

教師なし学習のハイブリッド化による頭部 MR 画像の組織分類

大谷 寿光[†] 佐藤 和人[†] 間所 洋和[†]

[†] 秋田県立大学システム科学技術学部 〒015-0055 秋田県由利本荘市土谷字海老ノ口 84-4
E-mail: †{B07A014,ksato,madokoro}@akita-pu.ac.jp

あらまし 本論文では、教師なし学習の SOM (Self-Organizing Maps) と ART (Adaptive Resonance Theory) をハイブリッド化し、頭部 MR (Magnetic Resonance) 画像における輝度特性や輝度分布のみから脳組織を分類する手法を提案する。本手法では、脳萎縮を定量化するために SOM で高粒度の組織分類を行い、組織分類した結合荷重を基に ART を用いて細分化した組織の領域を統合する。評価実験では、灰白質は脳脊髄液と白質の境界に沿う連続した帯状の領域を形成し、脳脊髄液は高輝度領域に沿って正しく抽出でき、解剖学的構造情報に沿った結果が得られた。更に、臨床現場で撮影された MR 画像に本手法を適用した結果、医師による脳萎縮の診断を支援するために、有効かつ客観性の高い分類結果が得られた。

キーワード MR 画像, SOM, FuzzyART, 組織分類, 脳萎縮の定量化

Segmentation of Brain MR Images Using Unsupervised Hybrid Learning

Toshimitsu OTANI[†], Kazuhito SATO[†], and Hirokazu MADOKORO[†]

[†] Faculty of Systems Science and Technology, Akita Prefectural University 84-4 Aza Ebinokuchi Tsuchiya,
Yurihonjo City, 015-0055 Japan
E-mail: †{B07A014,ksato,madokoro}@akita-pu.ac.jp

Abstract This paper presents a segmentation method using unsupervised hybrid learning of SOM (Self-Organizing Maps) and ART (Adaptive Resonance Theory) for brain MR (Magnetic Resonance) images only used in brightness characteristics and its distribution. This method consists of two steps. The first step is fine segmentation of brain tissues using SOM. The second step is to integrate categories using ART. We evaluated the method comparing with our former method only using SOM. The proposed method can extract according to the brain structures especially in CSF regions. Moreover we applied the method to clinical MR images. Objective classification results are obtained for diagnosis support for quantification of atrophy of the brain.

Key words MR images, SOM, FuzzyART, Segmentation, Quantification of atrophy of the brain

1. ま え が き

画像撮像装置の進歩に伴い、医療現場では高解像度の医用画像が大量に使用されている。医用画像は医師が診断に利用するばかりでなく、電子カルテによる共有化やインフォームドコンセント等に幅広く利用されている。このような利用形態を考えた場合、撮影された画像をそのまま使用するのではなく、診断精度の向上や負荷の低減などの観点から、対象となる組織ごとにオブジェクト化することが望ましい。

我々は、頭部 MR 画像を対象に脳萎縮の定量化を目指している。現在、頭部 MR 画像を用いた診断では、専門医が画像所見から経験的、主観的に脳萎縮の程度を判断している。専門医の負担軽減と客観的な診断を支援するためにも脳組織分類の自動化が必要となる。

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いる [1] ~ [10]。従来法は、分類対象組織の代表点をオペレータが事前に指定する方法と、そのような操作を必要としない手法に大別することができる。前者は、精度面で優位であるものの、分類結果がオペレータの主観に強く依存する傾向にある。更に代表点の数が多くとオペレータに対する負担が大きい。後者は、代表点の数が少ないと、例えばニューラルネットワークに代表される学習機能を用いる手法では、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してしまう。一方で、注目されているのが、オペレータによる代表点の設定を必要としない組織分類である。そのひとつに間所らの、SOM (Self-Organizing Maps, 以下 SOM と記す) 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 (脳脊髄液、灰白質及び白質) を分類する手法があ

る [11]. 間所らの手法では SOM のマップ層 (Kohonen 層) を 5 ユニットとしているが, 対象画像によって対応づけられる組織の構成は異なる. 臨床現場において最も使用頻度の高い T2 強調画像では, 浮腫や腫瘍が高輝度に画像化されるが, 白質と灰白質の輝度値の差異はわずかであり, 脳実質が白質と灰白質に分割できないことが多い. したがって, マップ層が 6 ユニット以上になった場合は, 一つの組織に対して複数のユニットを対応づける必要があり, オペレータ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. 個人差による影響の大きい MR 画像では, オペレータの主観によらず自動で脳組織分類を行うことが重要となる.

