

# 大腸がん診断支援のためのカスタマイズ可能なDSPによる 内視鏡動画リアルタイムCNN特徴抽出とSVM分類

岡本 拓巳<sup>1,a)</sup> 小出 哲士<sup>1</sup> 玉木 徹<sup>2</sup> Bisser Raytchev<sup>2</sup> 金田 和文<sup>2</sup> 吉田 成人<sup>3</sup> 三重野 寛<sup>3</sup>  
田中 信治<sup>4</sup> 菅原 崇之<sup>5</sup> 戸石 浩司<sup>5</sup> 辻 雅之<sup>5</sup> 小田川 真之<sup>5</sup> 丹場 展雄<sup>5</sup>

**概要:** 本稿は, Convolutional Neural Network (CNN) の処理結果を特徴量として使用し, Support Vector Machine (SVM) による病理タイプ分類を行う, 大腸 Narrow Band Imaging (NBI) 拡大内視鏡がん診断支援システムのリアルタイム処理実現を目的とする. CNN 特徴と SVM 分類を適用した診断支援システムをカスタマイズ可能な Digital Signal Processing (DSP) コアである, Cadence 社の Cadence Tensilica Vision P6 DSP コアに実装し評価を行った. さらに, 動画処理に向けたシステム処理速度改善のため, システム全体の処理サイクルプロファイリングによる改善の影響が大きい箇所の特定およびその改良により, 改良前と比較して処理サイクル数を 70%削減 (16.6 M サイクルから 4.8 M サイクル) でき, 200 MHz でシステムを動作させた場合に約 41 fps とシステムオーバーヘッドを加味してもリアルタイム処理が実現可能であることを示した.

## Implementation of Computer-Aided Diagnosis System for Colorectal Endoscopic Images with CNN features and SVM on Customizable DSP Core

TAKUMI OKAMOTO<sup>1,a)</sup> TETSUSHI KOIDE<sup>1</sup> TORU TAMAKI<sup>2</sup> BISSER RAYTCHEV<sup>2</sup> KAZUFUMI KANEDA<sup>2</sup>  
SHIGETO YOSHIDA<sup>3</sup> HIROSHI MIENO<sup>3</sup> SHINJI TANAKA<sup>4</sup> TAKAYUKI SUGAWARA<sup>5</sup> HIROSHI TOISHI<sup>5</sup>  
MASAYUKI TSUJI<sup>5</sup> MASAYUKI ODAGAWA<sup>5</sup> NOBUO TAMBA<sup>5</sup>

**Abstract:** This paper introduce an improvement of Computer-Aided Diagnosis (CAD) system for clorectal endoscopic images on a cumtamizable Digital Signal Processing (DSP) core, Cadence Tensilica Vision P6 DSP. We profiled the system processing cycles on Vision P6 DSP core that is using Convolutional Neural Network (CNN) as a feature extraction module for Support Vector Machine. As an estimation for processing cycles of whole the system, we traced bottlenecks of the system. By modifying the bottlenecks, we achieved that the processing cycles reduced from 16.6 M cycles to 4.8 M cycles (about 70 % cycles reduction).

### 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.

<sup>1</sup> 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

<sup>2</sup> 広島大学 工学研究院  
Graduate School of Engineering, Hiroshima University

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

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

<sup>5</sup> 日本ケイデンス・デザイン・システムズ社  
Cadence Design Systems, Japan

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

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) システム開発が求められている。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経て統合された (Japan NBI Expert Team: 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。

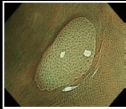
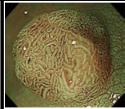
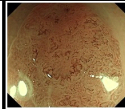
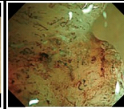
	Type 1	Type 2A	Type 2B	Type 3
Vessel pattern	● 認識不可	● 口径整 ● 均一な分布 (網目・らせん状)	● 口径不同 ● 不均一な分布	● 疎血管野領域 ● 太い血管の途絶
Surface pattern	● 規則的な黒色 または白色点 ● 周囲の正常粘膜 と類似	● 整(管状・樹枝状・ 乳頭状)	● 不整または不明瞭	● 無構造領域
Endoscopic image				

