

NAIST-IS-MT1551023

修士論文

多階層統計形状モデルの最適階層選択による CT 画像からの疾患骨盤領域自動抽出の精度向上

大谷 悠太

2017 年 3 月 16 日

奈良先端科学技術大学院大学
情報科学研究科 情報科学専攻

本論文は奈良先端科学技術大学院大学情報科学研究科に
修士（工学）授与の要件として提出した修士論文である。

大谷 悠太

審査委員：

佐藤 嘉伸 教授	（主指導教員）
金谷 重彦 教授	（副指導教員）
大竹 義人 准教授	（副指導教員）
横田 太 助教	（副指導教員）

多階層統計形状モデルの最適階層選択による CT 画像からの疾患骨盤領域自動抽出の精度向上*

大谷 悠太

内容梗概

人工股関節全置換術などに対するコンピュータによる術前手術計画システムを構築するためには，CT 画像から病気で変形した骨盤領域と大腿骨を高精度で抽出する必要がある．人工股関節全置換術対象の骨盤は病気で関節部が変形しているため，大腿骨との境界が CT 画像上で不明瞭であり高精度な抽出が難しい．先行研究では，変形系疾患 Crowe 分類 2 以上の症例の骨盤抽出精度が他の疾患症例と比較して 1mm 程低下していた．Crowe 分類 2 以上の骨盤は他の疾患と比較してその関節部が特に大きく変形してしまっていることが原因として考えられる．本研究は変形系疾患 Crowe 分類 2 以上の症例の骨盤抽出精度の向上を目的とする．多階層統計形状モデルの表現性能である汎化性と特異性に着目し，境界が明瞭な領域に対しては汎化性が高いモデル，不明瞭な領域に対しては特異性が高いモデルを用いることで骨盤領域を抽出する．本研究の新規点は，疾患骨盤の領域によって最適な階層を決定することで，領域ごとに最適な多階層統計形状モデルを用いた抽出が可能な点である．同一条件で従来法と提案法による crowe 分類 2 以上の症例の骨盤抽出実験を行い，提案法の有効性を検証した．実験の結果，提案法の平均 ASD 値が 2.535 であったのに対し，提案法は 2.053 であり抽出精度の向上が有意に認められた．

キーワード

自動手術計画，多階層統計形状モデル，統計形状モデル，変形性膝関節症

*奈良先端科学技術大学院大学 情報科学研究科 情報科学専攻 修士論文, NAIST-IS-MT1551023, 2017 年 3 月 16 日.

Optimal level selection of multi-level statistical shape model for accuracy improvement of automated segmentation of the diseased pelvis from CT images*

Yuta Otani

Abstract

To construct preoperative automated planning system for Total Hip Arthroplasty(THA), it is necessary to accurately segment pelvis and femur regions separately from CT images. It is difficult to segment the region due to deformed shapes and extremely narrow inter-bone regions in CT images. In previous research, the accuracy of segmentation of pelvises categorized Secondary osteoarthritis(OA) crowe over 2 are lower than others about 1mm because the deformation of joint region is severe. The purpose of this study is to improve the segmentation accuracy of pelvises categorized SecondaryOA crowe over 2. To improve the accuracy, we focused on generalization and specificity of hierarchical statistical shape models and we segment the region of pelvis using the model with high generalization or specificity if the border is clear or not. A novelty of this study is using optimal levels of hierarchical statistical shape model to the partial regions by deciding optimal level for each region. We validated the effectiveness of proposed method by conducting experiments both conventional and proposed method under the same conditions. As a result, while the average of ASD for conventional method is 2.535, proposed method's is 2.535 and accuracy of segmentation is improved significantly.

*Master's Thesis, Department of Information Science, Graduate School of Information Science, Nara Institute of Science and Technology, NAIST-IS-MT1551023, March 16, 2017.

Keywords:

preoperative planning, hierarchical statistical shape model , statistical shape model, Osteoarthritis

目次

図目次		vi
第 1 章	はじめに	1
1.1	医用画像処理による手術計画システム	1
1.2	先行研究と問題点	3
1.3	目的と意義	5
第 2 章	方法	7
2.1	方法概要	7
2.2	多階層統計形状モデルの構築	8
2.2.1	モデルの表現方法	8
2.2.2	位置・姿勢の正規化	8
2.2.3	頂点の対応付け	9
2.2.4	主成分分析を用いた形状の部分空間表現（統計形状モデル構築）	10
2.2.5	部分領域毎の統計形状モデル表現（多階層統計形状モデルの構築）	11
2.3	多階層統計形状モデルを用いた領域抽出の流れ	14
2.3.1	特定疾患骨盤の各頂点における最適な階層の決定	15
2.3.2	最適な階層を用いた CT 画像からの骨盤領域抽出	16
第 3 章	実験	17
3.1	データセット	17
3.2	評価尺度	17
3.3	実験内容	17
3.4	結果	18
第 4 章	考察	25
第 5 章	結びと今後の予定	27

謝辞	28
参考文献	29
発表リスト	33

図目次

1.1	左：アキシャル面 右：コロナル面	2
1.2	術全手術計画システムの概要	2
1.3	左：正常症例 右：疾患症例	3
1.4	左：正常症例 右：疾患症例	4
1.5	左：正常症例 右：Crowe 分類 2 以上の症例	5
2.1	前 骨 盤 平 面 の 定 義 左：前からの図 右：側面からの図	9
2.2	統計的形状モデルの変形の例	12
3.1	手動選択した関節部	19
3.2	階層の違いによる抽出精度の比較	20
3.3	正常症例	21
3.4	Crowe 分類 2 以上の症例	23
3.5	可視化結果	24

第 1 章 はじめに

1.1 医用画像処理による手術計画システム

医用画像は人体内部を撮像した画像であり，その情報をもとに病気の治療や診断が行われている．医用画像の種類としては，X 線 を利用した Computed Tomography(CT)，磁気を利用した Magnetic Resonance Imaging(MRI) のような医用画像撮像装置により撮影された CT 画像や MR 画像などがある．図 1.1 に患者を撮像した CT 画像の例を示す．図 1.1 の左は輪切りのアキシャル面で，右は横から輪切りにした coronal 面の画像である．白く写る領域は骨などのように X 線の透過率が低い組織であり，黒く写る領域は空気や軟組織などの透過率が高い組織となっている．近年このような医用画像撮像装置の進歩による医用画像の質の向上により，医用画像処理を用いたロボット手術やナビゲーションのような手術支援システムの臨床的な利用が増加してきている．手術支援システムとは術前に撮影された医用画像から人体内部情報を解析し，医師の手術支援や術前手術計画を行うことで高精度な手術を実現するためのシステムである．

