

## 脳 MR 画像におけるラクナ梗塞の検出法の改良 —AdaBoost テンプレートマッチングを用いた偽陽性削除—

谷河 文香<sup>†</sup>, 内山 良一<sup>††</sup>, 村松 千左子<sup>†††</sup>, 原 武史<sup>†††</sup>, 白石 順二<sup>††</sup>, 藤田 広志<sup>†††</sup>

<sup>†</sup>岐阜大学工学部応用情報学科 〒501-1193 岐阜県岐阜市柳戸 1-1

<sup>††</sup>熊本大学大学院生命科学研究部先端生命医療科学部門 〒862-0976 熊本県熊本市中央区九品寺 4-24-1

<sup>†††</sup>岐阜大学大学院医学系研究科知能イメージ情報分野 〒501-1194 岐阜県岐阜市柳戸 1-1

(2014 年 3 月 31 日受付, 2014 年 6 月 28 日最終受付)

### Improvement of Automatic Detection Method of Lacunar Infarcts on MR Images : Reduction of False Positives By Using AdaBoost Template Matching

Ayaka TANIGAWA<sup>†</sup>, Yoshikazu UCHIYAMA<sup>††</sup>, Chisako MURAMATSU<sup>†††</sup>,  
Takeshi HARA<sup>†††</sup>, Junji SHIRAISHI<sup>††</sup>, Hiroshi FUJITA<sup>†††</sup>

<sup>†</sup>Department of Information Science, Faculty of Engineering, Gifu University,  
1-1, Yanagido, Gifu, Gifu 501-1193, Japan

<sup>††</sup>Department of Medical Physics, Faculty of Life Science, Kumamoto University,  
4-24-1 Kuhonji, Chuo-ku, Kumamoto, Kumamoto 862-0976, Japan

<sup>†††</sup>Department of Intelligent Image Information, Graduate School of Medicine, Gifu University,  
1-1, Yanagido, Gifu, Gifu 501-1194, Japan

(Received on March 31, 2014. In final form on June 28, 2014)

**Abstract :** The detection of lacunar infarcts is important because their presence indicates an increased risk of severe cerebral infarction. However, their accurate identification is often hard because of the difficulty in distinguishing between lacunar infarcts and enlarged Virchow–Robin spaces. Therefore, we developed computer-aided diagnosis scheme for the detection of lacunar infarcts. The performance of our previous method indicated that the sensitivity of 96.8% with 0.76 false positive (FP) per slice. However, further reduction of FPs was remained as an issue to be solved for the clinical application. In this paper, we proposed AdaBoost template matching. This classifier can distinguish between lacunar infarcts and FPs by selecting suitable templates in the template matching. By using this technique, 55.5% FPs were eliminated while keeping the same sensitivity. Thus the proposed method was found to be useful for the sophistication of the automatic detection of lacunar infarcts in MR images.

**Keywords :** Computer-aided diagnosis, Lacunar infarcts, AdaBoost, Template matching

### 1. 緒言

本邦では、脳の疾患を早期に発見し対処することを目的とした脳ドックが行われている。無症候性のラクナ梗塞は脳ドックにおける MR 検査でしばしば発見される。ラクナ梗塞の存在は、後に発生する重篤な脳梗塞と関連が指摘されているため、その検出は重要である[1, 2]。しかしながら、加齢による正常な脳組織の委縮による血管周囲腔拡大などの鑑別が困難であるため、すべてのラクナ梗塞を正しく検出することは難しい[3]。そこで、われわれは MR 画像におけるラクナ梗塞の検出を支援するためのコンピュータ支援診断 (Computer-Aided Diagnosis, 以下, CAD) システムを開発してきた[4-9]。1143 枚の T<sub>1</sub> 強調画像と T<sub>2</sub> 強調画像を用いた実験の結果、従来法の検出性能は、真陽性率 96.8% のとき、偽陽性数 0.76 個/スライス画像であった[5]。本実験で用いた画像データでは、ラクナ梗塞が存在するスライスは 1 症例当たり 7~10 スライスであったため、1 症例当たりの偽陽性数は 5.32~7.6 個となる。真陽性率は高いものの、臨床で用いるには偽陽性数が多いという課題が残った。

