

脳萎縮の定量化における領域抽出と組織分類

大谷 寿光[†] 佐藤 和人[†] 間所 洋和[†] 犬上 篤^{††}

[†] 秋田県立大学大学院システム科学技術研究科 〒015-0055 秋田県由利本荘市土谷字海老ノ口 84-4

^{††} 秋田組合総合病院診療部長 〒010-0948 秋田県秋田市飯島西袋 1-1-1

E-mail: †{m11a004,ksato,madokoro}@akita-pu.ac.jp

あらまし 本論文では、脳萎縮の程度を定量的に解析する際の専門医の負担軽減を目的に、頭部 MR (Magnetic Resonance) 画像の輝度特性に基づく情報のみを用いて脳領域を抽出し、脳の各組織を自動分類する手法を提案する。脳領域の抽出では、可変形状モデルの LSM (Level Set Methods) のパラメータを進化的学習の GA (Genetic Algorithm) を用いて対象画像に合わせて最適化し、脳領域を抽出する。脳組織の分類では、抽出した脳領域を対象に、まず、SOMs (Self-Organizing Maps) を用いて画像の連続性や境界の位相特性を保持しながら近傍学習し、非線形な写像空間を利用して輝度を量子化する。次に、Fuzzy ART (Adaptive Resonance Theory) を用いて非線形に量子化された輝度分布の順序性に基づき脳組織に統合する。臨床画像を用いた評価実験では、脳ドック受診者の 30 代から 70 代の男女 60 症例の年代別 MR 画像データベースに適用した。その結果、脳領域の抽出では、47 症例で 90.0 % 以上の一致率が得られた。また、脳組織の分類では、加齢と脳脊髄液の増加について有意な相関を確認した。

キーワード 頭部 MR 画像, 脳萎縮, 脳領域, LSM, GA, 脳組織, SOMs, Fuzzy ART

Extract Region and Segment Tissues in Quantification of Brain Atrophy

Toshimitsu OTANI[†], Kazuhito SATO[†], Hirokazu MADOKORO[†], and Atusi INUGAMI^{††}

[†] Graduate School of Systems Science and Technology, Akita Prefectural University 84-4 Aza Ebinokuchi Tsuchiya, Yurihonjo City, 015-0051 Japan

^{††} Akita Kumiai General Hospital, 273-1, Nishibukuro, Iijima, Akita 011-0948, Japan

E-mail: †{m11a004,ksato,madokoro}@akita-pu.ac.jp

Abstract This paper presents a method for extracting brain region according to brain structure and automatic segmenting brain tissues based only on the brightness distribution of head MR (Magnetic Resonance) images. Our method is constructed of two steps of brain tissues for quantification of brain atrophy. The first step is to extract brain regions using LSMs (Level Set Methods) whose parameters are optimized by GA (Genetic Algorithm) to adapt to the target image. The second step is to segment brain regions using hybridized SOMs (Self-Organizing Maps) and Fuzzy ART (Adaptive Resonance Theory). Brain regions are segmented with high granularity regions using SOMs. Subsequently, these regions are integrated with Fuzzy ART while maintaining relations of anatomical structures of brain tissues and the order of brightness on head MR images. In evaluation experiment using clinical images, we applied our method to a head MR image database including data of 30 men and women in their 30s-70s. Extraction accuracy of brain region shows over 90.0 percent in 47 cases. Moreover, segmentation results of brain tissues revealed a significant correlation between aging and expanding of CSF(cerebrospinal fluid).

Key words Head MR image, Brain atrophy, Brain region, LSM, GA, Brain tissue, SOMs, Fuzzy ART

1. はじめに

近年, MRI (Magnetic Resonance Imaging) や X 線 CT (Computed Tomography) など撮像装置の進歩により高解像度の医用画像が大量に撮像され, 各種疾病の診断に大きな役割を果たしている。中でも MRI による画像は軟部組織を明瞭に描出することから, 頭部や腹部などの画像診断で重要な情報源になっている。また, 普及

が顕著な脳ドックでは, 異なる条件で撮像された数十枚の MRI 断層像を用いて, 画像所見から読影専門医が脳の萎縮や疾患 (脳腫瘍, 脳出血, 脳梗塞等) の有無を調べている。

人の脳は加齢と共に萎縮するが, 脳の萎縮は加齢だけでなく, 血圧, 飲酒といった脳血管障害危険因子との相関が報告されている。さらに, アルツハイマー病, Pick 病などの脳萎縮を伴う変形疾患も多数存在することが

ら、通常に加齢変化と病的な脳萎縮を鑑別する必要があり、脳萎縮の評価は脳画像診断において重要な指標の1つである。脳実質は主に神経細胞体からなる灰白質 (Grey Matter:GM) と神経繊維からなる白質 (White Matter:WM) で構成される。GM の体積は加齢と共に減少するが、WM の体積は血管周囲構造の変化により、必ずしも加齢により減少しないとの報告がある [1]。そのため、画像解析により脳萎縮を評価する際は、萎縮の程度を示す脳脊髄液 (Cerebrospinal Fluid:CSF) に加えて、GM と WM を分類することが求められる。しかしながら、脳萎縮の評価を客観的に行うことは容易ではなく、読影専門医が経験を基に主観的に診断しているのが現状である。

MRI を用いた脳の形態学的な画像研究は、関心領域 (Region of Interest:ROI) や解析に供する断面の選択に作業者の主観が入ることや、インタラクティブな解析では大量のデータを扱うことができず解析時間がかかることなどの問題がある。客観的な脳萎縮の評価を脳ドックなどの臨床現場で広く用いるためには、撮像した MR 画像を入力することで煩雑な手続きを必要とせず、可能な限り自動的に処理を行うことが重要である。

