

修士論文

頭部 MR 画像における
脳実質境界抽出精度の向上と
異常部位候補検出に関する研究



平成 22 年度修了
三重大学大学院 工学研究科
博士前期課程 情報工学専攻

稲垣 卓也

目次

アブストラクト	i
第 1 章 序論	1
1.1 はじめに	1
1.2 研究内容	1
第 2 章 病変部検出システム	3
2.1 病変部検出システム概略	3
2.2 照合処理概略	4
2.2.1 線形変換	5
2.2.2 非線形変換	6
2.2.3 B-Spline FFD	6
2.2.4 パラメータの探索と評価値	8
2.2.5 共役方向法	8
2.2.6 Powell 法	8
2.2.7 修正 Powell 法	8
2.2.8 評価値	9
2.2.9 B-Spline FFD の問題点	9
第 3 章 皮下脂肪除去のためのアルゴリズム	10
3.1 問題点	10
3.2 従来方法	10
3.3 濃度値分布図を利用した手法	11
3.3.1 異常部分の除去について	13
3.3.2 脳実質境界のモデル化	13
3.4 脳実質境界領域から脳実質境界の特定	14
3.4.1 Snakes	15
3.4.2 Snakes による脳実質境界の抽出	15
第 4 章 皮下脂肪除去に関する実験	17
4.1 実験データ	17
4.2 実験 1	17
4.2.1 実験結果	18

4.2.2	考察	25
4.3	実験 2	25
4.3.1	実験結果	25
4.3.2	実験考察	31
第 5 章	病変部候補検出における指標の提案	33
5.1	はじめに	33
5.2	変形特徴量について	33
5.2.1	収縮特徴量 (収縮モデル)	33
5.2.2	非可逆特徴量 (非可逆特徴量)	34
5.2.3	山本らにおける非可逆特徴量の問題点	34
5.2.4	疎特徴量	35
第 6 章	病変部抽出のための指標に関する実験	37
6.1	実験 1	37
6.2	実験 2	39
6.3	実験 3	39
6.3.1	実験内容	39
6.3.2	実験結果	41
6.4	実験考察	47
6.4.1	病変での反応	47
6.4.2	収縮特徴量との比較	47
第 7 章	むすび	49
7.1	まとめ	49
7.2	今後の課題	49
参考文献		51

アブストラクト

MRI(Magnetic Resonance Imaging : 磁気共鳴画像法)により少ない侵襲で脳の形態が診断できるようになり, 脳ドックが普及してきた. 脳ドックの目的は, 日本人の死亡原因の中でも多くの割合を占める疾患である脳梗塞やその他多くの疾患の早期発見及び予防をすることにある. 脳ドックのような集団検診において医師にかかる負担は増しており, 病変部を自動検出し, その位置や形状等の疾患情報を提示することで医師の負担軽減につながる. 病変部を自動検出するためには正常なモデルであるアトラス画像を利用することが有効である. そのため, アトラス画像と臨床画像を照合する必要がある, その精度は病変部の検出に大きな影響を与える. 精度に影響を与える要因として着目したのは, 皮下脂肪による精度の低下である. 本研究では, 照合精度を向上させるための前処理として臨床画像の皮下脂肪部分を自動除去するためのアルゴリズムを提案し, 実験を行いその有効性を検証した. 皮下脂肪の自動除去や脳実質の抽出には様々な研究が行われている [2] [3] が, 従来の方法では皮下脂肪と脳実質がくっついて見えている部分は一緒に脳実質として認識してしまう事や, 拡張する時にシードを手動で決定しなければならない等の問題点がある. そこで本研究で動的計画法を利用した脳実質抽出法の提案, 実装を行った. これにより, 照合の際問題となっていた皮下脂肪の自動除去が可能となり, 精度の向上が確認できた.

また病変部での照合による特徴的な変形モデルを病変部検出の指標とする研究 [1] が今まで研究されている. 本研究では新たな指標を提案し, 実験によって提案した病変部検出指標の妥当性について検討した. そしてその結果, 従来の提案手法よりも安定して病変が検出出来たことを確認した.

第 1 章

序論

1.1 はじめに

近年、画像診断技術の進歩により医療の現場では画像を用いた診断が頻繁に行われている。MRI(Magnetic Resonance Imaging：磁気共鳴画像法)はX線CT(Computed Tomography：X線コンピュータ断層撮影法)と比較し、X線による被曝の危険がない、骨や空気によるアーチファクト(虚像)がない、軟部組織の抽出に優れているため微小な脳腫瘍や梗塞といった頭部疾患の発見に優れているといった利点がある。また、従来では動脈に造影剤を入れX線で撮影していた血管撮影がMRA(磁気共鳴血管撮影)により人体に無侵襲で撮影できるようになった。少ない侵襲で脳の形態が診断できるようになり、MRIを主な検査とする「脳ドック」が普及してきた。「脳ドック」の普及により、脳や脳血管の疾患に対して早期発見及び予防が可能となった。MRIによる臨床画像は人間の目視による検出が比較的容易な場合が多いが、「脳ドック」のような集団検診において、大量の画像を目視検査するは医師に大きな負担となり、誤診の可能性が高まる。このため、病変部の自動検出や領域抽出、臓器構造のデータベース作成、3次元画像の可視化など医師を支援するための様々な研究が成されている[4]。特に、病変部の自動検出は集団検診における医師の負担軽減に有効であると考えられる。

1.2 研究内容

以上のような背景から、本研究室では医師の負担軽減を目的として、病変部を自動抽出する手法を開発している。この種の研究は他でも多く行われており、例えば、松井ら[9]は、ラクナ梗塞を検出する手法を考案している。しかし、頭部病変部には血腫、浮腫、腫瘍などあり、様々な疾患を検出するためには、これらの疾患は脳組織と同じような濃度分布をする部分が多いため、臨床画像の濃度値だけで検出することは難しい。このことから、健康な脳モデルであるアトラス画像と照合し、アトラス画像のもつ正常な組織分類を利用することが有効であると考えられる。照合では一方の画像を他方の画像へと組織構造を崩さないように変形させる必要がある。Ashburnerら[5]、Houhouら[6]、Rueckertら[7]は、このような画像の変形法について提案をしている。しかし、照合のほとんどは同一人物の時系列データであったり、疾患のない画像同士といった比較的照合し易い画像をその

対象としている。森山ら, [8] 山本ら [1] は, 異なる人物間を対象とした照合を試みている。アトラス画像を用いた照合において, 病変部を含まない臨床画像を使用すれば, 理想的には両画像間の組織対応がとれ, アトラス画像が持つ組織分類から臨床画像の組織分類を行うことができる。しかし, 病変部を含む臨床画像を使用した場合, 病変部がアトラス画像上には存在しない組織となり, 両画像間の対応がとれなくなる。この組織分類できない組織を病変部とすることで検出が可能となる。実際には, 脳の組織構造は複雑なため理想的な変形を行うことは不可能であり, 病変部の検出もれや誤検出が生じてしまう。アトラス画像を使用する検出は照合の精度に大きく影響する。しかし, 現在の照合は病変部以外の正常な部位でも正確に照合出来ているとはいえず, 特に病変部とは関係の無い皮下脂肪部分で誤変形を起こしていることが過去の実験で確認されている。そこでまず皮下脂肪を自動除去することにより, 照合精度を向上させるためのアルゴリズムを提案し, 実装, 実験を行った。次にその照合結果を利用して病変部の抽出を行う。照合において重要なのはアトラス画像と臨床画像の組織間の対応を正確にとり, 一方の画像を変形することである。しかし, 病変部が存在する場合には正確な組織対応がとれないまま変形することになる。

山本ら [1] はアトラス画像上には存在しない組織と対応関係をとらなければならない矛盾による変形の特徴をモデル化し, それを病変部検出の指標とした。しかし提案された指標は理想的な照合が行われた場合を想定しており実際の病変部に対して適応することが難しい。そこで本研究では実際の病変部検出指標として新たな特徴量を構築し, それが病変部検出指標となりうるか実験により示す。

本論文では, 第 2 章で病変部検出システムの全体像を説明する。第 3 章では皮下脂肪の自動除去のためのアルゴリズムを解説する。第 4 章では実際の臨床画像へ本手法を適応し有効性を示す。第 5 章では新たに提案した病変部検出特徴量について説明し, シミュレーションによる検証を行う。第 6 章では, 実画像を用いて, 提案したモデルの有用性を実験的に検証する。最後に第 7 章で結論を述べる。

第2章

病変部検出システム

2.1 病変部検出システム概略

本章では、本研究室で今までに開発された病変部検出システムの全体像を説明する。

まず病変部検出法について説明する。脳の病変部を人間が目視で検出を行う場合、周囲との濃度値の違いや医学知識により比較的容易に検出出来る場合が多い。これを自動的に検出するために今まで、対象となる疾患に応じた前処理をしてから閾値などで検出を行う手法 [9] や脳梗塞といった日本人に多い病変を対象に LevelSet 法を利用して病変を抽出する手法等の研究が行われている。

本研究では正常な組織構造を持つアトラス画像 (図 2.1) と異常な組織を持っているかもしれない臨床画像 (図 2.2) を比較することによって、病変部を抽出するという手法 [10] を基としている。しかし、アトラス画像と臨床画像では組織の形状及び位置が違いそのままでは比較することが出来ない。従って組織の形状及び位置を合わせる「照合」[8] [1] [11] という処理を行っている。この照合処理の際、臨床画像にアトラス画像に存在しない組織、病変部がある場合、病変部に対応する組織がアトラス画像に無いためその組織周辺で異常な変形が起きることが予測される。この異常な変形をモデル化することにより病変部検出の指標とし、そのモデルを利用して病変部のスクリーニングを行う。これらの詳しいアルゴリズムは、第5章で説明する。本研究では、吉崎ら [12] により作成された正常な組織構造を持つ3次元アトラス画像を利用している。今回対象となるのが2次元での頭部MRI画像であるので3次元アトラス画像から遺伝的アルゴリズム [13] [14] を利用して臨床画像に対応した2次元アトラス画像を選ぶ。これらのフローチャートを図 2.3 に示す。

以上の手順を用いて病変部候補領域を自動的に抽出する。

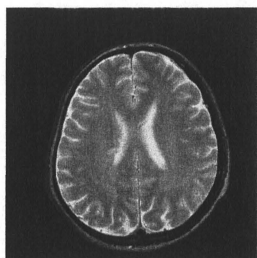


図 2.1 アトラス画像

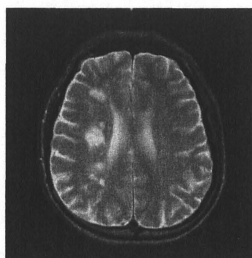


図 2.2 臨床画像

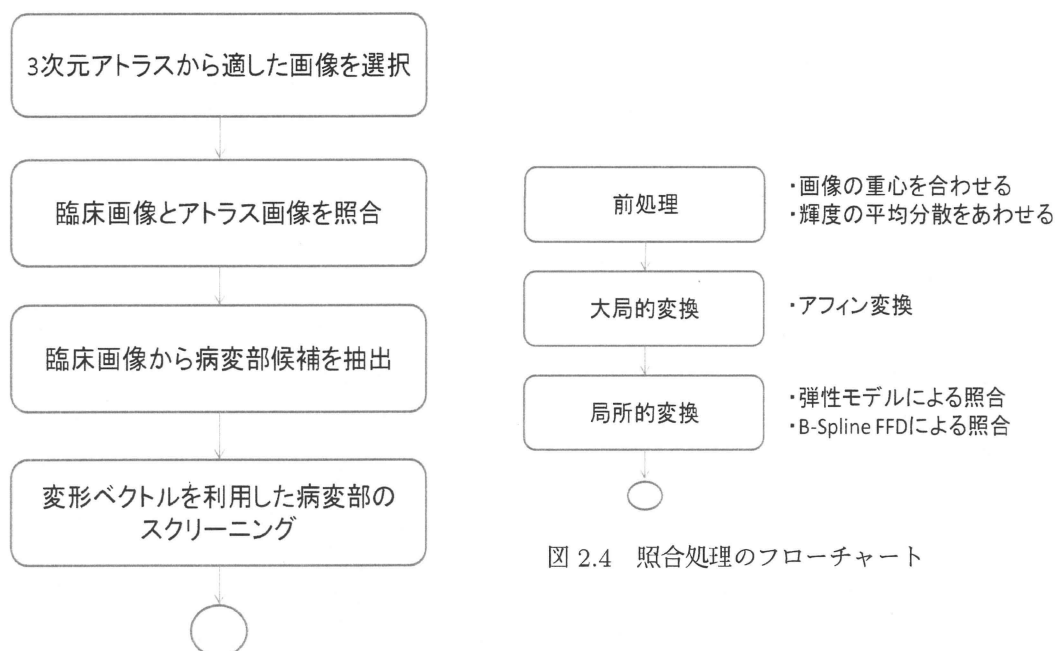


図 2.4 照合処理のフローチャート

図 2.3 システム全体のフローチャート

2.2 照合処理概略

本節では、アトラス画像と臨床画像の各組織の対応付けを行う照合処理について詳しく説明する。図 2.4 が照合処理のフローチャートである。照合処理には大きく分けて二つの段階がある。大局的な変形と局所的な変形である。大局的な変形とは大まかな形だけを合わせる、いわゆる線形変換（回転、拡大縮小、せん断、平行移動）による粗い変形である。そして大体の形を合わせると次に細かい変形、局所的な変形を行い各組織間の差異を合わせていく。例として図 2.1 と図 2.2 を照合した時の大局的な変形例と局所的な変形例を図 2.5) と (図 2.6 に示す。

次に各変換の具体的なアルゴリズムについて詳しく説明する。

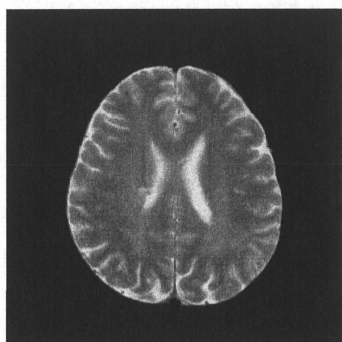


図 2.5 大局的変形

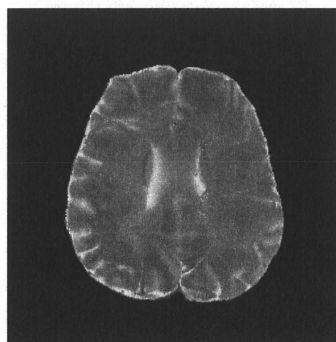


図 2.6 局所的変形

2.2.1 線形変換

この節では、線形変換の具体的なアルゴリズムを説明する。一般的に線形変換として、アフィン変換が利用される。

アフィン変換

3次元画像の変形を考える。ある座標 (x_i, y_i, z_i) がアフィン変換により (x'_i, y'_i, z'_i) に変換されたとすると、その変換式は式 (2.1) で定義される。ここで、 i は座標の番号を表している。

$$\begin{aligned}x'_i &= t_{11}x_i + t_{12}y_i + t_{13}z_i + t_{14} \\y'_i &= t_{21}x_i + t_{22}y_i + t_{23}z_i + t_{24} \\z'_i &= t_{31}x_i + t_{32}y_i + t_{33}z_i + t_{34}\end{aligned}\tag{2.1}$$

この変換式を行列表現 $\mathbf{x}'_i = \mathbf{T} \times \mathbf{x}_i$ と表現するならば、式 (2.2) で定義される。

$$\begin{bmatrix} x'_i \\ y'_i \\ z'_i \\ 1 \end{bmatrix} = \begin{bmatrix} t_{11} & t_{12} & t_{13} & t_{14} \\ t_{21} & t_{22} & t_{23} & t_{24} \\ t_{31} & t_{32} & t_{33} & t_{34} \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_i \\ y_i \\ z_i \\ 1 \end{bmatrix}\tag{2.2}$$

アフィン変換は、平行移動、回転、拡大縮小、せん断の変換に分解できる。例えば、剛体変換は4つの変換のうち平行移動と回転で表現することができる。

平行移動

ある座標を \mathbf{p}_t だけ移動させる場合、式 (2.3) で表すことができる。

$$\mathbf{x}'_i = \mathbf{x}_i + \mathbf{p}_t\tag{2.3}$$

また、行列表現では式 (2.4) で表すことができる。

$$\begin{bmatrix} x'_i \\ y'_i \\ z'_i \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & p_{t1} \\ 0 & 1 & 0 & p_{t2} \\ 0 & 0 & 1 & p_{t3} \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_i \\ y_i \\ z_i \\ 1 \end{bmatrix}\tag{2.4}$$

式 (2.4) によって座標は、 x 方向に p_{t1} 、 y 方向に p_{t2} 、 z 方向に p_{t3} だけ移動することになる。

回転

回転は平行移動より複雑である。各軸を回転させることで、3次元空間上の回転を表現する。回転方向の決め方によって多少変換行列は異なるがここでは左回りを正と決める。 x 軸を中心に p_{r1} 、 y 軸を中心に p_{r2} 、 z 軸を中心に p_{r3} だけ回転する変換は式 (2.5) で表される。

$$\mathbf{R} = \begin{bmatrix} \cos(p_{r3}) & -\sin(p_{r3}) & 0 & 0 \\ \sin(p_{r3}) & \cos(p_{r3}) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos(p_{r2}) & 0 & \sin(p_{r2}) & 0 \\ 0 & 1 & 0 & 0 \\ -\sin(p_{r2}) & 0 & \cos(p_{r2}) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos(p_{r1}) & -\sin(p_{r1}) & 0 \\ 0 & \sin(p_{r1}) & \cos(p_{r1}) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\begin{bmatrix} x'_i \\ y'_i \\ z'_i \\ 1 \end{bmatrix} = \mathbf{R} \begin{bmatrix} x_i \\ y_i \\ z_i \\ 1 \end{bmatrix} \quad (2.5)$$

回転において回転中心は各軸である．任意の座標を回転中心とする場合は，回転させる前にその座標が中心となるように平行移動させ，回転後に戻す必要がある．

拡大縮小

画像の x 座標を p_{z1} 倍， y を p_{z2} 倍， z を p_{z3} 倍にするための，行列表現は式 (2.6) で表される．

$$\begin{bmatrix} x'_i \\ y'_i \\ z'_i \\ 1 \end{bmatrix} = \begin{bmatrix} p_{z1} & 0 & 0 & 0 \\ 0 & p_{z2} & 0 & 0 \\ 0 & 0 & p_{z3} & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_i \\ y_i \\ z_i \\ 1 \end{bmatrix} \quad (2.6)$$

画像を拡大縮小する際には注意が必要である．各パラメータが負の場合，画像がその軸に対して反転することになる．つまり， P_{z1} を -1 とした場合は x 軸に線対称な画像となる．脳の形状は左右が似ている場合が多い．線形照合を脳シルエット画像で行うと左右を反転させてしまう可能性がある．このため，各パラメータが負にならないようにしなければならない．