異常陰影と偽陽性を区別する手法としてテンプレート

マッチングを用いたものが提案され、様々な病変の検出に適用されている[10-14]。われわれもラクナ梗塞検出の偽陽性削減のためにテンプレートマッチングによる手法を適用し、17.1% の偽陽性を削除できる効果があることを示した[9]。テンプレートマッチングによる手法では、テスト症例の病巣とよく似ているテンプレートが学習データに含まれている場合には、効率良くその病変を検出することができる。したがって、検出精度を高めるには、なるべく多くの病巣を集めてそれらを学習データとして用いれば良い。しかしながら、学習テンプレートとして使用する病巣を多く集めることは一般に困難である。少ない学習テンプレートでもうまく機能するように、テスト症例と学習データに含まれる類似度が上位の病巣の平均値と、テスト症例と類似度が上位の偽陽性の平均値を比較し、平均的に病巣と偽陽性のどちらに似ているかの基準で識別するアプローチも提案されている[15]。ところが、この方法では何枚のテンプレートから平均値を計算するのが最適かを判断することが困難であり、また、すべての学習データとテンプレートマッチングを行って上位の値の並べ替えを行わなければならない処理時間がかかる。そこで本論文では、これらの問題の解決策として、複数のテンプレートから病巣の平均画像

と偽陽性の平均画像をそれぞれ作成し、どちらの平均画像に似ているかの基準で識別を行い、その平均画像を作成する際のテンプレートの選択に AdaBoost[16]を採用する方法を提案する。AdaBoost は、逐次的に学習サンプルの重みを変化させながら異なる弱識別器を作り、これら複数の弱識別器の重み付き多数決によって最終的な識別関数を形成する手法である。AdaBoost の特長は、逐次的に学習サンプルの重みを変化させながら弱識別器を作る部分であり、この特長を利用した AdaBoost テンプレートマッチングでは、弱識別器の学習で病巣を区別するために最適なテンプレートを選択することができる。また、平均画像との比較で識別を行うため処理時間も短縮できる。以下に、AdaBoost テンプレートマッチングについて述べ、ラクナ梗塞と偽陽性の識別に応用することにより、その効果を検証する。

## 2. 実験試料

実験に用いた画像は、岐阜大学附属病院の 1.5T の MR 装置 (Signa Excite Twin Speed, GE Medical Systems) によって撮影された 132 名の  $T_1$  強調画像及び  $T_2$  強調画像である。本研究は倫理審査委員会での承認を得た。 $T_1$  強調画像の撮影条件は、Spin-Echo 法、TE : 8~12 ms, TR : 300~500 ms, Slice Width : 5 mm, Slice Gap : 2 mm であり、 $T_2$  強調画像の撮影条件は、Spin-Echo 法、TE : 8~12 ms, TR : 3000~5000 ms, Slice Width : 5 mm, Slice Gap : 2 mm である。画像サイズは 512×512 pixels, 空間分解能は 0.47 mm, 年齢は 28~83 歳 (平均 63.4 歳), 男性 75 名, 女性 57 名である。

ラクナ梗塞の位置は、2 名の神経放射線科医による読影実験によって決定された。それぞれ独立にラクナ梗塞の位置を決定してもらい、2 名がともにラクナ梗塞と判断した 93 箇所を“ラクナ梗塞”と定義し、真陽性率の計算に“ラクナ梗塞”を用いた。一方、2 名がともにラクナ梗塞はないと判断した 1063 枚のスライス“ラクナ梗塞を含まないスライス”と定義し、偽陽性数の計算に“ラクナ梗塞を含まないスライス”を用いた[5]。

## 3. 方法

ラクナ梗塞検出法の概要を Fig.1 に示す。上段は従来法であり、下段の網掛け部分が提案手法である。まず、 $T_1$  強調画像に領域拡張法を適用することによって、脳実質領域を抽出し、ラクナ梗塞の探索範囲を限定する。つぎに、 $T_2$  強調画像に対してトップハット変換を用いてラクナ梗塞を強調したのちに、多重しきい値処理を行うことによって、ラクナ梗塞の初期候補を決定する。それぞれの初期候補から、候補領域の 2 値画像の重心 X 座標と Y 座標、候補領域内とその周辺の濃度差を定量化した  $T_1$  及び  $T_2$  強調画像の信号強度、フィルタバンクの分解によって得られる解像度 1 から 4 までの粒状成分、解像度 1 から 4 までの粒状・線状成分からなる 12 個の画像特徴量を計測し、それらの特徴量を入力としたサポートベクタマシンによって、ラクナ梗塞と偽陽性を区別する[5]。手法の評価は、2-fold cross validation [17]によって行った。ここまでの処理を行った従来法の結果は、真陽性率 96.8% (90/93) のとき、偽陽性数 0.76 個/スライス画像 (813/1063) であった[5]。

