

# 眼底画像における複数の特徴量の 組み合わせによる血管抽出法の検討

田島 幹也<sup>†</sup>

<sup>†</sup> 滋賀県立大学大学院工学研究科電子システム工学専攻博士前期課程

## 1 緒言

近年、国民の健康への関心が高まり、特定健康診査(特定健診)や人間ドックなどの集団検診を受診する人の数は増加傾向にある [1, 2]。特定健診とは、メタボリックシンドローム(内臓脂肪症候群)に着目した糖尿病や高血圧症などの生活習慣病予防のための検診で、40歳以上74歳以下の公的医療保険加入者を対象として、2008年4月より厚生労働省により実施されている。人間ドックは、身体の精密検査を受けることによって、健康の維持と異常の早期発見を目的とする健康診断の一種である。

特定健診では、前年度の検診などの結果から、医師が必要と判断した場合に眼底検査が行われている。また、ほとんどの人間ドックにおいて、眼底検査は基本検査項目であるため、眼底検査の実施数は増加していると考えられる。特定健診や人間ドックなどの集団検診における眼底検査では、検査時間やコストの観点から、検眼鏡を用いた検査や造影剤を用いた眼底撮影ではなく、非造影の眼底撮影による眼底画像を用いた画像診断が一般的に行われている。眼底画像は、瞳孔から眼球の中に光を入射し、眼底を撮影したもので、黄斑、視神経乳頭、血管が眼底画像に映る。また、眼底は、人間の体内で血管を直視できる唯一の領域であり、その血管の状態から全身、特に脳血管の状態を推定することができる。眼底画像を読影することによって、白内障や緑内障、糖尿病網膜症、動脈硬化症、高血圧症などの診断ができる。しかし、眼底画像を読影する熟練した医師の数は十分であるとはいえず、特定健診や人間ドックなどの集団検診の受診者の増加により、さらに医師への負担は大きくなると予想される。また、眼底画像の読影による診断は、医師間での判定の相違が生じたり、同一の医師の判定であっても読影のたびに診断結果が異なる可能性がある。そのため、眼底画像を定量的に解析することで、眼科医の診断の支援を行うコンピュータ支援診断(CAD:Computer-Aided Diagnosis)システムの開発が求められている。CADとは、眼底画像や放射線画像などの医用画像に対して、コンピュータにより定量的に解析された結果を第2の意見として、医師に提示することで、医師による診断を支援するものであり、医師の読影経験による診断結果の差異の減少や、画像読影に対する診断の正確度の向上や再現性の向上が期待される。

眼底画像のためのCADシステムとして、これまでに、高血圧性網膜症のためのCAD、糖尿病網膜症のためのCAD、緑内障のためのCADなどの研究報告がなされている [3]。緑内障のためのCADにおいて、緑内障の診断所見の一つである垂直方向の視神経乳頭とその陥凹の直径比を自動算出する手法が提案されていた。この手法では、エッジ情報と動的輪郭モデルを用いて視神経乳頭の輪郭を決定し [4]、その領域内の濃度勾配の変化を解析することによって、視神経乳頭陥凹の輪郭を決定していた [5]。しかし、臨床的には視神経乳頭上の血管の屈曲点を視神経乳頭陥凹の輪郭の一部と考えるため、この点を考慮した改善法が提案された [6]。この手法では、濃度勾配を用いたベクトル集中度によって抽出した血管から屈曲点を検出しているが、著者の検証実験の結果、血管の抽出精度が不十分である問題点から、血管の屈曲点の検出精度も低くなっていると考えられる。したがって、血管の抽出精度の改善によって、視神経乳頭陥凹の輪郭の検出精度を改善できると考えられることから、本研究の目的とした。

血管抽出法として、これまでに濃度勾配を用いたベクトル集中度を用いた手法 [6]，ブラックトップハット変換を用いた手法 [7]，2重リングフィルタを用いた手法 [8]，ブラックトップハット変換と2重リングフィルタを組み合わせた手法 [9]，RGB カラー眼底画像の緑色成分画像から濃淡値の隆線を検出する手法 [10]，ガボールウェーブレットを用いた手法 [11, 12]，マッチドフィルタを用いた手法 [13]，Hough 変換を用いた手法 [14]，Contourlet 変換を用いた手法 [15]，Curvelet 変換を用いた手法 [16]，アンサンブル学習に基づく抽出手法 [17]，モルフォロジーフィルタバンクを用いた手法 [18] などが開発されている。