せん断

せん断はパラメータ $p_{s1}, p_{s2}, p_{s3}, p_{s4}, p_{s5}, p_{s6}$ により式 (2.7) で変換えられる．

$$\begin{bmatrix} x'_i \\ y'_i \\ z'_i \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & p_{s1} & p_{s2} & 0 \\ p_{s4} & 1 & p_{s3} & 0 \\ p_{s5} & p_{s6} & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_i \\ y_i \\ z_i \\ 1 \end{bmatrix} \quad (2.7)$$

2.2.2 非線形変換

次に，局所的な変形について説明する．前節で説明した線形変換といえばアフィン変換だが，局所的な変形は最適で安定した変換は難しく様々な手法が考案されている．[7] [8] [1] [11] 本研究では，B-Spline FFD(Free Form Deformation) [7] と呼ばれる手法を利用して，局所的な変換を行う．この手法では画素間に制約があるので，組織構造が壊しにくいという特徴があり，組織構造を壊してしまうような無理な変形が起こりにくいという利点がある．

2.2.3 B-Spline FFD

B-Spline FFD(Free Form Deformation) とは，画像上の制御点の移動ベクトルから，各画素の移動ベクトルを B-Spline の基底関数を用いて計算し，非線形な変形を行う方法である．臓器の形状記述 [20] によく使われる方法である．B-Spline の num 番目の基底関数を θ_{num} ，制御点が持つ移動ベクトルを Φ とし制御点が n_x, n_y, n_z の間隔で画像上に配置されてるとするならば，座標 (x, y, z) での移動ベクトルは式 (2.8) で与えられる．

$$\mathbf{T}(x, y, z) = \sum_{l=0}^3 \sum_{m=0}^3 \sum_{n=0}^3 \theta_l(u) \theta_m(v) \theta_n(w) \Phi_{i+l, j+m, k+n} \quad (2.8)$$

ただし,

$$i = \lfloor \frac{x}{n_x} \rfloor - 1, \quad j = \lfloor \frac{y}{n_y} \rfloor - 1, \quad k = \lfloor \frac{z}{n_z} \rfloor - 1$$

$$u = \frac{x}{n_x} - \lfloor \frac{x}{n_x} \rfloor, \quad v = \frac{y}{n_y} - \lfloor \frac{y}{n_y} \rfloor, \quad w = \frac{z}{n_z} - \lfloor \frac{z}{n_z} \rfloor$$

である。ここで, i, j, k は注目している座標が影響を受ける制御点へのオフセットである。2次元にある座標が影響を受ける制御点を図 2.7 に示す。注目している座標が青い四角内にある場合, その周囲 4x4 の青い丸で表される制御点から影響を受けることになる。 i, j, k は図 2.7 の青い四角の左上の青い丸の座標を指すことになる。3次元の場合, 影響を受ける制御点の数は 4x4x4 となる。注目点 (x, y) では, 影響を与える各制御点について重み $\theta_l(u), \theta_m(v)$ を計算することで移動ベクトルが計算される

実際

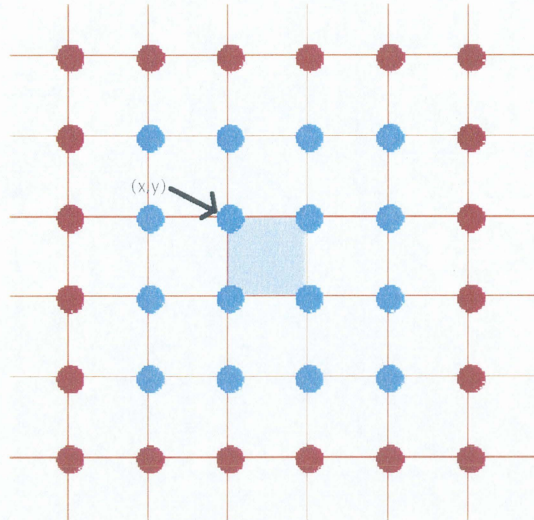


図 2.7 制御点

また, 基底関数は式 (2.9) で定義される。

$$\begin{aligned} \theta_0(u) &= \frac{(1-u)^3}{6} \\ \theta_1(u) &= \frac{(3u^3 - 6u^2 + 4)}{6} \\ \theta_2(u) &= \frac{(-3u^3 + 3u^2 + 3u + 1)}{6} \\ \theta_3(u) &= \frac{u^3}{6} \end{aligned} \quad (2.9)$$

画像上に配置された制御点の持つ移動ベクトルをパラメータとし, 各制御点パラメータにより変形される画像ともう一方の画像との評価値が尤も良くなるようなパラメータを決め, 式 (2.8) を適用して照合を行う。

2.2.4 パラメータの探索と評価値

局所的な変形において、評価値が最も良くなるパラメータを探索するために、本研究では共役方向法 [15] を利用している。

2.2.5 共役方向法

共役方向法とは、勾配法やニュートン法などのように関数の微分を用いるのではなく、関数の共役方向を利用する最適化法である。ある方向 \mathbf{u} に沿って最小化し、次に新しい方向 \mathbf{v} に沿って最小化する場合、 \mathbf{u} に沿った最小化を「無駄」にしないためには、勾配の変化が \mathbf{u} に垂直である必要がある。この条件を満たした二つの方向 \mathbf{u} , \mathbf{v} を共役であるという。共役方向法はこのような共役である方向ベクトルの集合を利用して最適化を行う。この方法は、微分を正確に求めることが困難な場合、勾配法やニュートン法などの微分を用いる方法よりも安定して解を求めることができる。

2.2.6 Powell 法

Powell 法は共役方向法の代表的な方法であり、共役方向を反復により更新する方法である。Powell 法のアルゴリズムを示す。まず方向ベクトル \mathbf{u}_i を基底ベクトルに初期化する。

$$\mathbf{u}_i = \mathbf{e}_i \quad i = 1, \dots, N$$

ここで、 N は方向ベクトルの総数 (パラメータの総数) である。そして、以下のステップを終了条件を満たすまで繰り返す。

1. 初期点 \mathbf{P}_0 とし、 $i = 1, \dots, N$ について、目的関数 $f(\mathbf{P}_{i-1} + \alpha_i \mathbf{u}_i)$ を最小とする α_i を求め、 $\mathbf{P}_i = \mathbf{P}_{i-1} + \alpha_i \mathbf{u}_i$ と置く。
2. $i = 1, \dots, N - 1$ に対して、 $\mathbf{u}_i = \mathbf{u}_{i+1}$ と置く。
3. $i = N$ に対して、 $\mathbf{u}_i = \mathbf{P}_i - \mathbf{P}_0$ と置く。
4. 目的関数 $f(\mathbf{P}_N + \alpha \mathbf{u}_N)$ を最小とする α を求め、 $\mathbf{P}_0 = \mathbf{P}_N + \alpha \mathbf{u}_N$ と置く。

ここで、本研究では目的関数の値が減少しなくなることを終了条件としている。目的関数として、画像の一致度 (類似度) を表す関数を用いる。(2.2.8 節参照) しかし、この方法では \mathbf{u}_1 を捨て、 $\mathbf{P}_N - \mathbf{P}_0$ をとる手続きによって出来る方向ベクトルの集合が線形従属となる傾向があるため、修正が必要である。

2.2.7 修正 Powell 法

修正 Powell 法はいくつか存在するが、ここでは本研究で使用する Acton による修正 Powell 法について説明する。基本的な考えは $\mathbf{P}_N - \mathbf{P}_0$ を新しい方向に選ぶが、目的関数 f がもっとも速く減少した方向を捨ててしまうことである。これは、目的関数 f がもっとも速く減少した方向、つまり前回の反復での最良の方向はこれから加える新たな方向の主

成分である可能性が高く、これを捨てることで線形従属性の累積を避けることができると考えられるからである。

この基本的な考え方にはいくつか例外があり、新しい方向を全く加えない方が良い場合がある。今 f_0, f_N, f_E を (2.10) のように定義する。

$$f_0 \equiv f(\mathbf{P}_0) \quad f_N \equiv f(\mathbf{P}_N) \quad f_E \equiv f(2\mathbf{P}_N - \mathbf{P}_0) \quad (2.10)$$

ここで f_E は新しい方向に少しだけ余分に進んだ点での目的関数の値である。また、現在の反復による最大の減少量を Δf とする。この時、

- $f_E \geq f_0$
- $2(f_0 - 2f_N + f_E)(f_0 - f_N) - \Delta f^2 \geq (f_0 - f_E)^2 \Delta f$

であるなら、現在の方向ベクトルの集合を次の反復にまで持ち越す。

この Acton による修正 Powell 法を本研究ではパラメータの最適化手法として採用する。

2.2.8 評価値

本研究では、画像の類似度を評価するための尺度として各対応画素の濃度値差を用いる。

$$S(A, B) = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} |(D_A(j, i) - D_B(j, i))| \quad (2.11)$$

A, B : 画像 N : 画像の縦方向のサイズ, M : 画像の横方向のサイズ, $D_A(i, j)$: 画像 A 上の (i, j) の濃度値 $D_B(i, j)$: 画像 B 上の (i, j) の濃度値

これを powell 法の評価関数としている。

2.2.9 B-Spline FFD の問題点

上記で示した照合法の問題点として、計算時間の膨大さがある。そこでブロック毎の powell 法による最適化手法を行った。格子点 1 点毎に最適化を行うことで計算時間は大幅に削減できた。今回、左上の格子点から順にラスタ走査を行い、右下まで各格子点毎に最適解を求めている。そのため、走査順番に変形が依存してしまっており、安定した照合が行われているとは言い難い。従って安定した照合手法を提案することが望まれる。

第3章

皮下脂肪除去のためのアルゴリズム

3.1 問題点

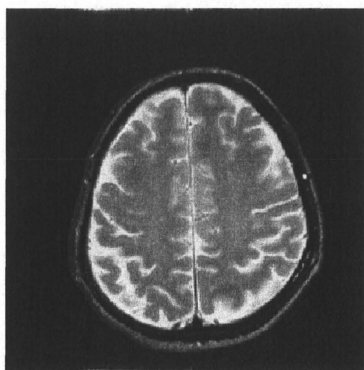
2章で、病変部検出のためには、アトラス画像と臨床画像を照合する必要があることを述べた。当然照合精度は高ければ高いほど誤差に惑わされず、正確に病変部を抽出することができる。

しかし、対象臨床画像によって照合処理が失敗してしまう例がいくつか存在する。

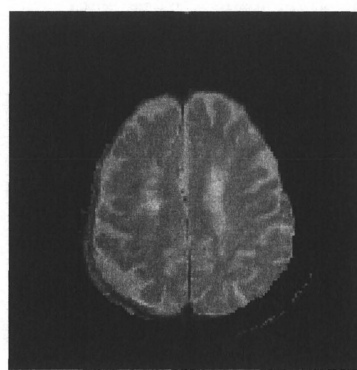
図 3.1 がその一例となる。見て分かるように左下の皮下脂肪が原因で照合が失敗していることが分かる。そこで照合する前処理として皮下脂肪を除去することによって照合精度を向上出来ないかと考えた。

3.2 従来方法

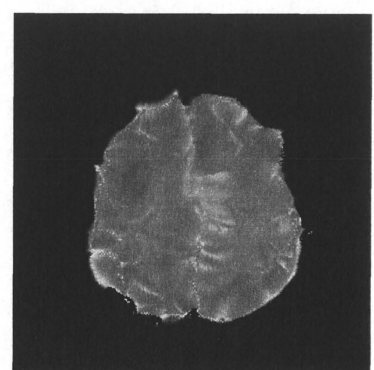
頭部の領域を抽出する手法は様々提案されている。主な方法としては [3] [2] で提案されている領域拡張法であるが、この手法は今回の例のように、皮下脂肪と脳実質領域がくっついて見えているケースで脳実質領域のみを抽出することは非常に難しい。またこの手法は拡張するシードの決定を手動で行っているので [3] 自動化が出来ないという問題もある。領域拡張は、様々な臓器の抽出に使われるが、脳画像は他臓器に比べ構造が非常に複雑で、



(a) アトラス画像

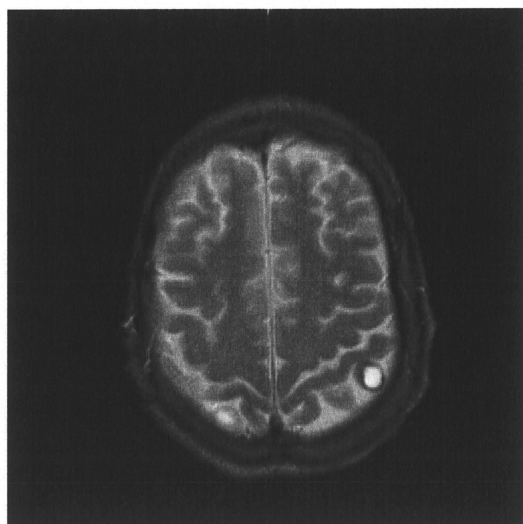


(b) 臨床画像

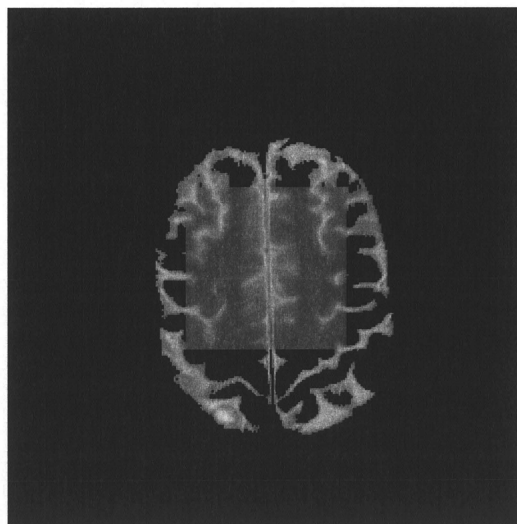


(c) 照合結果

図 3.1 照合失敗例



(a) 原画像



(b) 領域拡張を適用した結果

図 3.2 領域拡張適用例

抽出は難しい。簡単な領域拡張を適用した結果を図 3.2 に示す。今回は中心にシードを設定して、そのシード領域内の平均値を利用して、隣接する画素が平均以上であれば併合するという条件で領域拡張を行っている。

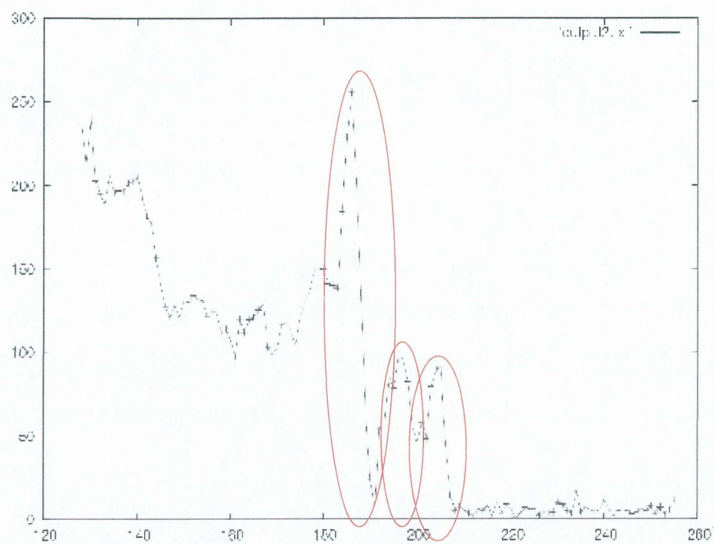
このように低輝度領域はほとんど抽出出来ていない。また本来は病変部等も抽出して貰いたいのだが、病変部の周りは非常に低輝度な領域に囲まれているので、病変部まで併合できない。当然、低輝度領域や病変部にシードを設定すれば、その部分は抽出できるが、病変部部分を抽出することが目的であるのに、その前処理で病変部やその他の組織の位置を必要とするのは本末転倒である。また今回紹介した例では見られないが、抽出してほしくない領域と抽出してほしい領域がくっついて見える場合、誤抽出が起きてしまうという問題が領域拡張にあることは良く知られている。このように安定して脳実質を抽出するには、領域併合処理の前に複雑な前処理を必要とする。

そこで、本手法は脳の形状情報を利用した濃度値分布図を利用した手法 [16] を利用する。

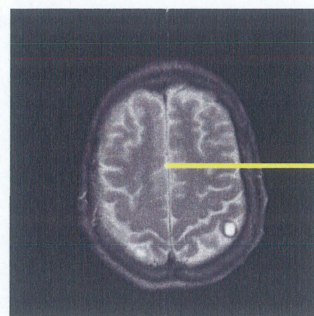
3.3 濃度値分布図を利用した手法

この手法は、自身の卒業研究で開発したアルゴリズムである。今回はその手法を改良し更に精度を向上させた。まず基本的な考え方を説明する。この手法は頭部の形状に着目した手法である。頭部 MR 画像はまず中心に脳実質が存在する、そして脳実質の縁に高輝度な CSF (脳脊髄液 cerebrospinal fluid) があり、さらにその外側に低輝度な頭骨があり、一番外側に比較的高輝度な皮下脂肪が存在する。頭部 MR 画像には一般的にこのような形状特徴がある。

図 3.3 は右の臨床画像上の黄色い線上の濃度値分布図である。左の丸から順に CSF、頭骨、皮下脂肪と判別することが出来る。図で分かるように CSF と皮下脂肪、頭骨の間に非常に大きなエッジが存在することが分かる。そこでこのような濃度値分布図を中心から放



(a) 濃度値分布



(b) 臨床画像

図 3.3 濃度値分布図と対応した臨床画像

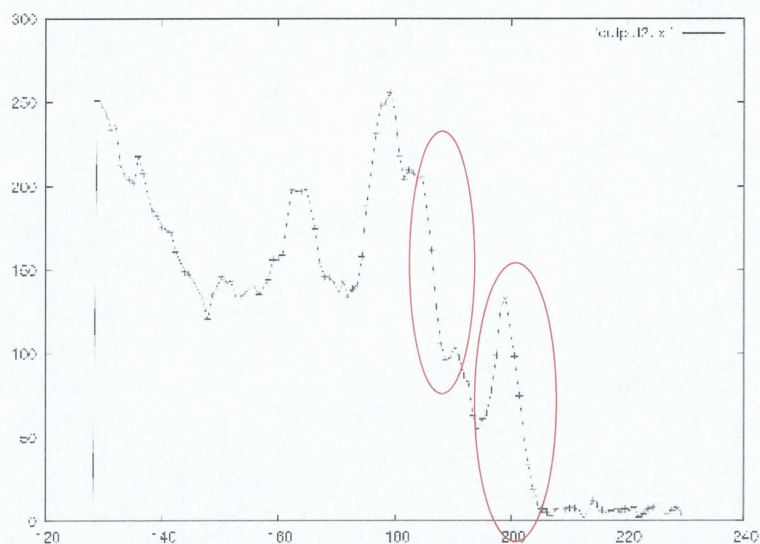


図 3.4 CSF のエッジより皮下脂肪のエッジの方が大きい場合の濃度値分布

射状に取得しその中で最大のエッジ部分を取得することで脳実質境界の抽出ができると考えた。

しかし、図 3.1 の例のように CSF よりも皮下脂肪の方が大きなエッジである場合、各濃度値分布のエッジを抽出するといった単純な処理では、脳実質を抽出できない。そこで脳の形状をモデル化することで皮下脂肪と脳実質を分離することが出来ないかと考えた。