本研究では、サポートベクタマシンのパラメータを細かく設定することで、偽陽性数を 0.76 個から 0.71 個にした結果を用いて実験を行った。Fig.1 の下段に示すように、

従来法[5]に AdaBoost テンプレートマッチング法を追加することによって、ラクナ梗塞と偽陽性の識別を行った。従来法によって検出したすべての領域 (2 値画像) から重心 (X 座標及び Y 座標) を計算し、その重心を中心に、51×51 の関心領域 (以下、ROI) を切り抜き、以下の処理を行った。ラクナ梗塞 ROI は 90 個、偽陽性 ROI は 753 個である。なお、AdaBoost テンプレートマッチング法の学習とテストは、従来法と同様に 2-fold cross validation によって行った。

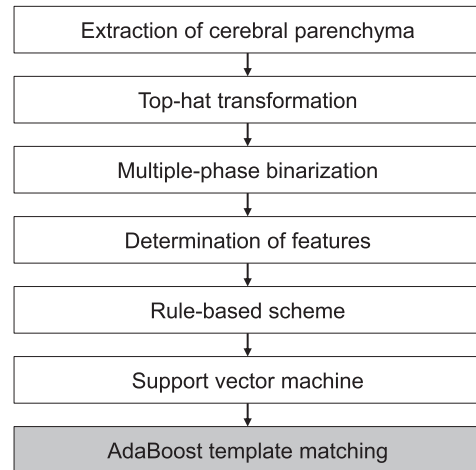


Fig.1 Overall scheme for detection of lacunar infarcts.

### 3.1 AdaBoost テンプレートマッチングによる偽陽性削除

AdaBoost は、逐次的に学習サンプルの重みを変化させながら異なる識別器を作り、これら複数の識別器の重み付き多数決によって最終的な識別関数を生成する手法である[18]。AdaBoost は、サンプルの重みを更新する部分が特徴的であり、テンプレートマッチングにこのアイデアを取り入れた場合には、テンプレートを選択する機能として働く。つまり、AdaBoost テンプレートマッチングとは、逐次的に学習テンプレートの選択をしながら異なる多数の弱識別器を作り、弱識別器の重み付き多数決により強識別器を作成し、ラクナ梗塞と偽陽性を識別するものである[18]。アルゴリズムは以下の通りである。まず、 $N$  個の学習データの  $i$  番目の ROI 画像 (サンプル  $x_i$ ) がラクナ梗塞であれば  $y_i=+1$ , 偽陽性であれば  $y_i=-1$  とラベル付けする。AdaBoost では各サンプルの重みを更新することによりサンプル分布を変更し、それぞれの分布の下で弱識別器を学習していく。具体的には、1 回目の学習ではすべてのサンプルの重みは同じとし、その後の学習では弱識別器が正しく識別できたサンプルについては重みを小さくし、間違えたサンプルについては重みを大きくする。 $t$  回目の学習時における  $i$  番目のサンプルの重みを  $D_t(i)$  とおく。初回の学習時では重みはすべて  $D_1(i)=1/N$  として初期化する。この重み  $D_t(i)$  を用いてラクナ梗塞の重み付き平均 ROI 画像  $A_{TP}$  と偽陽性の重み付き平均 ROI 画像  $A_{FP}$  を次式で作成する。

$$A_{TP}(i) = \sum_{i: y_i=1} x_i(j) \cdot D_t(i) \quad (1)$$

$$A_{FP}(i) = \sum_{i: y_i \neq 1} x_i(j) \cdot D_t(i) \quad (2)$$

ここで、 $j$  は画素の位置を表す。弱識別器  $h_t(x)$  は、ラクナ梗塞の重み付き平均 ROI 画像  $A_{TP}$  と偽陽性の重み付き平均 ROI 画像  $A_{FP}$  のどちらに似ているかを、相互相関係数  $CC$  で計算し、テスト ROI 画像を識別するように構成した。

$$h_t(x) = \begin{cases} +1 & \text{if } CC(A_{TP}, x) - CC(A_{FP}, x) > \theta_t \\ -1 & \text{otherwise} \end{cases} \quad (3)$$

