

## 3차원 무릎 자기공명영상 내에서 영역화와 정합 기법을 반복적으로 이용한 다중 해상도 기반의 뼈 영역화 기법

박 상 현<sup>a)</sup>, 이 수 찬<sup>b)</sup>, 윤 일 동<sup>c)†</sup>, 이 상 옥<sup>a)</sup>

### Bone Segmentation Method based on Multi-Resolution using Iterative Segmentation and Registration in 3D Magnetic Resonance Image

Sang Hyun Park<sup>a)</sup>, Soochan Lee<sup>b)</sup>, Il Dong Yun<sup>c)†</sup>, and Sang Uk Lee<sup>a)</sup>

#### 요 약

최근 의료 장비들이 발전하고 진단 및 연구에 다양하게 이용되면서 이로부터 얻은 3차원 의료 영상들을 자동으로 처리해주는 기술의 수요가 늘고 있다. 자동 뼈 영역화는 이러한 기술들 중 하나로써 골다공증이나 뼈 골절, 골격질환 등의 진단의 효율성을 크게 높여 줄 것으로 기대되고 있다. 현재까지 자동 뼈 영역화를 위한 연구들이 다양하게 진행되었지만 2차원 영상과는 달리 많은 데이터양과 주변 조직과의 모호한 경계들이 많다는 의료영상의 특성 때문에, 실제 진단에 사용할 수 있을만한 성능을 얻지 못하고 있다. 본 논문에서는 이와 같은 문제를 해결하기 위해 다중 해상도를 기반으로 하여 수행속도가 빠르고 영역화 성능이 좋은 자동 뼈 영역화 기법을 제안한다. 낮은 해상도 단계에서는 학습된 집합의 뼈 정보들을 바탕으로 최근 제안된 제한된 브랜치 앤 미컷 기법을 이용하여 대략적인 뼈 위치 및 비슷한 템플릿을 검출하고, 이후 해상도를 높여가면서 정합 과정과 영역화 과정을 반복적으로 수행한다. 제안하는 기법의 성능을 확인하기 위해 무릎 자기공명영상(magnetic resonance image)내에서 대퇴골(femur)과 경골(tibia)을 영역화 하는 실험을 진행하였으며, 100개의 학습 데이터들을 바탕으로 50개 영상에서 뼈들을 영역화 하였다. 제안하는 기법은 정확성 및 수행속도 측면에서 제한된 브랜치 앤 미컷에 비해 향상된 결과를 나타냈다.

#### Abstract

Recently, medical equipments are developed and used for diagnosis or studies. In addition, demand of techniques which automatically deal with three dimensional medical images obtained from the medical equipments is growing. One of the techniques is automatic bone segmentation which is expected to enhance the diagnosis efficiency of osteoporosis, fracture, and other bone diseases. Although various researches have been proposed to solve it, they are unable to be used in practice since a size of the medical data is large and there are many low contrast boundaries with other tissues. In this paper, we present a fast and accurate automatic framework for bone segmentation based on multi-resolutions. On a low resolution step, a position of the bone is roughly detected using constrained branch and mincut which find the optimal template from the training set. Then, the segmentation and the registration are iteratively conducted on the multiple resolutions. To evaluate the performance of the proposed method, we make an experiment with femur and tibia from 50 test knee magnetic resonance images using 100 training set. The proposed method outperformed the constrained branch and mincut in aspect of segmentation accuracy and implementation time.

Keyword : Bone Segmentation, Registration, MR images, Multi-resolution, Constrained branch-and-mincut

## 1. 서론

최근 자기공명영상(magnetic resonance image, 이후 MR)과 컴퓨터단층촬영영상(computed tomography) 등 3차원 의료 기기의 이용이 국내외적으로 보편화 되었고, 이로부터 얻은 의료영상들을 관리하는 기술의 수요가 늘어나고 있다. 이 중 3차원 MR영상 내에서 뼈를 영역화(segmentation) 해내는 작업은 골다공증이나 뼈 골절, 골격질환 등의 진단을 연구, 판단하는 데에 중요한 역할을 하고 있다. 하지만 이러한 작업들은 대부분 전문가들이 많은 시간을 들여서 해오고 있기 때문에 분석이나 진단에 한계가 있다.