3.3.1 異常部分の除去について

頭部 MR 画像は余程異常な写り方をしない限り中心に脳実質が存在し、その外側に頭骨部分、その更に外側に皮下脂肪が見える。ここで図 3.4 のような例を回避するために、脳実質の中心から放射状に取得した濃度値分布図から特徴点を計算し、脳実質境界をモデル化することにより、脳実質境界を自動的に抽出する。

図 3.4 のような濃度値分布図は全体の中でごく一部である。しかしこの濃度値分布図のみを利用して、脳実質境界を抽出しようとする、このような部分で誤抽出を許してしまう。そこで周りの正しい濃度値分布を考慮に入れることで異常な部分を除去する。

特徴点について

濃度値分布から取得できる特徴点について詳しく説明する。前説では、図 3.3 の濃度値変動から、エッジを利用して脳実質境界を抽出できると説明した。そのエッジを取得するために濃度値分布図の極大極小をひとつの対と定義する。それを取得したすべての濃度値分布図に対して、極大極小の対を取得する。ここで脳画像から特徴点を抽出するアルゴリズムを記す。尚、対象画像は 256×256 の 2 次元画像である。

1. 中心を (128,128) として、始点 (128,128) 終点 (256,128) の線分から濃度値分布を取得する。
2. 取得した濃度値分布から極大極小の値の実画像上での位置と濃度値を全て取得する。
3. 終点を 1 ピクセルだけ x 方向にずらして、終点 (257,128) とし、その線分上の濃度値分布を取得し、2. と同じように極大極小の対を取得する。
4. 以上の処理を終点が画像を一周するまで行う。

これらの操作により特徴量として下記に記す情報を取得できる。

1. 極大点の座標 (x_{max}, y_{max}) , 濃度値 d_{max}
2. 極小点の座標 (x_{min}, y_{min}) , 濃度値 d_{min}
3. 特徴点を取得した濃度値分布図の位置 $stepN$

3.3.2 脳実質境界のモデル化

抽出した特徴点を利用して濃度値分布から脳実質境界らしさを計算する。理想的な脳実質境界には以下のような特徴がある。

1. 極大極小対の濃度値差が他の対の濃度値差よりも大きい。
2. 周囲の特徴点の距離が近い。
3. 極大点の部分の濃度値が他の極大点の濃度値よりも比較的大きい。

これらを数式化すると以下のような式になる

$$d(a, b) = A * density(a) + B * value(a) - C * exp(rdist(a, b)) \quad (3.1)$$

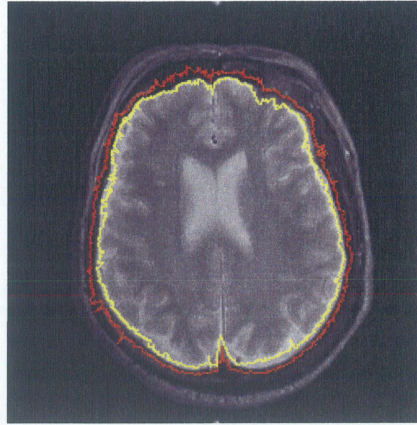


図 3.5 脳実質境界領域抽出例

a : 対象特徴点 b : 前の濃度値分布上の任意の特徴点 density : 極大極小の濃度値差
value : 極大点の濃度値 rdist:次の濃度値分布上の特徴点との距離 A,B,C:任意の係数

式 3.1 を目的関数として, 各濃度値分布から取得できる特徴点毎の多段決定問題と考え, 動的計画法を適用することで脳実質境界領域を抽出する.

動的計画法とは, 対象となる問題の部分問題の解を計算して記憶しておき, 計算時間を削減する手法である. 動的計画法は最適性の原理を利用しており, 多段決定問題, つまり, 各段における最適な系列を求めるような問題ならば, 動的計画法によって解くことが可能である.

今回の場合, 各濃度値分布毎の多段決定問題にすることで, この問題を動的計画法で解く. 式 3.3 と式 3.2 に本問題における再帰方程式を定義する.

$$\phi(2, m) = \max_{(M_1 \geq j \geq 1)} [d(a_{2,m}, a_{1,j})] \quad (3.2)$$

$$\phi(n, m) = \max_{M_{n-1} \geq j \geq 0} [\phi(n-1, j) + d(a_{n,m}, a_{n-1,j})] (M_n \geq m \geq 1, N \geq n \geq 1) \quad (3.3)$$

部分最適解を 2 次元配列 $\phi(n, m)$ に格納するとする.

M_n : n 番目の濃度値分布で得られる特徴量の個数 (n=1 は画像の中心から右方向の線分であり, n=N は回転して得られる最後の線分である) N : 取得できる濃度値分布の数
 $a_{n,m}$: n 番目の濃度値分布の m 個目の特徴量 $d(a_{n,m}, a_{n-1,j})$:式 3.1 の目的関数

M_1 個の $\phi_{N+1,m}$ のうち, 最大の値を持つものを選び, その段階で得られる極大極小対で囲まれる領域を脳実質境界領域とする. ここで領域としたのは, 探索した特徴点は濃度値分布の極大極小の情報のみであり, 脳実質境界を特定したわけではないからである. 図 3.5 に実際の臨床画像に適用した例について示す. 赤色と黄色の曲線は, それぞれ, 境界領域の極小値側と極大値側の曲線である.

3.4 脳実質境界領域から脳実質境界の特定

図 3.5 は前節の手法を利用して, 自動的に脳実質境界領域を抽出した結果である. 次に, この脳実質境界領域から脳実質を抽出する. 本研究ではその輪郭抽出に Snakes [17] とい

われる ACM(Active Control Model) を用いる手法を利用する. Snakes はノイズに対して頑強な境界追跡法として広く知られている. しかし, 初期輪郭を必要とする手法である. 本研究では, 前節で得られた脳実質境界領域を利用して初期輪郭を与えることができるので, この方法を採用した.

次に Snakes の詳しい理論を説明する.

3.4.1 Snakes

2次元画像における Snakes の理論を示す. Snakes は次式で与えられるエネルギー関数 $\epsilon(\vec{v})$ を最小化するように閉曲線 C が決定される

$$\epsilon(\vec{v}) = S(\vec{v}) + P(\vec{v}) \quad (3.4)$$

ただし $\vec{v}(s) = [x(s), y(s)]^t$ は閉曲線 C のパラメータ表現であり, $0 \leq s \leq 1$ は閉曲線 C の弧長パラメータである. $[]^t$ は転置を表している. 上式で $S(\vec{v})$ は閉曲線 C の内部パラメータであり, 次式により定義される.

$$S(\vec{v}) = \frac{1}{2} \int_0^1 (w_1(s) \left| \frac{\partial \vec{v}}{\partial s} \right|^2 + (w_2(s) \left| \frac{\partial^2 \vec{v}}{\partial s^2} \right|^2) ds \quad (3.5)$$

ただし, $w_1(s), w_2(s)$ はそれぞれ曲線の張力及び剛性を決定する非負の関数である.

$P(\vec{v})$ は外部ポテンシャルエネルギーであり, 一般に以下のように定義される.

$$P(\vec{v}(s)) = \int_0^1 Q[\vec{v}(s)] ds \quad (3.6)$$

ここで $Q(\vec{v}(s))$ は曲線と画像との適合度を表すポテンシャル関数であり, 例えばに以下のように定義される.

$$Q(\vec{v}(s)) = Q([x(s), y(s)]^t) = -c |\nabla G_\sigma \otimes I(x(s), y(s))| \quad (3.7)$$

ただし, c は定数, ∇ はグラディエント, $G_\sigma \otimes I(x, y)$ はガウシアンフィルタである. これにより, 曲線は画像中の濃度値勾配の大きな領域で停留するように制御される.

3.4.2 Snakes による脳実質境界の抽出

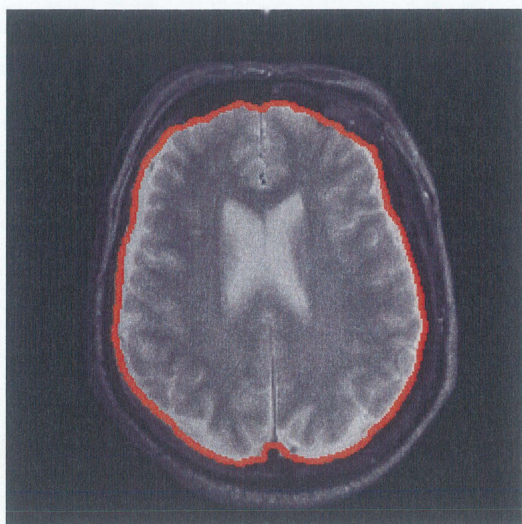
Snakes を利用した脳実質境界の抽出のアルゴリズムにを説明する.

1. 脳実質境界領域を取得する.
2. 取得した領域から中線を求め初期輪郭とする.
3. Snakes を適応して境界線を求める.

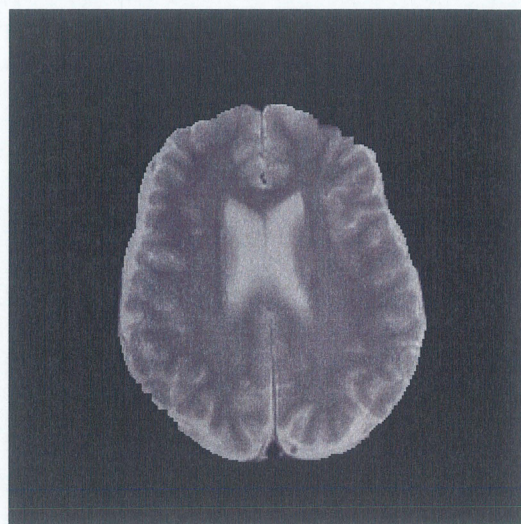
そのアルゴリズムを適用して輪郭を抽出した結果が図 3.6 である.

以上の手法で頭骨, 皮下脂肪などの不必要な組織を除去し, 正確に輪郭を抽出することが出来た.

次章で臨床画像に対して本手法を適用することで, 本手法の有用性について示す.



(a)Snakes 適用例



(b) 脳実質境界抽出例

図 3.6 脳実質抽出例

第 4 章

皮下脂肪除去に関する実験

4.1 実験データ

本実験で扱う画像は全て T2 強調画像 [19] とする。サイズは 256×256 の 2 次元データで, あらかじめ [14] [12] 等の手法を利用して 3 次元臨床画像から利用するスライスを選択する。今回, 手持ちの 10 例を対象に実験を行った。

4.2 実験 1

臨床画像に対して本手法を適用した。そして, 上手く脳実質の境界領域を抽出出来ているか目視で確認し, 境界領域を抽出出来た臨床画像に対して照合処理を行い, 皮下脂肪を除去していない場合としている場合の照合精度を比較し本手法の有用性を調べた。実験結果は図 4.1 のような形式で表す。

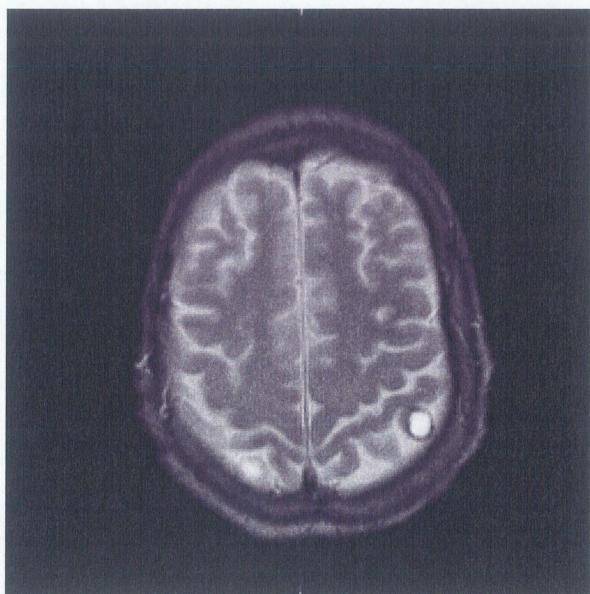


図 4.1 表示結果形式

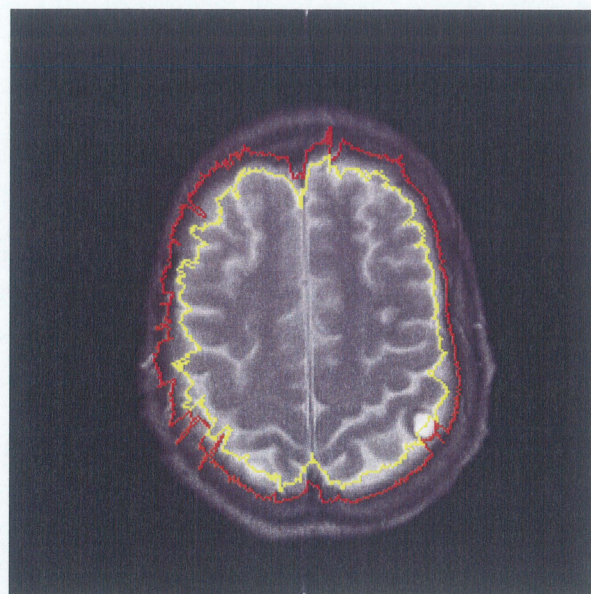
4.2.1 実験結果

実験 1

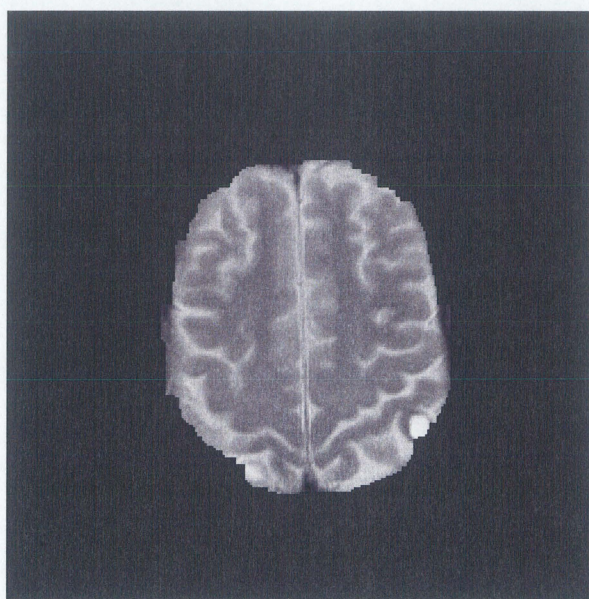
左下の部分で, 真の脳実質境界より内側を境界として抽出している. このように誤抽出された原因は, 脳溝髄液で得られるエッジ強度が真の境界のエッジ強度よりも強く, 広い範囲でエッジ強度が強くなっていることが原因である.



臨床画像



輪郭領域

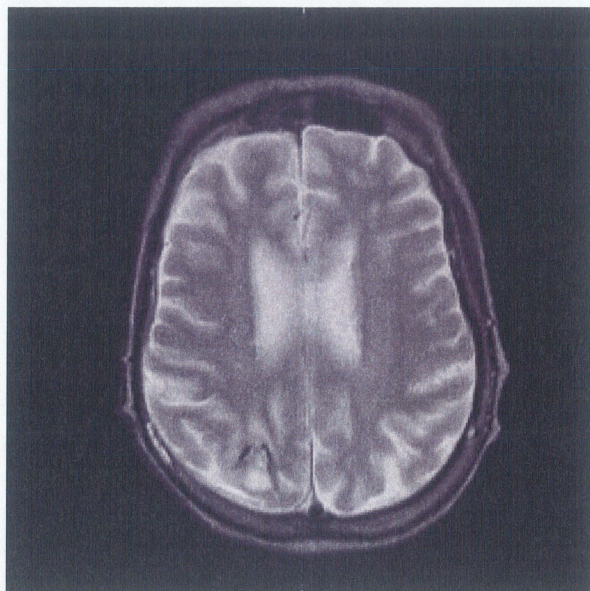


脳実質

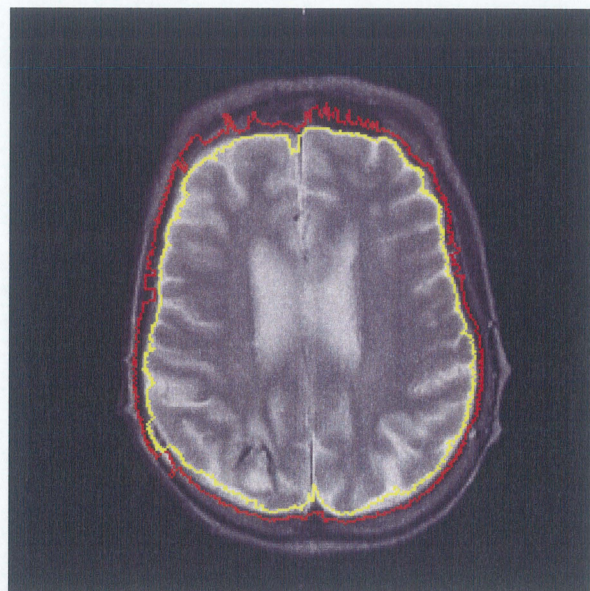
図 4.2 実験 1

実験 2

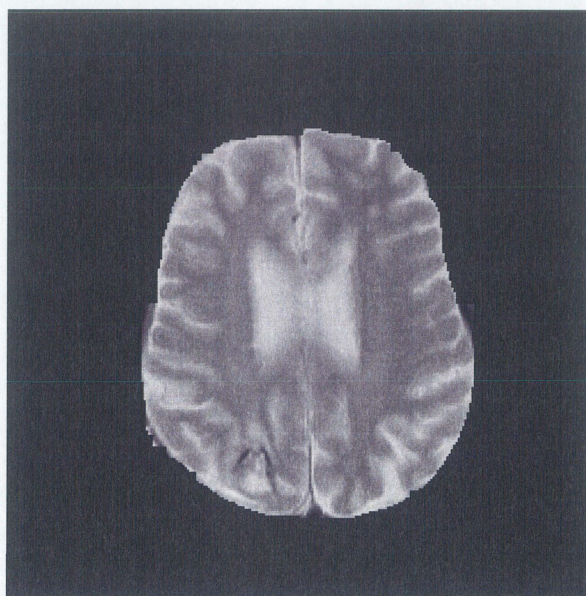
脳実質境界付近に所々、不要な皮下脂肪が接触していることが確認できるが、画像の勾配情報や、曲率を利用した Snakes により除去できていることが確認できる。