ここで、 $CC(A_{TP}, x)$  はラクナ梗塞の重み付き平均画像  $A_{TP}$  と入力画像  $x$  との相互相関係数を、 $CC(A_{FP}, x)$  は偽陽性の重み付き平均画像  $A_{FP}$  と入力画像  $x$  との相互相関係数をそれぞれ表し、 $\theta_t$  は、相互相関係数の値の差に対する閾値である。このとき、 $\theta_t$  はサンプルを識別したときの誤り率

$$\varepsilon_t = \sum_{i: y_i \neq h_t(x_i)} D_t(i) \quad (4)$$

が最小になるように調整した。つぎに、この誤り率から信頼度  $\alpha_t$  を次式で計算した。

$$\alpha_t = \frac{1}{2} \log \left( \frac{1 - \varepsilon_t}{\varepsilon_t} \right) \quad (5)$$

また、求めた信頼度を用いて  $t+1$  回目の学習時のサンプルの重みを

$$D_{t+1}(i) = D_t(i) \exp[-\alpha_t y_i h_t(x_i)] \quad (6)$$

によって更新した。式からわかるように、弱識別器で正しく識別できたサンプルについては  $y_i h_t = 1$  となるため、サンプルの重みは小さくなり、逆に、間違えたサンプルについては  $y_i h_t = -1$  となるため、サンプルの重みは大きくなるように更新される。重みの更新を行った後に、サンプルの重みの総和が 1 になるように正規化を行った。

$$D_{t+1}(i) = \frac{D_{t+1}(i)}{Z_{t+1}} \quad (7)$$

ただし、

$$Z_{t+1} = \sum_{i=1}^N D_{t+1}(i) = \sum_{i=1}^N D_t(i) \exp[-\alpha_t y_i h_t(x_i)] \quad (8)$$

である。ここまでの操作を  $T$  回行うことで学習を進める。AdaBoost テンプレートマッチングでは、1 回目の学習ではすべてのサンプルの重みが均等であるので、単純なサンプル平均の画像で識別が行われる。その後は重みが更新され、 $t$  回目の学習では識別が困難であったサンプルの重みが大きくなるため、重み付き平均画像が変わる。最終的な識別は、すべての弱識別器を信頼度  $\alpha_t$  で重みを付けて多数決をとる強識別器  $H(x)$  によって行った。

$$H(x) = \text{sign} \left[ \sum_{t=1}^T \alpha_t h_t(x) \right] \quad (9)$$

サンプル数と総学習回数  $T$  には関係がある。もし、サンプル数が少ない場合には、少ない学習回数ですべての学習データを弱識別器が正しく識別する。この場合には、サンプルの重みを更新できなくなり、同じ弱識別器ばかりが得られ学習を継続する意味がない。よって、サンプル数が少ない場合は、総学習回数は少なくても良い。本研究では総学習回数を経験的に  $T=100$  とした。

### 3.2 カスケード構造

本研究では、顔認識で取り入れられているカスケード構造[19]を採用することにより、高速化と高精度化を行った。カスケード構造の識別器は、Fig.2 に示すように、 $H^1$  から  $H^M$  までの  $M$  個の AdaBoost 識別器を直列に接続したものである。それぞれの AdaBoost 識別器  $H^m$  は以下の式で定義した。

$$H^m(x) = \text{sign} \left( \sum_{t=1}^{T^m} \alpha_t^m h_t^m(x) - \theta^m \right) \quad (10)$$

ここで、 $\theta^m$  は処理対象の ROI にラクナ梗塞が含まれているか否かを判断するための閾値である。カスケード構造の前段に配置される識別器  $H^1$  や  $H^2$  の役割は、ラクナ梗塞との鑑別が比較的容易な偽陽性を早い段階で棄却することである。これによって処理の高速化を実現できる。




Fig.2 Illustration of cascade structure.

本実験では、従来法を適用した結果を用いているため、従来法ではラクナ梗塞と区別ができなかった様々な種類の偽陽性が含まれている。カスケード構造を採用しない場合には、識別器  $H^1$  のみを用いた識別となるが、この場合には、様々な種類の偽陽性を含んでいるために識別器  $H^1$  の学習が困難であった。そこで、学習データの偽陽性を 8 種類のセットに分類し、タイプ 1 の偽陽性とラクナ梗塞の識別を識別器  $H^1$  に、タイプ 2 の偽陽性とラクナ梗塞の識別を識別器  $H^2$  に、という具合にそれぞれ役割分担をさせることで識別処理の高精度化を行った。ここで、偽陽性の分類には、階層的クラスタリング（階層併合的方法）[20]を採用した。階層的クラスタリングの入力には、 $T_1$  強調画像と  $T_2$  類強調画像を横に並べた  $51 \times 102$  の大きさの ROI を用い、類似度は ROI 画像の相互相関係数を採用した。また、クラスター生成には Ward 法を適用した。Fig.3 にクラスタリングによって分類された学習データに含まれる 8 種類の偽陽性の例を示す。このように分類された学習データのタイプ 1 の偽陽性とラクナ梗塞を用いて識別器  $H^1$  を学習し、タイプ 2 の偽陽性とラクナ梗塞を用いて  $H^2$  を学習するという順番で学習を進める。

