断支援システム 2 手法の概念図.
(AlexNet のネットワーク図は文献 [14] から引用)

するモデルを Cadence 社により組み込みシステム向けに処理を最適化したものを用いる [15]. AlexNet は画像サイズ 227×227 pixel を入力とし，畳込み演算による局所特徴量や Pooling による局所領域の値を用いた特徴マップの低解像度化を繰り返し実行し，最終結果として一般物体認識対象の 1000 ラベルの確率を出力する。

例として、Type 1, 2A, 3 の画像を AlexNet へ入力した時に出力される上位 5 つのカテゴリとその確率値を図 5, 図 6, 図 7 に示す. リファレンスモデルの AlexNet では内視鏡画像を識別する学習は行っていないため、絆創膏や三葉虫といった学習したカテゴリの中で近いと判断されるものを確率として高く出力している. 提案手法はこれらを内視鏡画像を入力した際に得られた 1000 次元の特徴量ベクトル値として利用し、SVM への入力データとする.

図9, 図10, 図11に図5～図7に示した Type 1, 2A, 3の典型的な特徴が見られる画像を入力した際の Visual Word ヒストグラムと AlexNet の出力値を示す。SVM において、これらのデータを元に線形分離を行うための識別超平面を構成するための学習を行う。VW ヒストグラム, AlexNet の出力値ともに各タイプで異なる特徴量が得られており、分離できる可能性があることが確認できる。次節にて、シミュレーションによる提案手法の識別精度検証を行う。

4. 提案手法による診断支援の精度シミュレーション

本節では、第3節で提案した特徴量抽出処理に CNN の処理結果を用いた SVM 分類手法について、その識別精度をシミュレーションにより検証する。

シミュレーション環境としては, Ubuntu 16.04 上で構築したオープンソースディープラーニングライブラリである, Caffe フレームワーク [16] を用いた. 用いる CNN としては AlexNet, SVM として LIBSVM を用いた場合と,



図 5 Type 1 の画像を入力した際の AlexNet の上位 5 カテゴリ.




図 6 Type 2A の画像を入力した際の AlexNet の上位 5 カテゴリ.



図 7 Type 3 の画像を入力した際の AlexNet の上位 5 カテゴリ.




図 8 AlexNet のアーキテクチャ図 [14].

LIBLINEAR を用いた場合とを比較する. LIBLINEAR は線形カーネルのみに対応し処理高速化を図ったもので, 式 (2) に示すようにサポートベクトルの生成を不要とし, 各次元の重み係数 $coef$ を学習により決定する.

$$f_{1:1}(\vec{x}) = \sum_{i=1}^{dims.} coef_i \times x_i \quad (dims. = 1000) \quad (2)$$

4.1 学習およびテスト用画像データセット

本稿では, 広島大学病院にて専門医師により大腸内視鏡




図 9 図 5 の画像を入力した場合の Visual Word ヒストグラムと AlexNet の出力値一例.




図 10 図 6 の画像を入力した場合の Visual Word ヒストグラムと AlexNet の出力値一例.



図 11 図 7 の画像を入力した場合の Visual Word ヒストグラムと AlexNet の出力値の一例.

診断時に撮影収集された, NBI 拡大内視鏡画像から病理タイプの特徴が明確に確認できる領域を矩形にトリミングした 908 枚の画像を用いる. この 908 枚の画像を学習し, 右へ 90 度回転させたものを未学習のテスト用の画像として用いる.

Type 1, 2A, 3 それぞれの枚数内訳と, 各タイプの画像の例を図 12 に示す.




図 12 大腸 NBI 拡大内視鏡画像データセット (広島大学病院提供).

4.2 採用する SVM の違いによるリアルタイム処理実現に向けて考慮すべき事柄

提案手法の組込みシステム化への実現に際し、LIBSVM と LIBLINEAR に関してシステムに必要なメモリデータ量を考慮する必要がある。LIBSVM では上述したように複数のカーネル関数やマルチクラス識別に対応するため、2 クラス識別の場合でも学習結果としてサポートベクトルを得る。サポートベクトルは前節で述べた条件で学習した場合、サポートベクトル数は 362 であった。サポートベクトルあたりが持つ次元数は 1000 であるため、1 次元のデータを double 型 64 bit で確保する場合、 $362 \times 1000 \times 64 = 2.7$ MB 程度となる。一方で LIBLINEAR をシステムに採用した場合、Logistic 回帰を行って識別する場合を想定すると各次元に対する重み係数を 1000 個保持する必要がある、必要なメモリデータ量としては $1000 \times 64 = 7.8$ KB 程度と非常に小さなデータ量となる。本システムが識別対象とする 3 病理タイプの場合、Type 1 と Type 2A および 3 ($\bar{1}$ と表記する) を識別する識別器と、Type 2A と 3 を識別する識別器との識別結果を組み合わせる、2 段階判定方式を採用すれば LIBLINEAR による SVM2 つで 3 タイプ識別が実現可能となる。

