

# 進化的可変形状モデルを用いた脳領域抽出法

海老澤 拓也<sup>†</sup> 大谷 寿光<sup>†</sup> 佐藤 和人<sup>†</sup> 間所 洋和<sup>†</sup>

<sup>†</sup> 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: †{B08A020,M11A004,ksato,madokoro}@akita-pu.ac.jp

あらまし 本論文では、可変形状モデルのレベルセット法 (Level Set Method: LSM) のパラメータを進化的学習の遺伝的アルゴリズム (Genetic Algorithm: GA) 用いて最適化し、脳領域を抽出する手法を提案する。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。個人差が顕著な頭部 MR 画像から脳領域を自動抽出するために、境界線の变形制御に寄与する LSM の外部エネルギー項に着目し、対象画像の濃度勾配や解剖学的構造の幾何学的特徴に合わせてパラメータを GA により最適化した。Ground Truth の輪郭を適応度関数として用いることで、萎縮の診断に重要となる脳脊髄液領域に入り込むことなく脳領域抽出を行う。臨床実験では、脳ドック受診者の 30 代から 70 代の男女 60 症例の頭部 MR (Magnetic Resonance) 画像に適用した結果、56 症例で 80 % を超える抽出率が得られた。

キーワード LSM, GA, 最適化, MR 画像, 脳領域

## An Extraction Method of Brain Regions Using Evolutionary Deformable Models

Takuya EBISAWA<sup>†</sup>, Toshimitsu OTANI<sup>†</sup>, Kazuhito SATO<sup>†</sup>, and Hirokazu MADOKORO<sup>†</sup>

<sup>†</sup> Faculty of Systems Science and Technology, Akita Prefectural University 84-4 Aza Ebinokuchi Tsuchiya,  
Yurihonjo City, 015-0055 Japan  
E-mail: †{B08A020,M11A004,ksato,madokoro}@akita-pu.ac.jp

**Abstract** This paper presents a method for extracting brain regions that optimized parameters of Level Set Methods (LSMs) using Genetic Algorithm (GA). Brain structures and shapes contain individual difference. In addition, setting of parameters cannot be decided uniformly, because transformation of the outline is strongly dependence sake in various parameters of partial differential equation. In our method, we use GA to optimize parameters of LSMs for target images. We obtained high extraction rates for the evaluation experiment using brain dock examination datasets constructed by 60 males and females in 30s-70s.

**Key words** LSM, GA, Optimization, MR image, Brain regions

### 1. はじめに

人間の脳は加齢と共に萎縮するが、これは日常診断からよく経験される周知の事実である。また、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も相関がある。さらに、アルツハイマー病、Pick 病などの脳萎縮を伴う変性疾患も多数存在していることから、通常に加齢変化や病的な脳萎縮についても注目されている。頭部 MR (Magnetic Resonance) 画像を用いた診断では、読影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。脳萎縮の客観的評価を実際の臨床現場で広く用いるためには、煩雑な手続きを必要とせず、自動的に関心領域 (Region of Interest: ROI) である脳領域を

個人の脳構造に沿って抽出し、萎縮の診断に有効な脳組織に分類することが重要である。

我々は、脳萎縮の診断支援を目指し、個人の脳構造に沿った脳領域の抽出を目的に研究を行っている。本研究で用いる頭部 MR 画像は、脳ドック等の臨床現場で使用されている T2 強調画像である。使用する頭部 MR 画像と ROI である脳領域を図 1 に示す。T2 強調画像は、萎縮の進行と共に拡大する脳脊髄液領域などの水成分が高輝度に画像化されるという特徴を有する。しかしながら、水成分以外の脳組織は類似した輝度値で画像化されるため、明確な境界は見受けられない。我々が対象とする ROI は脳領域であり、画像によっては、図 1(a) 中の矢印で示すように硬膜領域に厚く覆われている。硬膜が ROI に付




図 1 頭部 MR 画像と脳領域  
Fig.1 Head MR image and brain region.

