

高次局所自己相関特徴を用いた 眼底画像における血管抽出

佐茂 和輝[†]

[†]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 はじめに

近年、国民の健康への関心は高まり、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]。人間ドックとは、スクリーニング目的での身体各部位の検査である。その検査の一つが、高血圧症、緑内障、糖尿病などを早期発見可能な眼底検査である。眼底検査は体への負担が少なく安全面に優れており、かつ容易に行うことができる。また、眼底の血管は、人体で唯一外部から直接視認できる血管であるため、人間ドックにおいて必須検査となっている。外来臨床目的の眼底検査は、検眼鏡を用いた直視検査であるが、特定健診や人間ドックなどの集団健診では医師が個別に直視検査することが困難である。そのため、眼底カメラを用いて記録した画像を事後に判定する検査が行われている。

眼底画像とは、眼球の正面から強い光を眼球に通すことによって網膜の表面を撮影した画像のことである。眼底検査では、眼底画像に写る網膜の状態から、血管の異常や網膜病変の探索が行われる。医師は経験に基づいて目視で眼底を判断することから、医師間での判定に相違が生じたり、同一医師の判定であっても診断するたびに結果が異なったりする可能性がある。そこで、定量的に画像診断を行うために医師の診断を支援するコンピュータ支援診断 (Computer Aided Diagnosis:CAD) システムの開発が求められている。CAD システムの目的は、コンピュータが自動検出した異常を「第二の意見」(コンピュータの意見) として定量的な情報を医師に提示することで、医師に注意を促すとともに、医師が客観的で再現性のある診断を行えるように支援することである。

眼底画像の CAD の要素技術の一つとして、眼底血管の抽出があげられる。血管抽出は、その精度が病変の自動検出精度にかかわる重要な処理であり、さまざまな手法が報告されている。その報告例としては、RGB カラー眼底画像の緑色成分 (G 成分) 画像から濃淡値の隆線を検出する手法 [2]、ガボールウェーブレットを用いた手法 [3, 4]、Hough 変換を用いた手法 [5]、Contourlet 変換を用いた手法 [6]、Curvelet 変換を用いた手法 [7]、アンサンブル学習に基づく抽出手法 [8]、Black-top-hat 変換 (BTH) を用いた手法 [9]、二重リングフィルタ (DR) を用いた手法 [10]、BTH と DR を組み合わせた手法 (BTH+DR)[11] などがあげられる。しかし、これらの手法を用いた血管抽出の精度が不十分な場合があり、現在でも血管の抽出に関する研究が続けられている。

従来の血管抽出法の多くは、画像のコントラストを用いた抽出法であり、著者の知る限りでは隣接する画素間の相関を用いる手法は報告されていない。一方で、高次局所自己相関 (Higher-order Local AutoCorrelation:HLAC) 特徴が、画像認識分野において高い性能を示していた。HLAC 特徴は、画像内での位置に関わらず不変な特徴量であり、対象のモデルを仮定する必要がない。そのため、構造パターンが多種多様で柔軟なモデルを作ることが難しい血管の認識に有効であると考えられる。そこで本研究では、HLAC 特徴を用いた血管の抽出法を検討した。

2 手法

2.1 全体の流れ

本手法では、眼底画像における眼底が写っている領域(眼底領域)の網膜動静脈を検出する。図1(a)に、本手法全体のフローチャートを示す。

まず、カラー眼底画像(原画像)を読み込み、血管のコントラストが最大となるG成分画像を作成する。次に、前処理として、BTHを用いて血管領域を強調した一次抽出画像を作成する。その後、一次抽出画像の一部を切り出してこれを関心領域とし、図1(b)のフローチャートのように関心領域画像からHLAC特徴と画素値に基づく特徴量を計算する。以上の処理で得られた特徴量を用いて、各関心領域画像に対してニューラルネットワークによる血管判別を行なう。この関心領域を眼底領域全体に対して走査する。

2.2 前処理

本手法では、血管抽出の前処理として、従来手法であるBTHを用いて血管を強調した。BTHは、モルフォロジーフィルタの一種であり、周囲と比較して暗い画素を強調するフィルタである。眼底画像において、血管は暗く写るため、血管が強調される。この処理の目的は、血管を強調することによってHLAC特徴による分類精度を向上させることである。