臨床画像



輪郭領域

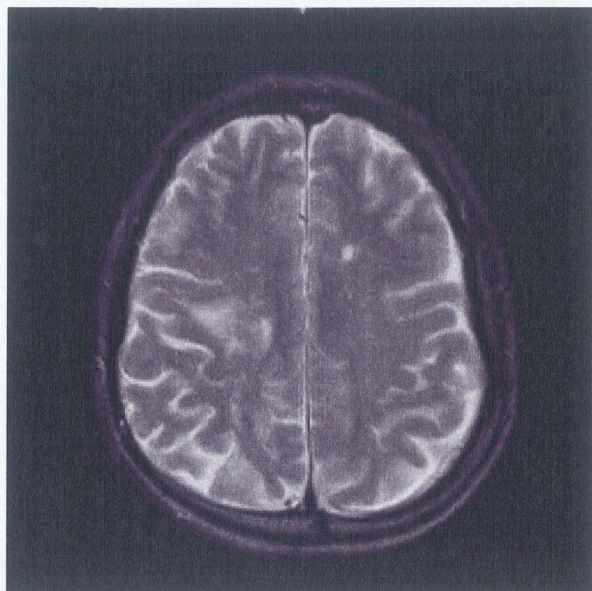


脳実質

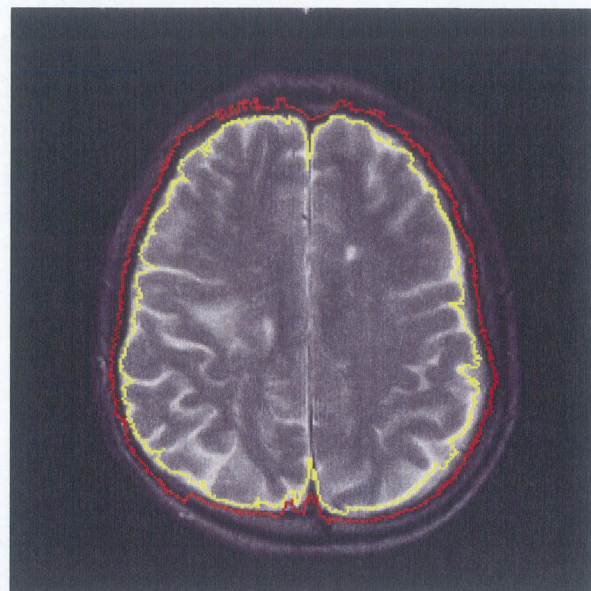
図 4.3 実験 2

実験 3

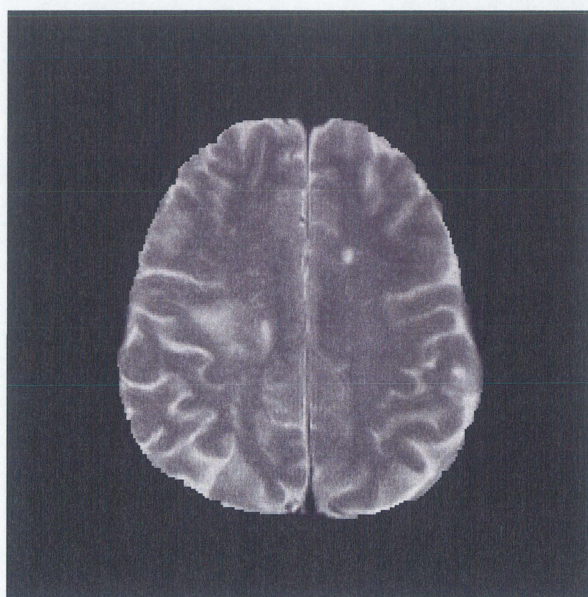
頭骨部分が良く見える撮像位置だが脳実質境界の間に空間が見え、分離されているので、本手法で上手に除去出来た。



臨床画像



輪郭領域



脳実質

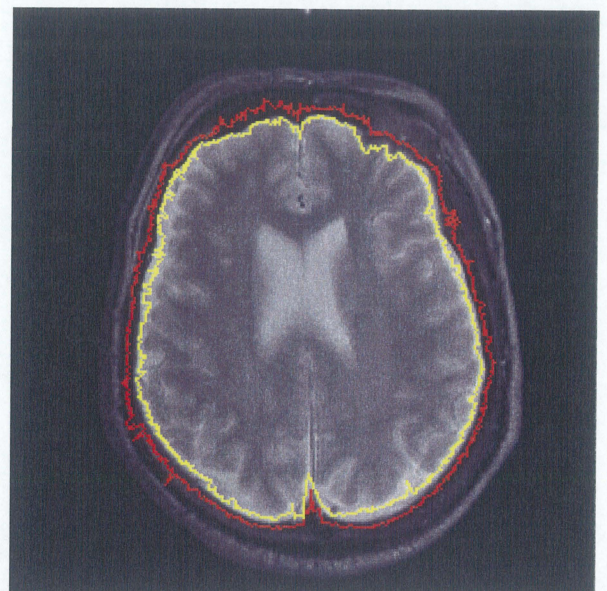
図 4.4 実験 3

実験 5

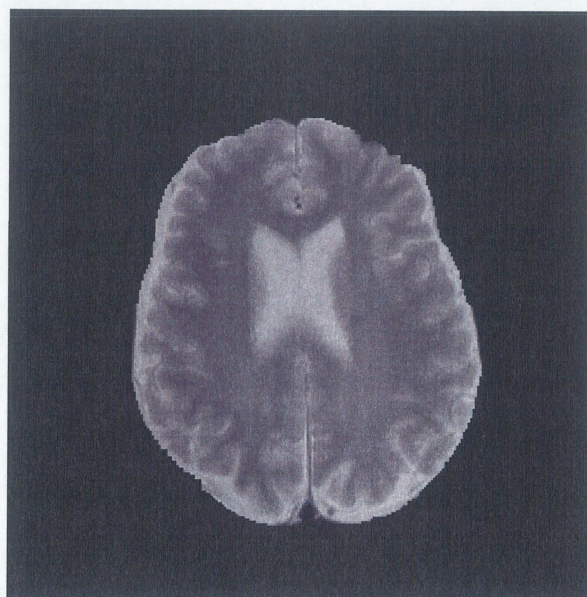
今までの臨床画像の撮像位置は、額上部の断面像であったが、この画像はそれよりも下部の画像であり、眼球部分が近いので前頭葉部分が今までとは違う形になっている。しかし、脳実質境界部に高輝度領域の CSF がはっきりと写っているので正確に実質を抽出することができた。



臨床画像



輪郭領域

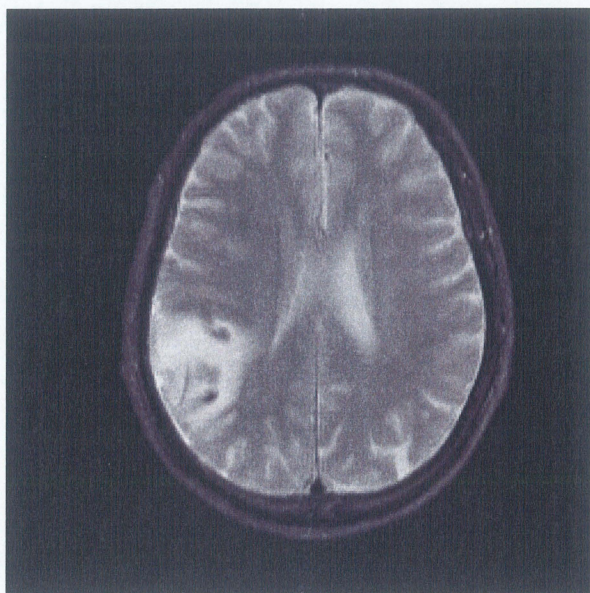


脳実質

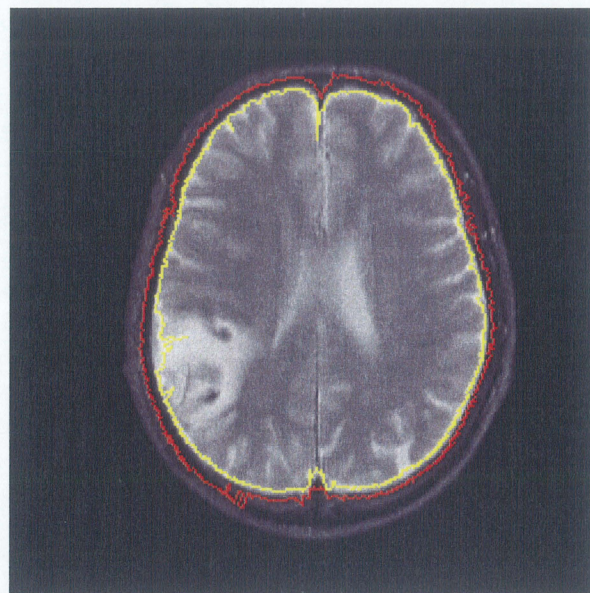
図 4.5 実験 5

実験 6

この画像では、画像下部に頭骨が見えたり見えなかったりする部分があるので、脳実質境界の抽出が困難である。しかし Snakes を用いるとその部分は無視され、境界を正確に抽出出来ていることが分かる。



臨床画像



輪郭領域



脳実質

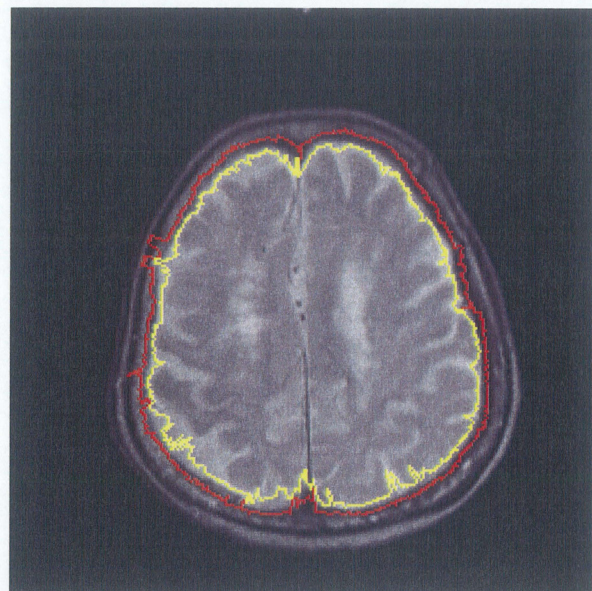
図 4.6 実験 6

実験 7

脳溝と頭骨, 皮下脂肪の濃度値の差があまり無く, 特に左下の脳実質境界と頭骨が接触して見える場所は, 以前から問題となっていた. しかし, 本手法を適用することで, 周りの比較的脳実質と頭骨が離れている領域から計算した情報により上手く脳実質境界が抽出できていることが分かる.



臨床画像



輪郭領域

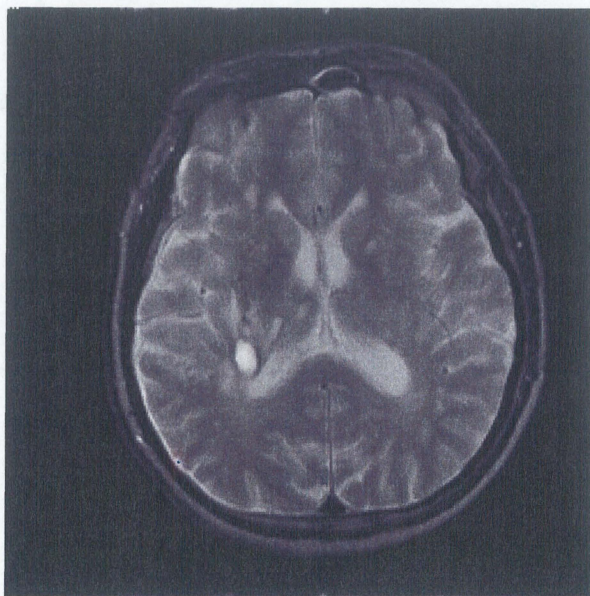


脳実質

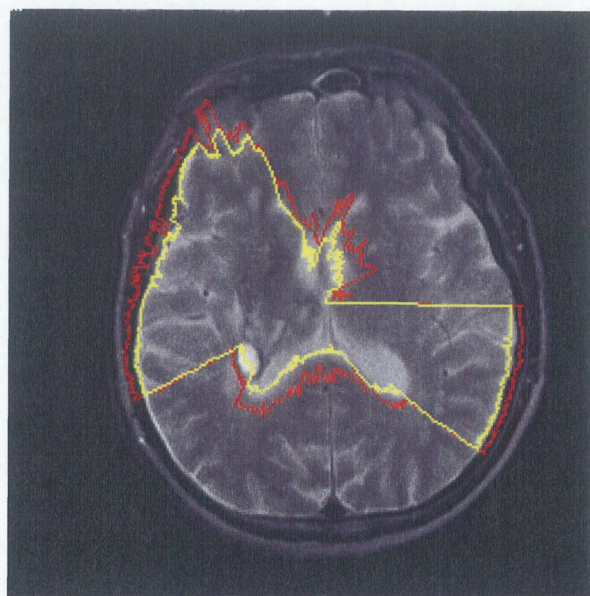
図 4.7 実験 7

実験 8

これは失敗例である。脳の構造が今回設定した目的関数の定義に合っていなかったことが原因と考えられる。今回、想定した脳実質の境界は、頭頂から眼球の上部分までを対象としている。眼球が写る断面とその下部では、前頭葉近辺のの形状が複雑になっている。従って、定義した目的関数では脳実質境界を抽出することが出来なかった。この例では、脳実質境界領域の抽出に失敗しているので、Snakes による皮下脂肪除去は行わなかった。



臨床画像



輪郭領域

図 4.8 実験 8

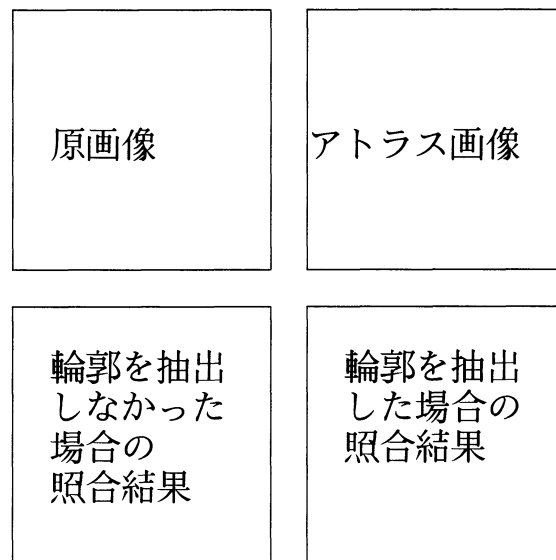


図 4.9 実験結果表示形式

4.2.2 考察

対象の臨床画像 10 例に対して本手法を適応した結果,10 例中 8 例に対して正確な脳実質境界を抽出出来たことが確認できた. 図 4.8 のようなこちらが想定していないような脳の形状をしている場合, 失敗してしまう. 今後 3 次元での脳実質抽出を考える場合避けられない問題である. 解決するために, 新たにその部分に適した目的関数を定義することにより抽出が可能となると考えられる.

4.3 実験 2

次に脳実質境界抽出に成功した臨床画像に対して照合処理を行い, 皮下脂肪を除去していない場合の精度と比較する. 画像の類似度として画素毎の残差の和を用いる (4.1).

$$D = \sum_i^{256} \sum_j^{256} I(i, j) - I'(i, j) \quad (4.1)$$

I: アトラス画像の濃度値, I': 臨床画像の濃度値

精度に関しては, (式 4.2) を利用する.

$$S = \frac{\text{照合前の残差} - \text{照合後の残差}}{\text{照合前の残差}} \quad (4.2)$$

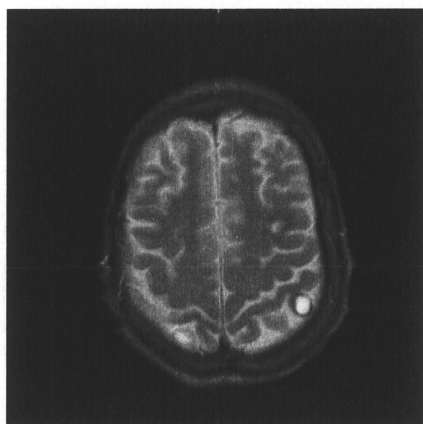
実験の表示形式を図 4.9 に示す.

4.3.1 実験結果

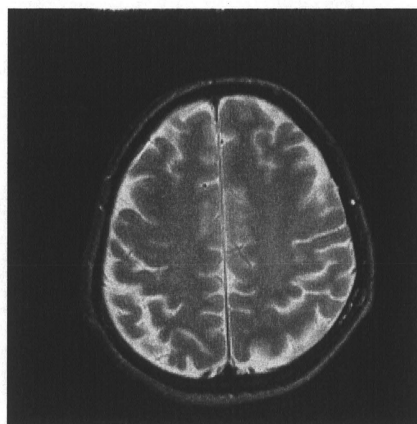
実験 1

外側の不必要な組織(皮下脂肪や頭骨)がかなりはっきりと出ている。これを放置したまま、照合すると下のような結果になる。皮下脂肪、頭骨部分に組織が引っかかり満足に変形出来ていない。しかし、前処理で不必要部分を除去すると外形にあった変形が行われている。

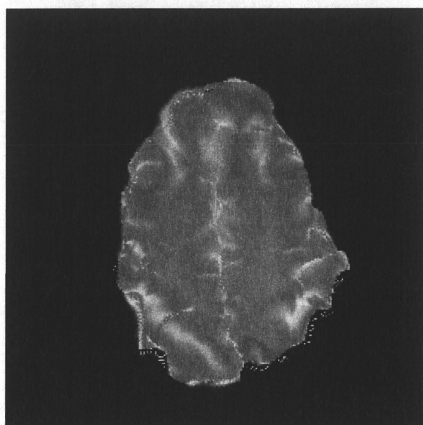
	照合前精度	照合後精度	改善度
皮下脂肪、頭骨を除去	9.194e+06	2.076e+06	0.77
除去しない	9.910e+06	6.269e+06	0.37