我々は, 頭部 MR 画像を対象に脳萎縮の程度を定量化するために, 教師無し学習の SOM と ART (Adaptive Resonance Theory, 以下 ART と記す) をハイブリッド化し, 輝度特性や輝度分布のみから脳組織を分類する手法を提案する. 本手法は, オペレータによる代表点の設定を必要とせず, SOM の自己写像特性を用いて, MR 画像が示す入力空間上における特徴量の結合荷重を持った各ユニットを対象画像に合わせて分類し, さらに ART を用いて細分化された組織の領域 (カテゴリ) の統合をすることで組織の境界があいまいな領域の分類が可能になる. SOM のマップ層を 5 ユニットと固定的に割り当てていた間所らの手法 (以下, 従来手法と記す) に対し, 本手法では, マップ層ユニット数を増やすことで組織分類数よりも高い粒度で分類し, さらに特徴空間上に分布したカテゴリの集合に分類できる ART を利用して, SOM から得られた結合荷重をもとにカテゴリの統合を行う. SOM と ART をハイブリッド化することで組織分類に適切な写像空間を割当て, オペレータの主観によらず, カテゴリを統合できるようになる. 従来手法に比べ, 組織の境界があいまいな領域が明確になり, 細部にわたる組織分類結果が得られた. また, 臨床現場で撮影された MR 画像に対して本手法を適用した結果, 医師による脳萎縮の診断を支援するために客観性の高い結果が得られたので報告する.

以下, 本論文の構成は, 2. で本提案手法である組織分類法について述べ, 3. で予備実験によりパラメータを決定し, 4. で実験結果及び臨床応用結果を示す. 最後に 5. で結論を述べる.

2. ハイブリッド型組織分類法

2.1 SOM アルゴリズム

Kohonen によって提案された SOM は, 競合学習型ニューラルネットワークで, 多次元の入力データを, 位相的な関係を保ちながら 1 次元や 2 次元などの低次元空間に自己写像する教師無し学習である [12]. SOM は入力空間上に提示された特徴量のみから, 自己学習を行う. SOM は入力空間における特徴量の位相関係を保存し, ネットワーク内部にトポロジカルに写像する自己写像特性を有する. したがって, SOM を用いることにより, 位相特性が類似する組織を自己写像することが可能であると考えられる. SOM のネットワークは, ニューロンが 1 次元ないし 2 次元的なつながりを持って配置され, 競合により勝ち残ったニューロンだけでなく, その近傍にあるニューロンも同時に学習を行うことを特徴としている.

SOM の学習アルゴリズムを以下に記す.

(1) $w_{ij}(1 \leq i \leq n, 1 \leq j \leq m)$ を時刻 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.

(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.

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

(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.

$$w_{ij}(t+1) = w_{ij} + \alpha(t)(x_i(t) - w_{ij}(t)) \quad (2)$$

$\alpha(t)$ 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.

2.2 Fuzzy ART アルゴリズム

ART は Grossberg らによって提案された手法で, 安定性と可塑性を保ちながら適応的にカテゴリを形成する自己組織化ニューラルネットワークである [13]. 本手法で用いた Fuzzy ART は, 教師無し学習で, 形成された位相空間が完全に保存された状態のまま細かな位相空間の類似したカテゴリの統合が可能, 入力パターンの記憶・クラスタリング, 連想の能力を有するニューラルネットワークである.

以下にアルゴリズムを記す.

m 次元入力ベクトル I , F1 層のニューロン数 m , F2 層のニューロン数 n とする. Fuzzy Art の動作は選択パラメータ $a(a > 0)$, 警戒パラメータ $p(0 \leq p \leq 1)$, 学習率パラメータ $r(0 \leq r \leq 1)$ により特徴付けられる.