本論文では、脳萎縮の程度を定量的に解析する際の読影専門医の負担軽減を目的に、個人の脳構造に沿って ROI を自動抽出し、頭部 MR 画像の輝度特性に基づく情報のみを用いて、脳の各組織を自動分類する手法を提案する。本手法の特徴は、操作する読影専門医の主観によらず読影対象の画像特性のみから脳萎縮の程度を定量化する点にある。提案手法は、萎縮の ROI を示す脳領域の抽出ステップと萎縮の程度を数値化する脳組織の分類ステップで構成される。脳領域の抽出ステップでは、可変形状モデルの LSM(Level Set Methods) における境界の結合や分離が制御可能なエネルギーバランスに着目し、GA(Genetic Algorithm) を用いて対象画像に合わせて最適化することにより ROI を自動抽出する。脳組織の分類ステップでは、写像特性の異なる 2 つの教師なしニューラルネットワークのハイブリッド化に着目する。初めに、SOMs(Self-Organizing Maps) を用いて脳組織の連続性や境界の位相特性を保持しながら、近傍学習により 1 次元の非線形な写像空間を利用して輝度を量子化する。次に、Fuzzy ART(Adaptive Resonance Theory) を用いて非線形に量子化された輝度の順序性を追加学習することにより、脳組織に対応した量子化数に統合する。

本手法を脳ドック受診者男女 60 症例に適用した結果、脳領域の抽出では、47 症例で 90.0 % 以上の一致率が得られた。また、脳組織の分類では、加齢に伴う各組織の占有率について有意な相関を確認したので報告する。

2. 周辺研究

近年、自由形状の領域抽出では偏微分方程式 (Partial Differential Equation : PDE) を用いた画像応用研究が

注目されている。PDE を利用する画像処理は、濃度勾配や曲率など画像中の幾何学的特徴を直接操作できることが大きな特徴であり、偏微分という局所的な演算の組み合わせにより、画像全体の大局的なエネルギーを操作することができる。中でも Kass らにより提案された Snakes [2] や Sussman らにより提案された LSM [3] が代表的な手法である。Snakes は、物体のエッジ情報や輪郭形状の滑らかさを基に対象物体の輪郭を形成するため、途切れたエッジを補間しながら対象物を抽出できる特徴を有する。LSM は PDE に基づき境界線を変形させる手法であり、境界の結合や分離などの位相変化が可能である。和田らは、複数の臓器を LSM を用いて抽出しているが、LSM の初期輪郭のエネルギーと抽出対象臓器の形状情報を確認しながら輪郭を更新している [4]。したがって、形状が複雑な対象物への適用ができない。座間らは、輪郭の内部と外部を二つのクラスとし、判別基準に基づいて LSM を適用している [5]。しかしながら、対象物の側面部よりも内側の輝度が大きい場合、輪郭が内部まで進行してしまう問題がある。

頭部 MR 画像を対象とした組織分類には、様々な手法が提案されており [6] [7] [8]、大きく分けて分類対象組織の代表点を事前に設定する手法と、そのような操作を必要としない手法がある。代表点を事前に設定する方法では、精度面で優位であるものの、分類結果が読影専門医の主観に強く依存する傾向にある。また、代表点の数が少ないと、学習データの不足から特化した学習が行われ汎化能力が低下する。一方で注目されているのが、代表点の設定を必要としない組織分類法である。我々は以前、SOMs [9] がもつ自己写像特性に着目し、頭部 MR 画像における輝度特性や輝度分布のみから脳組織 (CSF, GM 及び WM) を分類している [10]。従来手法では SOMs の写像空間を 1 次元とし、その大きさを近傍形成が可能な最少の 5 ユニットとしているが、対象画像によっては写像空間は十分ではなく、対応づけられる脳組織に偏りが発生するケースがある。このような場合、読影専門医が組織との対応関係を確認しながら割当てを行っていた。

3. 提案手法

提案手法は、脳領域の抽出ステップと萎縮の程度を数値化する脳組織の分類ステップで構成される。脳領域の抽出ステップでは、可変形状モデルの LSM における境界の結合や分離が制御可能なエネルギーバランスに着目し、GA を用いて対象画像に合わせて最適化することにより脳領域を抽出する。脳組織の分類ステップでは、写像特性の異なる 2 つの教師なしニューラルネットワークの SOMs と Fuzzy ART [11] をハイブリッド化し、輝度特性に基づく情報のみを用いて脳組織に分類する。

3.1 脳領域の抽出ステップ

頭部 MR 画像の脳領域は、図 1(a) 中の矢印で示すよ

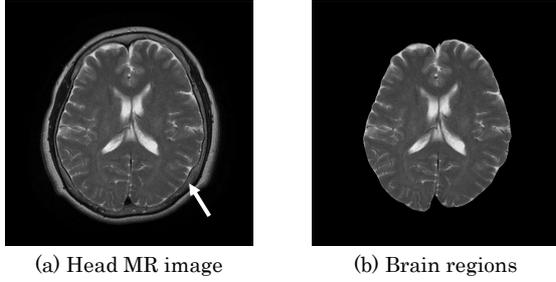


図 1 頭部 MR 画像と脳領域

Fig. 1 Head MR image image and brain region.

うに硬膜領域に厚く覆れている．脳領域は硬膜が隣接，または囲まれているが，硬膜と脳領域の輝度勾配差を利用する LSM を用いることで，脳の解剖学的構造情報に沿った脳領域の抽出を行う．しかしながら，LSM は初期化や更新による計算コストが高く，特に抽出対象となる画像や領域ごとに境界の更新式に関するパラメータを設定しなければならないなどの問題点を有する．そこで本手法では，境界線の変形制御に寄与する LSM の外部エネルギー項に着目し，対象画像の濃度勾配や脳組織の幾何学的特徴に合わせてパラメータを GA を用いて最適化することで脳領域を抽出する．

3.1.1 レベルセット法

LSM は，閉曲線の形状によって定義される内部エネルギーと画像情報によって定義される外部エネルギーとの和を最小化する問題として定式化される．1 次元高い空間で定義された補助関数のゼロ等高面 (zero level set) を注目する輪郭とみなし，境界の更新条件である PDE を数値的に解いて補助関数の形状を変更し，そのゼロ等高面を検出することで境界形状を動的に制御する．LSM のアルゴリズムを下記に示す．