着する箇所や量は様々であり、個人差がある。対象画像によって異なる特性を有する ROI を抽出するためには、単純な閾値処理では困難である。

そこで、近年、偏微分方程式 (Partial Differential Equation: PDE) を用いた画像応用研究として自由形状の領域抽出法が注目されている。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、画像全体のエネルギーなど大域的な量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 [1] や Sussman らにより提案されたレベルセット法 (Level Set Method: LSM) [2] 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。対象画像によって脳領域は硬膜領域に覆われているため、本研究では、エッジを利用した Snakes は有用ではない。LSM は硬膜領域と脳領域の輝度勾配差を利用するため有用である。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。

本論文では、個人差が顕著な頭部 MR 画像から萎縮の ROI を自動抽出するために、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解剖学的構造の幾何学的特徴に合わせてパラメータを最適化する脳領域抽出法を提案する。本手法を脳ドック受診者男女 60 症例に適用した結果、高い抽出率が得られた。

## 2. 周辺研究

頭部 MR を対象とした脳領域抽出には、これまで様々な手法が提案されている。Dickerson ら [3] や Killiany ら [4] は、T1 強調画像を用いて頭部 MR 画像から着目部位を手動で抽出し、体積を求め、アルツハイマー型認知症の進行状況と脳萎縮の関係を解析している。着目部位そのものの変化を捉えるには、微小な領域を正確に抽出することは効果的であるが、手動による領域抽出は作業が複雑でオペレータの負担が大きくなるため、日常診療での使用は困難である。また、領域抽出の代表的な手法とし

て可変形状モデルが挙げられる。可変形状モデルを用いた ROI 抽出法として、伊藤らは、Snakes に輪郭の伸縮を可能にするエネルギーを付加した Balloon models を用いて、アルツハイマー型認知症の診断に重要とされる海馬周辺や側頭葉領域を抽出する手法を提案している [5]。また、我々は以前、2 値化処理により頭蓋を取り除いた頭部 MR 画像に LSM を用いて脳領域を抽出し、教師なしニューラルネットワークの SOM (Self-Organizing Maps) と fuzzy ART (Adaptive Resonance Theory) を用いて脳を組織ごとに分類する手法を提案した [6]。しかしながら、LSM のパラメータ設定を手動で行っているため、対象画像に合わせた最適なパラメータを設定することが困難である。最近になって動的輪郭モデルのパラメータを自動的に決定する方法が幾つか提案されているが、いずれも収束アルゴリズムに依存しているため他のアルゴリズムへの応用が容易ではなかった。さらに、収束アルゴリズムに依存しない方法も幾つか提案されているが [7] [8] [9]、一部のパラメータの自動決定にとどまっていた。

## 3. 提案手法

### 3.1 可変形状モデル

可変形状モデルは、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ている。したがって、画像上で閉曲線を動的に変化させて対象物の輪郭に一致させることで対象物の輪郭を抽出するために頻繁に用いられている。LSM は、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、そのゼロ等高面を次々に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。

可変形状モデルの輪郭線を  $v(s) = (x(s), y(s))$ , ( $s \in [0, 1]$ ) とすると、輪郭の更新式としては以下の式が最も一般的である。

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

式 (1) の  $E_{\text{int}}$  は内部エネルギー、 $E_{\text{ext}}$  は外部エネルギーと呼ばれ、 $w$  は重み係数を表す。従来では、LSM の更新式はエネルギー項の初期化を必要としていたが、Chunming らによって再初期化が不要な更新式に改良された [11]。式 (2)、式 (3) に LSM の各エネルギー項を示す。

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

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

上記の  $\phi$  は記号付距離関数、 $\Delta$  はグラディエント演算子、 $g$  は標準偏差  $\sigma$  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、 $\mu$  は曲率を制御し、輪郭を形成する。 $\lambda$  は、大き

いほどに輝度勾配の大きいところで速度が遅くなる。 $\nu$  は 0 から遠くなるほどに輪郭の進む速度が上がる。この  $\nu$  は初期輪郭から目標となる輪郭が内側にある場合は負、外側ならば正である。 $\mu, \lambda, \nu$  の 3 つは重み係数であり、LSM の輪郭を動かす働きを左右するパラメータとなり、オペレータによる設定が必要となる。 $E_{\text{int}}$  は輪郭の形状を滑らかにする働きがあり、 $E_{\text{ext}}$  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。