### 3.3 ROI 画像の選択と識別方法

本実験で使用した画像データは、 $T_1$  強調画像及び  $T_2$  強調画像である。よって、上述した AdaBoost テンプレートマッチングに用いる ROI 画像の選択にいくつかの組合せがある。下記の 3 つの条件で実験を行うことによって性能の比較を行った。

条件 1:  $T_1$  強調画像から  $51 \times 51$  の大きさの ROI を選択し AdaBoost テンプレートマッチングによる認識を行った場合。

条件 2: 同じ位置の  $T_2$  強調画像から  $51 \times 51$  の大きさの ROI を選択し、 $T_1$  強調画像の代わりに  $T_2$  強調画像の ROI のみを用いて AdaBoost テンプレートマッチングによる認識を行った場合。

条件 3:  $T_1$  強調画像と  $T_2$  強調画像から ROI を選択し、それぞれの識別の結果を縦列に接続することで統合して識別を行った場合である。もし、 $T_1$  強調画像と  $T_2$  強調画像のそれぞれがラクナ梗塞と偽陽性を識別するために有用な情報を持っているとすれば、2 つの結果を統合した条件 3 が最も良い結果になると予想される。




Fig.3 Outputs of the agglomerative hierarchical clustering in the training dataset. False positive ROIs were classified into 8 types.

#### 4. 実験結果

Fig.4 に、カスケード構造の識別器の数（偽陽性の分類数）と偽陽性削除率の関係を示す。ROI の大きさを  $51 \times 51$  に固定して、条件 1 から条件 3 で実験を行った。図から  $T_1$  強調画像と  $T_2$  強調画像を統合した結果である条件 3 の結果が最も良いことがわかる。もし、 $T_1$  強調画像と  $T_2$  強調画像がラクナ梗塞と偽陽性の区別のために同じ情報しか持っていないならば、2つの画像を統合してもそれ以上の鑑別性能を得ることはできない。したがって、この結果は、 $T_1$  強調画像と  $T_2$  強調画像のそれぞれがラクナ梗塞と偽陽性を区別するための独立した情報を持っていることを示していると考えられる。また、偽陽性の分類数を多くすれば偽陽性削除率が大きくなるが 8 種類以上になると逆に低下する傾向も明らかになった。このことは、① 8 種類に分類するまではラクナ梗塞と特定の種類の偽陽性を区別するように識別器の学習を行うアイデアが機能したこと、② 偽陽

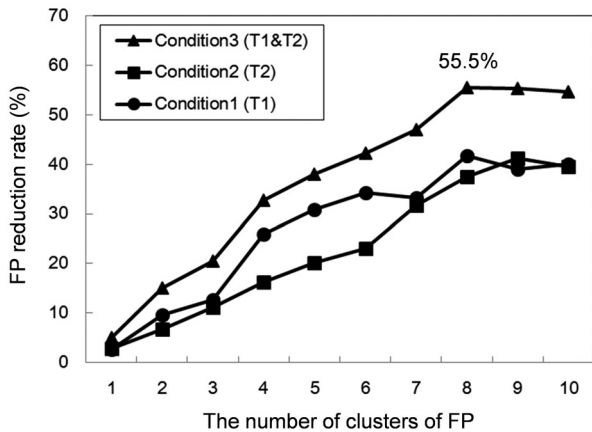


Fig.4 Relationship between FP reduction rate and number of classifiers in the cascade structure by using ROI size of  $51 \times 51$  at condition 1, condition 2, and condition 3.