LSM の輪郭線を $v(s) = (x(s), y(s))$, ($s \in [0, 1]$)， w を重み係数とすると，輪郭のエネルギー算出式は以下のようになる．

$$E = \int_0^1 E_{\text{int}}(v(s)) + w E_{\text{ext}}(v(s)) ds \quad (1)$$

内部エネルギー E_{int} ，外部エネルギー E_{ext} は，

$$E_{\text{int}} = \mu [\Delta \phi - \text{div}(\frac{\nabla \phi}{|\nabla \phi|})] \quad (2)$$

$$E_{\text{ext}} = \lambda \delta(\phi) \text{div}(g \frac{\nabla \phi}{|\nabla \phi|}) + \nu g \delta(\phi) \quad (3)$$

となる．ここで， ϕ は記号付距離関数， Δ はグラディエント演算子， ∇ はベクトル微分演算子， g は標準偏差 σ のガウシアンフィルタ， $\delta(\phi)$ はダイラック関数である．また， μ は曲率を制御し，輪郭を形成する． λ は，大きいほど輝度勾配の大きい領域で速度が遅くなる． ν は 0 から遠くなるほどに輪郭の進む速度が上がる．この ν は初期輪郭から目標となる輪郭が内側にある場合は負の値，外側ならば正の値である． E_{int} は輪郭の形状を滑らかに

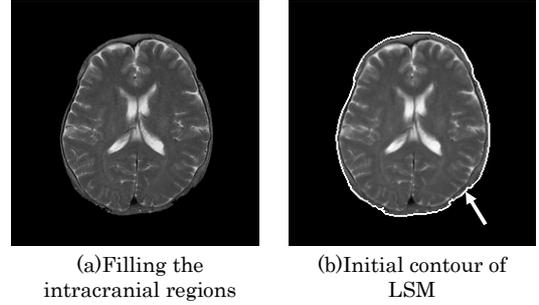


図 2 頭蓋内領域の抽出結果と LSM の初期輪郭

Fig. 2 Filling the intracranial regions and initial contour of LSM.

表 1 LSM の最適化対象パラメータ

Table 1 The range of optimization parameters of LSM.

parameter	range	interval
λ	$5.0 < \lambda < 20.0$	0.1
ν	$-5.0 < \nu < -1.0$	0.1
I	$1 < I < 500$	1

する働きがあり， E_{ext} はモデルの輪郭を画像中のエッジに引きつける働きがある．

ダイラック関数を以下に示す．

$$\delta_\varepsilon(x) = \begin{cases} 0 & , |x| > 0 \\ \frac{1}{2\varepsilon} [1 + \cos(\frac{\pi x}{\varepsilon})] & , |x| \leq 0 \end{cases} \quad (4)$$

ε は LSM の輪郭を動かす働きを左右するパラメータである．LSM の更新式は，

$$\frac{\partial \phi}{\partial t} = \mu [\Delta \phi - \text{div}(\frac{\nabla \phi}{|\nabla \phi|})] + \lambda \delta(\phi) \text{div}(g \frac{\nabla \phi}{|\nabla \phi|}) + \nu g \delta(\phi) \quad (5)$$

となる．更新回数を制御する Iterarions(I) によって式 (5) を繰り返し処理することで輪郭を更新する．

3.1.2 最適化対象パラメータの選択

LSM の初期輪郭の形状や設定位置が輪郭探索結果に与える影響は大きいことから，対象物の付近に初期輪郭を設定することが望ましい．図 2 に頭蓋内領域の抽出結果と LSM の初期輪郭を示す．まず，原画像に対し閾値の自動選定を行い，2 値化画像を作成する．続いて，最大オブジェクトを抽出し，穴埋め処理後，原画像をマスク処理し，頭蓋内領域を抽出する．LSM の初期輪郭は，原画像から抽出した頭蓋内領域の外輪円 (図 2(b) 中の矢印で示した白線) とした．

LSM の最適化対象パラメータとパラメータ範囲，間隔を表 1 に示す．輪郭を動かす働きを左右する LSM のパラメータのうち，任意に設定が必要となるのは， μ ， λ ， ν ， ε と I である． μ は，輪郭の滑らかさや連続性を保つ働きがあり，大きく変化させると輪郭の形状は分離してしまう．したがって，輪郭の形状を滑らかに保つために固定値とした．一方で λ ， ν ， ε は輪郭を動かす働きがある．これらのパラメータのうち， ε は，ダイラック関数

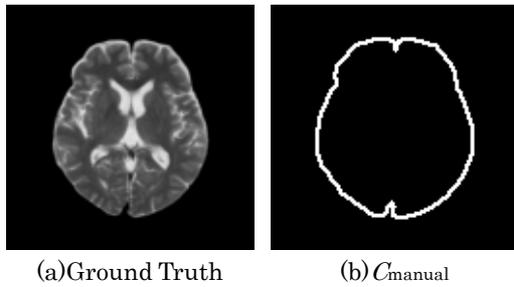


図 3 適応度関数

Fig. 3 The images to calculate fitness function.

