

琉球大学学術リポジトリ

カーネルICAを用いたMR画像内における脳組織強調化

メタデータ	言語: Japanese 出版者: 琉球大学工学部 公開日: 2008-09-02 キーワード (Ja): 医療画像, MR画像, 脳組織強調, 多変量解析, 独立成分分析, カーネル独立成分分析法 キーワード (En): 作成者: 健山, 智子, 仲尾, 善勝, Tateyama, Tomoko, Nakao, Zensho メールアドレス: 所属:
URL	http://hdl.handle.net/20.500.12000/7088

カーネルICAを用いたMR画像内における脳組織強調化

健山 智子* 仲尾 善勝**

Brain Matters Emphasis in MR Imaging Using Kernel Independent Component Analysis

Tomoko Tateyama* Zensho Nakao**

近年、医療機器の目覚しい発展とともに、医療診断と治療法は著しく向上をしている。その背景に基づき、現在我々は医療画像診断に関する客観的な判断材料を提供する CAD システム開発を目指している。

本論文において、カーネルICAを応用したMR画像における脳組織強調化について提案を行う。カーネル法を用いることで、画像を線形空間から非線形空間に射影を行うことを可能とし、その非線形空間において高次元の特徴を基に新たな特徴ベクトルを利用した解析を行うことが可能となる。この性質を利用することで、MR画像中における各脳組織の特徴を捉えることにより、より高度な脳組織解析が行うことが可能となる。本論文ではこれまでの先行研究としての独立成分分析をはじめに解説し、本提案法であるカーネル法について解説を行う。さらに、カーネル法を用いた解析と従来法の比較を行い、提案法がより脳組織の強調を行ってることを示す。

提案法により、医療診断における「客観的な意見」としてのシステムを提案することができる事を示す。

キーワード：医療画像, MR 画像, 脳組織強調, 多変量解析, 独立成分分析, カーネル独立成分分析法

1. 序論

近年、医療画像診断装置(X線、CT、MRI、超音波等)の高度化に伴い、それらの装置から得られる医療画像の質および量において情報量が飛躍的に増大し、医療画像診断分野においても、スライスの間隔で人体内部の観測を行うことが可能である。

多数のスライス画像により画像の解像度が向上し、画像に含まれる情報の質が更に向かっている一方、それら全てのスライス画像を見て診断する医師の負担は、膨大なものである。また、微小な病巣を発見するには、経時変化を調べることは医療現場において非常に重要であり、そのため、現在の医療画像と過去の医療画像とを比較読影する必要がある。その点でも、医師の負担は更に増大しているといえるであろう。さらには、診断の質を向上させるために、超音波診断装置とX線CT装置等の異なる診断装置で撮影した医療画像を比較しながら診断するニーズも高まっており、医療画像を読影する医師の負担は増大する一方である。そこで我々は医療画像診断に関する客観的な判断材料を提供する CAD システム開発を目指している⁽¹⁾。この CAD システムの出力結果を「客観的な意見」として診断に用いることで、より重

要な病変などの変化を確認することが可能となり、経年変化、さらには異なる装置上における撮影画像との比較について具体的に行うことが可能となる。また、上記で挙げたような医師の負担軽減にも多い可能性が期待できる。

これまでの先行研究として中井らにより MR 画像を ICA により解析することで画像のコントラスト強調が行われる成果が報告されている^{(2) (3)}。また、陳、杉木の研究は中井の研究報告に基づき、ICA で強調を行った後、認識手法を用いることで脳組織のパターン認識精度の向上なることが報告されている⁽⁴⁾。先行研究では MR 画像を線形結合に基づいて解析を行っており、実際には MR 画像の強調化が行われたものの、画像全体を線形結合で強調してあるため、線形成分での表現となっている。より画像内における脳組織の構造を顕著に表現するためには MR 画像を線形画像として扱うのではなく、非線形性を考慮した画像解析を行う必要があることが考えられる^{(5) (6)}。

本研究では、MR 画像を非線形結合として考慮し、画像に最適な基底関数をカーネル法と ICA により決定し画像を解析することで画像内における脳組織の強調化を行うことを提案する。