(1) 初期化

入力データベクトルセットのデータベクトル数 M を, 入力データベクトルセットの繰り返し表示回数 K をとし, すべての結合荷重 $w_i(i = 1, \dots, n)$ のすべての要素を 1 に初期化する.

(2) 繰返し

入力データベクトル I を順番に $M \times N$ 回表示して次の操作を繰返す.

(3) カテゴリ選択

入力 I と F2 層の各ニューロン i に対して, 選択強度 T_i を次式により計算する.

$$T_i = \frac{|I \wedge w_i|}{a + |w_i|} \quad (3)$$

ここで, M -次元ベクトル u と v に対して, ファジー AND オペレータは,

$$(u \wedge v)_j \equiv \min(u_j \wedge v_j) \quad (4)$$

により定義され, ノルムは,

$$|u| \equiv \sum_{j=1}^m |u_j| \quad (5)$$

により定義される． T_i の最大値を与える i_0 ，すなわち

$$T_{i_0} = \max\{T_i | i = 1, \dots, n\} \quad (6)$$

となる i_0 を勝者としてカテゴリを選択する．もし複数の勝者が存在するときは，最小のインデックスのカテゴリが選択される．カテゴリ i_0 が選択されたとき，F2 層の i_0 番目のニューロンの活動が 1，それ以外のニューロンの活動は 0 となる．

(4) 共鳴かりセットの判定

入力 I が (3) で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は，カテゴリ数を決定するパラメータである，ピジランスパラメータ ρ によって決まる．すなわち，F2 層の i_0 番目のニューロンからの信号の F1 層への伝達による F1 層の活動値 $I \wedge w_{i_0}$ に対して，マッチング関数が，

$$|I \wedge w_{i_0}| / |i| \geq \rho \quad (7)$$

のとき，入力 I とカテゴリ i_0 が共鳴し，カテゴリ i_0 の選択が確定するとともに，(5) でそのカテゴリの学習が入力 I に関してなされる．一方，上式が成り立たないときは，カテゴリ i_0 はリセットされ，次に大きい T_i の値を与えるカテゴリが再選択され，同様に共鳴かりセットかの判定がなされる．すべてのカテゴリがリセットされた場合は (6) へいく．

(5) カテゴリ i_0 と，結合荷重ベクトル w_{i_0} に従って成される．

$$w_{i_0} = r(I \wedge w_{i_0}) + (1 - r)w_{i_0} \quad (8)$$

学習パラメータ $r = 1$ のときを高速学習と呼ぶ．

(6) いずれのカテゴリにも属しないと判断されたときは，F2 層に新たなニューロン，すなわちカテゴリが追加される．

2.3 提案手法

本手法では，臨床現場において最も使用頻度の高い T2 強調画像を用いる．T2 強調画像では，髄液や膀胱などの水成分が高輝度に画像化されるため，浮腫や腫瘍は高輝度側に位置する．脳実質内において灰白質は高輝度側に位置し，白質は低輝度側に位置する．しかしながら，MRI は異なる組織が類似したコントラストで画像化されるため，境界があいまいな組織を分類することは困難である．また，対象画像によって対応づけられる組織の構成は異なる．特に T2 強調画像では，白質と灰白質の輝度値の差異はわずかであり，脳実質が白質と灰白質に分割できないことが多い．また，本論文で用いた MR 画像は，解像度が 512×512 pixel，輝度値が 16bit のオリジナルデータに対して直線量子化を用いて 8bit (256 階調) に変換している．

ここで，我々が提案する組織分類法は，教師なし学習の SOM と ART をハイブリッド化し，輝度分布のみから脳組織を分類する手法である．SOM の入力空間上における結合荷重の位相関係を保持しながら学習を行い写像する点と，ART の対象画像に適切なカテゴリ数に統合できる点に着目しハイブリッド化を行った．我々の手法は従来手法同様，オペレータによる代表