でパラメータの変動範囲が微小であり、輪郭の更新に与える影響が少ない。λ, ν は、輪郭を動かす働きのある外部エネルギーの係数であり、パラメータ変化に大きく左右される。同様に I は輪郭の更新回数であり、抽出結果に大きく影響する。本研究で最適化する LSM のパラメータは、λ, ν, と I とする。なお、最適化対象パラメータの有効範囲は、パラメータのバランスと脳領域に輪郭が入り込まないことを考慮し、 $5.0 < \lambda < 20.0$ (0.1 ステップ), $-5.0 < \nu < -1.0$ (0.1 ステップ), $1 < I < 500$ (1 ステップ) とした。ν は正の値で輪郭が外側に進み、負の値で内側に進むという特徴があり、本手法では、輝度情報の少ない背景側に LSM の初期輪郭を設定したため、負の値に設定した。

3.1.3 GA の適応度関数

本手法では、抽出した輪郭と Ground Truth の輪郭との一致率を適応度関数に用いた。なお、図 3(a) Ground Truth は脳領域を手動で抽出し、読影専門医が脳の解剖学的構造に基づき抽出された脳領域であると評価した画像を用いた。適応度関数を以下に示す。

$$\text{適応度 (\%)} = \frac{\#(C_{\text{result}} \cap C_{\text{manual}})}{\#(C_{\text{result}})} \times 100 \quad (6)$$

C_{result} は本手法により抽出した領域の輪郭であり、図 3(b) に示した C_{manual} は図 3(a) の輪郭である。また、 $\#(C)$ は領域 C に含まれる画素数である。本研究では脳領域の萎縮率に着目しているため CSF を残すように脳領域を抽出する必要がある。輪郭の一致率は Ground Truth 領域の輪郭の背景側のみに 1pixel マージンを持たせ、背景側に正解となる領域を広げることで CSF を残すように脳領域を抽出する。本手法では、臨床画像 60 症例の Ground Truth を作成し、対象画像に合わせて LSM のパラメータの最適化を行う。

また、GA の選択方法は、世代交代するにつれて、最大適応度の進化が見られた roulette とした。個体数が 40 以上、世代数が 20 以上に設定した場合、最大適応度に変化が現れず、収束してしまうことから、個体数、世代数は、それぞれ 20, 40 とした [12]。

3.2 脳組織の分類ステップ

前章で抽出した脳領域を対象に、写像空間の異なる 2

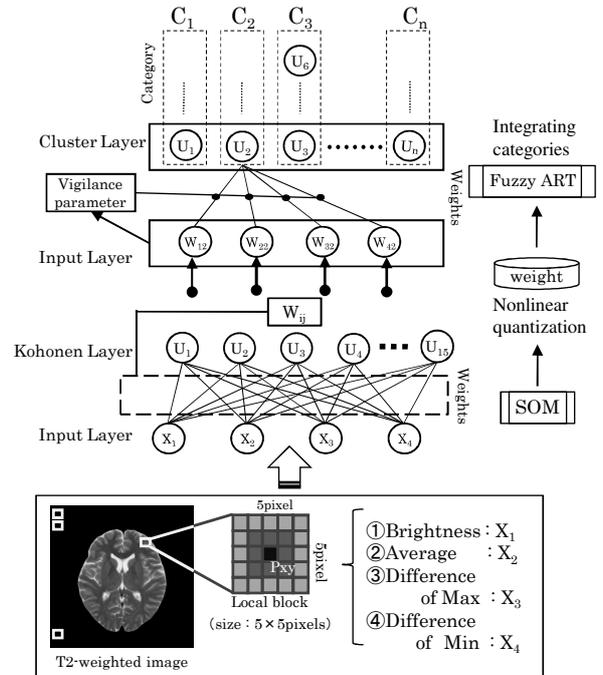


図 4 本手法の処理フロー

Fig. 4 Network architecture of our method.

つの教師なしニューラルネットワークのハイブリッド化に着目し、頭部 MR 画像の輝度特性に基づく情報のみから脳組織を分類する。初めに、SOMs を用いて画像の連続性や境界の位相特性を保持しながら近傍学習し、1次元の非線形な写像空間を利用して輝度を量子化する。次に、Fuzzy ART を用いて輝度分布の順序性に基づき写像空間を追加学習することにより量子数を脳組織に対応するよう統合する。本手法の処理フローを図 4 に示し、詳細を以下に記す。

3.2.1 SOMs による非線形量子化

SOMs は近傍学習を行うことから、頭部 MR 画像の示す輝度分布の近傍領域を形成し、非線形に量子化の特徴を有する。図 5(a) に頭部 MR 画像の輝度ヒストグラムと SOMs による非線形量子化の例を示す。輝度ヒストグラムは、SOMs によって対象画像の輝度特性を反映した組織の連続性と境界を近傍学習することで量子化される。SOMs の入力層に与える特徴量は、輝度値、平均値、最大値差分及び最小値差分の 4 種類とした [13]。これは、対象画像における注目画素の輝度値及び算出した各種特徴量である。まず対象画像からランダムに注目画素を選択し、局所ブロックを決定し、局所ブロック内の各種特徴量を算出する。頭部 MR 画像は異なる組織が類似した輝度値で画像化されることから、組織の連続性として平均値、組織の境界として最大値差分、最小値差分を選択し、SOMs に入力して自己学習を行った。SOMs の学習アルゴリズムを以下に記す。

(1) w_{ij} ($1 \leq i \leq n, 1 \leq j \leq m$) は、時刻 t における入力層ユニット i からマップ層ユニット j への結合荷重とする。ここで結合荷重を乱数で初期化しておく。