2.3 HLAC

HLACは、高次自己相関関数を応用したものである。自己相関関数とは、あるデータとそれ自身を一定の変位で変化させたデータがどれだけ整合しているかを示す特徴量である。位置 r にあるデータを $f(r)$ 、変位 a をもったデータを $f(r+a)$ 、データの総数を S 個とすると、自己相関関数

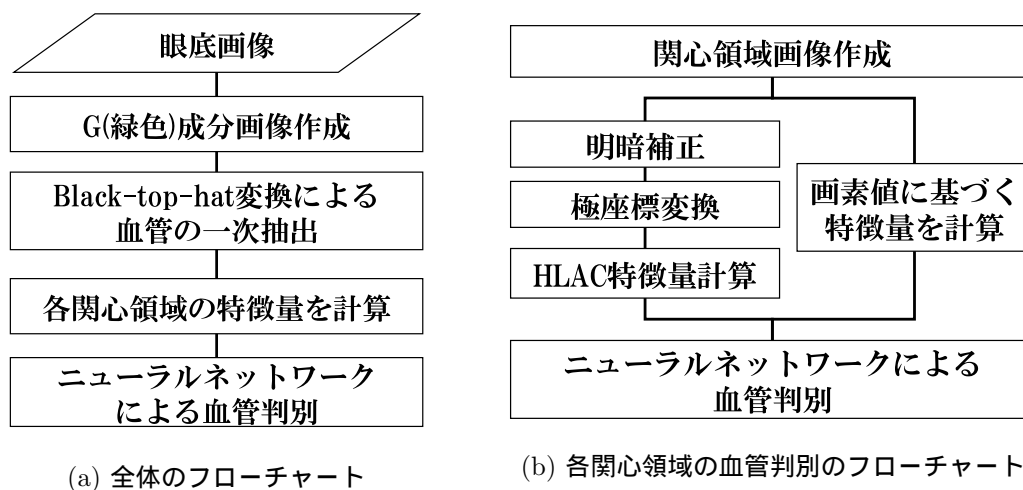


図1: 本手法のフローチャート

$R_{(a)}$ は以下の式で表される .


$$R_{(a)} = \sum_{r=0}^{S-1} f(r)f(r+a) \quad (1)$$

画像における自己相関特徴を求める場合 , 式 (1) は画像内の特徴量の総和となるため , 特徴量は画像内の対象の位置に関わらず不変の値を取る . 自己相関関数の高次元への拡張が高次自己相関関数である . 画像における N 次自己相関関数は , 変位 (a_1, a_2, \dots, a_N) に対して次式で定義される . ここで , T は局所パターン番号 , x と y は画像の横方向と縦方向の座標 , w, h はそれぞれ対象となる画像の横幅と縦幅である .

$$R_{N(a_1, a_2, \dots, a_N)}^T = \sum_{x=1}^{w-2} \sum_{y=1}^{h-2} f_{(x+y \times w)} f_{(x+y \times w+a_1)} \dots f_{(x+y \times w+a_N)} \quad (2)$$

したがって , 高次自己相関関数は , 次数 N や変位 (a_1, a_2, \dots, a_N) の取り方により多数の種類を考えられる . しかし , 画像に関して加法性を満たすためには , 変位は参照点 r 付近の局所領域に限定されなければならない . ここで , 対象となる画像を濃淡画像とし , 位置不変性を維持するために , 次数 N をたかだか 2 までに限定する . また , 加法性を維持するために , 変位を参照点 r の周囲 8 近傍までの局所的な 3×3 の領域に限定する . このとき , 平行移動により等価な特徴を除くと , 図 2 のような 35 個の局所パターンが得られる . この局所パターンから得られる特徴量を , HLAC 特徴量という . 35 種類の特徴量は , それぞれの局所パターンに対応する画素値の積を画像全体に対して足し合わせることで求められ , 画像の特徴を 35 次元のベクトルとして得ることができる . 本手法では , 35 種類の局所パターンに対して図 2(b) のようにパターンを 3 段階に拡大した特徴量を加え , 計 105 個の HLAC 特徴量を計算する .