我々は術前手術計画システムとして，人工股関節全置換術を対象とした自動手術計画システム [1][2][3] の開発を行っている．図 1.2 に我々が開発している自動手術計画システムの概要を示す．人工股関節全置換術とは，病気などで変形し傷ついた骨盤と大腿骨の関節部を取り除き，骨盤関節側ではカップ，大腿骨頭ではステムと呼ばれる人工関節に置き換える手術である．術前に撮影された下肢 CT 画像の骨盤と大腿骨の形状からカップやステムの大きさや位置等を医師が頭でシミュレートし，入念な手術計画を立てて手術が行われる．

我々の自動手術計画システムでは，まず過去に人工股関節全置換術が行われた多くの骨盤や大腿骨の形状データから統計的な形状のアトラスを構築する．それから術前に撮像された患者の下肢 CT 画像から骨盤と大腿骨を自動抽出し，統計アトラスに基づいて手術計画を自動立案することで，医師の手術支援を行っている．こうした自動手術計画システムを構築し臨床的に使用するためには，手術前に撮像された下肢 CT 画像から骨盤と大腿骨を正確に抽出しなければならない．骨盤と大腿骨の抽出精度が低下してしまうと，手術計画の自動立案時にコンピュータが患者




図 1.1 左：アキシャル面 右：コロナル面




図 1.2 術全手術計画システムの概要

本来の大きさとは異なったサイズの骨盤のカップや大腿骨のステムを提示してしまい、手術計画システムの精度の低下につながる。また、抽出精度を向上させるために CT 画像から手動で領域を抽出するとしても、3次元の画像であるため多大な労力を要する。したがって、臨床利用可能な手術計画システムを作るためには、高精度な骨盤と大腿骨領域の自動抽出が必要不可欠となる。




図 1.3 左：正常症例 右：疾患症例

1.2 先行研究と問題点

画像処理により画像から領域を自動抽出する方法としては、画素値ベースでの手法がある．[4][5][6] 画素値ベースの手法では画像中の画素値のコントラストをもとに領域を抽出する．この手法の場合、対象領域の画素値と他の領域との画素値の差が大きく、また同じような画素値を持った領域が隣接していない場合はよいが、そうでない場合は抽出に失敗してしまう．この手法を病気による変形がない正常な下肢 CT 画像に適用する場合は、骨盤と大腿骨の境界が明瞭であり画素値のコントラストが大きいため、ある程度精度のよい抽出が行える．一方、人工股関節全置換術の手術計画システムが実際の臨床で扱う骨盤と大腿骨は病気で変形している症例がほとんどであるため、骨盤と大腿骨の関節部の境界が不明瞭で画素値のコントラストがない症例が多く、画素値ベースでの抽出は難しい．図 1.3 と 1.4 に正常な骨盤と大腿骨の関節部の CT 画像と 3 次元形状を示す．図 1.3 の左は正常な骨盤と大腿骨であり、右が関節部が病気で変形した骨盤と大腿骨である．赤矢印で示している関節領域を比較すると正常では骨盤と大腿骨の境界が明瞭なのに対して、変形している症例ではその境界が不明瞭になっている事がわかる．図 1.4 の左は正常な骨盤で右が病気で変形した骨盤である．変形した骨盤の関節部が上にずれてしまっており正常な骨盤関節部と比較すると、大きく形状が変形している．こうした症例に対しては画素値ベースの手法ではなく、形状情報を用いた領域抽出が有効である．[7][8][9][10][19]




図 1.4 左：正常症例 右：疾患症例

形状情報を用いた骨盤と大腿骨領域抽出において，股関節の統計形状モデルを用いた手法が用いられている．[11][12][13] 統計形状モデルとは，多数の形状データを統計解析することで，対象形状がとりうるバリエーションを少数の変数で表現したモデルである．このモデルを変形し CT 画像上の対象形状のエッジに位置合わせすることで，領域抽出が行われる．骨盤，大腿骨領域抽出における先行研究として，大腿骨頭が球近似できると仮定して，股関節における姿勢変化を股関節中心 (Hip Joint Center:HJC) 周りの回転として定義することにより骨盤と大腿骨の関係を統計形状モデルに組み込んだ手法が提案されている．[11][12] 正常な骨盤においては上記の仮定が有効であると考えられるが，疾患股関節においては球形状から変形しているため，この仮定は成り立ちにくい．また，我々は多階層統計形状モデルと条件付き統計形状モデルを用いた手法を提案している．[13] 多階層統計形状モデルとは，全体形状を部分領域に再帰的に分割し，個々の部分領域において統計形状モデルを構築することで，部分領域のバリエーション表現可能なモデルである．多階層統計形状モデルを用いて骨盤領域を抽出し，その結果を関節領域とし大腿骨のモデルに組み込むことで抽出精度の向上を図っている．関節部の変形の程度が小さい症例の平均骨盤抽出精度は 1mm 程度であるが，大きく変形している変形系疾患 Crowe 分類 2 以上の症例では 2mm 程となっており，抽出精度不足が問題となっている．Crowe 分類 2 以上の症例の骨盤抽出精度が悪い原因として，変形により関節部と大腿骨頭の関節軟骨がすり減り，CT 画像上で境界が見えないことから多階層統計形状モデルを用いた抽出が失敗していることが考えられる．図 1.5 に正常な骨




図 1.5 左：正常症例 右：Crowe 分類 2 以上の症例

盤と crowe 分類 2 以上の症例に対して多階層統計形状モデルを用いた骨盤・大腿骨領域抽出結果を示す．図 1.5 の左が正常症例で右が crowe 分類 2 の症例となっている．それぞれ緑線は正解領域であり赤線は自動抽出結果である．正常な症例では境界が明瞭なことから全体が精度良く領域抽出できているが，crowe 分類 2 以上の症例では関節領域が誤抽出されてしまっている．

1.3 目的と意義

本論文では Crowe 分類 2 以上の骨盤領域の抽出精度を向上させる事を目的とする．そのために，多階層統計形状モデルによる最適な領域抽出手法を提案する．上述したように，多階層統計形状モデルとは全体形状を部分領域に再帰的に分割し，個々の部分領域において統計形状モデルを構築することで，部分領域のバリエーションを表現可能なモデルである．形状モデルを用いた骨盤領域抽出において，crowe 分類 2 以上の症例のように変形によって境界が不明瞭な症例ではモデルの汎化性と特異性のバランスが重要となる．汎化性とはあらゆる形状を表現できる能力であり，特異性は対象形状のみを表現できる能力である．[16][26][27][28] 多階層統計形状モデルの表現能力として，階層が深くなると汎化性高くなるが特異性は低下し，階層が低いと特異性は高く汎化性が低下するトレードオフの関係となっている．抽出手法としてモデルを変形し CT 画像上の骨盤エッジにあてはめることで抽出をおこなっているため，対象のエッジが見える領域に対しては汎化性が高く，エッジ