4.3 検証方法

識別精度検証の方法として、識別の正確さを示す指標である True Positive, 識別の偏りを示す指標である Precision Rate を用いて比較を行う。True Positive は式 (3), Precision Rate は式 (4) のように示され、分類する対象毎に評価する。本稿において、Type 1 と $\bar{1}$ の分類、Type 2A と 3 の分類を行うため、図 13, 図 14 に示すように、テストとして入力した画像の正しい Type と、SVM が識別した Type とを評価し True Positive と Precision Rate を計算する。

$$True\ Positive(x|1, \bar{1}, 2A, 3) = \frac{N_{x:x}}{\sum_{y=1, \bar{1}, 2A, 3} N_{y:y}} \quad (3)$$

$$Precision\ Rate(x|1, \bar{1}, 2A, 3) = \frac{N_{x:x}}{\sum_{y=1, \bar{1}, 2A, 3} N_{y:y}} \quad (4)$$

Type 1 vs $\bar{1}$ ($T = 2A, 3$)		識別され Type		True Positive
入力画像 Type	1 (非腫瘍)	1 (非腫瘍)	$\bar{1}$ (腫瘍)	
		$N_{1:1}$	$N_{1:\bar{1}}$	TP(1)
	$\bar{1}$ (腫瘍)	$N_{\bar{1}:1}$	$N_{\bar{1}:\bar{1}}$	TP($\bar{1}$)
Precision Rate		PR(1)	PR($\bar{1}$)	

図 13 Type 1 と $\bar{1}$ 分類における True Positive (TP), Precision Rate (PR).

4.4 シミュレーション結果

シミュレーション結果として、True Positive, Precision

Type 2A vs 3		識別された Type		True Positive
入力画像 Type	2A	2A	3	
		$N_{2A:2A}$	$N_{2A:3}$	TP(2A)
	3	$N_{3:2A}$	$N_{3:3}$	TP(3)
Precision Rate		PR(2A)	PR(3)	

図 14 Type 2A と 3 分類における True Positive (TP), Precision Rate (PR).

Rate に関して、図 15 に Type 1 vs $\bar{1}$ 分類器に関して、学習した画像をそのまま入力した場合の結果を示す。図 16 に画像を右へ 90 度回転させた場合の結果を示す。

Type 1 vs $\bar{1}$ の識別性能に関して、LIBLINEAR の識別性能が Type 1 の Precision Rate である 89.3% を除く全てで 90% 以上を確認でき、LIBSVM の識別性能よりも高いことが確認できた。これより、医師からの要求性能である 90% 以上で医師との診断結果が一致することをほぼ満たすことが確認できた。しかしながら LIBSVM と LIBLINEAR の識別精度に差が発生していることに関して、原因の追求を含め引き続き検証を行う必要がある。リアルタイム診断支援システムの実現に向けて本稿で提案した手法をカスタマイズブル DSP コアへ実装、メモリアクセスや CNN および SVM で主要な処理となる積和演算に対する最適化に関する議論を文献 [17] にて述べる。

識別器 : Type 1 vs not 1 (not1 = 2A, 3)
テストデータ : 学習データをそのまま入力




図 15 Type 1 vs $\bar{1}$ 分類器, 学習データをそのまま入力した場合。

識別器 : Type 1 vs not 1 (not1 = 2A, 3)
テストデータ : 学習データを右へ 90 度回転させ入力




図 16 Type 1 vs $\bar{1}$ 分類器, 画像を右へ 90 度回転した場合。

5. 結論

本稿では、大腸 NBI 拡大内視鏡診断支援を実現するため、これまでに研究グループで提案してきた BoF に基づ

くフレームワークにおける、特徴量抽出を CNN の出力結果を適用し、SVM への入力データとして病理タイプの識別を行う、CNN 特徴と SVM 分類を適用した大腸 NBI 拡大内視鏡画像がん診断支援手法を提案した。識別精度検証結果として、非腫瘍と腫瘍を識別する識別器は医師からの要求性能を満たす 90% の識別性能を確認することができた。今後の課題としては、CNN の出力値だけでなく中間層データを特徴量として用いることを検討し、システムのさらなる改良を行うことが挙げられる。

謝辞

本研究の一部は、JSPS 特別研究員奨励費 (16J06130)、JSPS 科研費基盤研究 (B) 26280015、JSPS 科研費基盤研究 (B) 17H01714、並びに、生体医歯工学共同研究拠点の助成を受けたものです。

本研究における組込みシステム向けに最適化された AlexNet の提供およびシミュレーションが実行可能な開発環境の提供など、日本ケイデンス・デザイン・システムズ社に御協力頂きました。ここに感謝致します。