本論文は、複数の先行研究での抽出手法を応用し、機械学習を用いて血管とそれ以外の領域に分類することによって、血管を抽出する手法について述べる。

## 2 手法

### 2.1 手法の概要

本研究では、眼底画像から p タイル法を用いて視神経乳頭の大凡の領域を検出し [7]，その領域の重心を中心として、図 1 のような、 $500 \times 500$  画素の領域で切り出した画像から、血管を抽出する。先行研究のブラックトップハット変換 (BTH)[7]，2重リングフィルタ (DRF)[8]，濃度勾配を用いたベクトル集中度 (VC)[6]，線集中度フィルタ (LCF)[19] および 2 次元ガボールフィルタ (GF)[20] の出力値と眼底画像の緑色成分 (G 成分) の画素値を血管抽出の特徴量として、機械学習で 1 画素ごとに血管領域とそれ以外の領域に分類する。なお、教師データには手書きで作成した血管画像を用いる。眼底画像の赤色 (R)，G，青色 (B) 成分の中で、G 成分が最も血管と血管以外の領域とのコントラストが高くなるため、血管抽出には眼底画像の G 成分が適しているため特徴量の作成には G 成分を用いた。

### 2.2 血管抽出のための特徴量の作成

#### 2.2.1 ブラックトップハット変換 [7]

BTH は、モルフォロジー演算の一種で、周囲と比較して画素値が小さい領域を抽出することができる。BTH は、モルフォロジー演算における Closing 処理をした画像と原画像の差分をとる処理である。Closing 処理は Dilation 処理を行った後、Erosion 処理を行う処理のことであり、Closing 処理した眼底画像の例を図 2(a) に示す。Dilation 処理は、注目画素を原点とする構造要素内の画素値の最大値を処理後の注目画素の画素値とし、Erosion 処理は、注目画素を原点とする

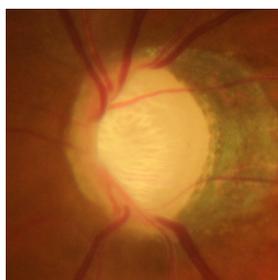
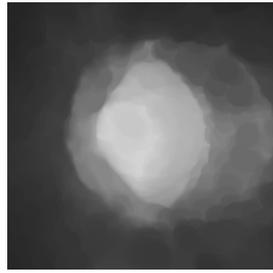
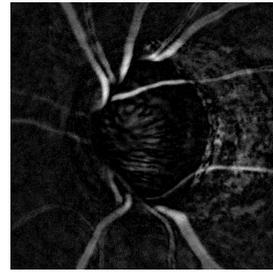


図 1: 視神経乳頭に注目した眼底画像



(a) Closing 処理後



(b) BTH の処理結果

図 2: 図 1 の眼底画像に対する BTH

構造要素内の画素値の最小値を処理後の注目画素の画素値とする処理である。Closing 処理を行うと、構造要素よりも小さく周囲よりも画素値が低い領域が周囲の高い画素値で埋められる。したがって、Closing 処理を行うと、図 2(a) のように周囲より画素値が低い血管領域が、周囲の高い画素値で埋められるので、Closing 処理をした画像と原画像の差分をとることで、血管領域が強調される。本研究では構造要素の形状は円とし、直径を 37 画素とした。BTH の出力値は、変換前の画素値を  $F(x, y)$ 、変換後の画素値を  $F'(x, y)$ 、画像の画素値の最大値を  $F_{\max}$ 、画像の画素値の最小値を  $F_{\min}$  とすると式 (1) で表される式により変換した。

$$F'(x, y) = \frac{(F(x, y) - F_{\min}) \times 255}{F_{\max} - F_{\min}} \quad (1)$$

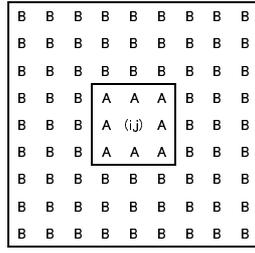
BTH を行った結果を図 2(b) に示す。BTH は画素値の局所分布が凹になる部分が強調される処理なので、図 2(b) のように、血管が強調されるが、色むらも強調されてしまう。