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

式 (4) の  $\varepsilon$  は LSM の輪郭を動かす働きを左右するパラメータであり、オペレータによる設定が必要となる。

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。可変形状モデルはエネルギー最小化法とも呼ばれ、LSM の更新式は内部エネルギーと外部エネルギーの和を最小化する式である。式 (5) を繰り返し処理することで輪郭が更新され、領域抽出を行う。なお、繰り返し数  $I$  はオペレータの設定を必要とする。

### 3.2 進化的可変形状モデル

我々は、膨大な組み合わせの中から最適解を発見する手法として有効である進化的学習の遺伝的アルゴリズム (Genetic Algorithm: GA) [12] を用いて、LSM の輪郭の形状や動きに大きな影響を与えるパラメータを最適化する進化的可変形状モデルを提案する。GA は、環境に対して最もよく適応した個体が高い確率で生き残り、目的関数に対して最適値を与えるような解を求めることが可能である。

輪郭を動かす働きを左右する LSM のパラメータのうち、オペレータによる設定が必要となるのは、 $\mu, \lambda, \nu, \varepsilon$  と  $I$  である。 $\mu$  は、内部エネルギーの係数であり、輪郭の曲率を制御し、形状を滑らかにする働きがある。 $\mu$  を大きく変化させると輪郭の形状は、複数に分離してしまうため、輪郭の形状を滑らかに保つために固定値とした。一方で  $\lambda, \nu, \varepsilon$  は輪郭を動かす働きがある。これらのパラメータのうち、 $\varepsilon$  は、ダイラック関数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。 $\lambda, \nu$  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。したがって、最適化する LSM のパラメータは、 $\lambda, \nu, \varepsilon$  と  $I$  である。GA を用いることで LSM パラメータは、世代を更新するにつれて適応するため、オペレータの主観を伴うことなく、対象画像に合わせたパラメータの最適化が可能である。

ここで、GA の探索空間を広く取るよりも収束を早めて複数回試行した方がよいと考え、最適解を絞るために最適化対象パラメータの有効範囲を決定した。パラメータのバランスと

表 1 最適化対象パラメータの範囲と GA のオプション

Table 1 The range of optimization parameters and options of GA.

最適化対象パラメータ	範囲
$\lambda$	$5.0 < \lambda < 20.0$
$\nu$	$-5.0 < \nu < -1.0$
$I$	$1 < I < 500$
GA のオプション	パラメータ
選択方法	roulette
個体数	40
世代数	20

脳領域に輪郭が入り込まないことを考慮し、 $5.0 < \lambda < 20.0$ 、 $-5.0 < \nu < -1.0$  とした。 $\nu$  は正数で輪郭が外側に進み、負数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、負の値で設定した。また、 $I$  は 500 以上では、輪郭脳領域の内部に入り込んでしまうという点から  $1 < I < 500$  とした。

GA はオプションの変更により、最適化処理の微調整を行うことが可能である。主なオプション設定に、選択方法と個体数・世代数がある。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、世代数は、増加させることで最大適応度の進化が見られた。しかしながら、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。以上の最適化対象パラメータの範囲と GA の選択方法、個体数、世代数を表 1 に示す。

### 3.3 初期輪郭の設定

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。LSM の PDE は、輪郭の内部、外部エネルギー情報によって更新し形状変化する。したがって、対象物以外のエネルギー情報に依存しないためにも、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 LSM の初期輪郭の設定手順を示す。まず、原画像に大津法を適用し、閾値の自動選定を行い、2 値化画像を作成する。作成後、最大オブジェクトを抽出し、穴埋め処理をした後、頭蓋内領域を原画像でマスク処理し、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、頭蓋骨領域を取り除き、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。

### 3.4 適応度関数

GA を用いてパラメータの最適化を行うには、適応度を求めるための適応度関数が必要である。適応度関数はある個体が他の個体より優れていることを示すものであり、対象問題によって異なる。本研究では、領域の一致率として、評価基準として広く使われている F 値を適応度とした適応度関数と、輪郭の一致率を適応度とした適応度関数の 2 種類を用いて実験を行い、脳領域抽出に適している適応度関数を決定する。まず、領域の一致率は適合率  $Co$  と再現率  $Rp$  を用いて F 値を算出し、適応度とする。以下に  $Co$  と  $Rp$  の式を示す。