が見えない領域に対しては汎化性をある程度保ちつつ特異性も高いモデルにより形状を予測することで抽出精度の向上のが期待される．2章でその詳細を記述する．

こうした画像からの高精度な対象領域抽出は手術計画システム以外にも多くの応用先がある．例えば，股関節ではなく，他の臓器抽出においても貢献できる．医用画像からの領域抽出は股関節のみならず肝臓，すい臓，腎臓などほかの領域抽出でも行われており，このような領域抽出において，他の臓器が隣接していたり，病気によって変形していることから，対象臓器と他の臓器の境界が不明瞭なことが多く，領域抽出が失敗してしまっている．[14] これらの臓器抽出においても精度のよい抽出が可能になれば，他の手術支援システムの精度向上が可能となる．また，多元計算解剖学と呼ばれる分野に大きく寄与できる．現在は個体間で異なる臓器の配置や形状に関する正確な統計は行われておらず，医学の教科書において各臓器の標準的な形や血管の配置などは記述されているが，形状が個体間でどの程度異なりうるのか，またどの程度の多様性があるのかといった統計的な記述はなされていない．患者ごとに詳細な解剖構造を自動的に抽出することができれば，病院で撮像される医用画像に適用することで，臓器の形状や配置に関する正確な統計の獲得が可能になる．[15]

第 2 章 方法

2.1 方法概要

本論文では，多階層統計形状モデルの構築と CT 画像へのモデルの位置合わせによる骨盤領域抽出の手法を基に，部分領域ごとに最適な多階層統計形状モデルの選択による骨盤抽出手法を提案する．以下に方法の概要を示す．

1. 多階層統計形状モデル構築
 - (a) モデルの表現方法
 - (b) 位置・姿勢の正規化
 - (c) 頂点の対応付け
 - (d) 主成分分析を用いた統計形状モデルの構築
 - (e) 部分領域での統計形状モデル表現
2. 多階層統計形状モデルの最適な階層選択による領域抽出

多階層統計形状モデル構築では，モデルの表現方法として点の集合で形状を表現する手法について説明する．次に，多数の骨盤形状データを統計解析するための，骨盤の位置・姿勢の正規化と頂点の対応付けによる学習データの整形方法について述べる．それから，整形された学習データに対して主成分分析を適用した統計形状モデル構築について説明し，統計形状モデルを拡張した多階層統計形状モデルの構築方法について述べる．これらを説明した後に提案法である多階層統計形状モデルの最適な階層選択による骨盤領域抽出手法について述べる．

上述した通り，先行研究における問題点として変形系疾患 Crowe 分類 2 以上の骨盤領域の抽出精度が不足していた．その原因としては，関節領域の境界が不明瞭なことから多階層統計形状モデルによる関節領域の抽出が失敗している事であった．我々は多統計形状モデルを用いた領域抽出におけるモデルの汎化性と特異性に着目し，エッジが明瞭な領域に関しては汎化性が高いモデル，エッジが見えない領域では特異性が高いモデルを使い分け領域抽出することで，抽出精度の向上が期待されると考える．汎化性とはあらゆる形状を表現できる表現能力であり，特異性は骨盤らしさを表現する能力である．モデルの表現能力として骨盤らしさを保持して

おいたほうが、見えない骨盤領域の予想精度が良くなると考える。上記の仮定により、骨盤の部分領域ごとに汎化性と特異性が最適なモデルを選択し、領域を抽出することで先行研究と比較して関節部や骨盤全体の抽出精度の向上が期待される。以降の節でその詳細を記述する。

2.2 多階層統計形状モデルの構築

2.2.1 モデルの表現方法

本論文ではモデルの CT 画像への位置合わせを目的として形状を表現する方法として、point distribution model(以後 PDM と略す)を採用する。PDM はその形状を表面上に配置した N 個の点群の座標により表現する方法であり、表面にメッシュを張ることで形状を表現している。具体的には、PDM の点 P_i の座標を $\mathbf{x}_i = (x_i, y_i, z_i)$ とあらわすとき、形状は $3N$ 次元ベクトル $\mathbf{x} = (x_1, x_2, \dots, x_N)^T$ により表現される。ほかのモデル表現方法としては、spline 関数を用いた方法 [16][17] や level set 関数に基づく方法 [16][18] がある。Spline 関数を用いる場合、対象形状は spline 関数の制御点の座標によって記述される。また level set 関数を用いる場合は、対象形状は距離関数の値がゼロ等値面によって表現される。これらの表現方法を用いる利点として、spline 関数を用いると表面の滑らかさを自然に導入することができ、level set 関数を用いると表面のトポロジーの変化を容易に追従することができる。しかし、これらの表現方法を利用すると、形状間の対応関係を陽に表現することは難しい。一方で PDM は対応関係を陽に表現することができるため、その表現方法の簡便さから形状モデリングにおける形状の表現方法として最も広く利用されている。[19][17][20][21] 本論文における多階層統計形状モデルの表現方法において PDM を用いることで、後述する PDM で表現された形状点群の対応関係や学習する形状の統計を求める処理を簡便化する。

2.2.2 位置・姿勢の正規化

多階層統計形状モデルは位置、姿勢の影響を除外した形状のみの統計情報を学習した形状モデルである。本研究では多階層統計形状モデル構築における学習データ




図 2.1 前骨盤平面の定義
左：前からの図 右：側面からの図

に対して，患者間でばらつきのある骨盤の位置，姿勢の影響を除外するために正規化を行う．正規化には横田らによって提案された骨盤解剖学座標系による位置，姿勢の正規化 [22]．を用いる．骨盤解剖学座標系とは，前骨盤平面 (Anterior Pelvis Plae. 以後 APP と略す) を基準とし，図 2.1 のように解剖学的に定義される．

2.2.3 頂点の対応付け

骨盤解剖学座標系による正規化により位置・姿勢の影響を除去した後，多数の骨盤形状を学習するために全学習データ間に対応関係をとる．学習データの骨盤は頂点の集合である PDM で表現されているため，骨盤の各頂点を全学習データ間で対応付ける．この処理を以後，頂点の対応付けと呼ぶ．以下に頂点の対応付けの流れを示す．