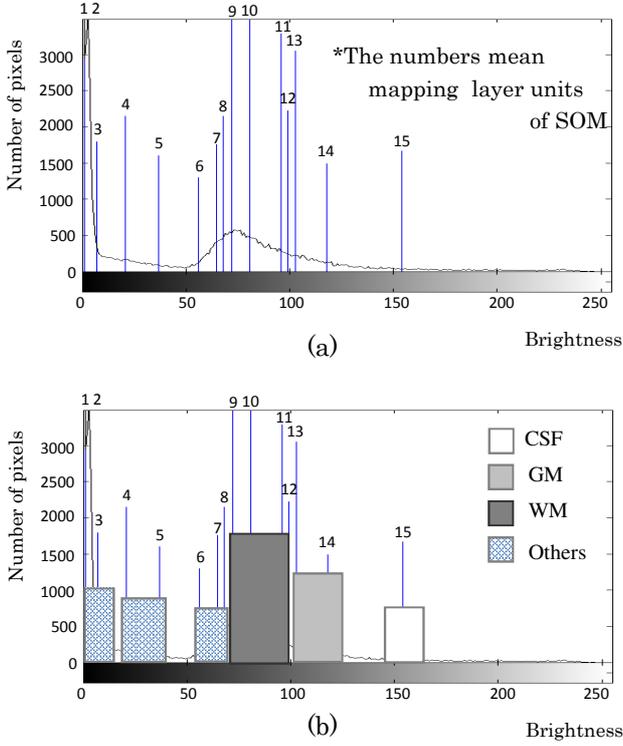


図5 頭部MR画像の輝度ヒストグラム:(a)頭部MR画像の輝度ヒストグラムとSOMsによる非線形量子化, (b)Fuzzy ARTによるカテゴリの統合

Fig. 5 Brightness histogram of head MR image:(a)histogram of brightness by head MR image and histogram with nonlinear quantization of SOMs, (b)histogram with integration of Fuzzy ART.

(2) $x_i (1 \leq i \leq n)$ を時刻 t における入力層ユニット i への入力データとする.

(3) x_i と w_{ij} のユークリッド距離 d_j を計算する.

$$d_j = \sqrt{\sum_{i=1}^n (x_i(t) - w_{ij}(t))^2} \quad (7)$$

(4) d_j が最小となるマップ層ユニット c を探索する.

(5) $N_c(t)$ で定義される近傍領域に含まれる結合荷重を更新する.

$$w_{ij}(t+1) = w_{ij} + \alpha(t)(x_i(t) - w_{ij}(t)) \quad (8)$$

$\alpha(t)$ は学習率係数 ($0 < \alpha < 1$), $N_c(t)$ は近傍領域であり, 学習の進行とともに減少させる.

(6) ステップ(2)~(5)を最大学習回数に達するまで繰り返す.

本手法では, SOMsの学習率 $\alpha(t)$ を0.5, 重みを更新する近傍領域 $N_c(t)$ をマップ層ユニット数の2/3, 学習回数は10,000回とした.

3.2.2 Fuzzy ARTによるカテゴリの統合

Fuzzy ARTは, 安定性と可塑性を有する追加学習型のニューラルネットワークの理論モデルである. SOMsの結合加重をFuzzy ARTの入力として追加学習する. 図

5(b)にFuzzy ARTによるカテゴリの統合結果を示す. 脳組織は, 高輝度順にCSF, GM, WMであり, カテゴリ統合の際には順序性を保持する必要がある. Fuzzy ARTを用いることで, 順序性に従って脳組織に対応した量子化数に統合する. Fuzzy ARTの学習アルゴリズムを以下に記す.

(1) F2層の各ユニット i に対応するF1層との間の結合荷重を w_i とし, すべての要素を1に初期化する.

(2) 入力 x が与えられたときに, F2層の各ユニット i に対して, 選択強度 T_i を次式により計算する.

$$T_i = \frac{|x \wedge w_i|}{a + |w_i|} \quad (9)$$

(3) T_i の最大値を与える c を勝者ユニット T_c として選択する. 複数の勝者が存在するときは, 最小のインデックスのユニットが選択される. T_c が選択されたとき, F2層の c 番目のユニットの活動が1, それ以外のユニットの活動は0となる.

(4) x が選択されたカテゴリに共鳴するか, そのカテゴリをリセットするかの判断を次式により行う. F2層の c 番目のユニットからの信号のF1層への伝達によるF1層の活動値 $x \wedge w_c$ に対して, マッチング関数

$$\frac{|x \wedge w_c|}{|i|} \geq p \quad (10)$$

のとき, x と c が共鳴し, 選択が確定するとともに, 次式により結合荷重が更新される.

$$w_{i0} = r(x \wedge w_{i0}) + (1-r)w_c \quad (11)$$

共鳴しない場合は, c はリセットされ, 次に大きい T_i の値を与えるユニットが再選択され, 同様に共鳴かりセットかの判定がなされる. すべてのユニットがリセットされた場合はF2層に新たなユニットが生成され, カテゴリが追加される.

3.2.3 予備実験

SOMsの写像空間とFuzzy ARTの分類粒度を決定するために予備実験を行った. 対象となる画像は30代から70代の2症例ずつ, 計10症例を用いた.

A マップ層ユニット数の決定

SOMsの写像空間を広げることで, 広いダイナミックレンジを示す輝度分布に対し, 高粒度な組織分類となる. SOMsのマップ層は, 近傍形成が可能な最少ユニット数の5ユニットから写像空間を広げて実験を行った. 予備実験の結果を図6に示す. 図6は萎縮の進行と共に拡大するCSFの分類結果である. マップ層が5ユニットでは, 高輝度領域であるCSFはGMまで広がっている. これに対してユニット数を増やし写像空間を広げるに従って, 分類結果が広範囲に広がるという問題を改善し, 高輝度領域に沿って分類している. しかしながら, マップ層が17ユニットでは, 頭部MR画像上の特徴を持たない未発火のユニットが現れてしまう. したがって, 本手

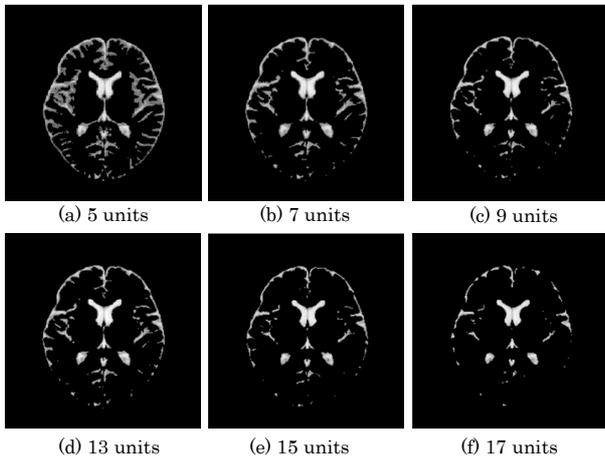


図 6 マップ層ユニット数による CSF の分類結果

Fig.6 Segmentation results of CFS according to mapping layer units.