図 2 初期輪郭の設定  
Fig. 2 Setting of initial contour.

$$Co = \frac{\#(R_{\text{result}} \cap R_{\text{manual}})}{\#(R_{\text{result}})} \quad (6)$$

$$Rp = \frac{\#(R_{\text{result}} \cap R_{\text{manual}})}{\#(R_{\text{manual}})} \quad (7)$$

図 3 に、適応度算出に用いた画像を示す。なお、図 3(a) Ground Truth は関心領域である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。 $R_{\text{result}}$  は本手法により抽出した領域を示し、図 3(b) に示した  $R_{\text{manual}}$  は図 3(a) の領域である。また、 $\#(R)$  は領域  $R$  に含まれる画素数である。適合率  $Co$  は領域  $R_{\text{result}}$  のうち領域  $R_{\text{manual}}$  と等しい領域の割合を示し、この値が 1 に近いほど誤って抽出した領域が少ない。再現率  $Rp$  は領域  $R_{\text{result}}$  が領域  $R_{\text{manual}}$  をどの程度網羅しているかを示し、この値が 1 に近いほど未抽出の領域が少ない。式 (6), (7) より領域の一致率を算出する。

$$\text{適応度 (\%)} = \frac{2 \times Co \times Rp}{Co + Rp} \times 100 \quad (8)$$

次に、輪郭の一致率を適応度とした適応度関数を以下に示す。

$$\text{適応度 (\%)} = \frac{\#(C_{\text{result}} \cap C_{\text{manual}})}{\#(C_{\text{result}})} \times 100 \quad (9)$$

$C_{\text{result}}$  は本手法により抽出した領域の輪郭であり、図 3(c) に示した  $C_{\text{manual}}$  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。以上の 2 つの評価式を用いた GA による最大適応度の世代交代による進化の様子を図 4 に示す。脳領域の一致率の適応度は 1 世代目からほとんどの個体が抽出率 90% を超えていることから世代交代による最大適応度の変化が小さい。これに対し、輪郭の一致率の適応度は 1 世代目では低い適応度のものが世代交代につれて上昇している。適応度に注目すると領域の一致率の方が高いが、本研究では脳領域の萎縮率に着目しているため脳脊髄液領域を残すように脳領域を抽出する必要がある。領域の一致率で用いている F 値は適合率と再現率を同等の評価としていることから、脳脊髄液領域を脳領域を残すように脳領域を抽出することが困難と考えている。これに対し、輪郭の一致率は Ground Truth 領域の輪郭の背景




図 3 適応度算出に用いた画像  
Fig. 3 The images to calculate fitness function.

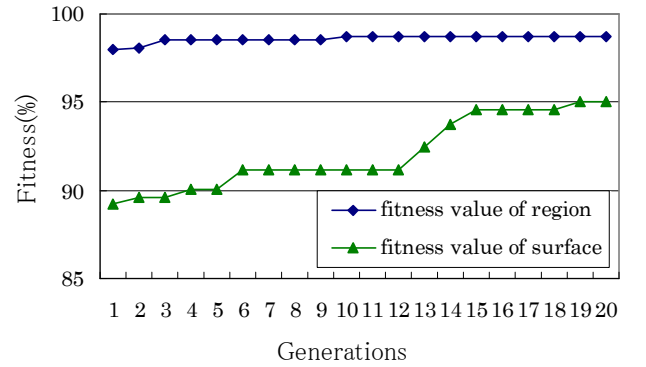


図 4 最大適応度の世代交代による進化の様子  
Fig. 4 The maximum fitness values of generations.