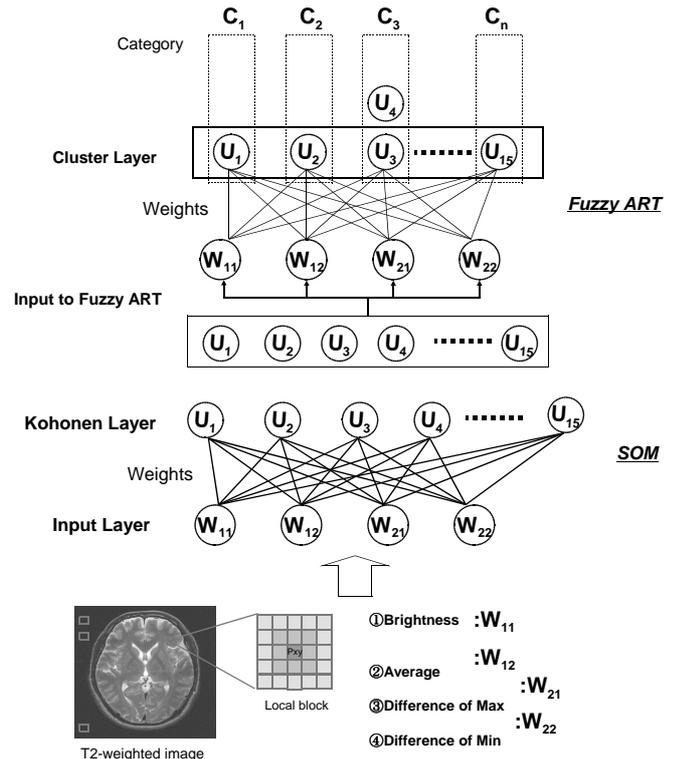


図1 提案手法
Fig. 1 Our proposal method.

点の選択を必要とせず，輝度分布のみから脳組織を分類する手法である．しかし，従来手法の SOM だけの組織分類では，対象画像によっては分類対象組織に対して特徴量の結合荷重を持ったユニット数が足りず，組織を分類できないことが多い．したがって，対象画像によってマップ層ユニット数を対応づける必要がある．本手法では，SOM と ART をハイブリッド化することで，対象画像の組織分類に合わせて写像空間を高い粒度で分類し，オペレータの主観によらず，カテゴリの統合を行うため，組織の境界があいまいな領域の分類が可能になり，精度の高い組織分類結果が得られる．

以下に本手法の詳細と処理フローを図1に示す．

Step1 頭蓋・頭皮領域の除去

脳実質と脳脊髄液のみを抽出するために，対象画像における頭蓋・頭皮領域を除去する必要がある．頭蓋・頭皮領域の除去は，はじめに背景領域に頭蓋・頭皮領域を加えて，背景領域と脳組織（脳脊髄液，灰白質及び白質）領域からなる 2 値化画像を大津法 [14] を用いて作成する．作成後，最大オブジェクトを抽出し，内側を塗りつぶしてオブジェクトプレーンを作成する．オブジェクトプレーン外を背景領域として再定義することにより，頭蓋・頭皮領域を取り除き脳実質と脳脊髄液のみを抽出する．

Step2 SOM による自己学習

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する．次に局所ブロック内の各種特徴量（輝度分布，エッジ，テクスチャ情報等）を算出する．注目画素の輝度値及び算出した各種特徴量を SOM に入力する．ここで，SOM に入力する特徴量は，従来手法と同様の，輝度値，平均値，最大値差分及

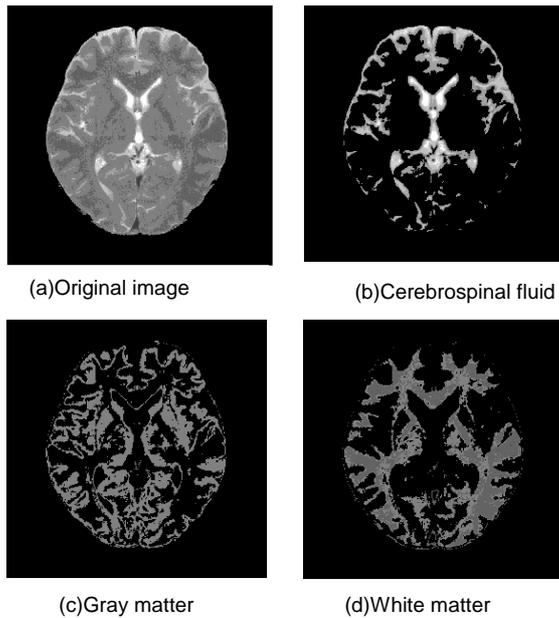


図 2 従来手法の組織分類結果
Fig. 2 Result of classification tissue using conventional proposal method.