* 琉球大学大学院理工学研究科総合知能工学専攻

Email:tomoko@augusta.eee.u-ryukyu.ac.jp

** 琉球大学工学部電気電子工学科

Email:nakao@augusta.eee.u-ryukyu.ac.jp

2. MR 画像

MR I (Magnetic Resonance Imaging) とは、磁場内において人体構成物質の大部分を占める水素原子核 (proton) の核磁気共鳴現象を利用して画像を得る方法であり、今日の医療現場において幅広く利用されている。

MR 画像は人体の組織に関するパラメータ (プロトン密度、縦、横 (T1, T2) 緩和時間等) と装置に関するパラメータ (繰り返し (TR) 時間、エコー (TE) 時間等) を組み合わせて撮像する。

本研究では MR 画像の代表的な T1 強調、T2 強調、PD 画像の 3 種類の画像を対象に研究を行った。T1 強調画像とはおもに縦緩和による核磁化分布を画像化したもので、高信号では脂肪、出血、銅や鉄などの沈着物で低信号は水や血液などが映し出され、解剖学的構造を確認することが可能である。T2 強調画像は横緩和による核磁化分布を画像化しており、高信号では水、血液、脂肪を、低信号では出血、石灰化、繊維組織が映し出され、病変部を描出し病変が起こった箇所で高い輝度を示す。

プロトン密度 (PD) 強調画像とは撮影時に TR, TE 時間を調整することにより、T1, T2 時間いずれの影響も受けずに組織内のプロトン (水素原子核) 密度をコントラストとして表現を行う。

本研究ではこの PD, T1, T2 画像を統合し、統合された画像より脳組織の一部である白質や灰白質、CSF の抽出を目指した。

3. 多変量解析による画像認識

式 1 のように、画像 I を空間領域上で線形変換を行うことで、新しい空間上で画像処理や特徴抽出を行うことが可能である。

$$I = a_0 + s_1 a_1 + s_2 a_2 + \cdots + s_i a_i + \cdots + s_n a_n \\ = \sum_n^m s_i a_i \quad \dots \quad (1)$$

ここで、 a_0 は画像の直交成分であり 画像の平均を示す。また、 a_i は i の基底関数を意味し、 s_i はその係数で画像 I の各変換軸の射影を示す。この s_i は画像 I の特徴ベクトルとして考慮できる。

画像を空間領域へ変換し、新しい空間上手法として、これまでフーリエ変換やコサイン変換、Wavelet 変換などが多く提案してきた。しかしこれらの基底関数は数的的に決定されるもので、画像に対し最適な基底関数とはいえない。

統計的な手法の観点より、従来のフーリエ変換や wavelet 変換などに比べると、画像に適した基底関数を抽出できるので、柔軟かつ信頼性の高い画像処理・認識・

理解が期待できる報告がある⁽³⁾⁽⁵⁾⁽⁶⁾。

本研究において、統計的手法に基づいた多変量解析により求められた基底関数により画像の特徴を抽出し画像の認識や識別を行う手法をシステムに導入する。

4. 独立成分分析

近年、独立成分分析 (Independent Component analysis: 以下、ICA) と呼ばれる多変量解析による画像処理が注目されている。ICA とはデータ間における統計的独立性という極めて単純な指標に基づき、混合された信号から源信号を分離するという手法である。よって、ICA により画像に含まれるノイズが画像の各特徴と無相関であると仮定することで、各特徴を数学的に表現することが可能となる。一般的に ICA は時間遅れなく空間のみに混合された信号の分離 (blind source separation 以下: BSS) 問題を指すことが多い。

ICA の定式化を以下のように行う。

n 次元の観測信号を X 、分離したい m 次元の独立した信号源 S とおくと、式 1 に基づき下記の線形モデルが成立する。

$$X = AS \quad \dots \quad (2)$$

ここで、 A は $m \times n$ の full Column rank 行列の混合行列であるとする。

混合信号行列 A が既知である場合、単純に式 2 に従い、 A の逆行列を求めることで簡単に求まるが、BSS 問題の場合、 S 同様に A も未知であることから、観測信号 X より両者を推定する必要がある。

よって、ある $n \times m$ の分離行列 W 、分離信号を Y と仮定すると以下の式が成立する。

$$Y = WX \quad \dots \quad (3)$$

したがって、下記の式が成立すれば、 Y と S は一致することになる。

$$W = A^{-1} \quad \dots \quad (4)$$

ICA では、 Y の各成分が互いに統計的に独立となる W を求めることが目的である。一般的に W は解析によって求めることは困難であり、自然勾配法などで推定されている。