### 2.2.2 2重リングフィルタ [8]

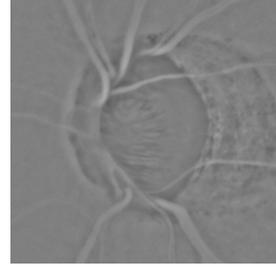
DRF は、図 3(a) に示すような内円領域と外円領域の 2 重リングの構造を持ち、注目画素を  $(i, j)$  としその周辺から内円領域を領域 A、外円を領域 B とする。DRF はこの内円領域と外円領域の平滑化差分を特徴量としており、周囲と比較して画素値が低い領域を強調するフィルタである。本研究での DRF の出力値  $D(i, j)$  は

$$D(i, j) = B_{\text{ave}} - A_{\text{ave}} + 128 \quad (2)$$

とした。ここで  $A_{\text{ave}}$  は領域 A の平均画素値、 $B_{\text{ave}}$  は領域 B の平均画素値であり、画素値が 255 以上になったとき 255、0 以下になったとき 0 とした。入力画像には眼底画像の G 成分を用いる。DRF の利点はラプラシアンなどのエッジ検出法に比べてノイズの影響を受けにくいことである。フィルタの外円の直径大きくするとコントラストの低い血管の抽出に失敗する傾向にあり、外円の直径を小さくするとノイズの影響を受けやすくなる問題がある。本研究での DRF の領域 A の直径を 3 画素、領域 B の直径を 41 画素とする。眼底画像の G 成分画像に対して、DRF で処理した結果を図 3(b) に示す。DRF は、コントラストの高い領域が強調される処理なので、図 3(b) のように血管が強調される。しかし、視神経乳頭の輪郭付近のように、濃度変化の大きい領域も強調されてしまう。



(a)DRF の構造



(b)DRF の処理結果

図 3: DRF による血管強調

### 2.2.3 濃度勾配を用いたベクトル集中度 [6]

VC には、眼底画像の G 成分の画素値を反転した画像を用いる。VC は、1 次微分フィルタである  $x$  方向、 $y$  方向の Sobel フィルタにより濃度勾配の方向および濃度勾配強度求め、ベクトル集中度を計算する。濃度勾配の強度成分は、眼底画像に  $x$  方向の Sobel フィルタを適用した結果を  $d_x$ 、 $y$  方向の Sobel フィルタを適用した結果を  $d_y$  としたとき、式 (3) から計算される。

$$d(s, t) = \sqrt{d_x(s, t)^2 + d_y(s, t)^2} \quad (3)$$

ベクトル集中度の計算は図 4(a) 中の構造要素 R に示す領域内において、式 (4) により求める。

$$c(i, j) = \sum_{x, y \in R} d(x, y) f(x, y) \quad (4)$$

ここで、 $c(i, j)$  は注目画素で  $d(x, y)$  は計算領域 R 内の点  $p(x, y)$  における濃度勾配の強度成分である。また  $f(x, y)$  は式 (5) で定義される。なお、実験的に  $n = 0.2$  とした。

$$f(x, y) = \cos[\theta(x, y) + n \cdot \sin\{2\theta(x, y) - \pi\}] \quad (5)$$

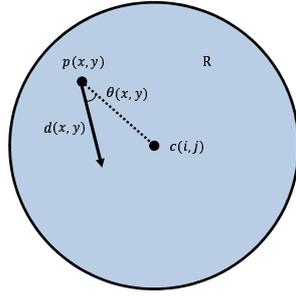
ここで、 $\theta(x, y)$  は点  $p(x, y)$  から構造要素の中心  $c(i, j)$  に向かう線分と、点  $p(x, y)$  における濃度勾配ベクトルとのなす角であり、式 (6) により計算される。

$$\theta(x, y) = \cos^{-1} \left\{ \frac{d_x(x, y)p_x(x, y) + d_y(x, y)p_y(x, y)}{\sqrt{d_x(x, y)^2 + d_y(x, y)^2} \sqrt{p_x(x, y)^2 + p_y(x, y)^2}} \right\} \quad (6)$$