HLAC 特徴は , 対象の位置に関わらず不変であるが , 対象の回転には脆弱である性質を持つ . よって , 類似の画素値や形状の血管であっても , 走行方向が異なる血管から計算される HLAC 特



(a) 35 局所パターン

(b) パターン拡大の例 (局所パターン番号 22)

図 2: 高次局所自己相関特徴のための局所パターン

徴ベクトルは、全く異なる。そこで、本手法では、関心領域に対して極座標変換を行なう。極座標変換画像では、関心領域の中心の画素（注目画素）からの距離成分と走行方向（角度）成分が平行移動成分として表される。したがって、極座標変換画像から計算される HLAC 特徴は、走行方向の変化に関わらず不変な特徴となる [13]。

HLAC 特徴は、非常に局所的な特徴であるため、画像の解像度が細かすぎても粗すぎても適切な特徴を得ることができない。本研究では、関心領域画像のサイズおよび極座標変換画像のサイズの複数の組み合わせで予備的に実験を行ない、関心領域画像のサイズが 19×19 pixel、極座標変換画像のサイズが 10×10 pixel のときに良好な結果が得られたため、その組み合わせを用いた。

2.4 特徴量

眼底画像では、撮影環境などの影響で、同一画像上でも血管と網膜のコントラストが位置によって異なる。HLAC 特徴量は、自己相関の総和であるため、画素値の違いが影響して血管領域内の画素を注目画素とする関心領域画像から得られる特徴間でも大きくばらつくことが推測される。そのため本研究では、ばらつきを抑える目的で関心領域画像に明暗補正を行なっている。しかしその影響で、網膜領域内の注目画素の特徴が血管領域内の注目画素の特徴に類似してしまう例があった。そこで、明暗補正前の関心領域画像から、領域内の画素値の最大値、最小値、平均値、標準偏差を計算し、機械学習に入力する特徴として追加した。したがって、本研究でニューラルネットワークに用いる特徴量は、計 109 個である。


2.5 ニューラルネットワーク

ニューラルネットワークによる学習は、Visual Mining Studio 8.1 を用いて行なった。実装されているニューラルネットワークは、入力層、隠れ層、出力層の 3 層で構成され、学習方法は誤差逆伝播法 (Backpropagation 学習法) を用いている。隠れ層のユニット数、出力層の活性化関数および最小化する目的関数はユーザが指定することができ、活性化関数と目的関数の組み合わせとして、Linear-Sum of Square, Sigmoid-Sum of Square, Sigmoid-Binomial, Softmax-Binomial, Softmax-Multinomial が用意されている。本研究では、入力層への入力を計算によって得られた 109 個の特徴量とし、各画素の血管判定を出力とする。学習では、学習用画像 20 枚の眼底領域約 400 万画素から正解画像の情報を元に血管領域から 5000 画素、網膜領域から 5000 画素をランダムにサンプリングし、それらの画素の特徴量を学習用データとして用いた。評価用データは、評価用画像 20 枚分の約 400 万画素をサンプルデータとして用いた。


3 実験結果および考察

3.1 使用画像

本研究では、研究のために公開されている DRIVE(Digital Retinal Images for Vessel Extraction)[2, 14] データベースを用いて実験した。DRIVE に含まれる眼底画像は、オランダの糖尿病網膜症スクリーニングプログラムから得られたものである。眼底画像は 40 枚用意されており、学習用画像 20 枚と評価用画像 20 枚の二組に分けられている。画像の大きさは 565×584 画素であり、24bit のカラー画像である。すべての画像に対して、熟練した眼科医が手動で血管構造を描画した画像が正解画像として用意されている。原画像と正解画像の一例を、図 3 に示す。画像には通し番号が付いており、検証用画像が画像 No.1 から No.20、学習用画像が No.21 から No.40 である。