これまで、ICA の分離行列 W を求める手法は数多く提案されており、Bell-Sezonowski アルゴリズムはニューラルネットワークの出力信号情報を最大化する InfoMax 理論の応用に基づき W の推定を行っている⁽⁷⁾。

そのアルゴリズムに基づく更新式を以下に示す。

$$\Delta W = (I + g(y)y^T)W \quad \dots \quad (5)$$

ここで、 $g(y)$ はそれぞれ Y の要素により以下のよう

に計算を行う.

$$g(y) = 1 - 2/(1 + e^{-y}) \dots \dots \dots \quad (6)$$

なお, 信号が互いに独立であれば, 互いに無相関であり, 分離行列 W は信号を無相関化する行列でもある.

5. カーネル ICA による多変量解析

ICA は幅広く入力データの冗長性と特徴を抽出した線形変換の手法で多くの分野で利用可能であるが、MR 画像に含まれている多くの情報は非常に複雑であることから非線形性を考慮した解析が必要となってくる。

近年, *Bach-Jordan* は ICA にカーネルトリックを利用した, カーネル独立成分分析 (Kernel Independent Component Analysis : カーネル ICA, KICA) の手法を提案している⁽⁸⁾.

カーネル法とは入力ベクトル x を特徴空間と呼ばれる高次元空間中の $\phi(x)$ として非線形写像を行うことで、画像内の特徴を識別する手法として近年注目が高まって いる^{(9) (10) (11)}。

本研究で用いるカーネル法について述べる。本研究で用いたカーネルICAとはカーネル正準相関分析へICAを拡張して行う手法であり、カーネル法を基に評価関数の最小化を行う手法である。

線形データ解析アルゴリズムを特徴空間で行うことによって、非線形アルゴリズムが得られるということは、「内積」を使って表現される線形手法（射影、相関、分散共分散など）なら非線形に拡張が可能である。以上より、このカーネル法の利点は線形モデルでは捉えることの出来ない特徴を非線形上に射影を行うことで画像内の特徴を捉えることが可能となる。

以下にカーネルICAの定式化を行う.

線形空間におけるモデルを非線形問題に対応するためには「カーネルトリック」と呼ばれる手法に基づいて行われる。カーネルトリックとは、高次元に特徴を写像しながら、実際に写像された空間上で特徴計算を避け、カーネルの計算のみで行う計算法のことを指す。

元の特徴空間 \mathcal{R}^N における特徴ベクトル X を何らかの非線形関数 Φ により下式のように射影方法を以下に示す。

$$\Phi : X \in \Re^N \rightarrow \Phi(x) \in F \dots \dots \dots \quad (7)$$

一般的に、式(7)で得られた特徴空間の次元は非常に高く、計算コストが膨大となってしまう。そこで、非線形特徴空間 F における内積計算を下式のようなカーネル関数 K で表現することにより、 $\phi(x_i)$ と $\phi(x_j)$ とのない積を低次元の入力特徴ベクトル x_i, x_j のみを用いて計算することが可能となる。

$$K_{ij} := (\phi(x_i) \cdot \phi(x_j)) = k(i, j) \dots \dots \dots \quad (8)$$

式 8 により、非線形空間上の関数 $\phi(x)$ が未知であっても、カーネル関数と入力ベクトル X のみを用いることで、非線形特徴空間 F 上での様々な計算が可能となる。

カーネル関数として, Gaussian カーネル, 多項式カーネル, Sigmoid カーネルなどがあるが, 本研究では以下の Gaussian カーネルを用いて, カーネル関数として定義した.

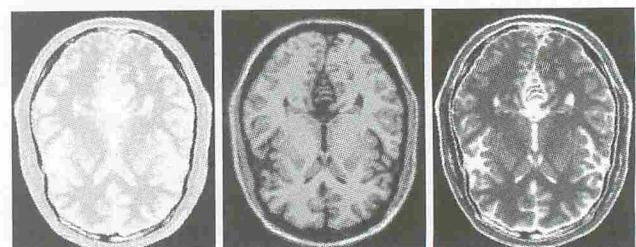
$$k(x_i, x_j) = \exp\left(-\frac{2}{\sigma^2}\|x_j - x_i\|^2\right) \dots \dots \dots \quad (9)$$