1. 基準形状を学習データへ位置合わせし，頂点の対応関係を取得する．
2. 平均形状を計算する．
3. 平均形状を基準形状として 1 を行い頂点の対応関係を取得する．

頂点の対応付けを行うために、まず学習データ内から基準となる骨盤形状を選択する。ここで、基準形状は骨盤の中央形状とする。それから、基準形状の各頂点を学習データの骨盤形状の表面に位置合わせし、基準形状の全頂点を学習データに伝播することで頂点の対応関係を求める。この処理を全学習データに対して行うことで、全学習データ間で対応関係を求める。頂点の対応関係を求めた後は、全学習データの各頂点の座標情報をもとに骨盤の平均形状を算出し、求めた平均形状を基準形状として位置合わせを行うことで最終的な頂点の対応付けを行う。

平均形状を基準形状として頂点の対応付けを行う理由としては、位置合わせへのノイズの影響をある程度除外するためである。中央形状を基準形状とした場合、形状が他の学習データと異なるような外れ値を持つ場合があり、非剛体位置合わせの精度低下を招いてしまう可能性がある。そのため、中央形状で対応付けを行った後に計算された平均形状データを用いて再度対応付けを行うことでノイズの影響を小さくする。

2.2.4 主成分分析を用いた形状の部分空間表現（統計形状モデル構築）

PDM における統計形状モデルは対象形状のみを表現する $3N$ 次元の形状ベクトルのバリエーションを主成分分析により少数のパラメータで表現したモデルである。このモデルを構築するために、全学習データに対して上述した手法により位置と姿勢を正規化し、症例形状間における頂点の対応付けを行った。ここで、個々の対応関係がとれた形状データ $S_i (i = 1, \dots, n)$ において、頂点数を m 、 j 番目の点の座標を $(x_i^{(j)}, y_i^{(j)}, z_i^{(j)})$ とすると、形状ベクトル $\mathbf{q}_i$ は

$$\mathbf{q}_i = \left(x_i^{(1)}, y_i^{(1)}, z_i^{(1)}, \dots, x_i^{(m)}, y_i^{(m)}, z_i^{(m)} \right)^T \in \mathbb{R}_i^{3m} \quad (2.21)$$

と表される。ここで、 $\mathbf{q}_i$ は $3m$ 次元ベクトルである。この頂点の対応関係が取れた学習データ内の n 個の形状ベクトル $\mathbf{q}_i (i = 1, \dots, n)$ に対して主成分分析を適用することで、部分空間表現による統計形状モデルを構築する。この統計形状モデルは $\mathbf{q}$ のバリエーションを以下のような部分空間によって表現する。

$$\mathbf{M}(\mathbf{b}) = \bar{\mathbf{q}} + \Phi \mathbf{b} \quad (2.22)$$

ただし,

$$\bar{\mathbf{q}} = \frac{1}{n} \sum_{i=0}^{n-1} \mathbf{q}_i \quad (2.23)$$


は形状の平均ベクトルを表し, $\mathbf{q}_i$ は i 番目の学習データの形状を表現する $3m$ 次元のベクトルを表す. また, $\mathbf{b}$ は r 次元の部分空間における係数を表し, n は学習データの数を表す. ここで r は一般的に累積寄与率に従って決定される. Φ は固有ベクトルを並べた $3m \times r$ の行列を表し, 以下の標本共分散行列 V に対して特異値分解を行うことで得られる.

$$V = \frac{1}{n} \sum_{i=0}^{n-1} (\mathbf{q}_i - \bar{\mathbf{q}})(\mathbf{q}_i - \bar{\mathbf{q}})^T \quad (2.24)$$


統計形状モデルの各主成分による変形の例を図 2.2 に示す. 図 2.2 の (a),(b),(c) にそれぞれ第 1 主成分, 第 2 主成分, 第 3 主成分において形状パラメータを $\pm 2 \sigma$ に振った場合の変形を示す.

2.2.5 部分領域毎の統計形状モデル表現 (多階層統計形状モデルの構築)


統計形状モデルは学習データ内の形状全体のバリエーションを主成分分析により少数のパラメータで表現したモデルである. 統計形状モデルで表現可能な形状のバリエーションは学習データ数に従って大きく増減することが知られている. [23][25] 統計形状モデルを構築するにあたり一般的に学習データの数は過少であるのが現状である. 医療画像のように匿名性が高い画像は実用上十分な画像データが手に入るのは稀であり, 例え十分な画像データがあったとしても, 人が手作業で 3 次元の画像から対象形状を抽出する必要がある, その作業は極めて煩雑で長時間となるため, 十分な数の学習データを揃えることは容易ではない. その結果統計形状モデルによる形状表現能力は, 個々の形状データの次元に比べてデータ数が少なくなってしまう, 十分な形状表現能力が得られない. そこで, 本論文では全体形状を複数の部分領域に再帰的に分割し個々の部分領域で統計形状モデルを構築したモデルを用い



(a) 第 1 主成分



(b) 第 2 主成分



(c) 第 3 主成分

図 2.2 統計的形狀モデルの変形の例

る．このモデルを多階層統計形状モデルと呼ぶ．多階層統計形状モデルは，形状全体のバリエーションを表現する通常の統計形状モデルと比較して，その表現性能が向上する．小さな領域になればなるほど，形状のバリエーションは小さくなるので，統計形状モデルで全体形状のバリエーションを表現するよりもモデルの汎化性が向上するためである．汎化性とは学習データに含まれない未知の形状をどの程度表現できるかを示す尺度である．ただし，対象の形状らしさを表現する特異性は低下するため，汎化性と特異性はトレードオフの関係となる．以下に多階層統計形状モデル構築方法について述べる．まず，基準形状 M_1 を，分割後の頂点数がなるべく等しくなるように複数の部分領域 $M_{1i}(i = 1, \dots, N_1)$ に分割する．[29] 分割した個々の形状に対しても再帰的に分割を行い，多階層統計形状モデル $M_{hi}(i = 1, \dots, N_h)$ を構築する．ここで， N_h は階層 h におけるモデルの分割数である．上述した頂点の対応付けにより学習データ内の頂点の対応関係が取れているので，全学習データにおいても同様の分割を行うことができ，これらを $M_{hij}(j = 1, \dots, N)$ とする． $M_{hij}(j = 1, \dots, N)$ の頂点群をベクトル化したものを $\bar{\mathbf{q}}_{hij}$ とする． $\bar{\mathbf{q}}$ に対して個々の領域ごとに上述した主成分分析を行うことで多階層統計形状モデルを構築する．多階層統計形状モデルは以下のように記述される．

$$\mathbf{M}_{hi}(\mathbf{b}_{hi}) = \bar{\mathbf{q}}_{hi} + \Phi_{hi}\mathbf{b}_{hi} \quad (2.25)$$