参考文献

- [1] H. Machida, Y. Sano, Y. Hamamoto, M. Muto, T. Kozu, H. Tajiri, and S. Yoshida, "Narrow-Band Imaging in the Diagnosis of Colorectal Mucosal Lesions: a pilot study," *Endoscopy*, vol.36(12): 1094-1098, 2004.
- [2] H. Ikematsu, T. Matsuda, F. Emura, Y. Saito, T. Uraoka, K.I. Fu, K. Kaneko, A. Ochiai, T. Fujimori, and Y. Sano, "Efficacy of Capillary Pattern type IIIA/IIIB by Magnifying Narrow Band Imaging for Estimating Depth of Invasion of Early Colorectal Neoplasms," *BioMed Central (BMC) Gastroenterology*, 2010.
- [3] H. Kanao, S. Tanaka, S. Oka, M. Hirata, S. Yoshida, and K. Chayama, "Narrow-Band Imaging Magnification Predicts The Histology and Invasion Depth of Colorectal Tumors," *Gastrointestinal Endoscopy*, vol.69, no.3, pp.631-636, mar 2009.
- [4] Y. Wada, S. ei Kudo, H. Kashida, N. Ikehara, H. Inoue, F. Yamamura, K. Ohtsuka, and S. Hamatani, "Diagnosis of Colorectal lesions with the Magnifying Narrow-Band Imaging System," *Gastrointestinal Endoscopy*, vol.70, 2009.
- [5] T. Nikami, S. Saito, H. Tajiri, and M. Ikegami, "The Evaluation of Histological Atypia and Depth of Invasion of Colorectal Lesions using Magnified Endoscopy with Narrow-Band Imaging," *Gastrointestinal Endoscopy*, vol.51, 2009.
- [6] Y. Sano *et al.*, "Narrow-Band Imaging (NBI) Magnifying Endoscopic Classification of Colorectal Tumors Proposed by the Japan NBI Expert Team," *Digestive Endoscopy*, vol.28, 2016.
- [7] T. Tamaki, J. Yoshimuta, M. Kawakami, B. Raytchev, K. Kaneda, S. Yoshida, Y. Takemura, K. Onji, R. Miyaki, and S. Tanaka, "Computer-Aided Colorectal Tumor Classification in NBI Endoscopy using Local Features," *Medical Image Analysis*, vol.17, no.1, pp.78-100, jan 2013.
- [8] T. Okamoto, T. Koide, A.T. Hoang, T. Shimizu, K. Sugi, T. Tamaki, T. Hirakawa, B. Raytchev, K. Kaneda, S. Yoshida, H. Mieno, and S. Tanaka, "An FPGA Implementation of SVM for Type Identification with Colorectal Endoscopic Images," *Proceedings of the 20th Workshop on Synthesis And System Integration of Mixed Information technologies (SASIMI 2016)*, pp.81-86, 2016.
- [9] T. Koide, T. Okamoto, T. Shimizu, K. Sugi, A.T. Hoang, T. Tamaki, B. Raytchev, K. Kaneda, S.Y. and Hiroshi Mieno, and S. Tanaka, "Compact and High-Speed Hardware Feature Extraction Accelerator for Dense Scale-Invariant Feature Transform," *Proceedings of the 31st International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC2016)*, pp.387-390, 2016.
- [10] T. Koide, T. Okamoto, K. Sugi, T. Shimizu, A.T. Hoang, T. Tamaki, B. Raytchev, K. Kaneda, S.Y. and Hiroshi Mieno, and S. Tanaka, "A Hardware Accelerator for Bag-of Features based Visual Word Transformation in Computer Aided Diagnosis for Colorectal Endoscopic Images," *Proceedings of the 31st International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC2016)*, pp.233-236, 2016.
- [11] Y. Kominami, S. Yoshida, S. Tanaka, Y. Sanomura, T. Hirakawa, B. Raytchev, T. Tamaki, T. Koide, K. Kaneda, and K. Chayama, "Computer-Aided Diagnosis of Colorectal Polyp Histology by using a Real-Time Image Recognition System and Narrow-Band Imaging Magnifying Colonoscopy," *Gastrointestinal Endoscopy*, 2016.
- [12] C.C. Chang and C.J. Lin, "LIBSVM: A library for support vector machines," *ACM Transactions on Intelligent Systems and Technology*, vol.2, pp.27:1-27:27, 2011.
- [13] R.E. Fan, K.W. Chang, C.J. Hsieh, X.R. Wang, and C.J. Lin, "LIBLINEAR: A Library for Large Linear Classification," *Journal of Machine Learning Research*, vol.9, pp.1871-1874, 2008.
- [14] A. Krizhevsky, I. Sutskever, and G.E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," in *Advances in Neural Information Processing Systems 25*, ed. F. Pereira, C.J.C. Burges, L. Bottou, and K.Q. Weinberger, pp.1097-1105, Curran Associates, Inc., 2012.
- [15] G. Efland, S. Parikh, H. Sanghavi, and A. Farooqui, "High Performance DSP for Vision, Imaging and Neural Networks," *IEEE Hot Chips 2016*, 2016.
- [16] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, and T. Darrell, "Caffe: Convolutional Architecture for Fast Feature Embedding," *arXiv preprint arXiv:1408.5093*, 2014.
- [17] 岡本 拓巳, 小出 哲士, 玉木 徹, Bisser Raytchev, 金田和文, 吉田 成人, 三重野 寛, 田中 信治, 戸石 浩司, 菅原 崇之, 辻 雅之, 小田川 真之, and 丹場 展雄, "CNN 特徴と SVM 分類を適用した大腸内視鏡画像がん診断支援システムのカスタマイザブル DSP コアへの実装," *DA シンポジウム 2017*, 2017.