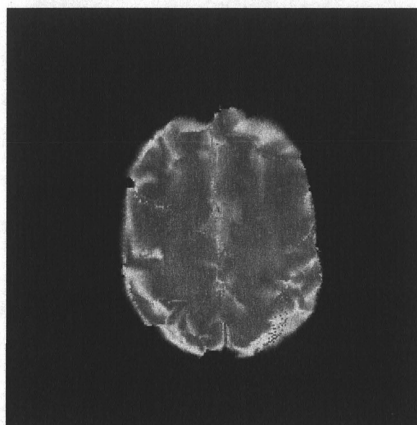
臨床画像



アトラス画像



輪郭を抽出しなかった場合
の照合結果

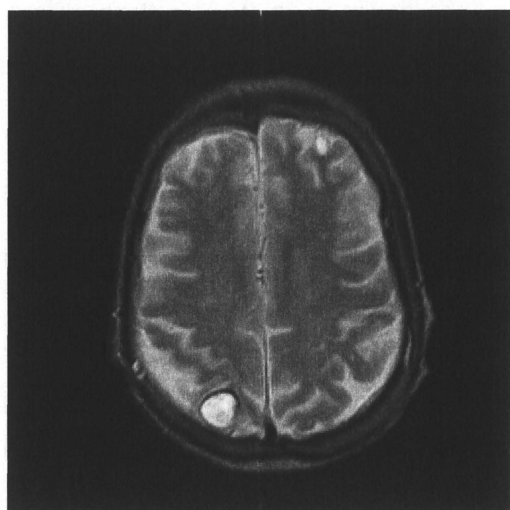


輪郭を抽出した場合
の照合結果

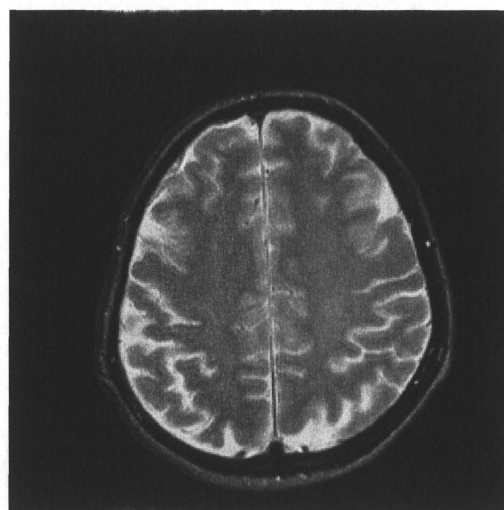
実験 2

脳実質を抽出しない画像では, 右下部, 左下部部分で非常に輝度の高い不必要部分があり, そこにアトラス画像の脳溝部分がひっきり誤変形が見られる. 不必要部分を除去することで, その部分が修正されている

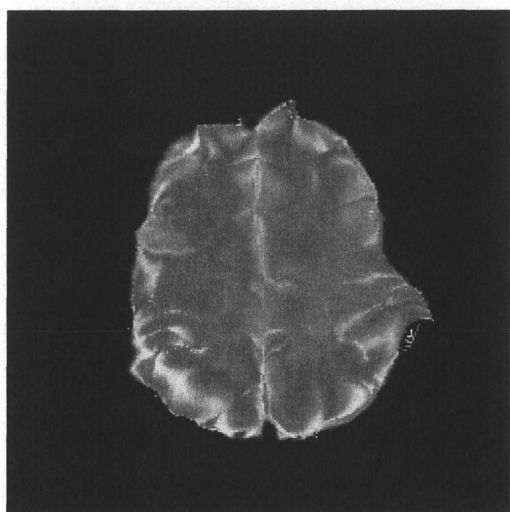
	照合前精度	照合後精度	改善度
皮下脂肪, 頭骨を除去	7.528e+06	2.359e+06	0.66
除去しない	9.381e+06	6.20e+06	0.34



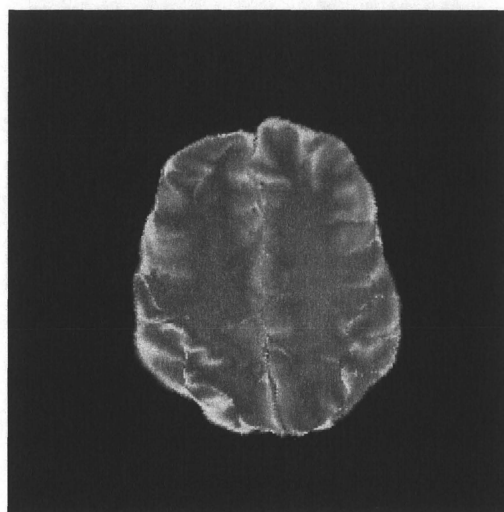
臨床画像



アトラス画像



輪郭を抽出しなかった
場合の照合結果

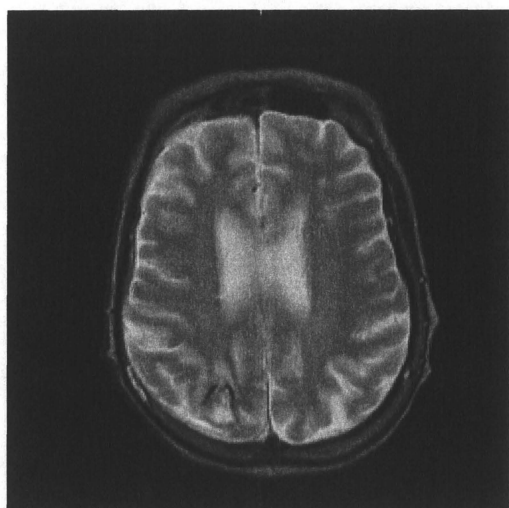


輪郭を抽出した
場合の照合結果

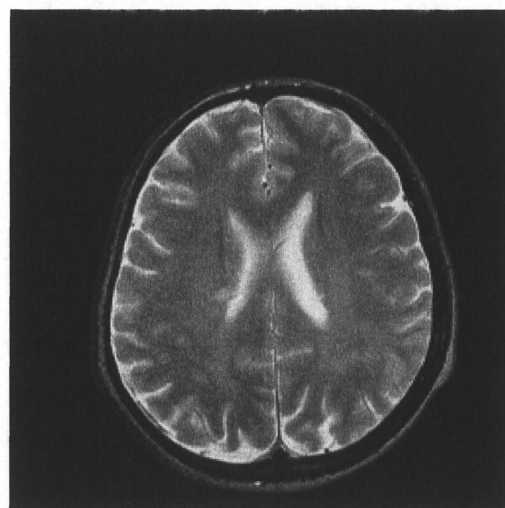
実験 3

臨床画像の境界付近に見える皮下脂肪が邪魔をし、変形に著しい異常が見られる。アトラス画像の下部の組織が丁度臨床画像の皮下脂肪、頭骨部分に反応し、誤変形が起きたと考えられる。それに対して、事前に脳実質境界を抽出した場合だとそれらの部位の影響が無く正常に変形していることが分かる。

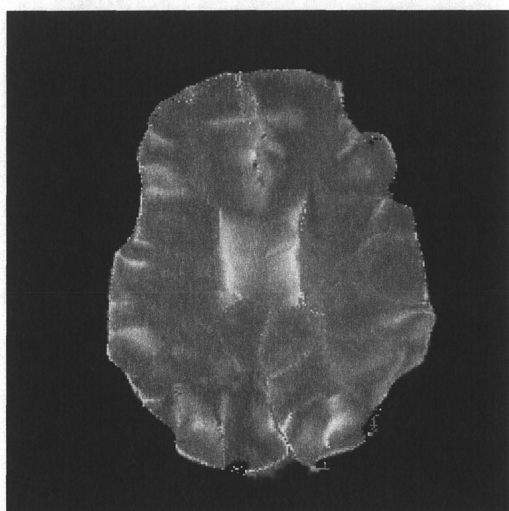
	照合前精度	照合後精度	改善度
皮下脂肪、頭骨を除去	7.528e+06	2.401e+06	0.67
除去しない	9.381e+06	4.9243+06	0.27



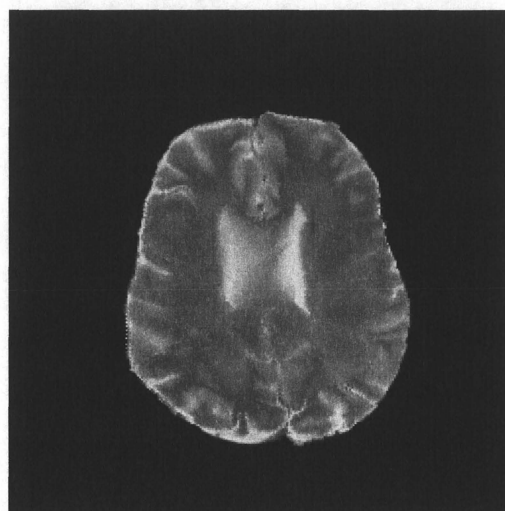
臨床画像



アトラス画像



輪郭を抽出しなかった
場合の照合結果

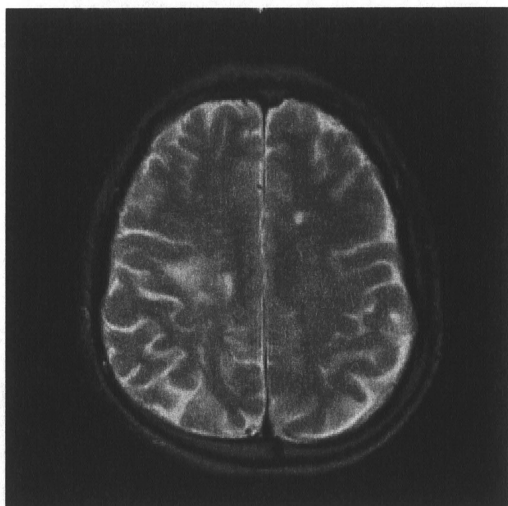


輪郭を抽出した
場合の照合結果

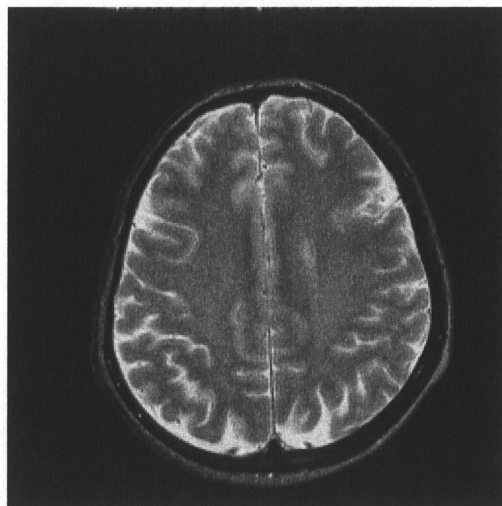
実験 4

除去しない画像は下部で異常な変形が起きている。アトラス画像の下部の高輝度領域が臨床画像の頭骨部分に反応し、異常な変形が起きている。また上矢状静脈洞部分が頭骨部分により、埋まってしまっている。

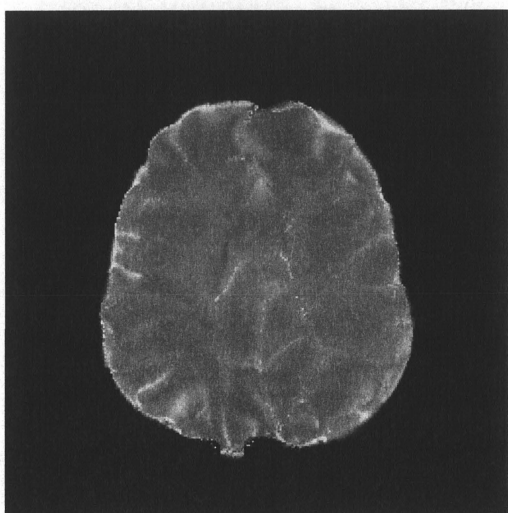
	照合前精度	照合後精度	改善度
皮下脂肪, 頭骨を除去	7.393+06	3.323e+06	0.54
除去しない	1.036e+07	6.887e+06	0.34



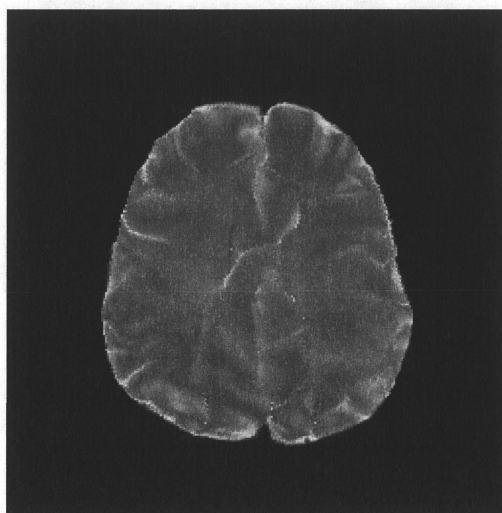
臨床画像



アトラス画像



輪郭を抽出しなかった
場合の照合結果

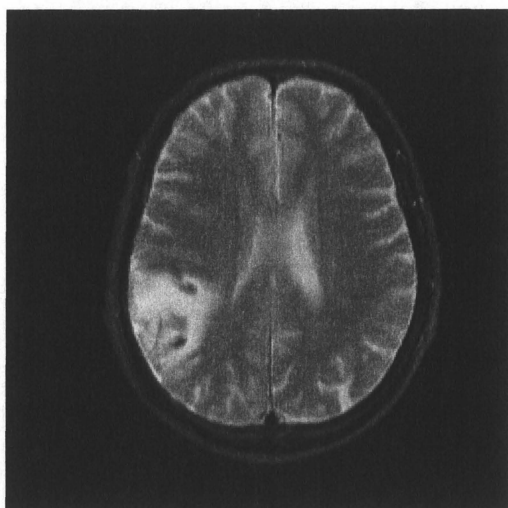


輪郭を抽出した場合
の照合結果

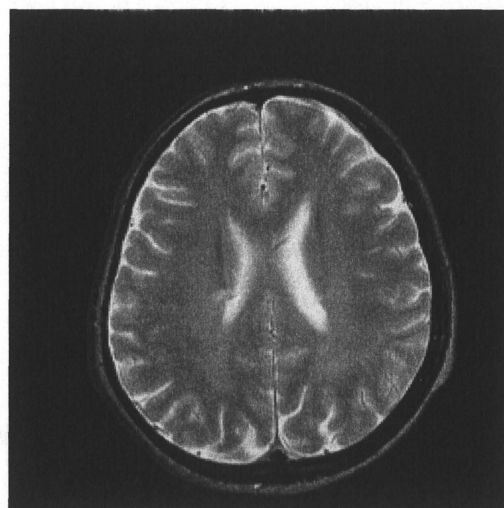
実験 5

皮下脂肪がかなり低い輝度値であり、脳実質境界との距離も離れていたため皮下脂肪を除去せずとも、正確な照合が出来ていた。しかし画像の下部に薄く頭骨が見えるために、上矢状静脈洞部分が無くなってしまった。脳実質を抽出した場合だと、上矢状静脈洞部分はちゃんと残っており、そのような細かい部分で精度に差が出たと思われる。

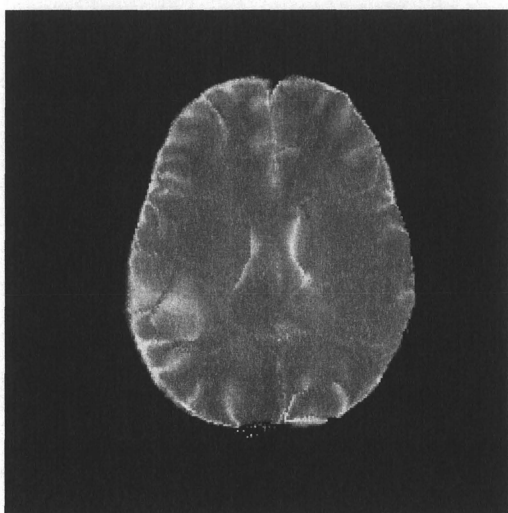
	照合前精度	照合後精度	改善度
皮下脂肪, 頭骨を除去	8.591e+06	2.423e+06	0.60
除去しない	1.051e+07	4.51e+06	0.57



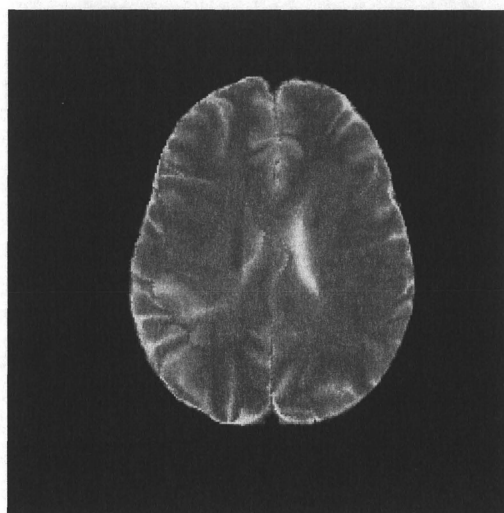
臨床画像



アトラス画像



輪郭を抽出しなかった
場合の照合結果

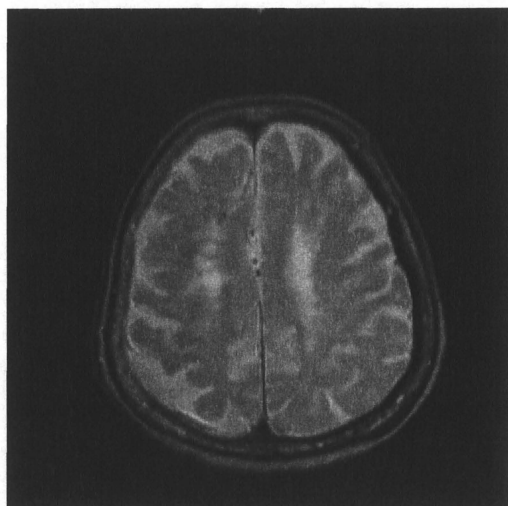


輪郭を抽出した場合の
照合結果

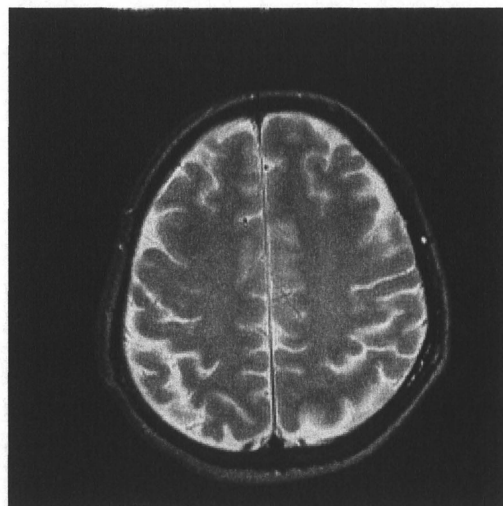
実験 6

臨床画像側の脳実質境界部分と頭骨, 皮下脂肪に輝度値の差があまり無く, 左下部分と右上部分で誤変形が見られる.

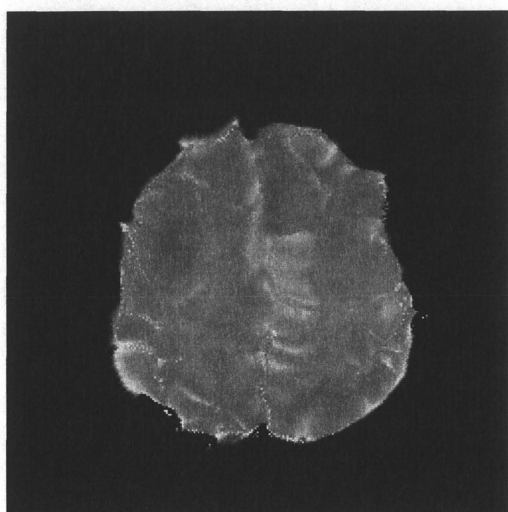
	照合前精度	照合後精度	改善度
皮下脂肪, 頭骨を除去	6.301e+06	2.122e+06	0.66
除去しない	8.591e+06	5.618e+06	0.37



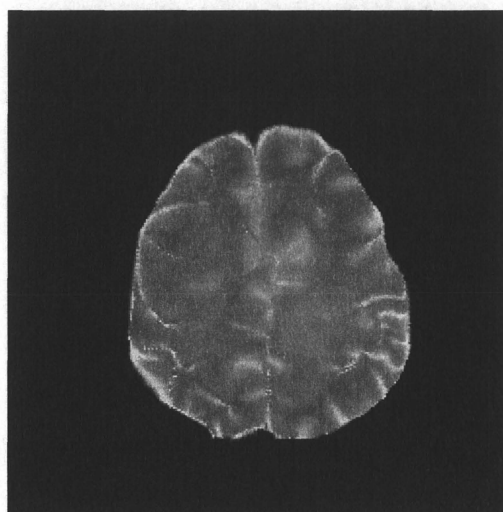
臨床画像



アトラス画像



輪郭を抽出しなかった
場合の照合結果



輪郭を抽出した場合
の照合結果

4.3.2 実験考察

実験結果を見て分かるように, 皮下脂肪を除去したことにより照合精度が向上した. 今回利用した B-Spline FFD 以外でも [8] [11] らの手法でも皮下脂肪による照合精度の低下が問題となっていた. 従って, 今後更に照合精度の向上を目指すために照合手法を変更しても, この手法は一定の精度向上に貢献できると考える. このことより, 皮下脂肪を自動的に除去したことによる照合における有効性を示すことが出来た.