このカーネル関数を用いて、先に述べた ICA へ拡張することにより、特徴空間上において MR 画像からの特徴ベクトルを求ることで画像の強調化を行う。

6. 実験方法

実際に本研究で利用したデータはイギリスの Brain-Web(<http://www.bic.mni.mcgill.ca/brainweb/>)。よりファジー処理で作成された Phontom データを対象とした。Fig.1 に T1 画像, T2 画像, PD 画像を示す。

今回、解析の対象としてこの3枚の画像を入力ベクトル $X = \{T1, T2, PD\}$ として Fig.2 に各画像を合成した3次元画像 X を用いて先に述べたICAならびに提案法であるカーネルICAによる画像強調化を行った後に各結果についての比較を行った。



(a) PD Image (b) T1 Image (C) T2 Image
 Fig. 1. Typical Multi-spectrum MR Images

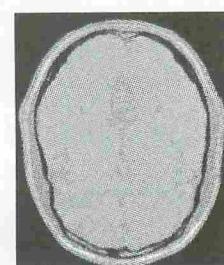


Fig. 2. 3-Dimensional Original MR Image

7. 実験結果

提案法による実験結果を以下に示す.

ICA ならびにカーネル ICA によって得られた分離行列, W_{IC} , W_{KIC} はそれぞれ以下のように得られた.

$$W_{IC} = \begin{bmatrix} 0.76489 & 0.22833 & 0.07193 \\ -0.28037 & 0.84825 & 0.18521 \\ -0.02122 & -0.23643 & 0.99838 \end{bmatrix} \quad (10)$$

$$W_{KIC} = \begin{bmatrix} -0.05086 & 0.05483 & 0.03818 \\ -0.03039 & 0.02095 & 0.04075 \\ 0.01592 & -0.00021 & -0.00950 \end{bmatrix} \quad (11)$$

式(10), 式(11)を用いて特徴画像を求めた結果をそれぞれ Fig.3(a), (b) に示す. また, ICA とカーネル ICA によって求められた各特徴画像をそれぞれ Fig.4, Fig.5 に示す. Fig.4, Fig.5 から確認できるように, ICA では線形変換で画像を強調しており画像のコントラストを向上させている.

一方, カーネル ICA で求められた変換画像は白質, 灰白質, CSF などの各脳組織の強調化が行われていることが確認できる. これは, カーネル ICA により非線形空間上で, 特徴空間の解析が行われていることから, 画像中の特徴をより鮮明に表現していることが確認できる.

実験において, 脳組織を強調していることを示すため, 我々は各結果より得られた画像を正規化し $Y = 75$ における X 軸プロファイルで実際に比較を行った. Fig.6 の (a)~(c) はデータベース上の各脳組織の画像, (d)~(f) は各入力画像, (g)~(j) に ICA より得られた強調画像, (k)~(m) にカーネル ICA によって得られた強調画像を示す. 各プロファイルの結果を Fig.7(a)~(c) に示す.

各結果から確認できるように, ICA 特徴画像のプロファイルは入力画像のコントラストの向上を行っていることが確認できる. 一方, カーネル ICA の結果はデータベース内の組織と追従しており, 脳組織の強調が行われていることが確認できる. よって, 本研究により, カーネル ICA をりようすることで MR 画像内におけるコントラストの強調を行うことと同時に脳組織の強調を行うことができることが確認され, 提案法は MR 画像中の脳組織強調として有効な手法であることがいえる.