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]。また、上述の診断支援システムでは Bag-of-Features (BoF) に基づいて、画像特徴量に Dense-Scale Invariant Feature Transform (D-SIFT) を用いている。これは、血管構造や腺構造といった内視鏡診断にて重要となる情報を、輝度勾配として抽出することを目的とした。また研究グループでは同様の BoF に基づいた、Convolutional Neural Network (CNN) を特徴量抽出部として、学習および識別部として Support Vector Machine (SVM) を用いる手法も提案している [11], [12]。CNN 特徴と SVM 分類を用いた識別手法では、高い識別性能が確認できる一方で、医療現場からの要求性能であるリアルタイム処理の実現のためにはシステム全体のさらなる改良が必要である。

本稿では、BoF フレームワークにおける特徴量抽出処理

として CNN を適用し SVM 識別を行う手法に関して、カスタマイズ可能な DSP コアに向けた最適化およびプロトタイプシステムを用いた実機環境上へ実装を行い、リアルタイム処理が実現可能であることを示す。

以下、2 節にて 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 CNN の計算結果またはその中間データの特徴量として利用し、SVM による学習および識別を行う識別手法について述べる。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。

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、その単語の出現頻度によって識別を行う。単語の出現頻度からその文書が何について記述されたものであるかが推定できることと同様に、画像全体から得られた特徴量ベクトルの出現頻度を用いて画像推定を行う。システムは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。

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<sup>8</sup>) 個のクラスターにクラスタリングを行い、各クラスターの中心を 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 [13]。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。

## 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 AlexNet から次元数  $dim_s$  である特徴量の計算結果が Type 1 か  $\bar{1}$  かを判断する際の例である。

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

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、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 [14] が公開されており、本稿ではこのライブラリを用いて識別精度検証を行う。

本稿において、システムの学習には表 1 に示した枚数の内視鏡画像を  $227 \times 227$ pixel にリサイズしたものをを用いた。専門の内視鏡医師により病変を鮮明に捉えた内視鏡画像の中央部を  $60 \times 60, 120 \times 120, 180 \times 180, 240 \times 240$  でトリミングしたものを作成した。これにより、病変に対して近寄った場合の画像や遠く離れた場合の画像として学習することで、様々な病変の捉え方に対応した有効な識別ができるといったことが期待できる。

表 1 学習画像データセット枚数内訳。

size	Type 1	Type 2A	Type 3	Total
60x60	504	847	422	1,773
120x120	485	806	421	1,712
180x180	379	616	358	1,353
240x240	239	423	237	899

## 2.2 CNN 特徴量を用いた診断支援システム

Convolutional Neural Network は LeCun らによって提案され、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の繰り返し

により実現され、一般物体認識の分野で高い認識性能を示していることで知られている [15]。本稿では、CNN の出力を入力画像の特徴量を表現していると解釈し、次節に述べる Support Vector Machine における入力データとしてこれを用いる。本稿にて利用する CNN は AlexNet を用いる。具体的には、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 カテゴリを出力とするモデルを 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 [16]。