(a) 原画像例 DRIVE 検証用画像 No.01



(b) 正解画像例 DRIVE 検証用画像 No.01

図 3: 使用画像例

3.2 実験方法と評価方法

本研究の提案手法を用いて、学習用画像 20 枚で機械学習を行ない、検証用画像 20 枚分の判別結果で評価を行なった。ニューラルネットワークは、Visual Mining Studio 8.1 で複数用意されている活性化関数と目的関数の組み合わせを用いて判別を行ない、それらの結果を比較した。評価は、Receiver Operating Characteristic(ROC) 解析によって得られた特性曲線の曲線下面積 (Area Under the Curve : AUC) を用いて行なった。ROC 解析と AUC の計算は、統計解析ソフト R の ROCR パッケージを用いて行なった [15]。目的関数以外のパラメータに関しては、様々な組み合わせを検討し、最大の AUC を実験結果として示す。

3.3 実験結果と考察

目的関数を変更しながら血管抽出を行なった結果を表 1 に示す。実験の結果、目的関数として Sigmoid - Binomial を用いたときに最も高い AUC を示していたが、目的関数を変更しても抽出率にそれほど大きな差は見られなかった。この抽出結果を従来手法 [9, 10, 11] と比較すると、AUC は表 2、ROC 曲線は図 4 のようになる。図 4 で、Human observer は、眼科医から訓練を受けたコンピュータ工学の研究者が手動で血管を抽出した際の結果を示しており、True positive rate が 0.775、False positive rate が 0.0275 である [2]。表 2 をみると、提案手法の AUC は、従来手法よりも高い値を示している。また、図 4 をみると、提案手法の ROC 曲線は、従来手法の曲線よりも Human observer に近づいていることがわかる。これらの結果は、提案手法が従来手法よりも人間の診断支援に貢献できる可能性が高いことを示している。

図 5 に、提案手法および従来手法による実際の血管抽出画像の例を示す。図 5(d),(e),(f) をみると、従来手法の抽出では網膜領域とのコントラストの低い血管の強調が不十分で、網膜領域の誤って強調されている領域と同等の出力値になっている。それに対して、図 5(c) をみると、提案手法の抽出ではコントラストの低い血管の出力値が網膜領域の誤強調に対して十分に大きくすることができている。提案手法において、処理の一部として BTH を用いていることを考慮すると、

表 1: 活性化関数と目的関数の組み合わせによる AUC の変化

分類分析	活性化関数-目的関数	AUC
Neural Network	Linear - Sum of Square	0.9331
	Sigmoid - Sum of Square	0.9342
	Sigmoid - Binomial	0.9351
	Softmax - Binomial	0.9348
	Softmax - Multinomial	0.9350

表 2: AUC による従来手法との比較

手法	AUC
提案手法	0.9351
BTH	0.9140
DR	0.8422
BTH+DR	0.9145

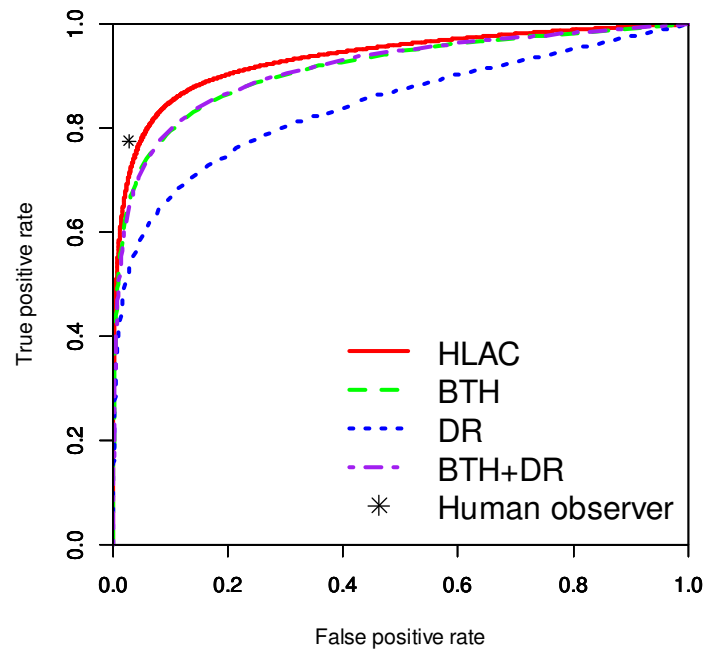





図 4: ROC 曲線による従来手法との比較




(a)G 成分画像 (DRIVE 画像 No.03)