第5章

病変部候補検出における指標の提案

5.1 はじめに

2章で病変部検出のためのアトラス画像を用いた照合の手法について簡単に紹介した。本章では、非線型照合と病変部の関係について考察していく。

正常な臨床画像ならば脳の構造は基本的には同じであるので理想的には完全に変形できる。しかし、臨床画像に病変部が存在する場合、アトラス画像には病変部は存在しないので、組織構造が基本的には同じであると言う前提が崩れる。そのため、照合がより困難となり病変部が存在することで変形に異常が起こる。そこで、文献 [1] は病変部が存在することによる変形の異常を特徴量として、収縮特徴量と非可逆変形特徴量を定義した。

これらの特徴量を利用することで病変部のみを抽出することは残念ながらできない。なぜなら他の領域でもこれらの特徴量が大きな値を示す領域が存在するからである。従って、この特徴量は前処理として病変部候補領域を抽出し、抽出した候補領域に対してこの特徴量を適用し、病変部を抽出するといった手順を利用する。しかし、特徴量として十分では無いため、更に別の特徴量を定義し、病変部検出のために必要な情報量を増やした。また、文献 [1] にて定義された特徴量に誤りがあったので、その部分を修正した。

5.2 変形特徴量について

山本ら [1] は二つの特徴量を定義した。その特徴量について簡単に説明する。

5.2.1 収縮特徴量 (収縮モデル)

臨床画像にアトラス画像には無い高輝度な病変部が存在する時、臨床画像からアトラス画像へ変形する場合を考える。その場合、高輝度な病変部はアトラス画像には存在しないため、病変部組織が収縮変形を起こす。この病変部が収縮する変形の特徴量を収縮特徴と呼ぶ。その例を図 5.1 に示す。

この画像はこちらが用意したテスト画像である。変形がわかりやすいように単純な組織構造となっている。臨床画像の左側の明るい組織を病変部としている。これらの画像を臨床画像からアトラス画像へ照合すると、図 5.1 で分かるように病変部部分が収縮している。このように領域が収縮している部分に対して反応するのが収縮特徴量である。

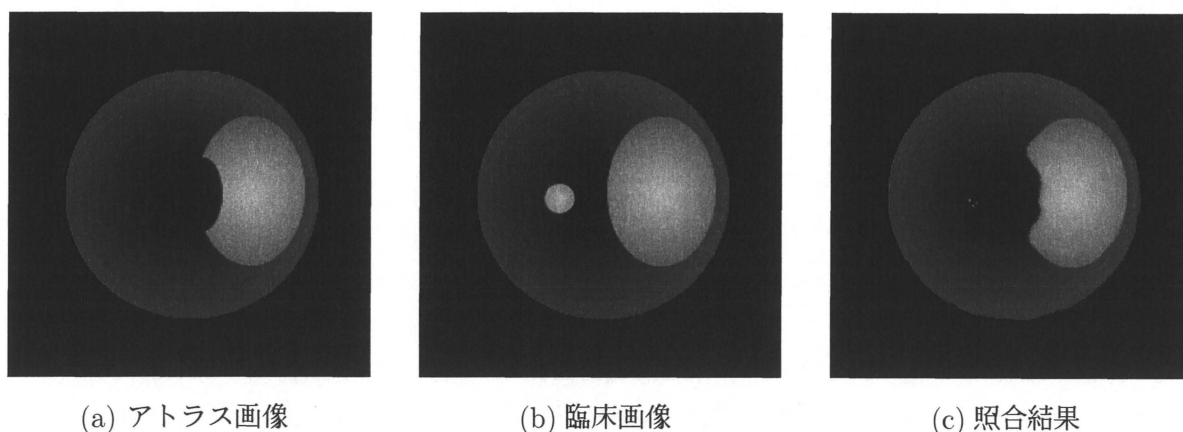


図 5.1 テスト画像照合結果

式 5.1 に収縮特徴量の式を定義する.

$$C_c(x, r) = \frac{D_{after}(x, r)}{D_{before}(x, r)} \quad (5.1)$$

x : 任意の画素, r : 画素 x を中心とする円の半径 D_{before} : 変形前の任意の点 x を中心に半径 r 内に存在する画素の密度, D_{after} : 変形後の任意点 x を中心に半径 r 内に存在する画素の密度

5.2.2 非可逆特徴量 (非可逆特徴量)

画像 A から画像 B への照合, 画像 B から画像 A への照合を考える. 両方の変形で理想的な変形が行えた場合, 互いに対応する画素同士は逆ベクトルになることが予測される. ここで, A をアトラス画像, B を臨床画像とすると, 例えば臨床画像にアトラス画像にはない病変組織が存在する場合, この関係が崩れることが考えられる. 具体的には, 画像 A のある座標 (x, y) の画素が画像 B との照合により変形ベクトル (a, b) 変形し変形後の画素は $(x+a, y+b)$ へ移動し, もう一方の照合で画像 B の座標 $(x+a, y+b)$ の画像 A との照合により移動ベクトル (c, d) を与えられたとする. 理想的な状況では, ベクトルの関係は $a = -c, b = -d$ になり, その画素が病変部であるなら $a \neq -c, b \neq -d$ であると考えられる.

このことから, アトラス画像から臨床画像へ変形するときの変形ベクトルと対応する臨床画像からアトラス画像へ変形する変形ベクトルは理想的には逆ベクトルになる, と言うことが予測される. この特徴量を対応ベクトルの余弦で求めた.

5.2.3 山本らにおける非可逆特徴量の問題点

文献 [1] が定義した非可逆特徴量だが, 余分な部分に大量に反応が出てしまっていることや, 病変部上で反応していない部分があった. この原因として変形方法に問題があったことが分かった. 文献 [1] では, アトラス画像を臨床画像に合わせる場合, 臨床画像の画素 p が変形前のアトラス画像の座標 p' に対応することを知らることが出来る. 同様に, 臨床画

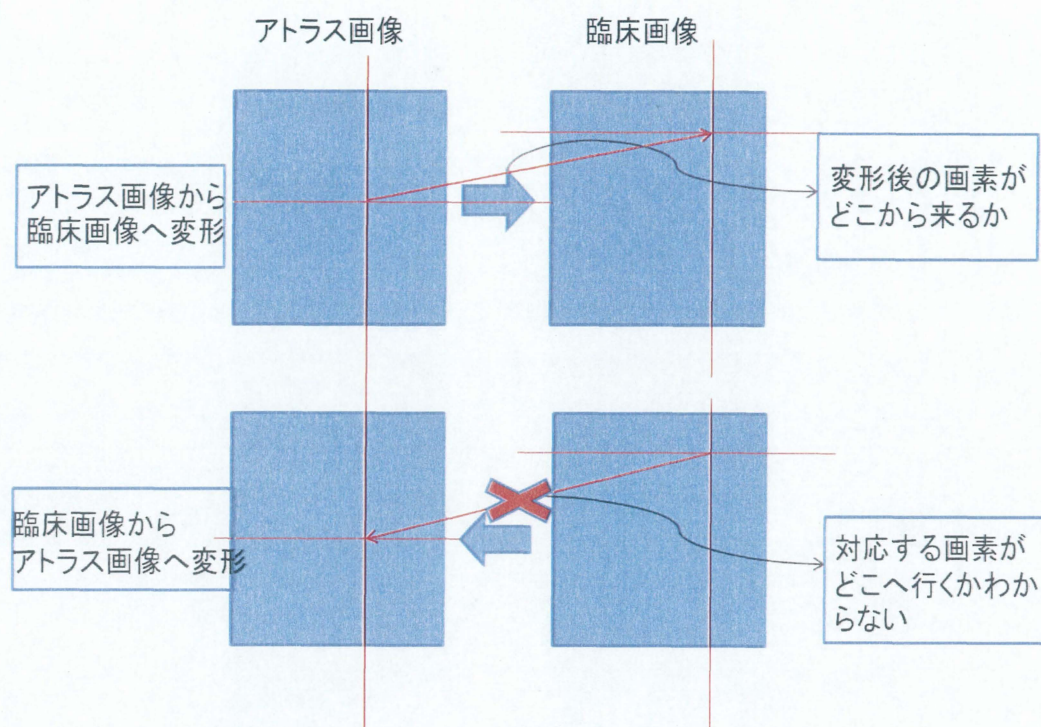


図 5.2 逆変形での非可逆特徴量の計算不可能性について

像をアトラス画像に合わせる場合、アトラス画像の画素 q が変形前の臨床画像の座標 q' に対応することを知ることが出来る。これらの変形結果を用いて非可逆性を調べる場合、アトラス画像を臨床画像へ合わせる時には、臨床画像の画素 p がアトラス画像の座標 p' に対応していることが分かる。理想的な変形が行われる場合、可逆な関係を検出できる。しかし、複雑な脳画像での照合では誤差は無視出来ない。もし誤差がある場合、画素 p と座標 q' の対応関係を取ることが出来ない。そのため非可逆特徴量を計算するにはこの変形方法では不十分であることが分かった。

そこで、変形法を通常の変形に戻し、その結果から非可逆変形特徴量を計算するように改善した。

5.2.4 疎特徴量

図 5.3 は図 6.1 に対してアトラス画像から臨床画像へ照合した時の変形ベクトルを可視化している。図 6.1 から、病変部付近の組織が外側に広がるように移動しているのが分かる。高輝度な病変部とそれに対応するアトラス画像の組織が低輝度な場合、アトラス画像の低輝度な画素は病変部周辺の低輝度な部分と合わせるほうが精度が良くなる。従って病変部分の変形ベクトルは病変部の外側へ移動することになるのである。このことから脳実質内に高輝度な病変部があり、それに対応するアトラス画像の組織が低輝度な場合、アトラス画像から臨床画像へ照合する際、病変部を避けるように変形することが予測できる。これをベクトルで見るとその部分が疎になることから、この疎になる部分を計算することで病変部の特徴量とする。この疎特徴量を式 5.2 のように定義した。

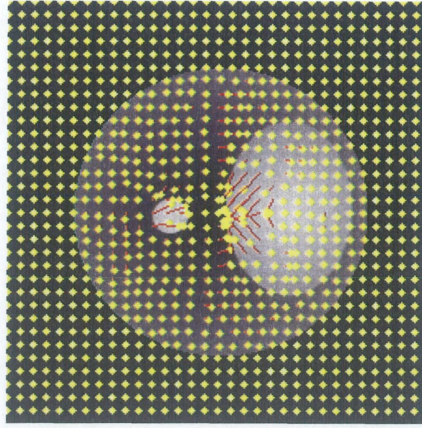


図 5.3 アトラス画像から臨床画像へ変形した時の変形ベクトル

$$\sum_{a=i-2}^{i+2} \sum_{b=j-2}^{j+2} \sqrt{(j-a+x_{ab})^2 + (i-b+y_{ab})^2} \quad (5.2)$$

j, i : 中心の座標 x_{ab} : 座標 (a, b) の x 方向の変形ベクトルの大きさ, y_{ab} : 座標 (a, b) の y 方向のベクトルの大きさ

このまま反応が出ている領域が病変部であるとする、誤差部分が非常に多くそのままの利用は難しい。そこで背景部分の反応は予め除去し、それ以外の反応部分の平均を計算し、それを閾値とした。そして、その閾値以上の反応部分を病変部候補とした。

次章でテスト画像を利用して変形方法の差による非可逆特徴量の抽出率の違いを検証し、変形方法を改善したことによる有効性を示す。また、提案した疎特徴量と、[1] が提案した特徴量 (収縮特徴量, 非可逆特徴量) を病変部面積の検出率, 誤検出率を実験的に検証し、有効性を示す。

第 6 章

病変部抽出のための指標に関する 実験

6.1 実験 1

節 5.2.3 で説明した変形方法の違いによる, 抽出率をテスト画像を用いて実験を行った. 今回図 6.1 のテスト画像に対して, 非可逆特徴量を計算した. そして, 病変部上で特徴量は反応している抽出率とそれ以外で反応している誤抽出率を計算した.

抽出率

$$S = \frac{\sum_{i=0}^{256} \sum_{j=0}^{256} D_x(i, j)}{S_d} \quad (6.1)$$

y $D_x(i, j)$: (i,j) 上が病変部かどうかの判断を行い病変部ならば 1, 違うなら 0 を返す関数, S_d : 病変部の画素数

誤抽出率

$$E = \frac{\sum_{i=0}^{256} \sum_{j=0}^{256} D_e(i, j)}{S_n} \quad (6.2)$$

$D_e(i, j)$: (i,j) 上が正常部かどうかの判断を行い正常部ならば 1, 違うなら 0 を返す関数, S_n : 正常部の画素数

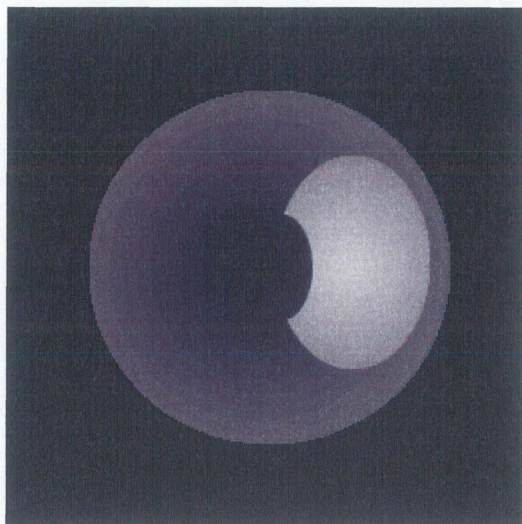
特徴量の反応を可視化した結果を図 6.2 に示す. 尚, 図 6.1 の臨床画像は左の高輝度組織が病変部であると仮定する.

抽出率, 誤抽出率を表 6.1 に示す.

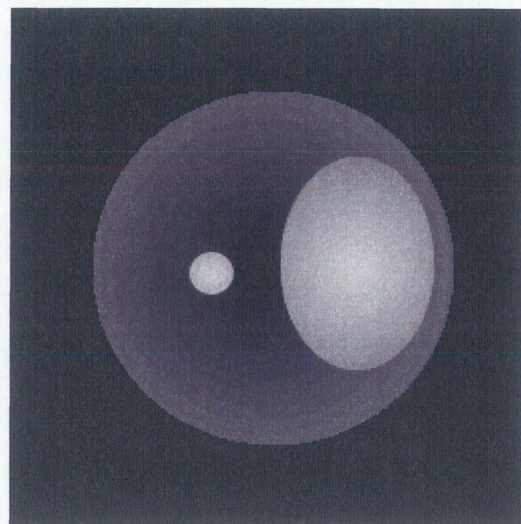
その結果, 抽出率は若干下がってしまったが誤抽出は格段に減らすことができた. これから非可逆特徴量で利用するベクトルは, 逆変換よりも通常の変換の方が正確な特徴量を計算できることが分かった.

	抽出率	誤抽出率
通常変換	0.767	0.01
逆変換	0.946	0.444

表 6.1 非可逆特徴量の抽出率と誤抽出率

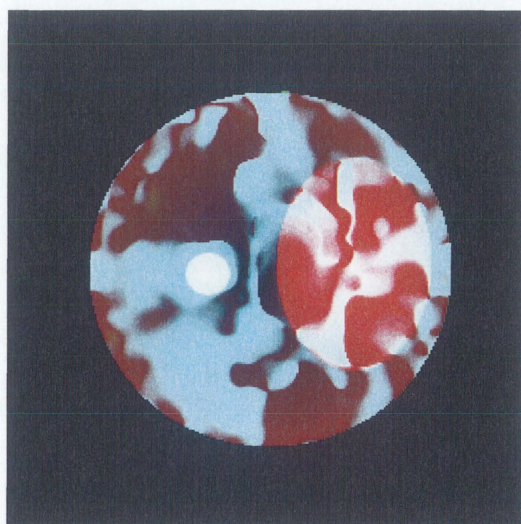


(a) テストアトラス画像

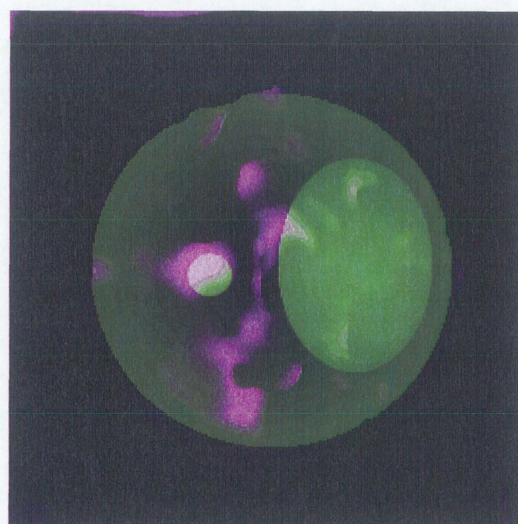


(b) テスト臨床画像

図 6.1 テスト画像



(a) 逆変換での非可逆特徴量



(b) 通常変換での非可逆特徴量

図 6.2 非可逆変換比較

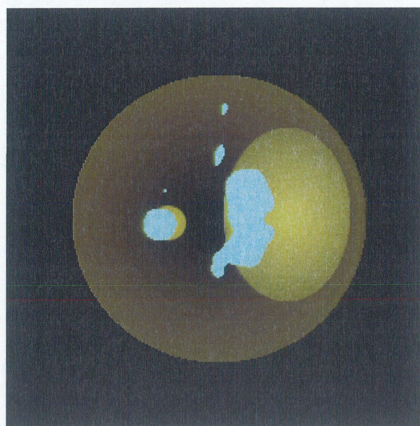


図 6.3 疎特徴量

6.2 実験 2

節 5.2.4 の特徴量の有用性について人工画像を利用して検証を行った。

図 6.3 に図 6.1 における疎特徴量をもとめた、病変部部分で反応が出ていることが分かる。このことから病変部抽出での指標で疎特徴量が指標となると考えられる。

6.3 実験 3

6.3.1 実験内容

5 章で説明した疎特徴量と [1] が提案した収縮特徴量、非可逆特徴量を比較し、疎特徴量の有効性について調べる。

実験対象は病変を含む 13 枚の 2 次元画像である。これらは、 256×256 のサイズをもつ T2 強調画像である。前章でも説明した通り、本手法は高輝度な血腫等を対象にしている。従って、CSF 等の高輝度領域のみを対象する。頭部 MR 画像に対して判別閾値法 [18] を使い、高輝度領域のみを抽出した。