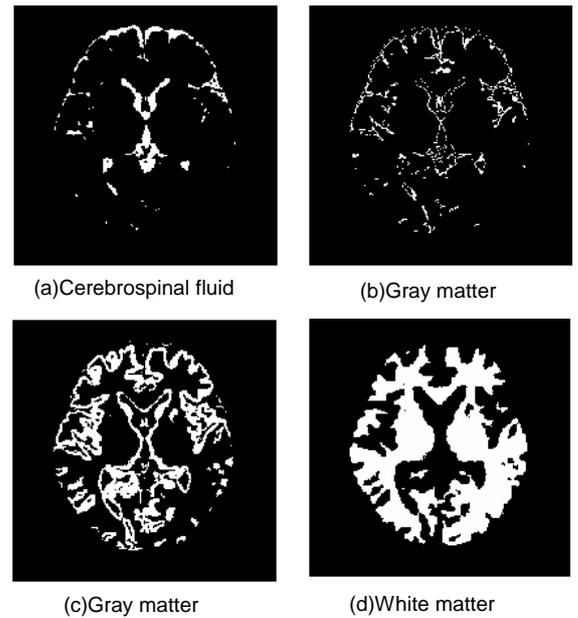


図 3 本手法の組織分類結果
Fig. 3 Result of classification tissue using our proposal method.

び最小値差分の 4 種類である [11]。これは、輝度値のみを入力とした場合では、白質領域内に灰白質成分が混在しており、また、灰白質領域内においても白質領域が混在している。MR 画像は異なる組織においても類似した輝度値で画像化される。このようなノイズを多く含んでしまうのは、画像の特徴量が画素単位で独立した情報となり、脳組織における連続性が考慮されていないからである。したがって特徴量は、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た。この 4 種類の特徴量を SOM に入力して自己学習を行う。

従来手法では、SOM のマップ層を 5 ユニットとしていたが、これでは、分類対象数に対して少ないため、精度の低い分類結果となっていた。したがって、本手法では、SOM のマップ層を十分なユニット数、つまり分類対象数の 2~5 倍程度にして、各ユニットの重みづけを行う。このように写像空間を広げることで、従来手法に比べて高粒度に組織を分類できる。なお、マップ層の具体的なユニット数は、次節の予備実験において記述する。

Step3 ART によるカテゴリの統合

SOM の学習結果から得られ、入力とした 4 つの特徴量（輝度値、平均値、最大値差分及び最小値差分）の結合荷重を持った各ユニットごとに ART で学習したカテゴリを統合する。なお、統合されるカテゴリ数は、ART のビジランスパラメータに依存し、ビジランスパラメータは、次節の予備実験で決定する。学習後、ART によって統合された新しいカテゴリに対しマッピングカラーを決定する。T2 強調画像における組織の輝度特性は、脳脊髄液が最も高輝度であり、灰白質、白質、頭皮・頭蓋の順になり、背景が最も低輝度である。したがって、マッピングカラーは結合荷重が大きいものからこの順としラベリングする。

Step4 マッピング

対象画像の全画素に対して、マッピングする値を算出してマッピング画素を作成する。各画素にマッピングする値は、学習で用いた特徴量を ART に再入力して勝者ユニットの検索を行い、勝者ユニットに対するマッピングカラーをもとに割り当てる。オブジェクトプレーン内にマッピング結果を重ね合わせた画像が、最終的な組織分類結果となる。