性の種類を多くし過ぎると学習に用いる特定の種類の偽陽性数が減少するためにラクナ梗塞と偽陽性を鑑別するための学習がうまく進まなくなったこと、を示していると考えられる。

提案手法と従来のテンプレートマッチングによる偽陽性削除率を条件 1 と条件 2 の場合で比較した結果を Table 1 に示す。この実験では、ROI の大きさを変えた場合に、偽陽性削除率がどのように変化するかについても調べた。表から、従来のテンプレートマッチングよりも提案手法の方がすべての条件で偽陽性削除率が高いことがわかり、提案手法の有効性を示している。また、 $51 \times 51$  の大きさの ROI を用いた場合に多くの偽陽性を削除できることも明らかになった。

最終的に、Fig.4 に示すように、 $T_1$  及び  $T_2$  強調画像から得た  $51 \times 51$  の大きさの ROI を用いて、ラクナ梗塞と 8 種類の偽陽性を区別するようにした場合の偽陽性削除率が最も良く、55.5% の偽陽性を削除することができた。提案手法を従来システムに追加した場合の最終的な性能は、真陽性率が 96.8% (90/93) のとき、偽陽性数 0.32 個/スライス画像 (335/1063) となった。したがって、提案手法は、ラクナ梗塞の検出の CAD システムの高度化に寄与することができた。

#### 5. 考察

従来のテンプレートマッチングと AdaBoost テンプレートマッチングの違いについて考察する。従来のテンプレートマッチングでは、最も似ているテンプレートに属するクラスを識別結果として出力する。“似ている”ことを定量化するために相互相関係数が使われる。このような識別方法は、最近傍決定側（以下、NN 法）と呼ばれる[21]。ラクナ梗塞 ROI と偽陽性 ROI には様々なパターンが存在する。よって、テスト ROI を正しく識別するにはそれらの違いをカバーするのに十分な量の学習テンプレートを収集

Table 1 Comparison of FP reduction rates between conventional template matching and AdaBoost template matching.

Method	Condition : Image	ROI size		
		$31 \times 31$	$41 \times 41$	$51 \times 51$
Conventional template matching	Condition 1 : $T_1$ -WI	8.9%	6.1%	12.7%
	Condition 2 : $T_2$ -WI	5.4%	5.0%	14.7%
AdaBoost template matching	Condition 1 : $T_1$ -WI	34.8%	33.2%	41.8%
	Condition 2 : $T_2$ -WI	28.4%	40.8%	37.5%

しなくてはならない。様々なパターンのラクナ梗塞を収集するのは困難な作業であり、また、収集できたとしても、すべての学習テンプレートとの相互相関係数を計算しなければならず、計算機の処理能力と記憶容量の問題が発生する。収集したラクナ梗塞の数が少ない場合には、実際のラクナ梗塞のパターンのごく一部しかカバーできていないことになる。そこで、より一般的な方法として、テスト ROI に最も良く似た  $k$  個の学習テンプレートを計算し、その中で最も多数を占めたクラスを識別結果とする方法があり、これを  $k$ -NN と呼ぶ。文献[15]のアプローチはこの  $k$ -NN のアイデアに基づいていると考えることができる。

すべてのラクナ梗塞 ROI と偽陽性 ROI のパターンを収集できないときの効率的な方法として少数の代表的なパターンをプロトタイプとして設定する方法が考えられる。最も簡単なプロトタイプの決め方は、平均 ROI 画像を用いることである。AdaBoost テンプレートマッチングでは、ラクナ梗塞 ROI と偽陽性 ROI から平均画像を作成し、どちらの平均画像に似ているかで識別を行う。この場合、相互相関係数によって作られる特徴量空間において、2つのクラスを分離する境界は2つのプロトタイプからの等距離の直線となり、複雑なパターンの識別は難しい。そこで、平均 ROI 画像を作成するためのテンプレートの選択に AdaBoost を採用したものが AdaBoost テンプレートマッチングである[18]。Fig.5 に、学習データから作成したラクナ梗塞と偽陽性の平均 ROI 画像をそれぞれ示す。1回目の学習ではすべてのテンプレートを用いて平均 ROI 画像が作成されているが、50回目の学習では平均 ROI 画像を作成する際の各テンプレートに対する重みが異なっている。つまり、50回目の学習では前段に位置する弱識別器が識別できなかった ROI 画像を後段の弱識別器のためのプロトタイプとして設定することを意味している。

AdaBoost テンプレートマッチングのもうひとつの特長は処理時間の短縮である。従来のテンプレートマッチングを用いた場合、ラクナ梗塞 ROI が 90 個、偽陽性 ROI が 753 個の学習テンプレートを含むデータをテストする場合には、すべての ROI との相互相関係数を計算する必要があるため、合計で  $90+753=843$  回の計算が必要である。しかし、AdaBoost テンプレートマッチングでは、ラクナ梗塞の平均画像と偽陽性の平均画像との相互相関係数を計算 (2 回) すれば良いため、100 個の弱識別器を用いた場