図 2 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。

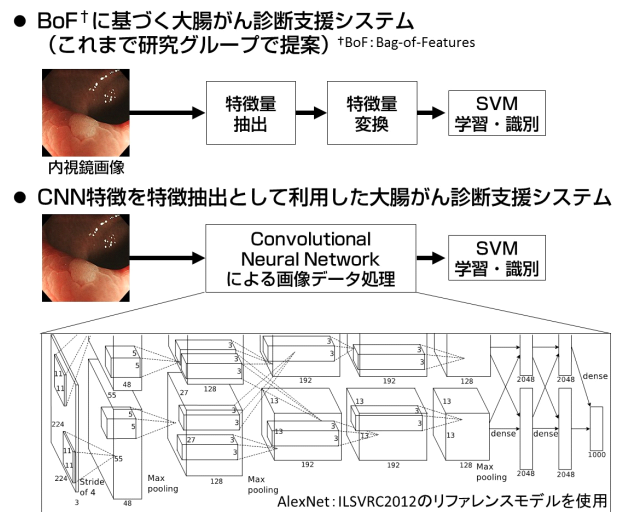


図 2 大腸がん診断支援システム 2 手法の概念図。  
(AlexNet のネットワーク図は文献 [17] から引用)

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 カテゴリを出力とするモデルを 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 [16]。図 3 に AlexNet の処理アーキテクチャと各処理及び特徴量次元数、そしてそれらを用いて SVM による学習、識別を行った識別結果を示す [18]。AlexNet は大きく分けて 8 層の中間層から構成され、画像サイズ  $227 \times 227$ 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。

大腸 NBI 拡大内視鏡画像がん診断支援システムの動作概観図を図 4 に示す。システムはホストコンピュータと、P6 コアが実装されたケイデンス・ラピッド・プロトタイプング・プラットフォーム Protium<sup>®</sup>\*1 S1[19] の 2 部から構成される。診断支援システムにおいて、CNN 部や SVM

\*1 Protium は Cadence Design Systems 社の登録商標です。

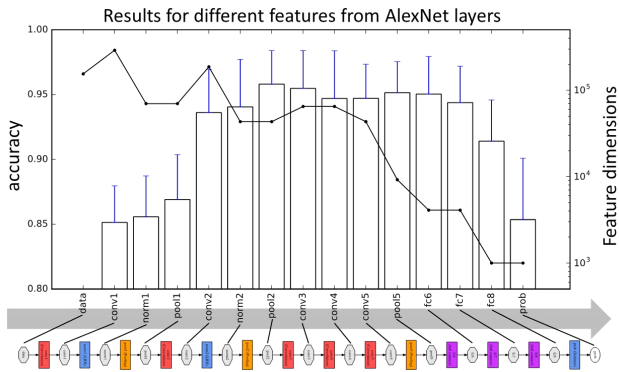


図 3 AlexNet の各中間層特徴を用いた場合の識別精度と次元数 [18].

部などの主となる処理は Cadence Design Systems 社から提供された、画像処理や CNN 処理に特化した命令セットや、設計者が搭載したい拡張命令が追加可能なカスタマイズ DSP コアである、Cadence Tensilica<sup>®</sup>\*2 Vision P6 DSP コア [20](以降、VP6 コア) で実行される。VP6 コアアーキテクチャと特徴を図 5 に示す。Protium S1 には Virtex Ultrascale XU440 が 1 基搭載されており、先述の VP6 コアを用いた処理部がダウンロードされ、ソフトウェア・ハードウェア協調によるホストコンピュータとシステム処理部を実機動作とほぼ同等環境でのシミュレーションおよび実機動作でのエミュレーションを行うことができる。

システムの動作フローチャートを図 7 に示す。システムが動作開始すると入力画像または動画からフレームデータとして画像を読み込む。次に CNN への入力データである 227 × 227 pixel の領域を識別領域として切り取る、あるいはそれ以外の大きさの領域を識別する場合にハリス処理を行った後、識別領域をホスト-DSP 間で共有しているメモリへ書き込む。その後、DSP 内で CNN および CNN の出力結果を入力とした SVM の識別処理が行われ、識別領域に対する処理結果を得る。その後処理結果を共有メモリへ書き込み、ホスト側が読み込み、最後に処理結果を入力画像と共に表示する。以上の処理を終了キーが押下されるまで繰り返し実行する。