そしてその高輝度領域内に含まれる病変部を手動で抽出し、特徴量を適用し病変部上でどれだけ抽出できているか、病変部のピクセル数と反応部分のピクセル数の面積の割合で表す。尚、今回病変部は抽出率の計算のため手動で抽出している。そして病変以外の反応を誤抽出率として病変部以外の組織に特徴量がどれくらい反応しているかを調べた。

抽出率は式 (6.1)、誤抽出率は式 (6.2) を利用する。

実験結果は図 6.4 のように表示する。病変部の数は各画像によって違う。従って上から原画像、二値化画像、病変部、各特徴量の順に表示する。

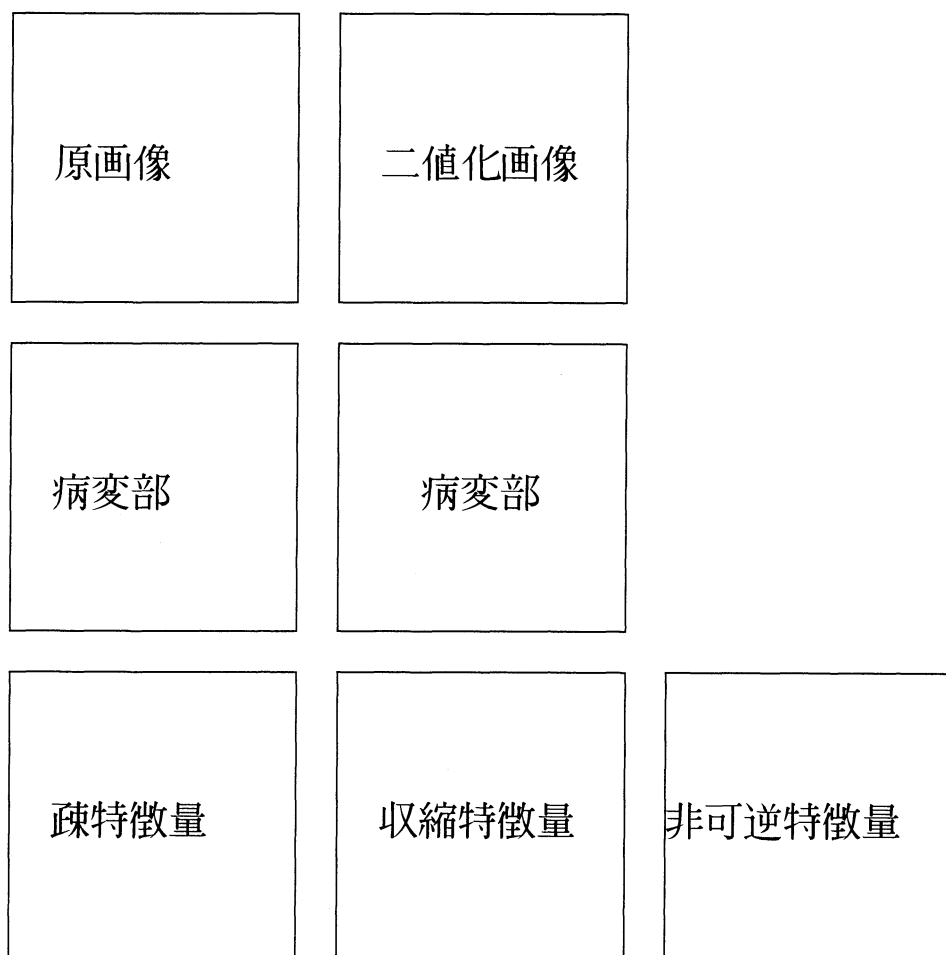


図 6.4 結果表示形式

特徴反応部分を水色で, 反応しなかった部分を黄色で表した.

本実験では病変部上に少しでも特徴量が反応した場合, 病変部を抽出できたと判断する.

6.3.2 実験結果

実験 1

	疎特徴量抽出率	収縮特徴量抽出率	非可逆特徴量抽出率
病変 1	0.511905	0.27381	0
病変 2	0.413793	0.224138	0.172414
	疎特徴量誤抽出率	収縮特徴量誤抽出率	非可逆特徴量誤抽出率
	0.416545	0.257264	0.315697

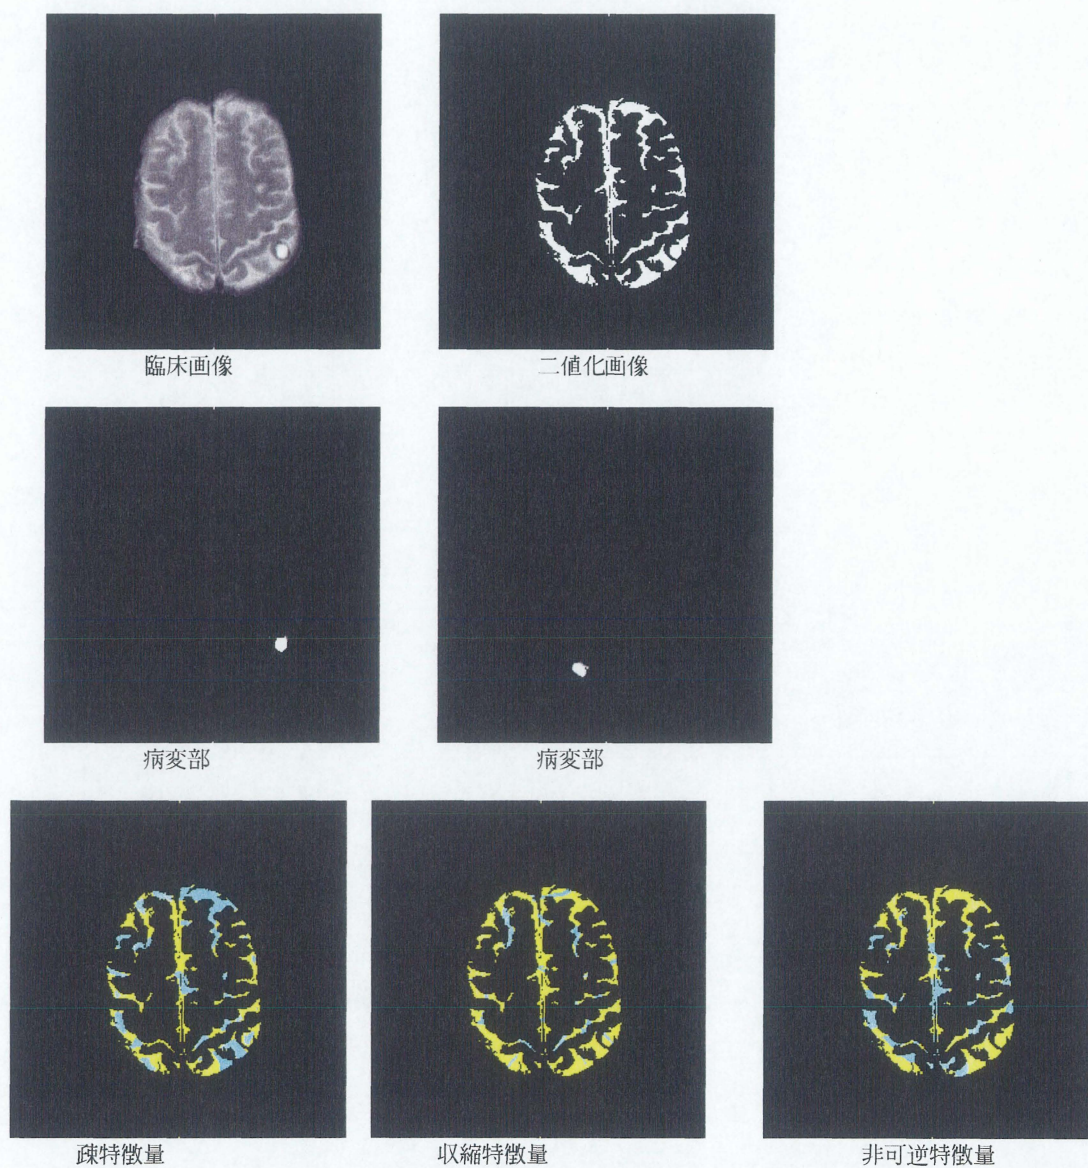


図 6.5 実験結果 1

実験 2

	疎特徴量抽出率	収縮特徴量抽出率	非可逆特徴量抽出率
病変 1	0.731	0.261	0.06
病変 2	0.149	0.207	0

疎特徴量誤抽出率	収縮特徴量誤抽出率	非可逆特徴量誤抽出率
0.394	0.263	0.454

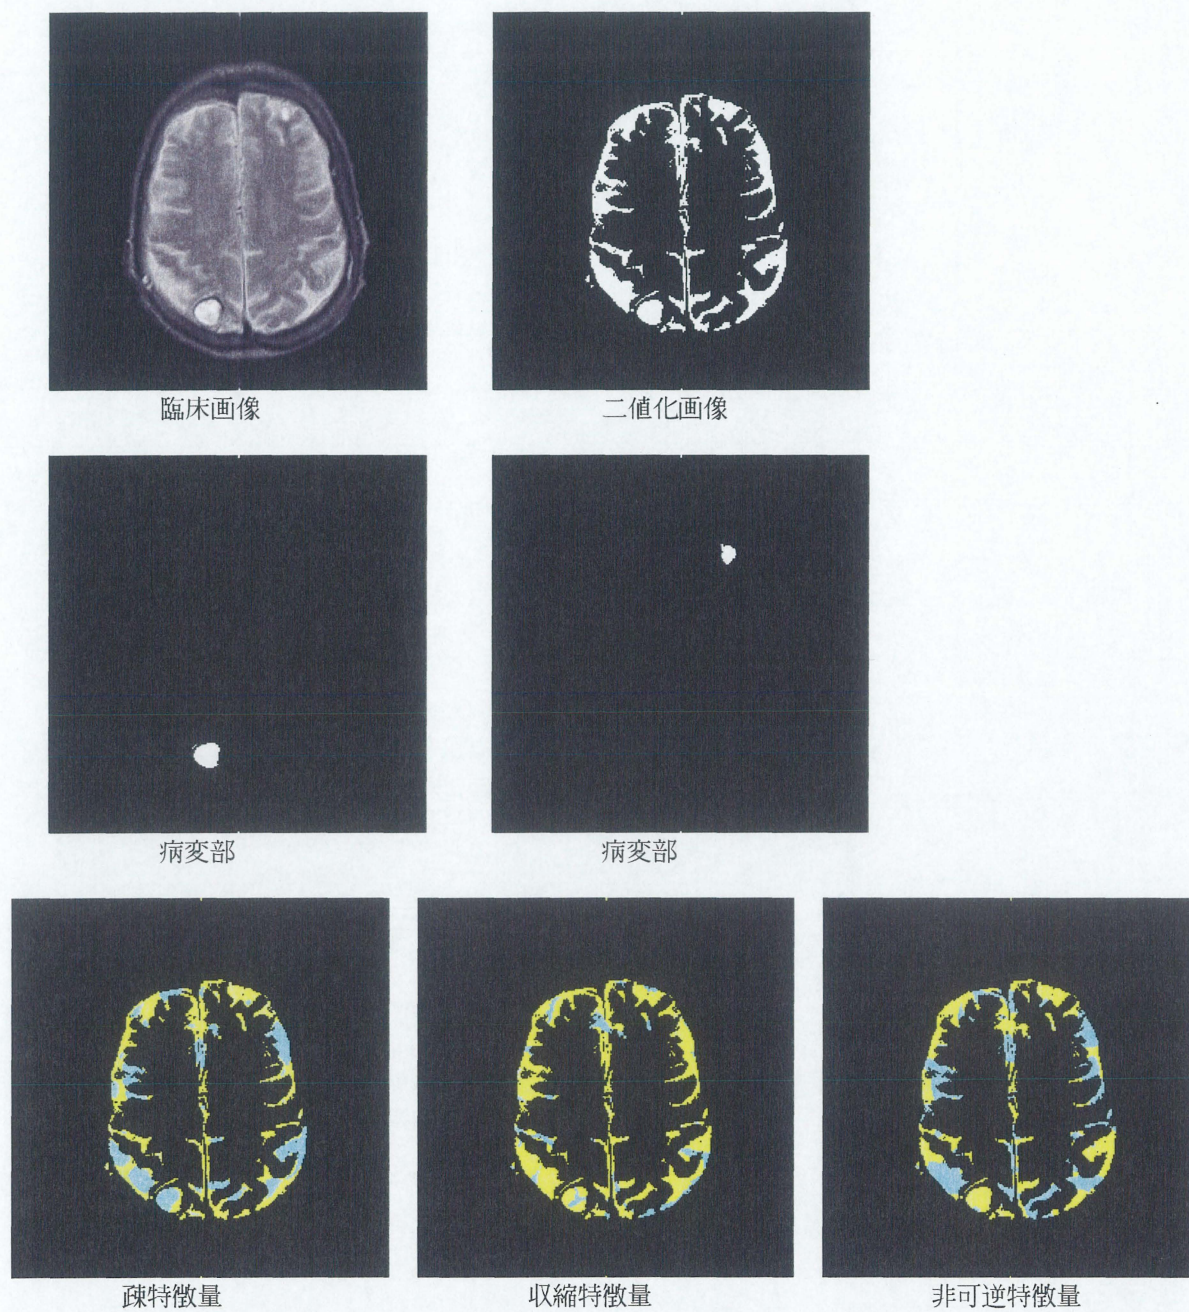
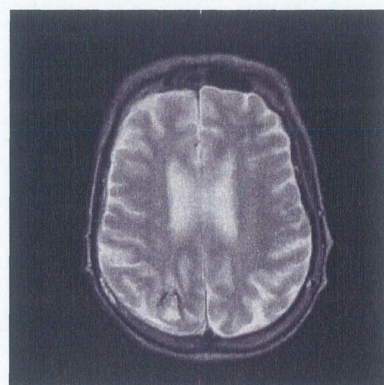


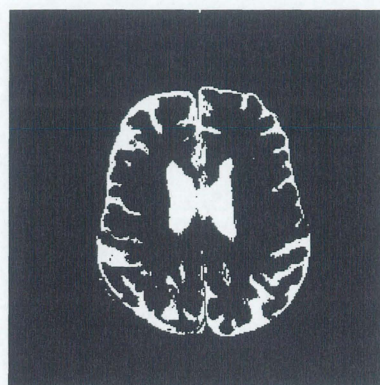
図 6.6 実験結果 2

実験 3

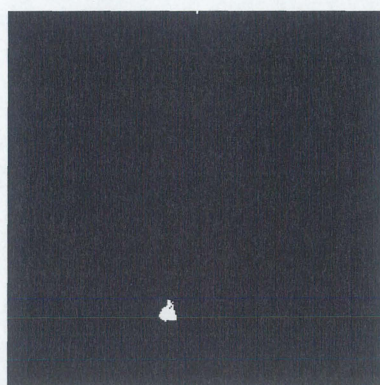
	疎特徴量抽出率	収縮特徴量抽出率	非可逆特徴量抽出率
病変 1	0.333	0.231	0
	疎特徴量誤抽出率	収縮特徴量誤抽出率	非可逆特徴量誤抽出率
	0.401	0.210	0.109



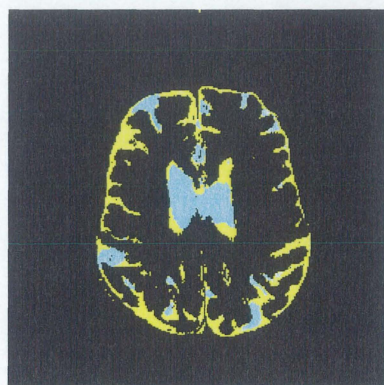
臨床画像



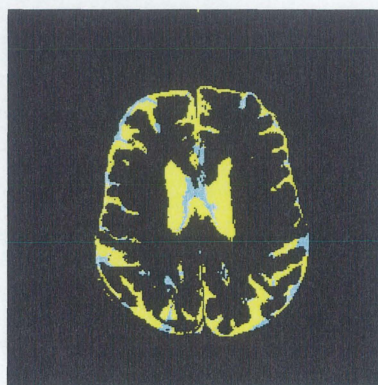
二値化画像



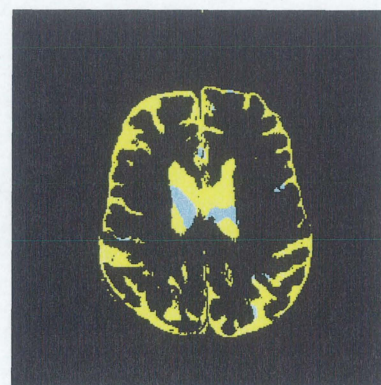
病変部



疎特徴量



収縮特徴量



非可逆特徴量

図 6.7 実験結果 1

実験 4

	疎特徴量抽出率	収縮特徴量抽出率	非可逆特徴量抽出率
病変 1	0.741	0	0.852
病変 2	0.801	0.463	0.139
病変 3	0	0	0
疎特徴量誤抽出率	0.407	0.203	0.138