이러한 배경을 바탕으로, 전문가들의 입력을 크게 줄여주는 반자동 혹은 완전 자동 뼈 영역화 기법들이 나타나고 있다. Bourgeat 등은 물체의 특징(feature)들을 추출하고 이를 학습하여, 복셀(voxel)단위로 전경과 배경을 분류(classification)해내는 기법<sup>[7]</sup>을 제안하였다. 이 기법은 분류 기법의 장점을 기반으로 하고 있지만 낮은 수준의 특징들만을 이용하였기 때문에 영역화 정확성에 한계가 있었다. Fripp 등과 Schmid 등은 좀 더 이론적으로 변분법(variational method)을 기반으로 하고 있는 능동형상모델(active shape model)<sup>[5]</sup>과 변형모델(deformable models)<sup>[6]</sup> 영역화 기법을 각각 제안하였다. 이 두 기법들은 형상 및 밝기 정보를 하나의 식 내에 모델링(modeling)하여 특징 기반의 영역화 결과보다 좋은 성능을 얻어냈다. 하지만 변분법 기반 기법의 경우, 어느 정도 정확한 초기값(initialization)이 필요하며 이 초기값이 좋지 못한 경우 결과가 국부적 최소값(local minimum)에 수렴한다. 다른 한

편으로는 초기값에 상관없이 전역적 최소값(global minimum)을 찾아낼 수 있는 그래프 기반 영역화 기법들<sup>[8,9,10]</sup>이 나타났다. 초기 그래프 기반 기법들의 경우, 복셀(voxel) 및 복셀 패어(voxel pair) 정보만을 모델링(modeling) 하였기 때문에 다수의 사용자 입력 없이는 정확한 영역화가 어려웠지만, 최근에는 좀 더 높은 차원의 사전지식(prior)들을 낮은 수준의 정보들과 함께 모델링(modeling)해줌으로써 모호한 지역에서도 오차를 줄이고자 하는 연구들이 나타나고 있다.

뼈 영역화를 위해 높은 차원의 사전지식을 그래프 내에 모델링 한 논문으로 제한된 브랜치 앤 민컷 기법(branch-and-mincut)<sup>[11]</sup>을 들 수 있다. 이 기법은 데이터양이 큰 3차원 뼈 영역화를 위해 기존의 브랜치 앤 민컷(branch-and-mincut) 기법<sup>[11]</sup>을 변형한 기법으로써, 다수의 템플릿(template)들 중 가장 비슷한 템플릿을 찾아 이를 형상 사전 지식(shape prior)으로 이용함으로써 경계가 모호한 지역에서도 견고한(robust) 성능을 나타냈다. 하지만 여전히 높은 복잡도와 메모리를 필요로 하고 있기 때문에 원래 해상도 MR 영상 내에서 뼈를 영역화하기 어려웠고, 브랜치 앤 민컷과는 달리 최종적으로 얻은 템플릿이 템플릿들 중 최적(optimal)의 템플릿이 아닐 수 있기 때문에 정확도 측면에서도 한계가 있었다.

이에 따라 본 논문에서는 제한된 브랜치 앤 민컷 기법의 복잡도와 정확성 성능을 동시에 향상시켜주는 자동 뼈 영역화 기법을 제안한다. 이를 위해 본 논문에서는 세 단계로 나누어진 다중 해상도(multi-resolution)영상들을 생성한 뒤, 하위 단계에서는 대략적인 뼈의 위치를 알아내고, 중간 및 상위 단계에서는 점차 정확한 템플릿과 영역화 결과를 얻어내는 기법을 제안한다. 복잡도가 높은 제한된 브랜치 앤 민컷은 가장 낮은 해상도에서 대략적인 뼈의 위치를 알기 위해서만 사용하고, 이후 복잡도가 적은 그래프 컷(graph cut) 기반<sup>[2]</sup>의 영역화와 경식(rigid) 정합 기법을 반복적으로 수행한다. 실험결과를 통해 해상도가 높아질수록 정합과 영역화 성능이 향상되는 것을 확인할 수 있었다. 제안하는 기법의 세부내용은 II절에, 실험결과는 III절에 제시한다.