側のみにマージンを持たせることで、背景側に正解となる領域を広げることで脳脊髄液領域を残すように脳領域を抽出することが可能となる。したがって、本研究では、輪郭の一致率を適応度とした適応度関数を用いた。なお、マージンは背景側のみに 1pixel とした。

#### 4. 脳ドックデータを用いた臨床実験

脳ドック受診者の 30 代から 70 代の男女 60 症例の頭部 MR 画像を用いて評価を行った。使用した画像データは、解像度  $512 \times 512$  pixel、輝度値 16 bit のオリジナルデータに対して  $256 \times 256$  pixel にリサイズし、直線量子化を用いて 8 bit に変換した。

##### 4.1 提案手法による抽出結果

本手法を臨床画像に適用し、脳領域を抽出した結果の 4 症例を図 5 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でも、(b) や (c) のように全体が覆われていても硬膜を除去し、脳領域を抽出できた。抽出率はそれぞれ、(a)100%、(b)95.3%、(c)80.2%で




図 5 本手法による脳領域抽出結果

Fig. 5 Extraction results of brain regions with our method.

あった．本手法を 60 症例に適用した結果，56 症例で 80.0 % を超える抽出率が得られた．

#### 4.2 手動設定との比較

最適化対象パラメータを手動で一意的に決定した結果と本手法の結果を比較する．まず，パラメータを一意的に決定するため，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，決定した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，高い抽出率が得られた症例もあるが，図 6 のように抽出率が 10 % 未満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，対象画像によって最適なパラメータは異なり，一意的に決定することはできない．本手法の脳領域抽出に対する有効性を確認するため，手動設定の抽出率との比較を行う．図 7 に 60 症例に対する手動設定と本手法の抽出率を示す．手動設定では抽出率が，0 % ~ 80 % 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 % 以上の抽出結果が得られた．

また，すべての画像において，萎縮の診断に必要な脳脊髄液領域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する．つまり，低輝度




図 6 手動設定による脳領域抽出結果

Fig. 6 Extraction results of brain regions with manual setting of parameters.




図 7 60 症例に対する手動設定と本手法の抽出率

Fig. 7 Extraction rates with manual setting and our methods in 60 cases.

である硬膜と高輝度である脳脊髄液領域が隣接または付着している箇所は輝度勾配差が大きいため，脳領域の輪郭を形成し易い．図 5 の (a) や (b) は脳脊髄液領域と硬膜が隣接しているため高い抽出率が得られた．図 5 の (c) のように，脳脊髄液領域に硬膜が隣接している箇所と，そうでない箇所が混在する画像でも高い抽出率を得ることができた．

これより，手動設定では困難である対象画像に合わせた脳領域抽出は，GA を用いることでパラメータを自動的に最適化することができた．

#### 4.3 考 察

手動設定の抽出率に比べ，本手法の進化的可変形状モデルを用いた抽出率では，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ことで，このような結果が得られた．これは，手動設定では LSM の輪郭が脳脊髄液領域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改善されているためである．つまり，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 を用いることで自動的に最適化することができた．また，脳領域抽出結果を読影専門医に評価してもらったところ，解剖学的構造の幾何学

表 2 GA によるパラメータの最適化結果

Table 2 Optimization results of parameters with GA.

	$\lambda$	$\nu$	$I$
(a)	12.05	-3.12	86
(b)	17.63	-4.41	1
(c)	9.82	-2.45	243




図 8 矢状静脈洞の抽出結果

Fig.8 Extraction result of sagittal sinus regions.

的特徴に沿った結果であるとの見解が得られた。したがって、本手法は脳領域抽出に対して有効であると言える。

最適化の対象パラメータである  $\lambda$ ,  $\nu$ , と  $I$  は、設定する際に互いのバランスが重要となる。図 5 の (a)–(c) のパラメータを、表 2 に示す。硬膜が少ない場合、 $\lambda$  と  $\nu$  は大きく、 $I$  は小さくなり、硬膜が多い場合は  $\lambda$  と  $\nu$  は小さく、 $I$  は大きくなる傾向が見られた。このように GA を用いることで、対象画像の硬膜の量に合わせたパラメータの自動設定ができた。