ホスト-DSP 間のデータ通信は図 4 および図 6 に示すように iPass コネクタによる PCI Express で行われ、プラットフォーム内のデータ通信は AXI バスにより実現し、CNN 部の学習データである重み係数データ、SVM 部の学習データであるモデルファイルデータはこれを介して DataRAM や必要に応じて外部 Work RAM に転送される。

### 3. 処理サイクルプロファイリングによるシステムボトルネック特定

本節では、システムのサイクル数評価を行い、ボトルネックとなる処理を特定することで処理速度改善のための方針を決定する。サイクル数評価には、VP6 の統合開発環

\*2 Tensilica は Cadence Design Systems 社の登録商標です。

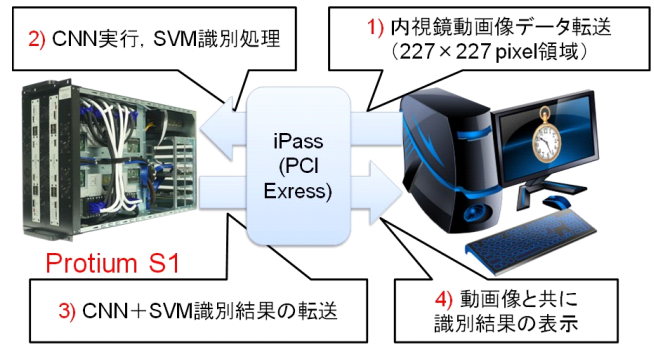


図 4 システムの動作概観.

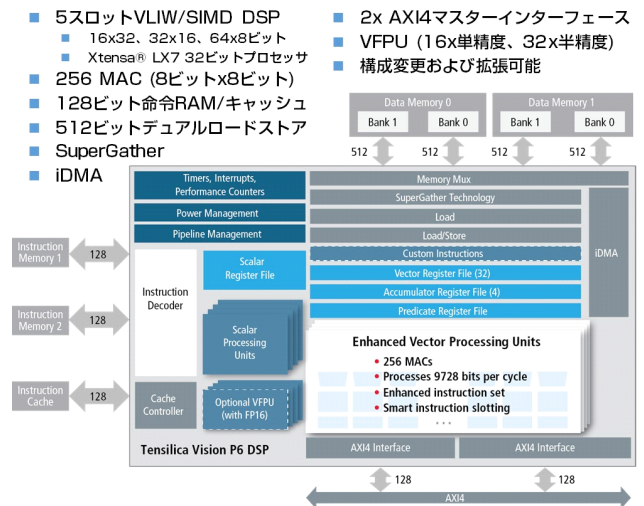


図 5 Cadence Tensilica Vision P6 DSP コア アーキテクチャ [20].

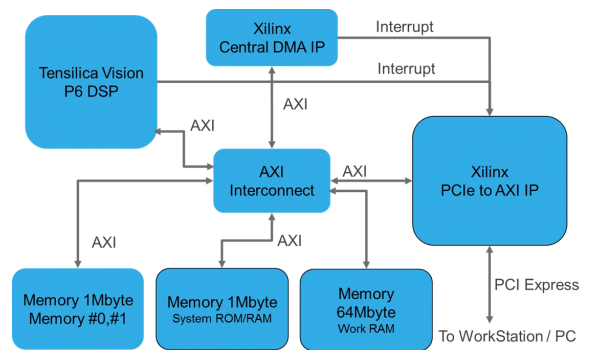


図 6 システムブロックダイアグラム.

境である、Xtensa Explorer の Profile 機能を用いる。

図 8 に画像 1 枚を処理する際のサイクルプロファイル結果を示す。画像 1 枚あたり処理サイクルの総数としては約 16.6 M サイクルである。

サイクル数の割合としては図内 *image\_preprocess* に示した、入力画像の前処理が大きな割合を占めていることが確認できる。この前処理部では、ホスト PC から転送された画像データを Red, Blue, Green の 3 色チャンネル成分へ分割しメモリ内の決められた場所へ格納する、入力画像の各チャンネルの平均色の計算を行う、といった処理が行われる。次に大きな割合を占めているのは、図内 *dma\_wait\_L7* に