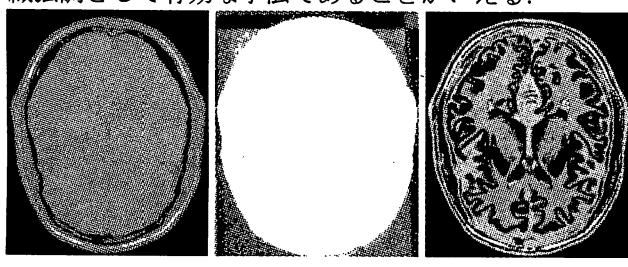
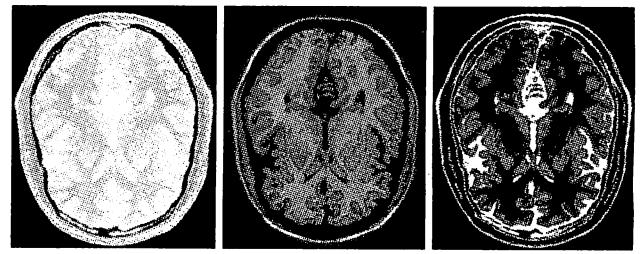
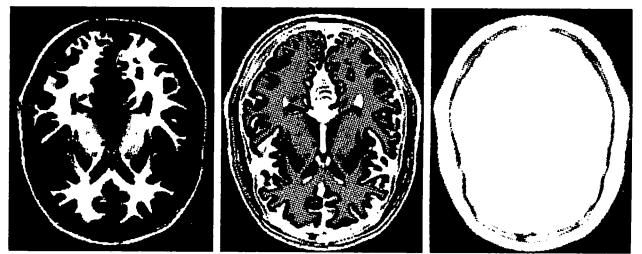


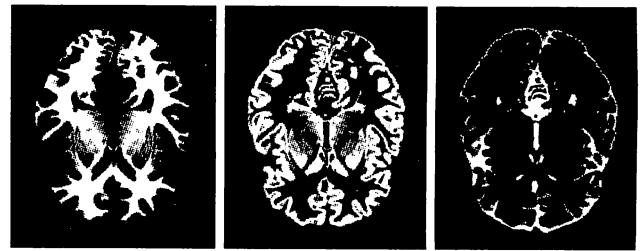
Fig. 3. A 3-dim MRI and Resulting Images



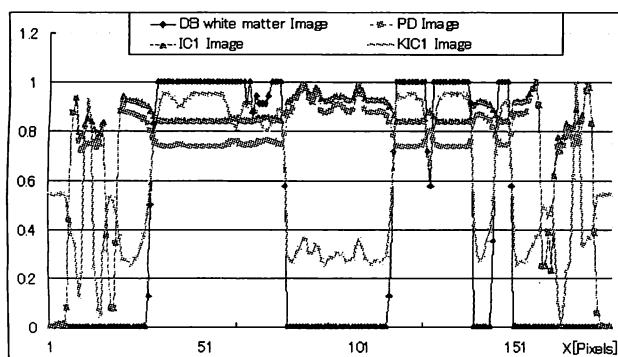
(a) IC Image1 (b) IC Image2 (c) IC Image3
Fig. 4. ICA Component Images



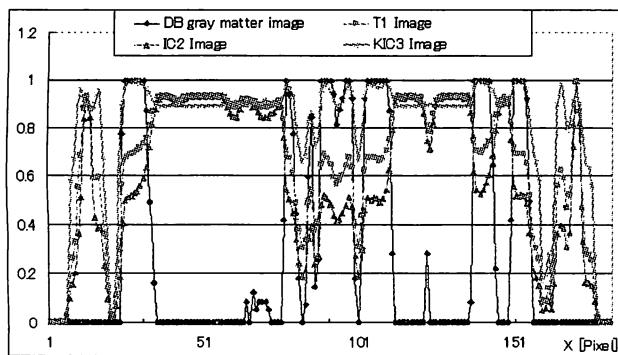
(a) KIC Image1 (b) KIC Image2 (c) KIC Image3
Fig. 5. Kernel ICA Component Images



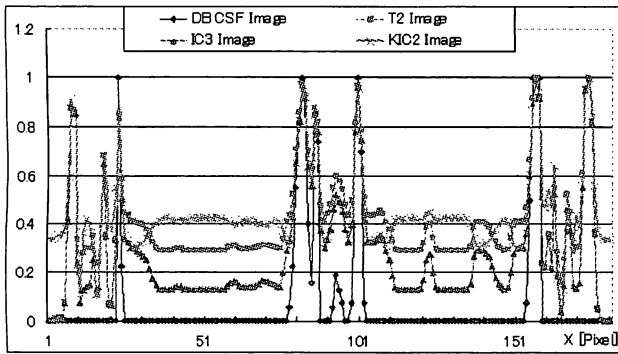
(a) White matter (b) Gray matter (c) csf matter
(d) PD Image (e) T1 Image (f) T2 Image
(g) IC Image1 (h) IC Image2 (i) IC Image3
(j) KIC Image1 (k) KIC Image2 (l) KIC Image3
Fig. 6. Brain matters: ICA and KICA images compared