ここで， $\bar{\mathbf{q}}_{hi}$ ， Φ_{hi} ， $\mathbf{b}_{hi}$ はそれぞれ平均形状ベクトル，変形成分，変形パラメータであり，添え字 h, i はそれぞれ階層と分割領域番号である．

2.3 多階層統計形状モデルを用いた領域抽出の流れ

本論文で提案する抽出手法の流れは以下の通りである．

- ・ 入力 CT 画像からの抽出前（学習データ内）
 1. 特定疾患に対する頂点ごとの最適な階層の決定
 - 1.1 多階層統計形状モデル構築
 - 1.2 階層ごとの領域抽出
 - 1.3 各階層での抽出精度評価
- ・ 入力 CT 画像からの抽出
 2. 最適な階層を用いた CT 画像からの骨盤領域抽出
 - 2.1 多階層統計形状モデル構築
 - 2.2 階層ごとの領域抽出
 - 2.4 各抽出結果からの最適な頂点の取得

従来手法と提案法の違いは多階層統計形状モデルを用いた抽出において、骨盤全体を同じ階層で抽出するか、部分領域ごとに最適な階層を選択し抽出するかである．以下にその詳細を示す．提案法による骨盤領域抽出の流れは 1. 入力 CT 画像からの骨盤領域抽出前に行う処理と 2. 入力 CT 画像からの骨盤領域抽出の大きく二つに分けられる．1 では骨盤領域を抽出する前に、特定の疾患に分類された骨盤の部分領域において最適な多階層統計形状モデルの階層を求める．2 では部分領域ごとに 1 で求めた最適な階層選択し抽出を行うことで骨盤領域を抽出する．上述したように、多階層統計形状モデルの表現性能として、階層を深くすると汎化性は向上するが、特異性は低下する．骨盤の関節部以外はエッジが明瞭に見えているためモデルの階層が深いほど抽出精度の向上が期待されるが、関節部においてはエッジが不明瞭なため誤抽出が起こる．我々はエッジが見えない領域に対しては階層がある程度低いモデルで形状を予測したほうが抽出精度が向上すると考える．従来手法では、領域による最適な階層の選択は行われておらず、最も深い階層で全骨盤領域を抽出していたことから、関節部において誤抽出が生じていた．そのため、本手法では特定疾患骨盤の各領域ごとに最適な階層を事前に決定し、入力 CT 画像からの骨盤領域抽出を部分領域ごとに最適な階層で行うことにより骨盤抽出精度を向上させる．

```

1: input training surfaces  $S_i (i = 1, \dots, n)$  including disease cases  $m$ 
2: Construct hssm  $M_h (h = 0, \dots, N)$  from training surfaces  $S$ 
3: for each  $M_h$  do
4:   for each of the crowe over 2 cases  $j$  do
5:      $D_{jh} \leftarrow$  Calculate distance error vector  $D_{jh}$ 
        by registering  $M_h$  to target surface
6:   end for
7:   for  $k$  until  $m$  do
8:      $A_h \leftarrow$  Calculate average distance error vector for each vertex in  $D_{kh}$ 
9:   end for
10: end for
11:  $\mathbf{x} \leftarrow$  argmin  $A_h$  for each vertex
12: return  $\mathbf{x}$ 

```

2.3.1 特定疾患骨盤の各頂点における最適な階層の決定

学習データを用いて特定疾患骨盤に最適な階層を骨盤の頂点ごとに決定する。アルゴリズムを以下に示す。学習データ n 症例の内に特定疾患に分類された骨盤が m 症例含まれているとする。まず、学習データ n で多階層統計形状モデル $M_h (h = 0, \dots, N)$ を構築する。ここで N は多階層統計形状モデルの階層の深さとする。多階層統計形状モデルの 0 から N の各階層で学習データ内の全疾患骨盤 m 症例の抽出を行うことで、階層ごとに m 症例分の抽出された骨盤を取得する。抽出された m 症例の骨盤の頂点ごとに平均抽出誤差を求める。これを各階層で行うことで、骨盤各頂点における平均抽出誤差を各階層で算出する。算出した平均抽出誤差を全階層間で頂点ごとに比較し、最も誤差が小さい階層をその頂点における最適な階層とすることで、特定疾患における全頂点の最適な階層を求める。

2.3.2 最適な階層を用いた CT 画像からの骨盤領域抽出

学習データ内で求めた，特定疾患骨盤の各頂点における最適な階層に基づき，入力 CT 画像から骨盤領域を抽出する．まず，階層の深さ N の多階層統計形状モデルを構築し，入力 CT 画像から全階層で骨盤領域を抽出する．次に，学習データ内で求めた最適な階層を頂点ごとに選択し，それぞれの階層で抽出された骨盤から頂点を取得する．そして，取得した全頂点に面を張ることで最終的な骨盤領域抽出結果を得る．

第 3 章 実験

本研究では，構築した多階層統計形状モデルを用いて，CT 画像から骨盤領域の抽出を行い抽出精度を評価する．

3.1 データセット

本実験で使用した評価データと学習データは全て大阪大学病院で撮像された，人工股関節全置換術施術予定である患者の術前 CT 画像である．学習データは片側正常，片側疾患の 100 症例の計 200 片側骨盤とし，評価データは変形系疾患 Crowe 分類 2 以上の片側骨盤 24 症例とした．また比較データとして正常片側骨盤 100 例を用いた．専門家の指導の下，全症例の CT 画像から骨盤領域をマニュアルセグメンテーションすることで形状データを作成し，学習データ，評価データ，正解データとして扱った．マニュアルセグメンテーションとは CT 画像から手動で領域を抽出する作業である．また，200 症例に含まれる右側骨盤を鏡像反転することで全て左側骨盤として扱った．使用した CT 画像データセットの詳細を表 3.1 に示す．

3.2 評価尺度

骨盤領域の抽出精度の評価尺度として，正解領域の輪郭と自動抽出領域の輪郭との誤差を Average Symmetric surface distance(ASD) を用いて求めた．[30] ASD は参照する形状の全頂点において，対象形状の最近傍ボクセルとの距離誤差をユークリッド距離により求めその平均を返す．この処理を正解から自動抽出，自動抽出から正解の双方向で距離誤差を計算する手法である．