a) 서울대학교 전기·컴퓨터공학부 자동화시스템연구소  
Automation and Systems Research Institute, School of Electrical Engineering and Computer Science, Seoul National University

b) 삼성전자  
Samsung Electronics

c) 한국외국어대학교 용인캠퍼스 디지털정보공학과대학교  
School of Digital Information Engineering, Hankuk University of Foreign Studies

✉ 교신저자 : 윤일동 (yun@hufs.ac.kr)

※ 본 논문은 한국외국어대학교 학술연구비 지원에 의해서 연구되었음.  
· 접수일(2011년9월2일), 수정일(2011년12월6일), 게재확정일(2012년1월5일)

## II. 제안하는 기법

### 1. 제한된 브랜치 앤 미컷 기법의 요약

제한된 브랜치 앤 미컷(constrained branch-and-min-cut)<sup>[11]</sup>은 브랜치 앤 미컷(branch-and-min-cut)<sup>[1]</sup>의 프레임워크(framework)을 따르되, 3차원 뼈 영역화에 적합하도록 메모리와 수행시간을 단축시킨 기법이다. 이 기법은 기존에 영역화 레이블(label)만을 찾기 위해 정의되었던 그래프 컷(graph cut)<sup>[2]</sup>의 에너지 식에 지역적이지 않은 사전지식(non-local prior) 정보를 함께 모델링(modeling)하고 있다. 식 (1)은 브랜치 앤 미컷의 에너지 식이다.

$$E(X, w) = \sum_{v \in V} F^v(w)x_v + \sum_{v \in V} B^v(w)(1-x_v) + \sum_{u, v \in \xi} P^{uv}(w)|x_u - x_v| \quad (1)$$

이 식의  $X$ 는 모든 복셀들의 집합  $V$  안에 있는 각 복셀  $v$ 의 레이블  $x_v$ 들의 벡터 집합을 의미하고, 전경의 복셀 레이블은  $x_v = 1$ , 배경의 복셀 레이블은  $x_v = 0$ 으로 정의된다.  $F^v(w)$ 와  $B^v(w)$ 는 각각 복셀  $v$ 의 전경 퍼텐셜과 배경 퍼텐셜을,  $P^{uv}(w)$ 는 모든 복셀 이웃들의 집합  $\xi$  안에 있는 이웃한 복셀  $u, v$  간에 쌍방향 퍼텐셜(pairwise potential)을 의미한다.

복셀 및 복셀 페어들 간의 정보를 바탕으로 퍼텐셜들을 정의했던 그래프 컷 기법과는 달리 식 (1)의 모든 퍼텐셜들은 지역적이지 않은 사전지식(non-local prior)  $w$ 에 의해 정의된다. 제한된 브랜치 앤 미컷 기법에서는  $w$ 를 형상사전지식(shape prior)으로 정의하였으며, 위치, 각도, 모양 등에 대해 변화가 가능한 모든 형상 템플릿을 의미하였다. 형상사전지식  $w$ 가 고정되어 있을 때는 이를 바탕으로 에너지를 최소화하는  $X$ 만 구하면 되지만,  $w$ 가 변하면 (1)의 모든 퍼텐셜들이 바뀌기 때문에 지역적이지 않은 사전지식들의 총 집합  $\Omega$  내에 모든 템플릿들에 대해 에너지를 비교함으로써 최적의  $w$ 를 찾아야 했다. 이 검색은 너무 복잡도(complexity)가 높았기 때문에 Lempitsky 등은 브랜치 앤 바운드(branch and bound) 트리 검색 기법<sup>[1]</sup>을 제안하였다.