合でも  $2 \times 100 = 200$  回の計算をするだけで良い。よって、約 76% の計算を短縮できる。実際のラクナ梗塞のパターンの多くをカバーするために、より多くの学習テンプレートを集めた場合には、それに伴い相互相関係数の計算回数が増えるが、AdaBoost テンプレートマッチングでは学習テンプレートを増やしたとしても相互相関係数の計算回数は同じでも良い。したがって、処理時間を短縮する効果も期待できる。

本研究のリミテーションは、ひとつの施設から収集した MR 画像を用いた実験しか行われていないことである。今後、複数の施設の異なる MR 装置によって撮影した画像を用いて実験を行う必要がある。また、フレア画像も用いられていない。ラクナ梗塞の診断には、 $T_1$  強調画像、 $T_2$  強調画像とともに、フレア画像が用いられることが一般的であることから、フレア画像を追加した場合に、どのような実験結果が得られるかを検討する必要がある。

## 6. 結 語

ラクナ梗塞と偽陽性を識別するために AdaBoost テンプレートマッチングを用いる手法を提案した。従来のテンプレートマッチングでは 17.1% の削除率であったが、本手法では、55.5% の偽陽性を削除できる効果があった。従来のテンプレートマッチングによる処理を本提案手法で置き換えることにより、最終的な性能は、真陽性率が 96.8% (90/93) のとき、偽陽性数 0.32 個/スライス画像 (335/1063) となった。よって、本手法はラクナ梗塞検出の CAD システムの高度化に寄与することができた。しかしながら、実用化のためには、さらに偽陽性を減らすための方法の検討が必要である。

## 謝 辞

本研究の一部は、科学研究費基盤研究 C (課題番号 24591815)、科学研究費新学術領域研究「医用画像に基づく計算解剖学の創成と診断・治療支援の高度化」(課題番号 21103001)、及び研究成果最適展開支援プログラム A-STEP (課題番号 AS2511004P) によって行われました。

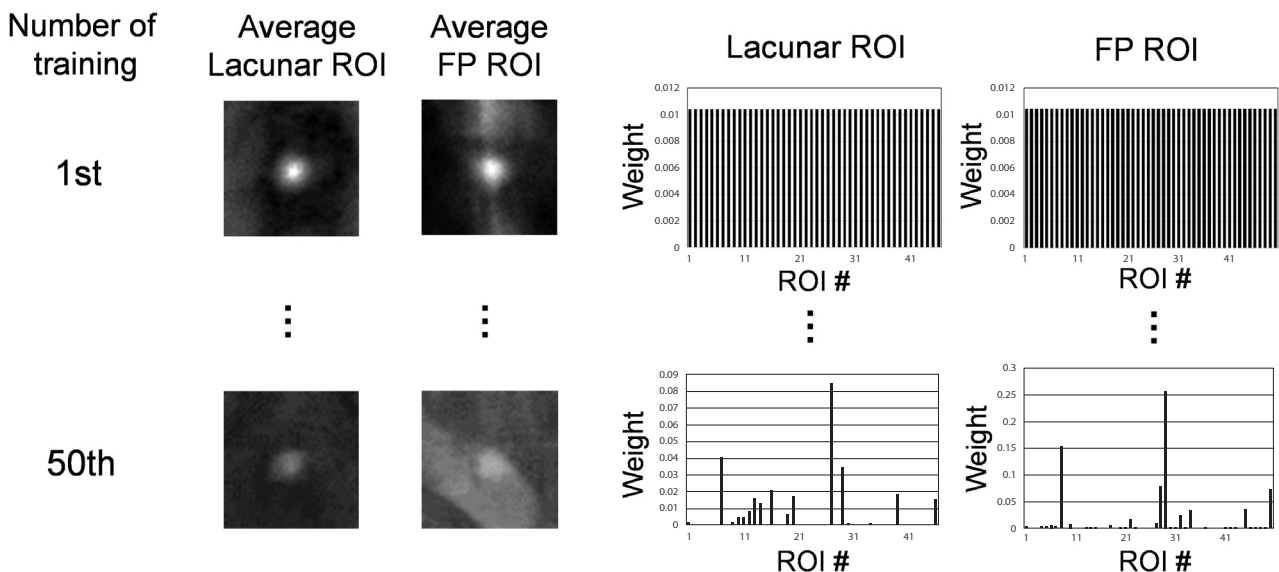


Fig.5 Changes of average image and weights when the training was progressed.