法では組織分類するために十分な写像空間かつ未発火のユニットが現れない 15 ユニットとした。

B ビジランスパラメータの決定

Fuzzy ART のビジランスパラメータ ρ は、分類過程の分解能を制御し、一定の粒度でカテゴリの統合が可能である。本研究では、 ρ を 0.800 ~ 0.950 の範囲を 0.025 毎で実験を行った。図 7 に代表的な分類結果 (0.850, 0.875, 0.900) を示す。CSF は ρ の変化による大きな差異はみられないため、GM と WM の分類結果に着目した。 ρ が 0.900 以上では組織のオーバーラップ箇所が独立に分類され、GM を 2 つの領域に分けてしまう問題がある。 ρ が 0.850 以下では組織が拡大して分類され、GM と WM が同じ領域として抽出される。また、 ρ が 0.850 では、比較的良好な分類結果を示すが、対象画像によって GM が広範囲に分類される。 ρ が 0.875 ではどの対象画像に対しても、GM は CSF と WM の境界に沿う連続した帯状の領域を形成している。これらの実験結果を読影専門医の目視により判断してもらい、 ρ は GM と WM の境界が脳構造に沿った良好な結果である 0.875 に設定した。

4. 脳ドックデータを用いた評価実験

脳ドック受診者の 30 代から 70 代の男女 60 症例の頭部 MR 画像を用いて評価実験を行った。

4.1 脳領域の抽出結果

臨床画像 60 症例の Ground Truth を作成し、本手法を全ての臨床画像に適用対してパラメータを最適化し脳領域を抽出した。抽出した 60 症例の結果のうち 2 症例を図 8 に示す。原画像中の矢印は硬膜領域を示す。図中の (a) のように、硬膜がまばらに分布している画像や、(b) のように全体が覆われている症例に対しても硬膜を除去し、脳領域を抽出できた。一致率はそれぞれ、(a)100.0%、(b)95.3%であった。本手法は 60 症例中、47 症例で 90.0%を以上の一致率が得られた。

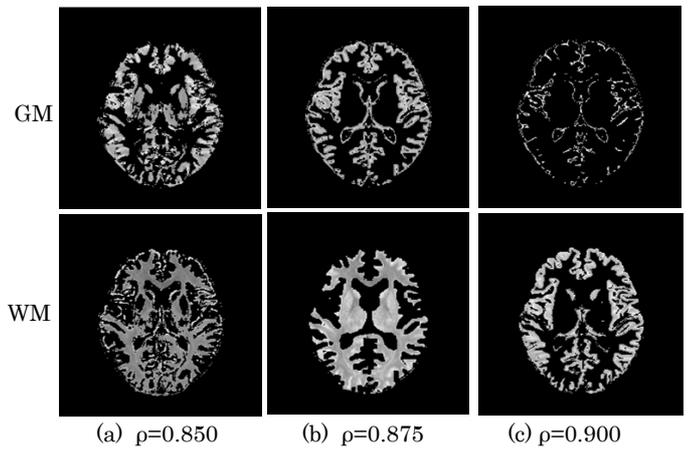


図 7 ビジランスパラメータによる GM と WM の分類結果

Fig.7 Analysis of segmentation results of gray and white matter according to vigilance parameters.

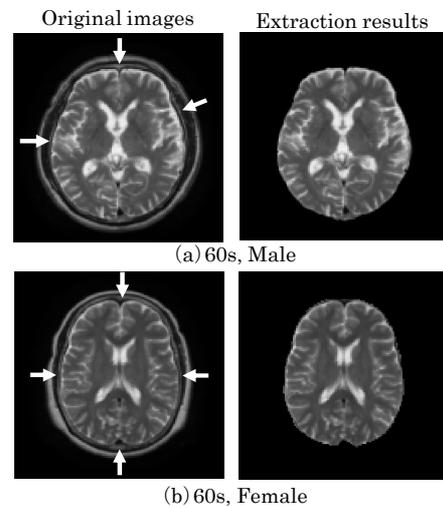


図 8 脳領域の抽出結果

Fig.8 Extraction results of brain regions with our method.

最適化対象パラメータを手動で設定した結果と本手法の結果を比較する。まず、各年代の代表画像を 2 症例ずつ選択し、10 症例に対して抽出結果が良好と思われるパラメータを設定した。なお、パラメータはそれぞれ $\nu = -0.5$, $\lambda = 8.0$, $I = 200$ である。これらのパラメータを用いて 60 症例に適用した。手動設定では、硬膜を除去し、高い一致率が得られた症例もあるが、一致率が 10.0%未滿の低い症例もあった。また、対象画像によっては脳領域の内部に入り込む症例も見られた。したがって、一意にパラメータ設定することは困難であり、対象画像によって最適なパラメータは異なる。

図 9 に 60 症例に対する手動設定と本手法の一致率を示す。手動設定では一致率が、0.0% ~ 80.0%と広範囲に分布しているが、本手法では全データにおいて 70.0%以上の抽出結果が得られた。また、すべての画像において、CSF に入り込むことなく抽出できている。LSM は、画像上の輝度勾配情報を利用して輪郭を移動することから、輝度勾配差が大きいところで輪郭の移動を停止

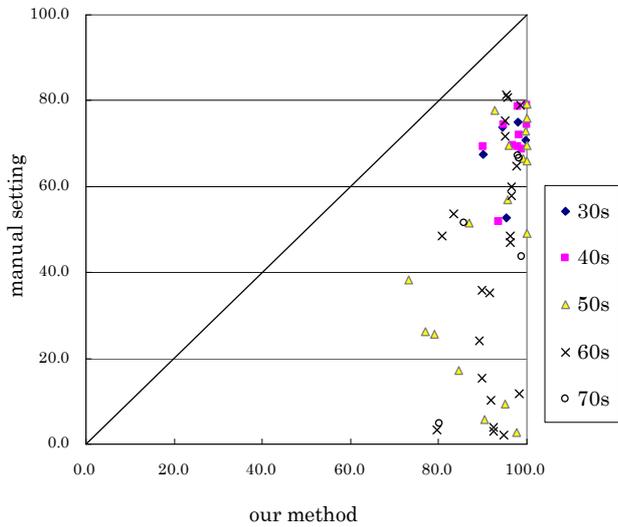


図 9 60 症例に対する手動設定と本手法による散布図.