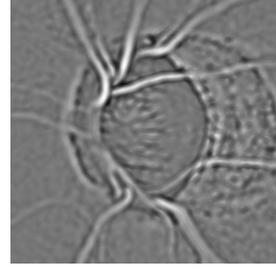
ただし、 $p_x(x, y)$  は点  $p(x, y)$  から  $c(i, j)$  に向かうベクトルの  $x$  成分であり、 $p_y(x, y)$  は  $y$  成分である。 $d(x, y)f(x, y)$  は濃度勾配が構造要素の中心方向に向き、かつその濃度勾配が大きいとき、大きい値をとる。本研究では、構造要素 R の形状を円として、半径を 9, 11, 13 画素の 3 種類を用い、式 (7) により最大値演算を行った。

$$C(i, j) = \max[c_9(i, j), c_{11}(i, j), c_{13}(i, j)] \quad (7)$$

図 4(b) に VC による結果を示す。血管領域付近では濃度勾配が強いため、図 4(b) のように血管が強調される。しかし、視神経乳頭の輪郭付近のように、濃度勾配が強い領域でも強調されてしまう。



(a)VC の計算のための構造要素



(b)VC の処理結果

図 4: VC による血管強調

#### 2.2.4 線集中度フィルタ [19]

LCF とは、対象として直線と考えた場合の集中度フィルタであり、VC とは異なり、濃度勾配の方向のみに注目する。線集中度の計算は、図 5(a) のように、注目点を通り方向  $\phi$  の直線を考え、これをベクトル集中線と仮定する。これと平行な探索線を考え、探索線に囲まれる両側に幅  $w_R$  または  $w_L$ 、長さ  $l$  の矩形領域を考える。この領域内の距離  $i$  の探索線上の  $j$  画素目の輝度勾配ベクトルとそこからベクトル集中線に対する垂線とのなす角度を  $\theta_{ij}(\phi)$  とすると、 $R$  側であれば、そこでの評価値  $c_R$  は以下のように定義される。

$$c_R(\phi) = \max_{0 < w_R \leq W_{\max}} \frac{1}{l \cdot w_R} \sum_{i=1}^{w_R} \sum_{j=0}^l \cos \theta_{ij}(\phi) \quad (8)$$

ここで  $W_{\max}$  は最大探索幅である。L 側の評価値  $c_L$  も同様に行う。仮定した方向  $\phi$  に対する注目点の線集中度は、 $c_R$  と  $c_L$  の平均値とする。本当のベクトル集中線の方法は不明であるから、 $[0, \pi]$  の範囲で方向を分割し、それぞれの方向ごとの集中度を求め、その中の最大値を注目点での LCF の出力とする。本研究では、実験的に  $l = 11$  画素、方向を 16 分割とした。また、 $W_{\max} = 9$  画素として、式 (8) で処理した場合よりも、 $w_R = 9$  画素、 $w_L = 9$  画素の場合のみで処理したときの方が、良い結果であったため、 $w_R = 9$  画素、 $w_L = 9$  画素で LCF の処理を行った。濃度勾配は Sobel フィルタを眼底画像の G 成分の画素値を反転した画像に適用し計算した。LCF で処理を行った結果を図 5(b) に示す。血管は線の構造をもっているため、LCF によって、図 5(b) のように強調される。しかし、視神経乳頭の輪郭付近など血管以外の領域でも多く強調されてしまっている。

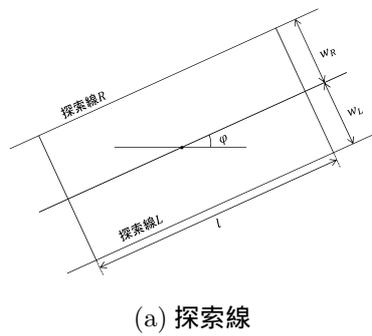
#### 2.2.5 2次元ガボールフィルタ [20]

GF は次式で定義される。

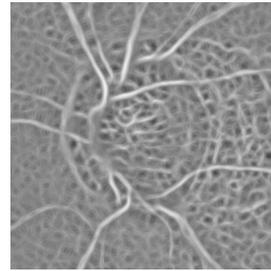
$$g(x, y) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda} + \phi\right) \quad (9)$$