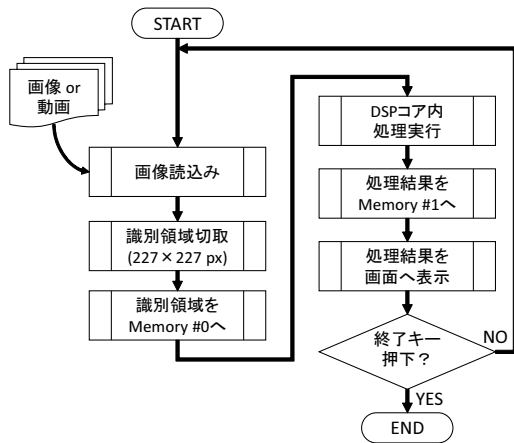


図 7 システム動作フローチャート.

示した、全結合層 (Full Connect layer) の FC1 を開始するための待ち時間であることが確認できた。さらなる解析を進めところ、これは前の処理終了を待っているのではなく学習済み AlexNet における FC1 の重み係数の読み込みおよび格納のための DMA 待ち時間であることがわかった。これは全結合層では前レイヤの全てのノードを入力とした演算が行われるため、全ての接続に対する重み係数が必要であることに起因している。

これらのプロファイル結果から入力画像の前処理部のコード最適化や、仮に全結合層以降を実行させずに、より前段レイヤでの中間データを用いた特徴量抽出を行うことができれば、図 8 の太枠で示したおよそ全体の 70% のサイクル数を削減することが可能である。




図 8 改良前のシステム全体処理サイクルプロファイル結果.

#### 4. 内視鏡動画リアルタイム診断支援に向けたシステムの処理最適化

前節のサイクル数プロファイル結果により、入力画像に対する前処理部や、全結合層の重み係数の読み込みが主なボトルネックとなっていることがわかった。これらの処理サイクル数削減を行うことでシステム処理速度向上を図る。まず入力画像の前処理に関しては、コード修正を行い VP6

が搭載する専用命令を用いることで改善を行う。VP6 コアではメモリアクセスの効率的な読込、格納が実現可能なベクトル命令が搭載されており、これらを適切に使用することでサイクル数削減を行う。2つ目の重み係数の読み込み待ち時間に関して、これは全結合層より前の中間データの特徴量として使用し、AlexNet の処理自体をそこで終了させることにより改善を図る。これら改良によるシステム識別精度の違いとしては、AlexNet の最終出力である 1000 ラベルの確率値の他にも中間データの特徴量として用いた場合でも同等以上の識別精度が確認できている [21] ことから、識別精度を保持したままシステム速度向上が可能である。システム最適化前後でのサイクル数比較を図 9 に示す。この結果より、3 で述べたおよそ 70% の処理サイクル数削減を実現することができ、200 MHz でシステムを動作させた場合で 41.6 fps と医師からの要求性能を満たせることが確認できた。図 10 にシステムの動作画面例を示す。

#### 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、特徴量抽出を CNN の中間データを利用し、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のリアルタイム処理実現に向けたシステム改善について報告した。システム全体のサイクルプロファイルを行い、処理のボトルネックを特定、改良を行うことで処理サイクル数を 16.6 M サイクルから 4.8 M サイクルへ削減し、改善前から約 70% の処理サイクル数削減が実現可能であることを確認し、動作周波数 200 MHz でシステムを実行した場合には 41.6 MHz とシステムオーバヘッドを加味しても医師からの要求性能を満たすリアルタイム処理が実現可能であることを示した。

#### 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。

#### 参考文献

- [1] H. Machida, Y. Sano, *et al.*, "Narrow-Band Imaging in the Diagnosis of Colorectal Mucosal Lesions : a pilot study.," *Endoscopy*, vol.36(12): 1094-1098, 2004.
- [2] H. Ikematsu *et al.*, "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 *et al.*, "Narrow-Band Imaging Magnification Predicts The Histology and Invasion Depth of Colorectal Tumors," *Gastrointestinal Endoscopy*, vol.69, no.3,




図 9 システム改良前後の処理サイクル比較.