3.3 実験内容

まず，仮説の検証実験として階層が異なるモデルを用いて関節と骨盤領域を抽出し，階層の違いによる領域抽出精度を検証した．そして crowe 分類 24 症例の骨盤 CT 画像に対して従来法と提案法を用いた骨盤と臼蓋領域の抽出を行った．ここ

表 3.1 多階層統計形状モデル構築に使用した CT 画像データセットの情報

項目	画像情報
提供機関	大阪大学病院
正解データ	手動の骨盤領域
学習データ	片側正常, 片側疾患の 100 症例の計 200 片側骨盤
評価データ	Crowe 分類 2 以上の片側骨盤 24 症例
比較データ	正常片側骨盤 100 例
画像の縦横解像度	512×512 [<i>pixels</i>]
スライス厚	2.5 [<i>mm</i>] (200 症例)
ボクセルサイズ	$0.703 \times 0.703 \times 1.0$ [<i>mm</i> ³]

で, 関節領域の設定は専門家の指導の下多階層統計形状モデルの基準形状に手動で設定した. (図 3.1) 多階層統計形状モデル構築時に頂点の対応付けが取れているため, モデル構築の基準形状に手動設定することで全症例の関節領域が自動で決定される. また, 正常な症例と crowe 分類 2 以上の症例で抽出精度を比較し, 疾患症例に対する提案法の有効性を検証した. ここで各実験のそれぞれの症例は従来手法である階層レベル 5 で抽出した結果と提案手法の最適な階層で抽出した結果を比較した.

3.4 結果

仮説の検証実験として階層の違いによる関節と関節以外の領域抽出結果をそれぞれ図 3.2 の 3.2(a)3.2(b) に示す. それぞれの図における縦軸は各階層の全症例 ASD[mm] の平均値を取り, 横軸に多階層統計形状モデルの階層をとる. 青線は正常, 紫線は Crowe 分類 2 以上の症例を示す. また, 表 3.2 と 3.3 に関節と関節以外における各階層ごとの全症例平均 ASD[mm] を示す. 関節において階層 1, 階層 2, 階層 3, 階層 4, 階層 5 における全症例平均 ASD[mm] は正常が 1.272, 1.052, 0.893, 0.810, 0.771, 0.756 であり Crowe 分類 2 以上が 2.458, 2.284, 2.241, 2.343, 2.432, 2.535 であった. 関節以外においては正常が 1.056, 0.909, 0.799, 0.719,




図 3.1 手動選択した関節部


表 3.2 関節領域における各階層ごとの全症例平均 ASD

階層	正常 [mm]	疾患 [mm]
0	1.272	2.458
1	1.052	2.284
2	0.893	2.241
3	0.810	2.343
4	0.771	2.432
5	0.756	2.535


0.652, 0.617 であり, Crowe 分類 2 以上が 1.201, 1.048, 0.961, 0.830, 0.767, 0.732 であった.

変形系疾患 Crowe 分類 2 と抽出精度比較するために, 正常 100 症例の CT 画像に対して従来法と提案法を用いた関節と骨盤領域の抽出を行った結果の箱ひげ図をそれぞれ図 3.3(a) と図??に示す. この図は縦軸に ASD[mm] をとり, 横軸は提案法と従来法を示す. 関節において従来法の平均 ASD[mm] は 0.756 であり提案法は 0.732 であった. 骨盤においては従来法が 0.619 であり, 提案法が 0.616 であった. 従来法と提案法で t 検定を行ったところ, 関節と骨盤の両方において有意水準 1 % の有意差が認められなかった.

crowe 分類 24 症例の CT 画像に対して従来法と提案法を用いた関節と骨盤領




(a) 関節部の抽出精度比較




(b) 骨盤の抽出精度比較

図 3.2 階層の違いによる抽出精度の比較



(a) 関節部の抽出精度比較



(b) 骨盤の抽出精度比較


図 3.3 正常症例

表 3.3 関節以外における各階層ごとの全症例平均 ASD


階層	正常 [mm]	疾患 [mm]
0	1.056	1.201
1	0.909	1.048
2	0.799	0.961
3	0.719	0.830
4	0.652	0.767
5	0.617	0.732

域の抽出を行った結果の箱ひげ図をそれぞれ図 3.4(a) と図 3.4(b) に示す．縦軸に ASD[mm] をとり，横軸は提案法と従来法を示す．関節において従来法の平均 ASD[mm] は 2.535 であり提案法は 2.053 であった．骨盤においては従来法が 0.861 であり，提案法が 0.798 であった．従来法と提案法で t 検定を行ったところ，関節と骨盤の両方で有意水準 1 % で提案法において有意に抽出精度が向上した．

図 3.5 に従来法と提案法による抽出結果を示す．図 3.5 の 3.5(a) に，従来法の正解骨盤領域，抽出結果領域と距離誤差マップを示し，図 3.5(a) に提案法を示す．なお，距離誤差マップは，正解領域 と抽出された骨盤領域のサーフェースにおける最近傍頂点の距離誤差を示している．色が濃いほど誤差が大きく，赤と青はそれぞれ過抽出領域及び抽出不足領域を示し，白に近いほど，精度良く抽出されている．また 3.5(c) に従来法と提案法の抽出結果の断面図を示す．それぞれの画像における緑線は正解領域を示し，赤線は抽出結果領域を示す．




(a) 関節部の抽出精度比較




(b) 骨盤の抽出精度比較


図 3.4 Crowe 分類 2 以上の症例



(a) 従来法による抽出結果



(b) 提案法による抽出結果



(c) 左：従来法 右：提案法

図 3.5 可視化結果

第 4 章 考察

変形系疾患 crowe 分類 2 以上の症例の骨盤領域抽出精度を従来法と提案法の二つの手法で比較した。提案法による抽出精度が関節と骨盤領域の両方において従来法よりも有意に向上した。従来法では階層 5 の多階層統計形状モデルを用いて骨盤領域を抽出しており、関節部のエッジが見えない領域における抽出が失敗していた。各階層ごとの関節部とそれ以外の領域抽出精度の検証実験の結果、関節以外は階層 5 での抽出精度が最も良いが関節部は階層 5 ではなく、階層 2 のように階層が低いモデルの方が抽出精度が良いことが示された。また、関節部の境界が明瞭な正常症例における関節骨盤領域抽出において、従来手法よりも提案手法のほうがそれぞれ抽出精度が向上しているものの、crowe 分類 2 以上のように抽出精度に有意差が認められない。これらのことから、仮説通り関節部以外のエッジが見えている領域抽出においては汎化性が高く、関節部においては特異性が高いモデルを用いたほうが抽出精度が良いことが示される。従って、骨盤全体を同一の階層で抽出するのではなく、疾患に最適な階層を領域ごとに選択しエッジが見えている領域は汎化性が高く、見えない領域は特異性が高いモデルによる本手法の骨盤抽出手法が疾患症例に対して有効であったと考える。