ここで、 $x' = x \cos \theta + y \sin \theta$ 、 $y' = -x \sin \theta + y \cos \theta$  であり  $\lambda$ :波長、 $\theta$ :方向、 $\phi$ :位相、 $\sigma$ :標準偏差、 $\gamma$ :アスペクト比である。 $\sigma$  と  $\lambda$  は帯域幅  $b$  を用いると次式の関係がある。

$$\frac{\sigma}{\lambda} = \frac{1}{\pi} \sqrt{\frac{\ln(2)}{2}} \cdot \frac{2^b + 1}{2^b - 1} \quad (10)$$



(a) 探索線



(b) LCF の処理結果

図 5: LCF による血管強調

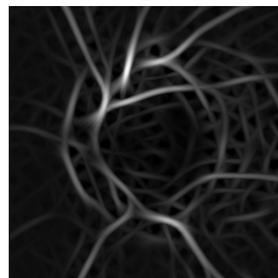


図 6: GF で処理した結果

本研究では  $b = 1$ ,  $\lambda = 30$ ,  $\phi = 0$ ,  $\gamma = 1$ , フィルタサイズを  $(6\sigma + 1) \times (6\sigma + 1)$  とし,  $\sigma$  は式 (10) から求めた. GF を  $\theta = 0$  から  $\frac{1}{12}\pi$  ずつ  $\theta = \frac{11}{12}\pi$  までの 12 方向作成し, この 12 方向の GF を眼底画像の G 成分画像に適用し, 最大値演算を行った結果を特徴量とする. GF をかけた結果を図 6 に示す. GF は特定の方向の線を強調するため, 12 方向で処理した結果の最大値をとることで, 図 6 のように血管が強調される. しかし, 視神経乳頭の輪郭付近などのエッジになっている部分が強調されてしまう.

### 2.3 特徴量を用いた機械学習

機械学習に入力するデータは 2.2 章で作成した, BTH, DRF, VC, LCF, および GF の出力値に加えて, G 成分の画素値である. これらの 1 画素ごとの各特徴量から構成される特徴ベクトルを入力する.

## 3 実験結果および考察

### 3.1 使用画像および正解画像

本研究では  $2144 \times 1424$  画素の眼底画像 10 枚を用いた. 本研究で用いる機械学習は, 教師あり学習なので, 血管とそれ以外領域を識別する教師データが必要であり, また, 抽出精度を確認するために血管領域の正解画像が必要であるから, 画像編集ソフトの GIMP 2.6.11 を用いてマウスで作成した.

### 3.2 機械学習の方法

10 枚の画像を画像 No.1 ~ No.5 と No.6 ~ No.10 の 2 グループに分け、学習と分類を交差で行った。機械学習に inputs する学習データは学習用データから Visual Mining Studio 8.1 のサンプリング機能により 1 枚の画像の血管領域から 20000 データ、血管領域外から 20000 データ分をランダムでサンプリングし、5 枚分の合計 200000 データを学習データとして作成し、すべての機械学習で同じものを用いる。

### 3.3 機械学習による血管抽出結果の比較

Visual Mining Studio 8.1 のニューラルネットワーク (Sigmoid-Binomial), RBF ネットワーク (Sigmoid-Binomial) および SVM (Linear カーネル) を用いて実験を行った。各機械学習のパラメータは実験的に求め、良い結果であったものを利用した。血管抽出精度の統計的な評価を行うため、ROC (Receiver Operating Characteristic) 解析による ROC 曲線の AUC (Area Under the Curve) で行う。ここで、評価の指標となる AUC とは ROC 解析で求めた、偽陽性率と真陽性率との関係を示す ROC 曲線の曲線下面積で、AUC が 1 に近づくほどその分類器が高い精度をもつことを示す。本研究では、統計解析ソフト R [21] のパッケージ ROCR [22] を用いて ROC 解析を行った。

特徴量作成に用いている手法は、血管のコントラストや太さによって、抽出精度が異なるので、画像ごとの精度を比較するためニューラルネットワーク、RBF ネットワーク、SVM による各画像の AUC を表 1 に示す。また、BTH, DRF, VC, LCF, GF および G 成分の各画像の AUC を表 2 に示す。表 3 に画像 10 枚のデータに対して、ROC 解析を行ったときの AUC を示す。