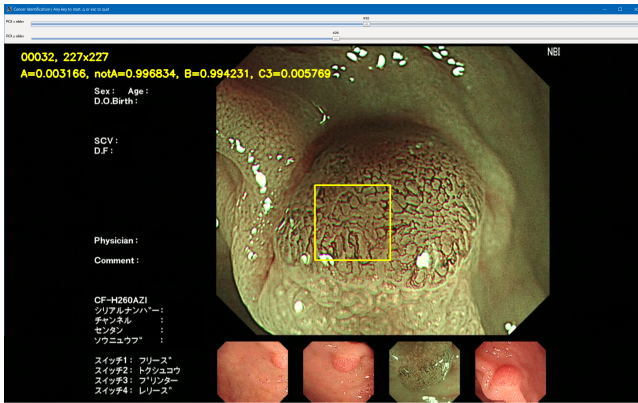


図 10 デモシステム出力画面例.

pp.631–636, mar 2009.

[4] Y. Wada *et al.*, “Diagnosis of Colorectal lesions with the Magnifying Narrow-Band Imaging System,” *Gastrointestinal Endoscopy*, vol.70, 2009.

[5] T. Nikami *et al.*, “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 *et al.*, “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 Com-*

munications (ITC-CSCC2016), pp.233–236, 2016.

[11] M. Tsuji, M. Odagawa, H. Toishi, T. Sugawara, N. Tamba, T. Okamoto, T. Koide, T. Tamaki, B. Raytchev, K. Kaneda, S. Yoshida, H. Mieno, and S. Tanaka, “Real-time Processing of Computer-Aided Diagnosis System for Colorectal Tumor Classification in NBI Endoscopy Using CNN Features by Implementing to Tensilica Vision P6 DSP,” *Proceedings of the 2nd International Symposium on Biomedical Engineering*, pp.24–25, 2017.

[12] M. Odagawa, M. Tsuji, H. Toishi, T. Sugawara, N. Tamba, T. Okamoto, T. Koide, T. Tamaki, B. Raytchev, K. Kaneda, S. Yoshida, H. Mieno, and S. Tanaka, “Tensilica DSP Cores for Neural Networks and an Application to Computer-Aided Diagnosis System for Colorectal Tumor Classification,” *Proceedings of the International Workshop on Nanodevice Technologies 2018*, pp.6–7, 2018.

[13] 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.

[14] 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.

[15] Y. LeCun, B. Boser, J.S. Denker, D. Henderson, R.E. Howard, W. Hubbard, and L.D. Jackel, “Backpropagation Applied to Handwritten Zip Code Recognition,” *Neural Computation*, vol.1, no.4, pp.541–551, Dec. 1989.

[16] G. Efland, S. Parikh, H. Sanghavi, and A. Farooqui, “High Performance DSP for Vision, Imaging and Neural Networks,” *IEEE Hot Chips 2016*, 2016.

[17] 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.

[18] T. Tamaki *et al.*, “Computer-Aided Colorectal Tumor Classification in NBI Endoscopy Using CNN Features,” *FCV2016*, 2016.

[19] I. Cadence Design Systems, “Protium S1 FPGA-Based Prototyping Platform.” <http://www.cadence.com/news/protium>.

[20] I. Cadence Design Systems, “Vision DSPs for Imaging and Neural Networks.” <https://ip.cadence.com/vision>.

[21] 岡本拓巳, 小出哲士, 玉木徹, B. Raytchev, 金田和文, 吉田成人, 三重野寛, and 田中信治, “CNN 特徴と SVM 分類を用いた大腸 NBI 拡大内視鏡診断支援システムの最適化,” *デザインガイア 2017*, 2017.