브랜치 앤 바운드(branch and bound) 트리 검색에서는 모든 사전지식들을 트리의 최하단(leaf) 노드들에 위치시켜 놓고 주변의 비슷한 사전지식들을 군집(cluster)시켜 가면서 집합된 퍼텐셜  $F_\Omega^v = \min_{w \in \Omega} F^v(w)$ ,  $B_\Omega^v = \min_{w \in \Omega} B^v(w)$ ,  $P_\Omega^{uv} = \min_{w \in \Omega} P^{uv}(w)$ 들을 구해 상위노드들의 에너지를 정의한다. 이후 루트(root)노드로부터 하단 노드로 검색을 수행함으로써 모든  $w$ 에 대해 미 컷을 수행하지 않고도 최적의 사전지식  $w_{opt}$ 을 찾아낸다. 이 기법은 2차원 영상 영역화에 잘 동작하였지만, 3차원 영상의 경우 가능한 사전지식의 수가 너무 많았기 때문에 메모리와 수행속도 측면에서 문제가 발생했다.

제한된 브랜치 앤 미컷<sup>[11]</sup>은 트리 검색 속도를 더욱 향상 시켜주기 위해 하단 노드로 브랜칭(branching)을 할 때 단항 및 쌍항 퍼텐셜의 관계와 영역화 결과를 함께 고려해줌으로써, 트리의 상단에서 가능성이 적은 노드들을 제거하였다. 하지만 여전히 수행속도 문제로 인해 [11]에서는  $384 \times 384 \times 160$  영상을 x, y, z축에 대해 각각 1/2로 다운샘플링(downsampling)하여 실험을 진행하였으며, 트리검색의 범위가 제한적이었기 때문에 때때로 사용자의 입력 및 정제(refinement)작업이 필요했다. 또한 간혹 지역적인 최소값(local minimum)으로  $w$ 가 수렴하는 경우가 있었기 때문에 정확성 면에서 문제를 보이기도 하였다. 자세한 내용은 [11]을 참조한다.

### 2. 다중 해상도 기반의 영역화 프레임워크

본 논문에서는 상위단계, 중간단계, 하위단계로 구성된 다중 해상도(multi-resolution)를 기반으로 하여 제한된 브랜치 앤 미컷보다 빠르고 정확하게 원본 해상도 내의 뼈를 영역화 해내는 프레임워크(framework)를 제안한다. 본 실험에서 사용한 3차원 무릎 MR 영상의 경우 평균적으로 300복셀 정도의 x축, 350복셀 정도의 y축, 120복셀 정도의 z축으로 구성되어 있었기 때문에, 원본 영상, x와 y축의 크기를 1/2로 줄인 중간단계 영상, 중간단계의 해상도를 다시 x, y, z축에 대해 1/2로 줄인 하위단계 영상을 각각의 단계로 정의하였다. 그림 1은 각 단계에서 수행하는 작업 및 수행결