表 3 から、ニューラルネットワークを用いた場合の AUC が 0.9536 と最も高くなった。また、表 1 と表 2 は、ニューラルネットワークが画像ごとの AUC の標準偏差が最も小さいことを示している。したがって、ニューラルネットワークを用いた場合が最も精度が高く、画像間の精度のばらつきが小さいことから、安定した分類が行えている。機械学習を行うことによって、画像 No.1, No.2, No.3, のように、特徴量作成に用いた手法のみでは比較的 AUC が低い画像の AUC を機械学習を用いることで、向上することができている。特徴量の AUC が高い場合はあまり向上しない結果となった。先行研究の抽出手法などによる複数の特徴量を用いて、機械学習により血管抽出を行うことで、BTH や従来手法である VC よりも良好な結果が得られた。

表 1: 機械学習の出力値による各画像の AUC

画像 No.	ニューラルネットワーク	RBF ネットワーク	SVM
1	0.9356	0.9346	0.9308
2	0.9043	0.8934	0.8937
3	0.9548	0.9459	0.9532
4	0.9848	0.9807	0.9849
5	0.9672	0.9645	0.9648
6	0.9445	0.9384	0.9413
7	0.9648	0.9459	0.9566
8	0.9467	0.9414	0.9414
9	0.9750	0.9673	0.9710
10	0.9724	0.9602	0.9627
平均	0.9550	0.9472	0.9500
標準偏差	0.02348	0.02393	0.02535

表 2: 血管抽出の各特徴量の出力値で求めた AUC

画像 No.	BTH	DRF	VC	LCF	GF	G 成分
1	0.8984	0.8858	0.8911	0.8647	0.8860	0.6501
2	0.8615	0.8717	0.8886	0.8595	0.8362	0.5904
3	0.9190	0.8954	0.9125	0.8692	0.9107	0.6727
4	0.9739	0.9426	0.9462	0.9163	0.9641	0.7089
5	0.9416	0.9094	0.9289	0.8843	0.9324	0.6119
6	0.9316	0.8771	0.8919	0.8515	0.9117	0.5289
7	0.9401	0.8995	0.9162	0.8428	0.9282	0.7120
8	0.9356	0.8862	0.8828	0.8231	0.9011	0.6542
9	0.9633	0.9375	0.9455	0.9194	0.9323	0.6385
10	0.9588	0.9056	0.9244	0.8808	0.9262	0.5792
平均	0.9324	0.9011	0.9128	0.8712	0.9129	0.6347
標準偏差	0.03314	0.02374	0.02353	0.03041	0.03424	0.05805

表 3: ROC 解析における AUC

データ	AUC
ニューラルネットワーク	0.9536
RBF ネットワーク	0.9452
SVM	0.9497
BTH	0.9310
DRF	0.8499
VC	0.9123
LCF	0.8708
GF	0.9094
G 成分	0.6051

### 3.4 入力する特徴量を変えた場合の比較

各特徴量をそれぞれ一つずつ除いて、ニューラルネットワークで血管抽出を行った。また、CAD は計算時間が短い方が好ましいので、特徴量の計算時間を考慮して特徴量の組み合わせを考える。表 4 に示すスペックの PC での、各特徴量の計算時間を表 5 に示す。表 5 から、VC と LCF の計算時間が長いことから、この 2 つの特徴量を除いた特徴量の組み合わせで、同様にニューラルネットワークで実験を行った。入力する特徴量を変えた場合も同様に ROC 解析による AUC で抽出精度の評価を行った。ROC 解析により、得られた AUC を表 6 に示す。

表 6 から BTH, GF, G 成分の特徴量を用いた場合が最も AUC が高く、また、6 種類すべての特徴量を用いた場合よりもわずかに高い結果となった。1 枚ごとに ROC 解析を行った場合の AUC の標準偏差は 0.02108 となり、精度のばらつきも小さくなっていった。各特徴量をそれぞれ 1 つずつ除いた場合のすべてにおいて、特徴量を単体で用いた場合よりも AUC は上回っていることから、複数の手法による特徴量を用いて、機械学習で分類することにより抽出する手法は有効であると考えられる。使用する特徴量によって血管抽出結果は異なってくるので、今回とは異なる手法による特徴量の追加や組み合わせ、同じ手法においても異なるパラメータによって特徴量を作成することで、血管抽出の精度を向上させることができると考えられる。