## 参考文献

- [1] S. Kobayashi, K. Okada, H. Koide, et al.: Subcortical silent brain infarction as a risk factor for clinical stroke, *Stroke*, 28, 1932-1939, 1997.
- [2] S.E. Vermeer, M. Hollander, E.J. Dijk, et al.: Silent brain infarcts and white matter lesions increase stroke risk in the general population. The Rotterdam Scan Study, *Stroke*, 34, 1126-1129, 2003.
- [3] H. Boukura, S. Kobayashi, S. Yamaguchi, et al.: Discriminant of silent lacunar infarction from enlarged Virchow-Robin spaces on brain magnetic resonance imaging and pathological study, *J Neurol*, 245, 116-122, 1998.
- [4] R. Yokoyama, X. Zhang, Y. Uchiyama, et al.: Development of an automated method for the detection of lacunar infarct regions in brain MR images, *IEICE Transaction Information & Systems*, Vol.E90-D(6), 943-954, 2007.
- [5] Y. Uchiyama, R. Yokoyama, H. Ando, et al.: Computer-aided diagnosis scheme for detection of lacunar infarcts on MR image, *Academic Radiology*, 14(12), 1554-1561, 2007.
- [6] 國枝琢也, 内山良一, 原武史, 他: クラスタリングを用いた脳ドック MR 画像における無症候性大脳白質病変の検出法, *Medical Imaging Technology*, 26(1), 39-47, 2008.
- [7] 國枝琢也, 内山良一, 原武史, 他: 脳 MR 画像におけるラクナ梗塞と血管周囲腔拡大の鑑別法, *医用画像情報学会雑誌*, 26(3), 59-63, 2009.
- [8] Y. Uchiyama, T. Asano, H. Kato, et al.: Computer-aided diagnosis for detection of lacunar infarcts on MR images – ROC analysis of radiologists' performance –, *J Digit Imaging*, 25(4), 497-503, 2012.
- [9] 阿部晃子, 内山良一, 村松千左子, 他: テンプレートマッチングを用いたラクナ梗塞検出のためのコンピュータ支援診断システムの改良, *医用画像情報学会雑誌*, 30(2), 39-43, 2013.
- [10] Y. Lee, T. Hara, H. Fujita, et al.: Automated detection of pulmonary nodules in helical CT images based on an improved template-matching technique, *IEEE Trans Med Imaging*, 20(7), 595-604, 2001.
- [11] Q. Li, S. Katsuragawa, K. Doi: Computer-aided diagnostic scheme for lung nodule detection in digital chest radiographs by use of a multiple-template matching technique, *Med Phys*, 28(10), 2070-2076, 2001.
- [12] M.A.Mazurowski, J.Y. Lo, B.P. Harrawood, et al.: Mutual information-based template matching scheme for detection of breast masses: from mammography to digital breast tomosynthesis, *J Biomed Inform*, 44(5), 815-823, 2011.
- [13] G.D. Tourassi, R. Vargas-Voracek, D.M.Jr. Catarious, et al.: Computer-assisted detection of mammographic masses: a template matching scheme based on mutual information, *Med Phys*, 30(8), 2123-2130, 2003.
- [14] N. Kilic, O.N. Ucan, O. Osman: Colonic polyp detection in CT colonography with fuzzy rule based 3D template matching, *J Med Syst.*, 33(1), 9-18, 2009.
- [15] 竹永智美, 内山良一, 平井俊範, 他: MR 画像における転移性脳腫瘍検出のコンピュータ支援診断, *日本放射線技術学会雑誌*, 69(6), 632-640, 2013.
- [16] Y. Freund and R.E. Schapire: A decision – theoretic generalization of on-line learning and an application to boosting, *Journal of Computer and System Sciences*, 55(1), 119-139, 1997.
- [17] S. Theodoridis, K. Koutroumbas: *Pattern Recognition*, Academic Press, London, 1999.
- [18] 倉爪亮, 石川博, 加藤丈和, 他: コンピュータビジョン最先端ガイド 1, アドコム・メディア, 2008.
- [19] P. Viola, M. Jones: Robust real-time face detection, *International Journal of Computer Vision*, 57(2), 137-154, 2004.
- [20] 宮本定明: クラスター分析入門, 森北出版株式会社, 1999.
- [21] 石井健一郎, 上田修功, 前田英語作, 他 著: やかりやすいパターン認識, オーム社, 1998.