3. 予備実験

SOM に入力するマップ層ユニット数と ART に入力するビジランスパラメータを決定するために、次の 2 項に関して予備実験を行った。

3.1 マップ層ユニット数

対象画像によって対応づけられる SOM のマップ層ユニット数と組織の構成は異なる。特に T2 強調画像では、白質と灰白質の輝度値の差異はわずかであり、脳実質が白質と灰白質に分割できないことが多い。したがって、対象組織数よりも高い粒度で分類するよう、MR 画像によって適した写像空間を扱う必要がある。予備実験では、SOM のマップ層ユニット数を決定するためにマップ層を 7 ユニット、9 ユニット、11 ユニットと写像空間を広げていき、すべての対象画像に対応づけるために予備実験を行った。なお、発火ユニットに対し、第一近傍、第二近傍と対応づけるため、マップ層は 2 ユニット毎とした。予備実験結果から、従来手法の 5 ユニットでは組織分類するには写像空間が不十分であり、組織の境界があいまいになってしまう MR 画像に対し、7 ユニット、9 ユニット、11 ユニットで適用した結果、精度良く組織分類できることを確認した。また、対象画像によって最適なユニット数があり、11 ユニットよりも 7 ユニットの方が高い精度で組織分類できる場合もあることを確認した。したがって、我々は組織分類を未知なカテゴリとして

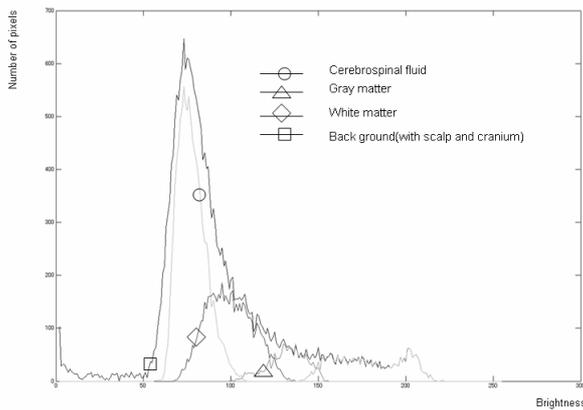


図 4 組織別輝度ヒストグラム
Fig. 4 Histogram of brightness classified by tissue.

定義し，SOM の写像空間を十分に広げ，ART でカテゴリに統合する必要がある．しかし，マップ層が 17 ユニットでは，写像空間が広くなりすぎてしまい，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．これより，本手法では，SOM のマップ層を 15 ユニットとした．

3.2 ビジランスパラメータ

ART の分類粒度は，ビジランスパラメータにより制御される．このビジランスパラメータを決定することで，一定の粒度で統合できるため，分類目標としている組織数と分類粒度の対応づいた統合が可能となる．予備実験では，ビジランスパラメータ値を 0.85 ~ 0.95 の 0.05 毎で行った．統合した結果を，読影専門医の目視により判断してもらい，低輝度側の境界が顕著にみられる 0.90 をビジランスパラメータ値とした．

4. 評価実験

4.1 従来手法と本手法の比較

前節で決定したパラメータを用いて組織分類を行った．従来手法の組織分類結果と本手法を用いた組織分類結果を図 2，3 に示す．対象画像は同じであるが，組織分類結果に違いがみられる．まず，従来手法の組織分類結果では，図 2(b) より，脳脊髄液は広範囲にわたり分類され，灰白質とみなすべき領域まで及んでいる．同様に，図 2(c)，図 2(d) より，灰白質，白質領域も広範囲にわたり組織分類されてしまう．これに対し，本手法の組織分類結果では，図 3 (a) のように，脳脊髄液は高輝度領域に沿って正しく抽出できている．これは，従来手法を適用した脳脊髄液の組織分類結果 (図 2 (a)) における，灰白質とみなすべき領域を図 3 (b) のように，細かく分類されたためである．この図 3 (b) の領域を我々は，灰白質とみなした．図 3 (c) では，灰白質は脳脊髄液と白質の境界に沿う連続した帯状の領域を形成している．つまり，脳組織の連続性及び境界を反映した組織分類の実現が可能となり，脳の解剖学的構造情報に沿った分類結果が得られている．したがって，従来法と比べて本手法では，組織の境界が明確で，細部にわたり組織分類が可能になっていることから，従来法では，不可能であった組織分類に適切な写像空間と割当てが自動的にできていることがわ