表 4: 本研究で用いた PC のスペック

CPU	Intel Xeon E3-1225 V2 3.20GHz
Memory	16GB
コンパイラ	Visual C++ 2012
OS	Windows7 Professional 64bit

表 5: 1 枚あたりの各特徴量の計算時間

手法	計算時間 [秒]
BTH	13.3
DRF	0.5
VC	118.1
LCF	175.6
GF	10.3
G 成分	-

表 6: 入力する特徴量を変えた場合の AUC

入力した特徴量	AUC
DRF, VC, LCF, GF, G 成分	0.9374
BTH, VC, LCF, GF, G 成分	0.9538
BTH, DRF, LCF, GF, G 成分	0.9528
BTH, DRF, VC, GF, G 成分	0.9542
BTH, DRF, VC, LCF, G 成分	0.9421
BTH, DRF, VC, LCF, GF	0.9498
DRF, G 成分	0.8388
DRF, GF, G 成分	0.9258
BTH, DRF, GF, G 成分	0.9534
BTH, DRF, GF	0.9495
BTH, GF	0.9495
BTH, GF, G 成分	0.9546

## 4 結言

本研究では、視神経乳頭上および周縁の血管抽出精度を改善することを目的とし、先行研究の抽出手法などによる特徴量を用いて、機械学習により視神経乳頭上および周縁の血管抽出を行った。ブラックトップハット変換、2次元ガボールフィルタおよび眼底画像のG成分の3種類の特徴量を入力として、ニューラルネットワークで、眼底画像10枚に対して血管抽出を行った結果、ROC解析によるAUCは0.9546となり、従来手法で用いられているベクトル集中度の0.9123を上回ったことから、視神経乳頭上および周縁の血管抽出の精度を改善したと結論づける。さらなる抽出精度の向上のため、新たな特徴量の追加などの検討を行う必要がある。

## 謝辞

本研究を進めるにあたり、著者の所属研究分野、ならびに関係者の皆様に感謝の意を表します。

## 参考文献

- [1] 厚生労働省, “平成 24 年度特定健康診査・特定保健指導の実施状況について”, [http://www.mhlw.go.jp/bunya/shakaihoshho/iryouseido01/dl/info03\\_h24.00.pdf](http://www.mhlw.go.jp/bunya/shakaihoshho/iryouseido01/dl/info03_h24.00.pdf), [accessed October 29, 2015].
- [2] 株式会社矢野経済研究所, “健診・ドック市場に関する調査結果 2013”, <http://www.yano.co.jp/press/pdf/1222.pdf>, [accessed October 29, 2015].
- [3] 畑中裕司, “検診眼底画像研究の現在・未来,” 医用画像情報学会雑誌, Vol. 31, No. 2, pp. xxviii–xxxi, 2014.
- [4] C. Muramatsu, T. Nakagawa, A. Sawada, Y. Hatanaka, T. Hara, T. Yamamoto, and H. Fujita, “Automated segmentation of optic disc region on retinal fundus photographs: Comparison of contour modeling and pixel classification methods,” *Computer Methods and Programs in Biomedicine*, Vol. 101, No. 1, pp. 23–32, 2011.
- [5] Y. Hatanaka, A. Noudo, C. Muramatsu, A. Sawada, T. Hara, T. Yamamoto, and H. Fujita, “Automatic measurement of cup to disc ratio based on line profile analysis in retinal images,” *Proceedings of the 33rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 3387–3390, 2011.
- [6] Y. Hatanaka, Y. Nagahata, C. Muramatsu, S. Okumura, K. Ogohara, A. Sawada, K. Ishida, T. Yamamoto, and H. Fujita, “Improved automated optic cup segmentation based on detection of blood vessel bends in retinal fundus images,” *Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 26–129, 2014.
- [7] 中川俊明, 林佳典, 畑中裕司, 青山陽, 水草豊, 藤田明宏, 加古川正勝, 原武史, 藤田広志, 山本哲也, “眼底画像診断支援システムのための血管消去画像を用いた視神経乳頭の自動認識及び疑似立体視画像生成への応用,” *電子情報通信学会論文誌 D*, Vol. 89–D, No. 11, pp. 2491–2501, 2006.
- [8] Y. Hatanaka, T. Nakagawa, Y. Hayashi, A. Aoyama, X. Zhou, T. Hara, H. Fujita, Y. Mizukusa, A. Fujita, and M. Kakogawa, “Automated detection algorithm for arteriolar narrowing on fundus images,” *Proceedings of the 27th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 286–289, 2006.
- [9] 岩瀬達彦, 村松千左子, 畑中裕司, 周向栄, 原武史, 藤田広志, “眼底画像における細動脈狭窄評価のための主幹動静脈の自動検出および分類法,” *電子情報通信学会技術報告*, Vol. 109, No. 407, pp. 189–193, 2010.
- [10] J. J. Staal, M. D. Abramoff, M. Niemeijer, M. A. Viergever, and B. van Ginneken, “Ridge-based vessel segmentation in color images of the retina,” *IEEE Transactions on Medical Imaging*, Vol. 23, No. 4, pp. 501–504, 2004.
- [11] F. Oloumi, R. M. Rangayyan, P. Eshghzadeh-Zanjani, and F. J. Ayres, “Detection of blood vessels in fundus images of the retina using Gabor wavelets,” *Proceedings of the*