従来法と比較して提案法の抽出精度は有意に良くなったものの、症例によってはまだ抽出精度が十分ではない。これは以下の原因が考えられる。まず、骨盤関節部の病気による変形バリエーションを多階層統計形状モデルが十分に表現できていないことが考えられる。これは多階層統計形状モデル構築時の頂点の対応付けがうまくいっていないことが原因だと予想される。本論文における多階層統計形状モデル構築時の頂点の対応付けは、基準形状を学習骨盤形状の平均形状とし平均形状を各学習データの骨盤形状のエッジに位置合わせすることで対応付けを行った。正常な症例の場合は骨盤形状全体において局所的に大きな変形がなく、さらに画像上にエッジが見えていることから位置合わせによる頂点の対応付けがうまく行えるため、個体間の変形のバリエーションをモデルが表現できる。しかし、変形系疾患 Crowe 分類 2 以上の症例は、関節部において局所的に大きな変形があり、かつ画像中に関節部のエッジも見えていないため、基準形状の位置合わせが失敗してしまっており頂点の対応付けがうまく行えていない事が考えられる。また、Crowe 分

類 2 以上の骨盤関節部においては変形だけでなく，骨棘と呼ばれる新たな骨が生えてしまっており，そもそも頂点同士対応づかないためモデルが骨棘を表現できていないことが考えられる．それから，多階層統計形状モデル構築における Crowe 分類 2 以上のデータは 24 症例程度しかないため学習データが十分ではないことが考えられる．頂点の対応付けに関しては基準形状を学習データに手動で対応付けを行う手法を行うなど正しく頂点の対応付けを行う手法を用いる必要があると考える．また，モデルの位置合わせにおける骨盤エッジ検出手法として現在は閾値処理による検出を行っており，境界が不明瞭な領域においてエッジの誤検出がおこっているため，不明瞭な領域にも対応できるような新たなエッジ検出手法を用いる必要がある．また学習データを増やし疾患症例のみで多階層統計形状モデルを構築することで，疾患に特化したモデルを構築しより高精度な領域抽出が可能になると考える．

第 5 章 結びと今後の予定

本論文では，人工股関節全置換術における術全手術計画システムの構築を目指し，病気により変形している骨盤に特化した領域抽出手法を提案した．多階層統計形状モデルにおける汎化性と特異性に着目し，部分領域ごとに汎化性が高いモデルと特異性が高いモデルを使い分けることで最適な階層で骨盤抽出が可能な手法を提案した．従来法と提案法を同一のデータセットで比較することで，変形した骨盤抽出における提案法の有効性を検証した．変形系疾患 Crowe 分類 2 以上の症例に対して従来法と提案法を用いた自動抽出を行った結果，提案法が従来法よりも有意に抽出精度が向上した．また，比較として境界が明瞭な正常症例に対しても提案法を用いた骨盤抽出を行った結果，従来法と比較して提案法の抽出精度は向上したものの，有意差はなく Crowe 分類 2 の症例ほど抽出精度の向上が確認されなかった．これらのことから，従来法と比較して本手法が Crowe 分類 2 のように境界が見えていない症例の抽出に特に有効であることを示した．今後の予定として，臨床の自動手術計画システムに用いるために抽出精度がどの程度必要なのかを検証する．検証方法として骨盤抽出精度と自動手術計画システムの精度の関係についての研究として，自動手術計画システムが提示するカップサイズの誤差を，骨盤抽出を自動と手動で比較した鍵山らの方法 [31] を用いた検証を行う予定である．

謝辞

本研究を進めるにあたり，多くの方々にご指導，ご協力，ご支援を賜りました．ここに謝意を添えてお名前を記させていただきます．

主指導教員であり，本論文の審査委員を務めていただいた奈良先端科学技術大学院大学 情報科学研究科 佐藤嘉伸教授に対し，厚く御礼申し上げます．研究に対する直接的な指導に限らず，研究に取り組む上での心構えから研究者としての在り方まで，ありとあらゆる面で熱心なご指導を賜りました．

副指導教官であり，本論文の審査委員を務めていただいた奈良先端科学技術大学院大学 情報科学研究科 金谷重彦教授には，学内発表において研究の質を高める上で非常に貴重なご意見を頂きました．心より感謝申し上げます．

本研究を遂行するにあたり，多くの有益な御助言と丁寧な御指導を頂きました 奈良先端科学技術大学院大学 情報科学研究科 生体医用画像研究室 大竹義人 准教授に深く感謝申し上げます．

奈良先端科学技術大学院大学 情報科学研究科 横田太助教には，研究の進め方から，論文執筆，プレゼンテーション作法まで何度も明敏なご指導を頂きました．横田先生から頂いた数々の指導は私の将来の財産になると確信しております．心より感謝申し上げます．

参考文献

- [1] Y. Kagiyama, M. Takao, M. Nakamoto, Y. Sato, N. Sugano, H. Yoshikawa, K. Akazawa, S. Tamura, Y. Tada, Automated planning of multi-component implants for THA using multiple criteria including limb length and range of motion, *International Journal of Computer Assisted Radiology and Surgery* 1 (S1) (2006) 232–234.
- [2] I. Otomaru, K. Kobayashi, T. Okada, M. Nakamoto, Y. Kagiyama, M. Takao, N. Sugano, Y. Tada, Y. Sato, Expertise modeling for automated planning of acetabular cup in total hip arthroplasty using combined bone and implant statistical atlases, in: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Vol. 5761 LNCS, 2009, pp. 532–539, 2009.
- [3] I. Otomaru, M. Nakamoto, Y. Kagiyama, M. Takao, N. Sugano, N. Tomiyama, Y. Tada, Y. Sato, Automated preoperative planning of femoral stem in total hip arthroplasty from 3D CT data: atlas-based approach and comparative study., *Medical image analysis* 16 (2), pp. 415–26, 2012.
- [4] 成平拓也, 清水昭伸, 小畑秀文, 縄野繁, 篠崎賢治, “単純と造影 ct 像からの転移 性肝腫瘍セグメンテーション処理
- [5] Y.Y.Boykov and M.P.Jolly, “Interactive graph cuts for optimal boundary and region segmentation of objects in ND images,” *Computer Vision, 2001. ICCV 2001. Proceedings. Eighth IEEE International Conference on*, pp.105–112, 2001.
- [6] 北坂孝幸, 小川浩史, 横山耕一郎, 森健策, 目加田慶人, 長谷川純一, 末永康仁, 鳥 脇純一郎, “解剖学的知識に基づく非造影 3 次元腹部 X 線 CT 像からの複数臓器領域の抽出, ” *コンピュータ支援画像診断学会論文誌*, vol.9, no.1, pp.1–14, 2005
- [7] H. Hontani, T. Matsuno, and Y. Sawada, “Robust nonrigid icp using outlier-sparsity regularization,” *Computer Vision and Pattern Recognition*