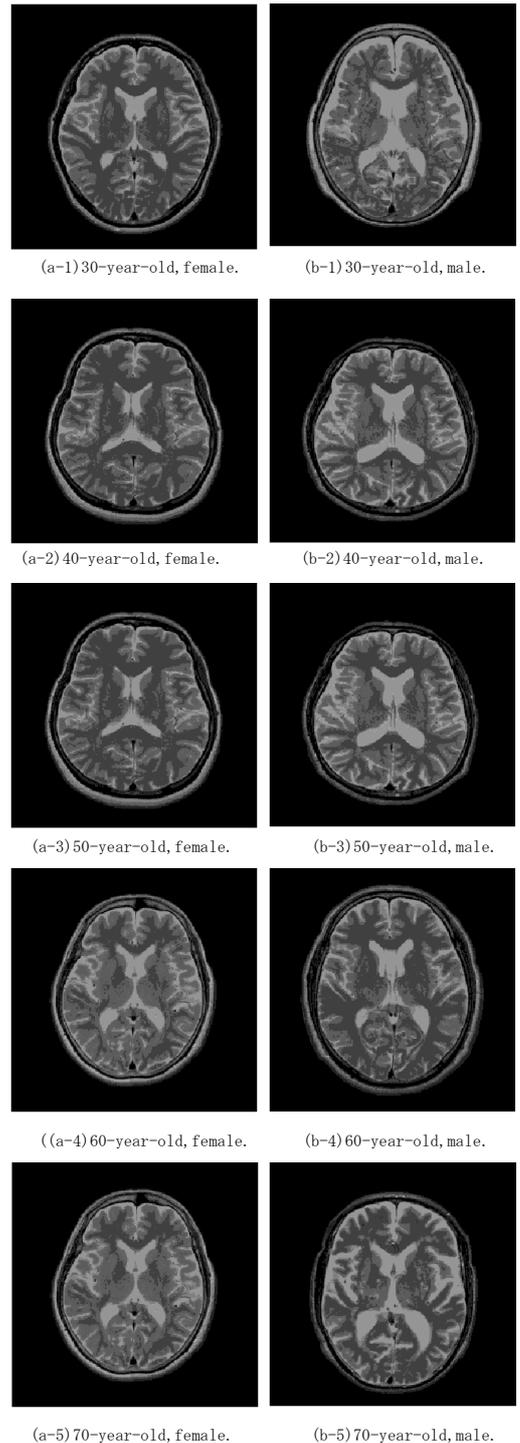


図 5 臨床 MR 画像の組織分類
Fig. 5 Segmentation result of the clinical MR image.

かる．また，分類結果の組織別ヒストグラムを図 4 に示す．輝度ヒストグラムでは単一の分布であった脳実質が，本手法により灰白質と白質に分類できている．ヒストグラムにおける組織間のオーバーラップは，特徴量 (平均値，最大値差分及び最小値差分) から生成されていると考えられる．つまり，輝度情報のみでは一意に分類できない画素に対してこれらの特徴量は，組織の連続性と組織の境界を識別するために有効な特徴となっていることを示している．なお，背景領域が脳実質内に深く入り込んでいるのは，脳実質と類似した輝度特性を示す頭皮・頭

蓋領域を背景領域として取り除いたからである。

4.2 臨床画像への応用

本手法を脳ドック受診者の、30代から70代の男性5名と女性5名の計10名のMR画像に適用し、臨床応用に関する評価を行った。脳萎縮の程度を示す脳脊髄液の実験結果10例を図5に示す。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、本手法を用いた組織分類結果では、脳脊髄液と灰白質の境界は明確であり、脳脊髄液は高輝度領域に沿って正しく抽出できている。また、読影専門医の目視による評価で、いずれも脳構造に沿った良好な結果であることを確認した。したがって、脳萎縮の診断に必要なとされる組織（脳脊髄液、灰白質及び白質）を脳構造に沿った高い精度で分類できていることから、脳萎縮の診断を支援するために、客観性の高い情報提供ができる見通しが得られた。