29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pp. 6451–6454, 2007.

- [12] J. V. B. Soares, J. J. G. Leandro, R. M. Cesar, H. F. Jelinek, and M. J. Cree, “Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification,” *IEEE Transactions on Medical Imaging*, Vol. 25, No. 9, pp. 1214–1222, 2006.
- [13] M. Himaga, D. Usher, and J. F. Boyce “Accurate retinal blood vessel segmentation by using multiresolution matched filtering and directional region growing,” *IEICE Transactions on Information and Systems* Vol. E87-D, No. 1, pp. 155-163, 2004.
- [14] F. Zana, and J. C. Klein, “A multimodal registration algorithm of eye fundus images using vessels detection and hough transform,” *IEEE Transactions on Medical Imaging*, Vol. 18, No. 5, pp. 419–428, 1999.
- [15] S. H. Rezatofghi, A. Roodaki, and H. Ahmadi Noubari, “An enhanced segmentation of blood vessels in retinal images using contourlet,” *Proceedings of the 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 3530–3533, 2008.
- [16] M. S. Miri, and A. Mahloojifar, “Retinal image analysis using curvelet transform and multistructure elements morphology by reconstruction,” *IEEE Transactions on Biomedical Engineering*, Vol. 58, No. 5, pp. 1183–1192, 2011.
- [17] 赤塚祐己, Elco Oost, 清水昭伸, 小畑秀文, 古川大介, 片山昭宏, “アンサンブル学習と分類器のカスケード化に基づく眼底画像からの血管抽出,” *電子情報通信学会技術報告*, Vol. 109, No. 407, pp. 143–148, 2010 .
- [18] A. Buyandalai, 内山良一, 畑中裕司, 村松千左子, 原武史, 藤田広志, “モルフォロジーフィルタバンクを用いた眼底画像における血管抽出,” *電子情報通信学会技術研究報告*, Vol.110, No.364, pp.105–108, 2011 .
- [19] 吉永幸靖, 小畑秀文, “集中度評価法とベクトル集中度フィルタ,” *Medical Imaging Technology*, Vol. 19, No. 3, pp. 154–160, 2001.
- [20] J. Kaur, and H. P. Sinha, “Automated detection of retinal blood vessels in diabetic retinopathy using Gabor filter,” *International Journal of Computer Science and Network Security*, Vol. 12, No. 4, pp. 109–115, 2012.
- [21] R Core Team, “R: A language and environment for statistical computing,” R Foundation for Statistical Computing, 2014.
- [22] T. Sing, O. Sander, N. Beerenwinkel, T. Lengauer, F. Lisacek, J. C. Sanchez, and M. Muller, “ROCR: visualizing classifier performance in R,” *Bioinformatics*, Vol. 21, No. 20, pp. 3940–3941, 2005.