Fig.9 Extraction accuracy with manual setting method and our method in 60 cases.

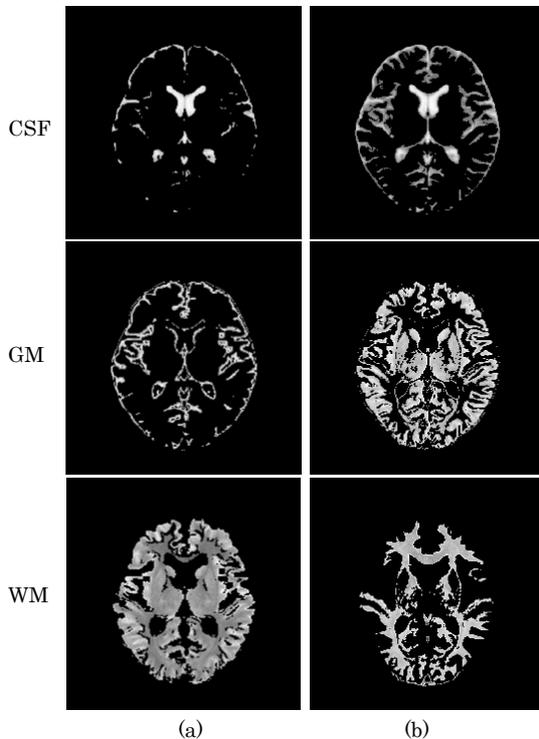


図 10 従来法と本手法による組織分類結果:(a) 本手法の組織分類結果,(b) 従来法の組織分類結果

Fig.10 Results of classification tissue compared with our method and conventional method:(a)result of our method(b)result of the former method.

する．図 8 の (a) や (b) は CSF と硬膜が隣接しているため高い一致率が得られた．

4.2 脳組織の分類結果

本手法を用いた組織分類結果を図 10(a) に、また、比較のために SOMs のマップ層を 5 ユニットとしていた従来法の組織分類結果を図 10(b) に併示する．本手法では、CSF と GM の境界は類似したコントラストを示すにも

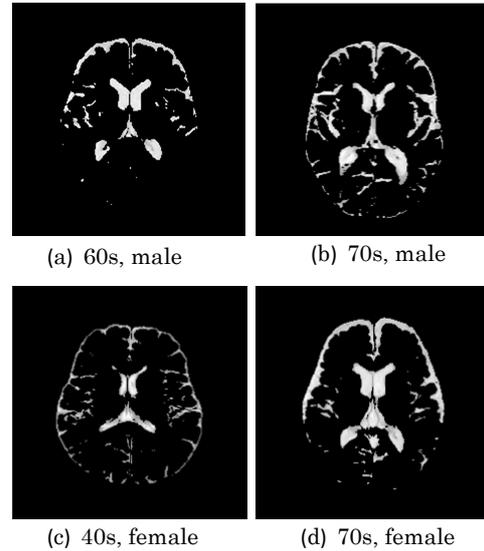


図 11 臨床画像による CSF の組織分類結果

Fig.11 Segmentation results of the CSF in the clinical head MR image.

かわらず、CSF は高輝度に沿って抽出できた．また、GM は CSF と WM の境界に沿う連続した帯状の領域を形成している．本手法と比べると従来法による組織分類結果では、CSF は広範囲にわたり分類され、GM とみならずべき領域まで及んでいる．同様に、GM も広範囲にわたり組織分類されている．これは、SOMs のマップ層を 5 ユニットと固定的に割り当てていたため、頭部 MR 画像が示す輝度特性を十分なマップ層ユニット数で写像できていないと考えられる．また、対象画像によっては対応づけられる組織の輝度特性は異なることから、さらに広範囲に分類された結果となった．

我々が特に着目した脳萎縮の程度を示す CSF の実験結果を図 11 に示す．なお、適用した臨床画像の中から、特に画像特性の違いが表れている代表的な画像を示した．脳構造には、個人差があり、様々な特徴があるにもかかわらず組織分類結果では、CSF と GM の境界が明確となり、CSF は高輝度領域に沿って抽出できた．

本手法を年代別 MR 画像データベースに適用した結果を図 12 に示す．分類対象組織の面積比率から脳に加齢変化について定量化した．図 12 より脳領域に加齢変化は、加齢に伴い CSF が拡大し、GM が縮小している．一方、WM は加齢による変化が見られない．

4.3 考察

脳領域の抽出では、手動設定に比べ、本手法を用いた一致率がすべての症例について上回る結果となった．本手法では GA により LSM のパラメータを対象画像に合わせて最適化したためである．手動設定では LSM の輪郭が CSF に入り込んでいる症例が見られたが、本手法では適応度関数に輪郭の一致率を用いることで CSF に入り込むことなく脳領域を抽出できた．手動設定では困難である対象画像に合わせたパラメータ設定は、GA を

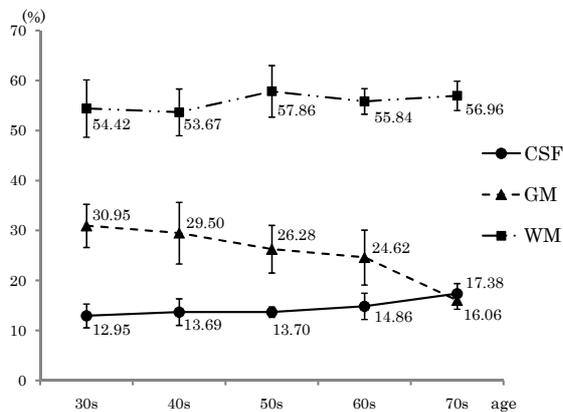


図 12 脳領域の加齢変化

Fig. 12 Volume rates of segmented tissues.