5. むすび

本論文では、SOMの自己写像特性を用いて、MR画像が示す特徴量の結合荷重を持った各ユニットの集合を細かく分類し、さらにARTを用いてカテゴリの統合をすることで組織の境界があいまいな領域を分類する手法を提案した。SOMとARTをハイブリッド化することで、従来手法で課題となっていた、対象画像に合わせた、組織分類に適切な写像空間と、割当てが可能となった。MR画像によって適切な分類領域は異なり、それに伴い、SOMのマップ層は対象組織数よりも高い粒度のユニット数が必要であり、予備実験では、少ないマップ層ユニット数では組織の境界があいまいになってしまうMR画像に対して、ユニット数を増やしていくことで、精度の高い分類結果が得られたことから、SOMの写像空間を広げる有効性を確認した。評価実験では、脳組織の連続性及び境界を反映した組織分類の実現が可能となり、脳の解剖学的構造情報に沿った分類結果を得ることができた。また、従来手法と本手法の組織分類結果を比較し、対象画像の組織分類に適した写像空間とカテゴリの統合が可能になり、従来法の課題であった組織分類に適切な写像空間と、割当てが改良されたことを示した。

本手法を、臨床現場で撮影されたMR画像10例に適用した結果、精度の高い組織分類結果が得られた。また、読影専門医による脳組織（脳脊髄液、灰白質及び白質）分類結果の目視による判断において、いずれも脳構造に沿った結果であることが確認された。これにより医師による脳萎縮の診断を支援するために、客観性の高い情報提供が実現できる見通しを得た。

本論文では、分類結果の評価は医師の視察による全体的な評価のみであったが、本手法の分類能力として、今後は医師が分類した結果と比較を行う予定である。更に、脳組織オブジェクトを抽出するための脳表面輪郭の抽出法について検討を行うとともに、脳梗塞や脳腫瘍などの病変部位の抽出を目的とする診断支援システムへの応用について検討する予定である。

謝辞 本研究を進めるにあたり、臨床画像の提供と分類結果に対する臨床評価を快く御協力頂いた、秋田組合総合病院診療部長の犬上篤先生に深く感謝申し上げます。

文 献

- [1] 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.
- [2] M. ozkan, B.M. Dawant, and R.J. Maciunas, ' 'Neural-network-based segmentation of multi-modal medical images: A comparative and prospective study, ' 'IEEE Trans. Med. Imaging, vol.12, no.3, pp.534-544, Sept. 1993.
- [3] W.E. Reddick, J.O. Glass, E.N. Cook, T.D. Elkin, and R.J. Deaton, ' 'Automated segmentation and classification of brain using artificial neural networks, ' 'IEEE Trans. Med. Imaging, vol.16, no.6, pp.911-918, Dec. 1997.
- [4] J. Alirezaie, M.E. Jernigan, and C. Nahmias, ' 'Automatic segmentation of MR images using self-organizing feature mapping and neural networks, ' ' Proc. SPIE The International Society for Optical Engineering, pp.138-149, 1997.
- [5] R. Sammouda, N. Niki, and H. Nishitani, ' 'Segmentation of brain MR images based on neural networks, ' 'IEICE Trans. Inf. & Syst., vol.E79-D, no.4, pp.349-356, April. 1996.
- [6] R. Sammouda, N. Niki, and H. Nishitani, ' 'A comparison of Hopfield neural network and Boltzmann machine in segmenting MR images of the brain, ' 'IEEE Trans. Nucl. Sci, vol.43, no.6, pp.3361-3369, Dec. 1996.
- [7] S. Haring, M.A. Viergever, and J.N. Kok, ' 'Cohonen networks for multiscale image segmentation, ' ' Image Vision Comput., vol.12, pp.339-344, July/Aug. 1994.
- [8] S.C. Amartur, D. Pirano, and Y. Takefuji, ' 'Optimization neural networks for the segmentation of magnetic resonance images, ' 'IEEE Trans. Med. Imaging, vol.11, no.2, pp.215-220, June. 1992.
- [9] 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.
- [10] 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.
- [11] 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-), vol.J87-D-, no.1, pp.117-125, Jan 2004.
- [12] T. Kohonen, Self-organizing maps, Springer Series in Information Sciences, 1995.
- [13] T. Kamio, S. Soga, H. Fujisaka, and K. Mitsubori, " An adaptive state space segmentation for reinforcement learning using fuzzy-ART neural network, " Proc. IEEE MWSCAS 2004, vol.3, pp.117-120, 2004.
- [14] 大津展之. 判別および最小 2 乗基準に基づく自動しきい値選定法. 電気通信学会論文誌, Vol. J63-D, No.4, pp.349-356, 1980.