- (CVPR), 2012 IEEE Conference on, pp.174–181, 2012.
- [8] B.Al-Diri, A.Hunter, and D.Steel, “An active contour model for segmenting and measuring retinal vessels,” *IEEE Transactions on Medical Imaging*, vol.28, no.9, pp.1488–1497, 2009.
 - [9] S.Zhang, Y.Zhan, M.Dewan, J.Huang, D.Metaxas, and X.Zhou, “Deformable segmentation via sparse shape representation,” *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2011*, pp.451–458, 2011.
 - [10] S.Zhang, Y.Zhan, M.Dewan, J.Huang, D.N.Metaxas, and X.S.Zhou, “Towards robust and effective shape modeling: Sparse shape composition,” *Medical image analysis*, vol.16, no.1, pp.265–277, 2012.
 - [11] Kainmueller, Dagmar, et al. "An articulated statistical shape model for accurate hip joint segmentation." *Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE. IEEE*, 2009.
 - [12] Schmid, Jérôme, Jinman Kim, and Nadia Magnenat-Thalmann. "Robust statistical shape models for MRI bone segmentation in presence of small field of view." *Medical image analysis* 15.1 (2011): 155-168.
 - [13] [4] F. Yokota, T. Okada, M. Takao, N. Sugano, Automated CT Segmentation of Diseased Hip Using Hierarchical and Conditional Statistical Shape Models, in: *Medical image computing and computer-assisted intervention : MICCAI International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2013, pp. 190–197, 2013.
 - [14] 新田修平, 本谷秀堅, 深見忠典, 湯浅哲也, 赤塚孝雄, 呉 勁, 武田 徹, 織内昇, 遠藤啓吾, 渡邊順久, “画素値の確率分布に基づく PET/CT 画像中の腫瘍領域の抽出,” *MEDICAL IMAGING TECHNOLOGY*, vol.24, no.5, pp.409–418, 2006
 - [15] “計算解剖学”. <http://www.comp-anatomy.org/wiki>
 - [16] 医用画像工学会ハンドブック編集委員会, 医用画像工学ハンドブック, 国際文献出版社, 2012.

- [17] M.Kass, A.Witkin, and D.Terzopoulos, “Snakes: Active contour models,” *International journal of computer vision*, vol.1, no.4, pp.321–331, 1988.
- [18] D. Cremers, M. Rousson, and R. Deriche, “A review of statistical approaches to level set segmentation: integrating color, texture, motion and shape,” *International journal of computer vision*, vol.72, no.2, pp.195–215, 2007.
- [19] T.Heimann and H.P.Meinzer, “Statistical shape models for 3D medical image segmentation: A review,” *Medical image analysis*, vol.13, no.4, pp.543–563, 2009.
- [20] T.F.Cootes, C.J.Taylor, and J.Graham, “Active shape models-their training and application,” *Computer Vision and Image Understanding*, vol.61, no.1, pp.38–59, 1995.
- [21] T. Cootes, G. Edwards, and G. Taylor, “Active appearance models,” *Computer Vision-ECCV’ 98*, pp.484–498, 1998
- [22] 横田太, et al. "統計アトラスを用いた股関節三次元 CT 画像からの骨盤解剖学的座標系の自動設定." *Medical Imaging Technology* 30.1 (2012): 43-52.
- [23] Lamecker, H., Lange, T., Seebaß, M., 2004. Segmentation of the liver using a 3D statistical shape model. Tech. rep., Zuse Institute, Berlin
- [24] Davies, R.H., 2002. Learning shape: optimal models for analysing shape variability. Ph.D. Thesis, University of Manchester.
- [25] Heimann, T., 2007. Statistical shape models for 3D medical image segmentation. Ph.D. Thesis, University of Heidelberg, Germany.
- [26] R.H. Davies, C.J. Twining, T.F. Cootes, and C.J. Taylor, “Building 3-d statistical shape models by direct optimization,” *Medical Imaging, IEEE Transactions on*, vol.29, no.4, pp.961–981, 2010.
- [27] M.Styner, K.Rajamani, L.P.Nolte, G.Zsemlye, G.Székely, C.Taylor, and R.Davies, “Evaluation of 3D correspondence methods for model evaluation,” *Information processing in medical imaging*, pp.63–75, 2003.
- [28] A.Saito, A.Shimizu, H.Watanabe, S.Yamamoto, and H.Kobatake, “A statistical shape model of a dead liver for autopsy imaging,” *International*

- Forum on Medical Imaging in Asia (IFMIA), pp.1–5, 2012.
- [29] Zhao, Zheen, Stephen R. Aylward, and Eam Khwang Teoh. "A novel 3D partitioned active shape model for segmentation of brain MR images." International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer Berlin Heidelberg, 2005.
 - [30] Styner, Martin, et al. "3D segmentation in the clinic: A grand challenge II: MS lesion segmentation." *Midas Journal* 2008 (2008): 1-6.
 - [31] Kagiya, Yoshiyuki, et al. "International journal of computer assisted radiology and surgery 11.12 (2016)

発表リスト

[1] 大谷 悠太, 横田 太, 大竹 義人, 高尾 正樹, 小川 剛, 上村 圭亮, 菅野 伸彦, 佐藤 嘉伸 "疾患固有統計形状モデルを用いた CT 画像からの骨盤領域の自動抽出 " 医用画像研究会 volume IEICE-MI2015-78, pp.31-34, 2016 年 1 月.

[2] 大谷 悠太, 横田 太, 大竹 義人, 高尾 正樹, 小川 剛, 上村 圭亮, 菅野 伸彦, 佐藤 嘉伸 "疾患固有統計形状モデルを用いた CT 画像からの局所変形骨盤領域の自動抽出 " 医用画像研究会 , 2017 年 1 月.