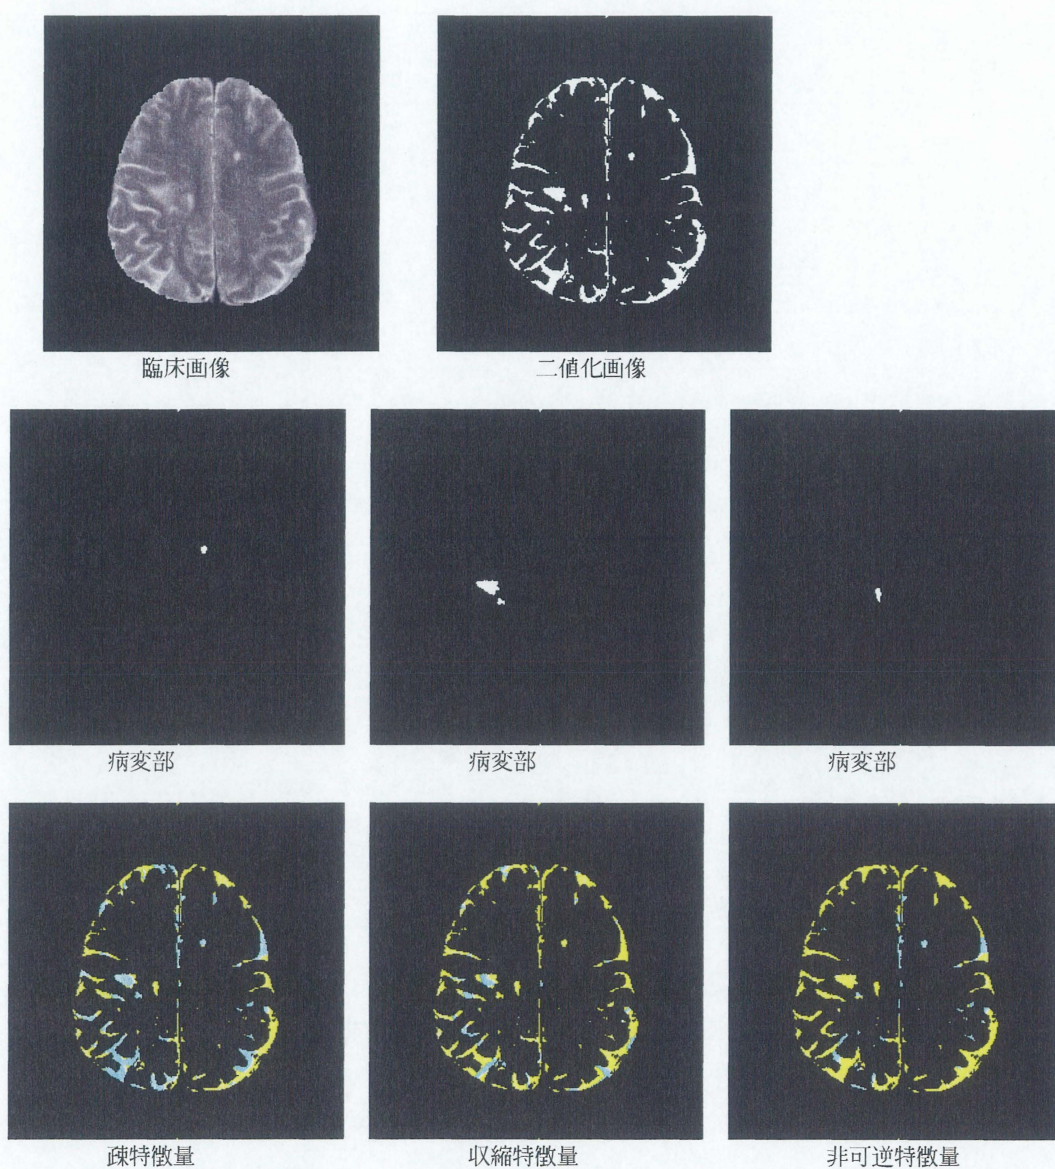


図 6.8 実験結果 4

実験 5

	疎特徴量抽出率	収縮特徴量抽出率	非可逆特徴量抽出率
病変 1	0.891	0	0
病変 2	0.844	0.377	0
病変 3	0.79	0	0
病変 4	0	0.64	0
	疎特徴量誤抽出率	収縮特徴量誤抽出率	非可逆特徴量誤抽出率
	0.258	0.204	0.058

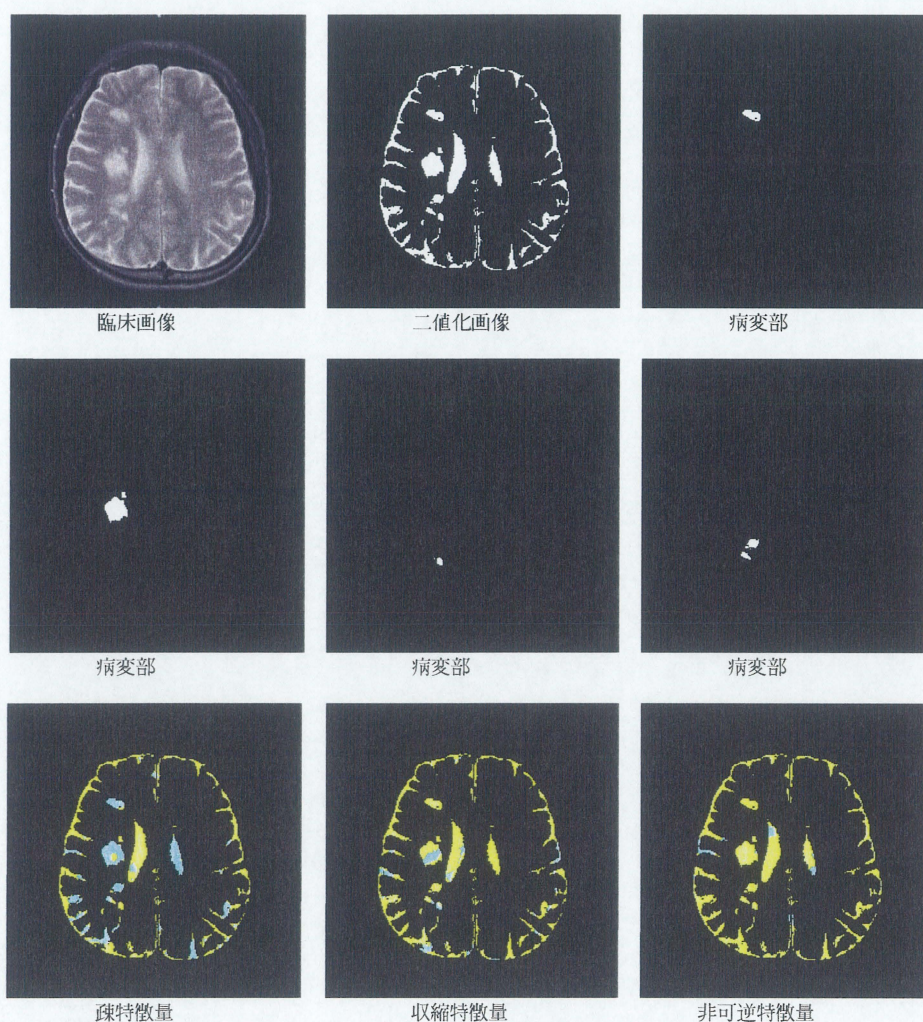
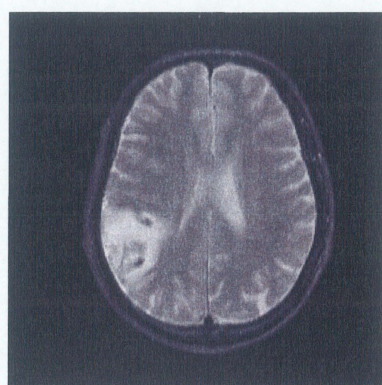


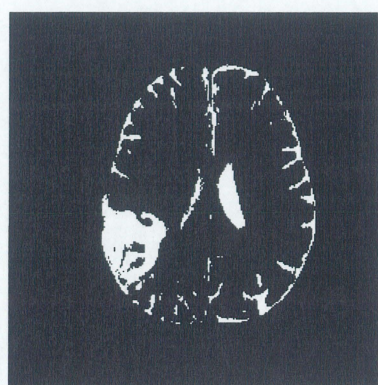
図 6.9 実験結果 5

実験 6

	疎特徴量抽出率	収縮特徴量抽出率	非可逆特徴量抽出率
病変 1	0.554	0.204	0.394
	疎特徴量誤抽出率	収縮特徴量誤抽出率	非可逆特徴量誤抽出率
	0.215	0.260	0.343



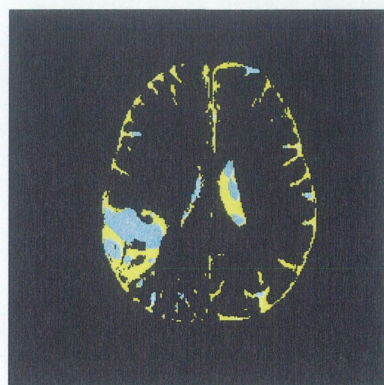
臨床画像



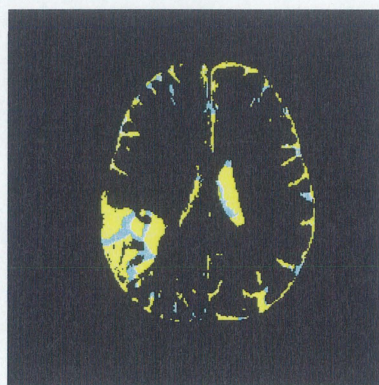
二値化画像



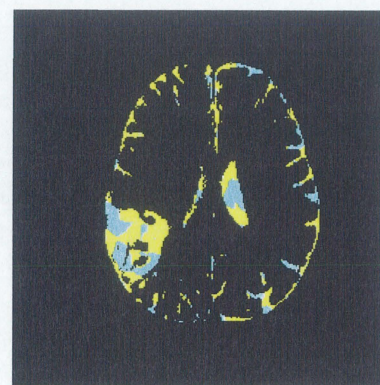
病変部



疎特徴量



収縮特徴量



非可逆特徴量

図 6.10 実験結果 1

6.4 実験考察

6.4.1 病変での反応

病変部 13 例に対して疎特徴量は 11 例, 収縮特徴量は 9 例, 非可逆特徴量は 3 例, 病変部を抽出することができた。

今回定義した疎特徴量の反応を考察していきたいと思う。まず, 病変部の出現位置を分類したいと思う。実験 1,2,3 は CSF などの高輝度領域に病変部が存在する。更にそのなかでも, 高輝度領域に融け込むように存在している病変部と, 一目ではっきりと分かる病変部が存在することが分かる。そして, 実験 4,5 は低輝度領域上に病変部が存在する。実験 6 は病変部がかなり広範囲で存在する場合である。実験 1,2,3 の病変部については一目で判断できる病変部上での疎特徴量の反応である。対応するアトラス画像の低輝度領域が臨床画像の病変部周りに存在する低輝度領域に反応して病変部上で疎な反応を見せていることが分かる。しかし, 移動する量が少なく疎特徴量の反応は若干弱くなる。一方, 周りの CSF に溶け込んでいて分かりづらい病変部は疎特徴量, 収縮特徴量ともに, 反応が見られない。一応若干の反応が両反応ともに見られるものの, 周りの CSF に反応している特徴量から判断すると, 偶然に反応したと判断できる。実験 4,5 は非常に分かりやすく, 臨床画像の病変部分と対応しているアトラス画像の組織は, 低輝度であるので, 高輝度な病変部を避けるように画素が動き, その部分が疎となり反応した。

実験 6 は臨床画像に対応する病変部部分はアトラス画像ではちょうど脳溝部分と重なるので, それが変形によって広がった結果, 疎な反応が確認できた。

誤抽出についてだが, 収縮特徴量に比べて大きく出てしまった。収縮は周りの画素が一点に集まるところを探索するので, どうしても抽出領域が小さくなる。反対に疎特徴量は広く反応が出るので, 誤抽出でも収縮特徴量に比べて大きく出てしまう。

また, 非可逆特徴量の抽出結果だが他の特徴量と比べて, 非常に良くなかった。非可逆変形は理想的な変形する場合, 反応が無くなる。シミュレーション実験では非常に簡単な形状の画像を利用したので, 反応が確認できた。しかし, 実際の臨床画像は完全に照合することは難しく, お互いの照合が逆ベクトルになる場合が無かった。当初, このような照合誤差によりも病変部状での変形異常が強く出ると考えてられていたが, こちらが予測したよりも変形誤差が大きく出てしまったのが抽出率が低くなった原因であると考えられる。

6.4.2 収縮特徴量との比較

前節でも考察したが, 収縮特徴量と疎特徴量は互いに逆の性質を持っている。そのため, 抽出率では疎特徴量が高くで, 収縮特徴量が低くでた。そして誤抽出に関しても同じことが言える。実験 4 の右上の小さな病変部は, 疎特徴量だと広く反応するので, 病変部上で反応が見られた。しかし収縮特徴量の場合, 小さい病変部だと小さな病変部が更に小さくなり場合によっては雑音と変わらない程度に収縮してしまう可能性がある。これだと病変部に反応しているのか雑音なのか判断できない。従って, 疎特徴の方が小さな病変部を抽出しやすいと考えられる。また, 実験 1,2 では収縮特徴量は縦に収縮反応が見られる。これ

は臨床画像の病変部がアトラス画像の脳溝に合わせて変形してしまうことが原因と考えられる。従って病変部を避ける特性を抽出する疎特徴量の方がより病変部に合った反応を見せる。以上の性質から病変部を安定して抽出するには、収縮特徴量より疎特徴量の方が適していると言える。

今後、疎特徴量の誤抽出の低下、及び脳溝に溶け込むように存在する病変部に反応する特徴量の提案が課題となる。また、複数の特徴量を組み合わせることで誤抽出を低減できると考えている。

第7章

むすび

7.1 まとめ

本研究では、以前から問題となっていた皮下脂肪による照合の誤変形を防ぐために、皮下脂肪などを除去するアルゴリズムを提案し、実装した。そして、皮下脂肪を除去した臨床画像と、除去しない場合の臨床画像をアトラス画像と照合して、照合精度が向上するか実験を行った。その結果、皮下脂肪を除去した臨床画像の方が除去しなかった方と比べ、照合精度が向上した。このことにより、照合時に皮下脂肪を除去することの有効性が認められた。

次にアトラス画像と臨床画像を照合する際にできる変形パラメータから、病変部上で確認された特徴的な変形を解析した。そして、先行研究 [1] が定義した特徴量とは違う、「アトラス画像から臨床画像へ変形する際病変部上の変形ベクトルは病変部を避けるように変形する」といった疎特徴量を定義した。そしてその特徴量と従来の特徴量と比較して、疎特徴量の特性を調べた。その結果、収縮特徴量と真逆の性質を持つことが分かった。特に小さな病変部に対しては収縮特徴量より安定して病変部を検出できる事が分かった。しかし、疎特徴量の誤検出は疎特徴量と収縮特徴量の性質から収縮特徴量よりも悪くなってしまう事が分かった。

7.2 今後の課題

- 定義した脳モデル以外のモデル。具体的には眼球部分よりも下の部分に対して、脳実質境界を取得できる脳モデルを設定し、取得できる範囲を増やす。
- 定義した疎特徴量の誤検出率の高さの問題。病変の検出率がいくら高くても、誤検出率が高ければ特徴量としては使いにくいので誤検出率を抑える特徴量について改めて考えなければならない。
- 脳溝などの高輝度成分内に溶け込んでいるような病変部は今までに定義した特徴量では検出できないので、そのような病変部に適用できるような特徴量が必要であるとする。

謝辞

日ごろから多くの御指導を頂きました太田義勝教授，鈴木秀智准教授に深く感謝いたします。そして，日頃何かとお世話になりました落合美子事務員に感謝いたします。また，本論文作成にあたって特にお世話になりました鈴木秀智准教授に深く感謝いたします。最後に，日頃から熱心に討論して頂いた研究室の諸氏に感謝いたします。

参考文献

- [1] 山本 祐司. "頭部アトラスを用いた非線型照合と組織構造の関係に関する研究" Master's thesis. 三重大学大学院 2007.
- [2] 柳瀬 正人, "ノンパラメトリック リージョン グローイング法を用いた脳実質の自動抽出" 東京理科大学 1996.
- [3] 上野 育子 "3次元領域拡張法を用いた脳 MRI 画像からの脳腫瘍の抽出" 岩手県立大学 2002.
- [4] 村木茂. "3次元画像解析とグラフィックス技術の医学応用に関するサーベイ" 電子情報通信学会論文誌, Vol. J87-D-II, No.10, 10 2004.
- [5] John Ashburner. "Computational neuroanatomy".
- [6] Nawal Houhou. "Medical images registration with a hierarchical atlas"
- [7] D.Rueckert "Nonrigid Registration Using Free-Form Deformations: Application to Breast MR Images" IEEE TRANSACTIONS ON MEDICAL IMAGING. 1999.
- [8] 森山圭. "頭部アトラスとの非線型照合の改良" Master's thesis. 三重大学. 2004.
- [9] 松井篤. "Mri 画像におけるラクナ梗塞検出のためのコンピュータ診断システムの開発"
- [10] 福島 俊之. "頭部アトラスを用いた出血領域の自動抽出に関する研究" Master's thesis. 三重大学大学院 1998.
- [11] 白藤 知沙. "頭部アトラス画像との非線形照合による出血領域の自動抽出に関する研究" Master's thesis 三重大学大学院 2001.
- [12] 住吉 英知. "3次元脳アトラスのデータ構造と組織分類法の改良" 卒業論文. 三重大学 1995.
- [13] 住吉 英知. "複数断面と GA を用いた MRI 断層像の位置決めに関する研究" Master's thesis. 三重大学大学院 1997.
- [14] 佐藤 博文 "遺伝的アルゴリズムに基づく 3次元脳アトラス内での MRI 断層像の断面位置決定法" Master's thesis 三重大学大学院 1996.
- [15] William H. Press. "NUMERICAL RECIPES in C" 技術評論社. 1994
- [16] 稲垣 卓也 "頭部 MR 画像における脳実質境界の高精度抽出法の開発" 卒業論文. 三重大学. 2008.
- [17] M.Kass, A.P. Witkin and D.Terzopoulos: "Snakes: Active Contour Models", Int. J. Comp. Vision(1), No.4, pp321-331, 1988
- [18] 大津 "別および最小 2 乗基準に基づく自動しきい値選定法" 電子通信学会論文誌,

Vol.J63-D、No.4、pp.349-356 1980

[19] 荒木 力 "MRI「再」入門" 南江堂 1999.

[20] 陳 延偉 "MRI 画像誘導ナビゲーションシステムにおける視認性を向上させる技術"
立命館大学.

付録

作成したプログラムの使いかた

この章では、本研究で作成されたプログラムの使いかたについて簡単に説明する。本研究で作成したプログラムは大別して以下の3つに分けられる。

1. 脳実質境界抽出に関するプログラム
2. レジストレーションによる照合に関するプログラム
3. 病変部検出に関するプログラム

この中で脳実質境界抽出に関するプログラムと病変部検出に関するプログラムは画像処理ライブラリ OpenCV を必要とする。

脳実質境界抽出

このプログラムは入力された頭部 T2 強調 MR 画像の脳実質境界を抽出するためのプログラムである。論文本文で説明したように、抽出処理は脳実質境界領域抽出処理と脳実質境界抽出処理を分けて行っている。

まず、脳実質境界領域抽出プログラムについて説明する。入力画像は1画素2byte、サイズ 256×256 の医用画像である。出力は脳実質境界領域を表した画像(図 3.5)と、境界領域の極大極小の閉曲線の座標を出力する。

次に脳実質境界抽出処理のプログラムは入力に上記で説明した境界領域の極大極小の閉曲線の座標を使用する。そして、出力に脳実質境界を抽出した画像(図 3.6)を出力する。

レジストレーションによる照合に関するプログラム

このプログラムはアトラス画像と臨床画像を照合するプログラムである。入力はレジストレーションのコンフィグファイルである。出力はグローバル変換された画像とローカル変換された画像が出力される。尚、画像のデータの形式は1画素2byte、サイズ 256×256 である。そして、変形ベクトルのベクトルデータも出力される。

病変部検出に関するプログラム

このプログラムは照合処理を利用した病変部検出に関するプログラムである。入力として上節で出力されるベクトルデータと処理対象の臨床画像が利用される。出力として特徴量反応画像(図 5.1)のような画像が出力される。