本研究で用いた T2 強調画像では、脳脊髄液領域は高輝度に、その他の脳組織は類似した輝度値で画像化される。LSM は、画像上の輝度勾配情報を利用して輪郭を形成することから、輝度勾配差が大きいところで輪郭を形成する。つまり、低輝度である硬膜と高輝度である脳脊髄液領域が隣接、または附着している箇所は輝度勾配差が大きいので、脳領域の輪郭を形成し易い。このような場合、LSM の輪郭は、輝度勾配差の大きい領域間では止まるが、小さい領域間では脳領域の内部まで入り込んでしまう。次に抽出率が 80 % 以下となった 4 症例に着目すると、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抽出率が低下したと考えられる。図 8 に、矢印で示した矢状静脈洞の抽出失敗例を示す。脳の萎縮は、前頭葉に顕著に現れ、脳脊髄液領域が広がる。つまり、前頭葉に硬膜が附着もしくは隣接していても、輝度勾配差が大きいので輪郭を形成することができた。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、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。LSM のパラメータを対象画像によって最適化しても、前頭葉と後頭葉で最適なパラメータが異なることから、後頭葉の特徴点抽出は困難な問題であることが見受けられた。

## 5. ま と め

本論文では、脳萎縮の診断支援を目指し、脳領域の抽出を行った。我々は、可変形状モデルである LSM を用いて対象画

像の濃度勾配や解剖学的構造の幾何学的特徴に合わせて脳領域を抽出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) 対象画像に合わせて、LSM のパラメータを GA を用いて最適化した。
- (2) パラメータの手動設定と比較し、全ての画像で抽出率を上回る結果が得られたことから、本手法の有効性が確認できた。
- (3) 60 症例の脳ドックデータによる実験では、最も高い適応度で 7 症例で 100.0 %、最も低い適応度で 73.2 % となり、対象画像の 47 症例で 90.0 % 以上の結果が得られた。

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。後頭葉の特徴点である矢状静脈洞の座標値と輝度値の相関をパラメータとして大量のサンプルを学習させ統計的なモデルを構築することで、矢状静脈洞の抽出に有効であると考えている。

## 謝 辞

本研究を進めるにあたり、臨床画像の提供と脳領域の Ground Truth ならびに抽出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] M.Kass, A.Witkin, and D.Terzopoulos, "Snakes:Active Contour Models, "IJCV,1(4),pp321-332, 1987.
- [2] 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.
- [3] B.C.Dickerson, I.Goncharova, M.P.Sullivan, C.Forchetti, R.S.Wilson, D.A.Bennett, L.A.Beckett, and L.deToledo-Morrell, "MR-rerivad entorhinal and hippocampal atrophy in incipient and very mild Alzheimer's disease", Neurobiology of Aging22, pp.747-754, 2001.
- [4] R.J.Killiany, B.T.Hyman, T.Gomez-Isla, M.B.Moss, R.Kikinis, F.jolesz, R.Tanzi, K.Jones, and M.S.Albert, "MR measures of entorhinal cortex vs hippocampus in preclinical AD, " Neurology,58, pp1188-1196, 2002.
- [5] 伊藤桃代, 西田真, 苗村育郎, "Balloon models を用いた認知症診断支援のための脳領域抽出法, "電学論 C, 129 巻 7 号, 2009.
- [6] 大谷寿光, 佐藤和人, 間所洋和, "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, "FAN2009, Aizu-Wakamatsu, Sep.2009.
- [7] 瀬川英吾, 徐剛, 辻三郎, "形状に依存しないパラメータを用いた snake, "情処研資 CV79-5 : 33-36, 1992.
- [8] 天野晃, 坂口嘉之, 美濃導彦, 他, "サンプル輪郭モデルを利用した Snakes, "信学論 D-II J76D-II(6) : 1168-1176, 1993.
- [9] F.Laymarie, M.D.Levine, "Tracking Deformable Objects in the Plane Using an Active Contour Model, "PAMI15(6) : 617-634, 1993.
- [10] 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.
- [11] C.M. Li, C.Y. Xu, C.F. Gui, and M.D. Fox, "Level Set Evolution Without Re-initialization: A New Variational Formulation, "IEEE Computer Society Conference, Vol.1, Issue, 20-25, pp.430-436, June 2005.
- [12] J. H. Holland, "Adaptation in Natural and Artificial Systems, "University of Michigan Press, 1975.