(b) 正解画像




(c) 提案手法による抽出結果



(d)BTH による抽出結果



(e)DR による抽出結果



(f)BTH+DR による抽出結果

図 5: 提案手法と従来手法の血管抽出画像例

HLAC 特徴量を用いたことで網膜領域の誤強調を抑制し、コントラストの低い血管を強調されたと考えられる。

一方で、提案手法の抽出結果では、血管領域を正解画像よりも太く抽出してしまう傾向が見られた。この傾向から、関心領域から特徴を抽出していることで、血管領域と網膜領域の境界付近を注目画素としたときの判別結果が血管領域の影響を強く受けていると考えられる。この傾向は、病変を検出するための指標である血管径の計測処理などの精度に大きく影響することが考えられるため、改善する方法を検討する必要がある。また、BTH による一次抽出の段階で、網膜領域内で病変などが原因となって比較的広い領域が誤って強調されている場合、それらを抑制することができていない例があった。これは、HLAC 特徴量の計算前に一次抽出処理を加えたことによって一次抽出の精度の影響を受けてしまうことが原因であると考えられる。一次抽出に用いる従来手法の変更や、抽出後に偽陽性領域を判断する処理の検討が必要であると考えられる。

4 結論

本研究では、眼底画像から BTH と HLAC を組み合わせて血管の抽出実験を行なった。実験の結果、提案手法はニューラルネットワークの目的関数を Sigmoid - Binomial としたときに最も良好な結果を示し、従来手法と比べて血管の抽出精度が改善された。一方で、網膜領域が誤って強調される例がみられたため、それらを改善する方法を検討する必要がある。

5 謝辞

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

参考文献

- [1] 人間ドック学会, “2013 年「人間ドックの現況」”, <http://www.ningen-dock.jp/wp/wp-content/uploads/2014/09/e15c7a0a97982c27d3743f7d2caa017c.pdf>, [accessed January 25, 2015].
- [2] 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.501–509, 2004.
- [3] 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*, Vol.29, No.1, pp.6451–6454, 2007.
- [4] J. V. B. Soares, J. J. G. Leandro, R. M. Cesar Jr., 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.
- [5] 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.

- [6] S. H. Rezatofighi, A. Roodaki, and H. Ahmadi Noubari, “An enhanced segmentation of blood vessels in retinal images using contourlet”, *Proceedings of IEEE Engineering in Medicine and Biology society*, Vol.30, pp.3530–3533, 2008.
- [7] 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.
- [8] 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.
- [9] 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擬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.J89-D, No.11, pp.2491–2501, 2006.
- [10] Y. Hatanaka, T. Nakagawa, Y. Hayashi, A. Aoyama, X. Zhou, T. Hara, H. Fujita, Y. Mizukusa, A. Hujita, 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.
- [11] 岩瀬達彦, 村松千左子, 畑中裕司, 周向榮, 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.
- [12] N. Otsu, T. Kurita, “A new scheme for practical flexible and intelligent vision systems”, *Proceedings of International Association of Pattern Recognition workshop on Computer Vision*, pp.431–435, 1988.
- [13] 栗田多喜夫, 堀田一弘, 三島健稔, “Log-Polar 画像の高次局所自己相関特徴を用いた大きさに変な顔画像認識”, *電子情報通信学会論文誌.D-II, 情報・システム, II-情報処理 J80-D-2(8)*, pp.2209–2217, 1997.
- [14] DRIVE: Digital Retinal Images for Vessel Extraction ホームページ, <http://www.isi.uu.nl/Research/Databases/DRIVE/>, [accessed January 24, 2015].
- [15] Tobias Sing, Oliver Sander, Niko Beerenwinkel, Thomas Lengauer, “ROCR: visualizing classifier performance in R”, *Bioinformatics* 21(20), pp.3940–3941, 2005.