用いることで自動的に最適化することができた。また、最適化対象パラメータの λ, ν, I は、硬膜が少ない場合、 λ と ν は大きく、 I は小さくなり、硬膜が多い場合、 λ と ν は小さく、 I は大きくなる傾向が見られた。

次に、脳領域の一致率が80.0%以下となった4症例に着目する。これらは後頭葉の特徴点である矢状静脈洞が硬膜に厚く覆われているため一致率が低下したと考えられる。低輝度である硬膜と高輝度であるCSFが隣接、または付着している箇所は輝度勾配差が僅かなため、脳領域の輪郭を形成し易い。しかしながら、後頭葉は脳組織と硬膜との輝度勾配差が見られないため、特徴点の抽出は困難であり、仮に硬膜領域にLSMの輪郭が入り込んでも、脳領域との輝度勾配が類似しているため脳領域内部に入り込んでしまうと考えられる。

脳組織の分類では、対象画像によって輝度特性は異なるが、本手法では個人の脳構造に沿った脳組織の分類結果が得られた。これは、SOMsで高粒度に非線形量子化し、脳組織に対応付くようFuzzy ARTで一定粒度で統合したため、低輝度領域の組織の割り当てが反映された結果が得られた。ダイナミックレンジが広い頭部MR画像に対して、SOMsの量子化レベルを上げることで、輝度に対し十分な写像空間で量子化できた。また高粒度に量子化された輝度をFuzzy ARTによって一定の粒度で統合することで、CSF, GM, WMに割り当てることができた。なお、本論文では読影専門医の目視による全体的な評価であったが、今度、読影専門医が分類した結果と比較することで分類精度と有効性を確認する予定である。

5. まとめ

本論文では、個人の脳構造に沿って脳領域を抽出し、頭部MR画像の輝度特性に基づく情報のみを用いて脳組織を自動分類する手法を提案した。本論文で得られた成果は以下の通りである。

(1) 脳領域の一致率は、60症例中、47症例で90.0%以上の結果が得られ、最も低い適応度で73.2%であった。

(2) SOMsの非線形な写像空間を利用して輝度を量子化し、Fuzzy ARTを用いて輝度の順序性に基づき量子数を統合することで脳組織を分類する有効性を確認した。

(3) 年代別MR画像データベースに適用し、加齢に伴いCSFは拡大し、GMは縮小、WMは加齢による変化がないことを確認した。

一方で、対象画像によっては後頭葉の特徴点である矢状静脈洞の抽出ができていない。輝度勾配や輝度特性のみでは抽出が困難であることから、今後は、形状を利用した統計モデルによる抽出を試みる。

文 献

- [1] 滝靖之, “脳MRIから「年齢相応の脳」を診断する,” 月刊新医療, vol.6, pp.81-84, 2005.
- [2] M.kass, A.Witkin, and D.Terzopoulos, “Snakes:Active Contour Models,” IJCV,1(4),pp.321-332, 1987.
- [3] M.Sussman, P.Smereka, and S.Oshar, “A level set method for computing solutions to incompressible two-phase flow,” J.Comp.Phys., vol.114, pp.146-159, 1994.
- [4] 和田貴成, 清水昭信, 姚淙, 小畑秀文, 縄野繁, “統計的経常情報を用いた3次元腹部CT像からの複数臓器抽出法の改善,” 信学論, MI, 2006.
- [5] 座間健, 倉林有, 八嶋弘幸, “判別基準に基づくレベルセット法を用いた胸部MR画像の領域抽出,” 信学論, MI, 2006.
- [6] K. Sato, K. Sugawara, Y. Narita, and I. Namura, “Consideration of the method of image diagnosis with respect to frontal lobe atrophy,” IEEE Trans. Nucl. Sci., Vol.43, no.6, pp.3230-3238, Dec. 1996.
- [7] O.-K. Yoon, D.-M. Kwak, B.-S. Kim, D.-W. Kim, and K.-H. Park, “Automated segmentation of MR brain images using 3-dimensional clustering,” IEICE Trans. Inf. & Syst., vol.E85-D, no.4, pp.773-781, April. 2002.
- [8] M.C. Clark, D.b. Goldgof, R. Velthuizen, F.R. Murtagh, and M.S. Silbiger, “Automatic tumor segmentation using knowledge-based techniques,” IEEE Trans. Med. Imaging, vol.17, no.2, pp.187-201, April. 1998.
- [9] T. Kohonen, Self-organizing maps, Springer Series in Information Sciences, 1995.
- [10] 間所洋和, 佐藤和人, 石井雅樹, 門脇さくら, “自己写像特性を用いた頭部MR画像の組織分類,” 信学論(D-II), vol.J87-D-II, no.1, pp.117-125, Jan 2004.
- [11] T. Kamio, S. Soga, H. Fujisaka, and K. Mitsubori, “Anadaptive state space segmentation for reinforcement learning using fuzzy-ART neural network,” Proc. IEEE MWSCAS 2004, vol.3, pp.117-120, 2004.
- [12] 海老澤拓也, 大谷寿光, 佐藤和人, 間所洋和, “進化的可変形状モデルを用いた脳領域抽出法,” 信学論, PRMU, Mar., 2010.
- [13] 川原敏一, 坂本雄児, ザナムシイワ, “テクスチャ領域の大きさを可変としたMRIからの臓器自動抽出法,” 信学論(D-II), vol.J80-D-II, no.7, pp.1651-1658, July 1997.