(a) White matter vs PD vs IC1 vs KIC1



(b) Gray matter vs T1 vs IC2 vs KIC2



(C) CSF vs T2 vs IC3 vs KIC3

Fig. 7. Profile Comparisons(Y=75)

8. 結 論

本研究において、カーネル ICA を用いた画像強調について提案を行った。従来法では画像自体のコントラストが向上したもの、画像内の脳組織の強調を行えなかったのに対し、提案法は画像のコントラストの強調のみではなく、脳組織内の特徴強調を行うことが得られた画像より確認できた。また、各画像を $Y = 75$ で X 軸プロファイルを取り比較を行うと、ICA では画像のコントラストを強調するのに対し、カーネル ICA による結果は各脳組織の強調を行うことが可能となることが確認できた。カーネル ICA を利用することで入力された画像はそれぞれ高次元の特徴空間において各特徴に射影さ

れ、より詳細な解析を行えることから、提案法は MR 画像からの脳組織強調に対し有効な手法であることが確認された。

今回、本手法は Phomtom データを利用しているが、今後の課題として実際の脳腫瘍データを用いた大規模なデータベースを用いて本手法の評価を行うこと、ならびに今回抽出の対象外であった別組織の抽出を行うことなどが挙げられる。

9. 謝 辞

本研究において、多くの有益な議論をしていただきました立命館大学情報理工学部メディア情報学科の陳延偉教授、ポストドクターの韓先花博士、知的画像処理研究室の皆様ならびに沖縄高専情報通信システム工学科の野崎真也助教に深く感謝をいたします。また本研究は、SCOPE No.072311002 の研究の一部として協力をいたしております。本研究の一部は 2007 年 11 月 26 日に台湾高雄市で開催された IIH-MSP2007 において成果報告⁽¹⁾を行いました。

文 献

- (1) Tomoko Tateyama, Zensho Nakao, Yen-Wei Chen: "Brain Matters Emphasis in MRI by Kernel Independent Component Analysis," pp. 117-120, Third International Conference on International Information Hiding and Multimedia Signal Processing - Vol.1 (IIH-MSP 2007), 2007
- (2) T.Nakai, S.Muraki, E.Bararinao, Y.Miki, Y.Takehara, K.Matsuo, C.Kato, H.Sakabara and H.Izoda: "Application of independent component analysis to magnetic resonance imaging for enhancing the contrast of gray matter and white matter," *NeuroImage* 21:251-260, 2003.
- (3) 村木茂: "独立成分分析と医用画像処理," *Med Imag Tech*, 20(1), pp.36-45, 2002.
- (4) Y.-W. Chen and D. Sugiki: "Segmentation of MR images using independent component analysis," *KES*, 2:63-69, October 2006.
- (5) 陳延偉: "独立成分分析(1) - カクテルパーティー. 効果," *Med Imag Tech* 21(1) : PP.81-85, 2003.
- (6) 陳延偉: "独立成分分析法(ICA)のパターン認識・画像処理への応用と MATLAB シミュレーション," トリケップス, 2007
- (7) A. J. Bell and T. J. Sejnowski: "An information maximization approach to blind separation and blind deconvolution," *Neural Computation*, 7:1129-1159, 1995.
- (8) F. R. Bach and M. I. Jordan: "Kernel independent component analysis," *Journal of Machine Learning Research*, 3:1-48, July 2002.
- (9) 赤穂昭太郎: "カーネルマシン," 信学技報, NC-2003-34, 2003.
- (10) 赤穂昭太郎: "カーネル正準相関分析," 情報論の学習理論ワークショップ (IBIS2000) 予稿集, pp.123-128, 2000.
- (11) S. Mika, B. Scholkopf, A. Smola, K.-R. Muller, M. Scholz, and G. Ratsch: "Kernel PCA and de-noising in feature spaces," in *Advances in Neural Information Processing Systems* 11, 1999.
- (12) J. Cheng, Q. Liu, H. Lu, and Y.-W. Chen: "Texture classification using kernel independent component analysis," *ICPR*, 1:620-623, 2004.
- (13) 國枝琢也, 内山良一, 原 武史, 藤田広志, 加藤博基, 浅野隆彦, 星博昭, 山川弘保, 安藤弘道, 岩間 亨: "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, 2008.1