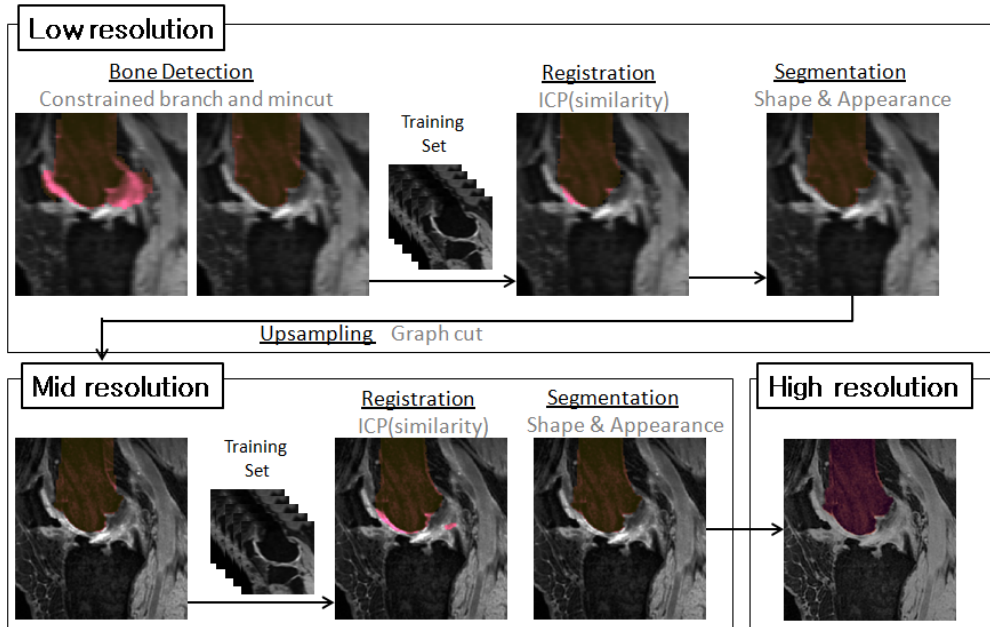


그림 1. 제안하는 기법의 흐름도. 하위 해상도 박스 왼쪽부터 각각 제한된 브랜치 앤 미컷을 이용하여 찾은 유사한 템플릿 결과, 뼈 영역화 결과, 학습 템플릿들 중 초기 영역화에 가장 정합이 잘 된 템플릿, 정합이 잘 된 템플릿을 이용하여 얻은 영역화 결과를 보여준다. 중간 해상도 박스 왼쪽부터 각각 확장된 결과, 학습 템플릿들 중 확장된 영역화 결과에 가장 정합이 잘 된 템플릿, 템플릿을 이용하여 얻은 영역화 결과를 보여준다. 상위단계의 최종결과는 중간단계의 영역화 결과를 확장한 것이다. 정합과 영역화가 반복되면서 두 결과가 모두 점차 향상됨을 확인할 수 있다.

Fig. 1. Flow chart of the proposed method. From left side of low resolution box, a detected template using constrained branch and mincut, a segmentation using constrained branch and mincut, a best aligned template, and a segmentation result of low resolution using the best aligned template. From left side of middle resolution box, the up-sampled segmentation of the low-resolution segmentation result, the best aligned template, the mid-resolution segmentation result. The final result is the up-sampled segmentation of the mid-resolution segmentation result. As iteratively conducting the segmentation and the registration, the performances of them are enhanced.

과를 보여준다.

해상도가 가장 낮은 하위단계에서는 제한된 브랜치 앤 미컷 기법[11]을 이용하여 학습 집합(training set)으로부터 영역화 하고자 하는 뼈와 비슷한 뼈 템플릿을 찾고, 이를 사전지식으로 이용하여 초기 뼈 영역화 결과를 얻는다. [11]은 한 개의 평균 템플릿으로 40\*40\*12 범위의 위치변형만으로 19200개의 템플릿들을 생성하여 트리를 구성했지만, 본 논문의 하위단계에서는 계산량이 적기 때문에 30개의 학습 템플릿들을 15\*18\*10 범위의 위치변형을 시켜 만든 81000개의 템플릿들을 생성하여 트리를 구성하였다. 해상도가 낮은 영상에서 더 많은 템플릿들을 생성하여 넓은 범위 내에서 검색을 수행함으로써 초기 영역화 정확성을 향상시켰다.

제한된 브랜치 앤 미컷을 통해 많은 템플릿들 중 좋은 템플릿을 찾았다고 해도 3차원에서 각도, 모양, 위치 변환을 시킨 모든 템플릿을 생성할 수는 없기 때문에, 이후 좀더 정확한 뼈 템플릿을 얻기 위한 작업을 수행한다. 이를 위해 하위단계의 초기 영역화 결과에 학습 집합 내의 모든 뼈 템플릿들을 정합한 뒤 L1 거리가 최소인 템플릿  $w_{opt}$  을 얻어낸다. 뼈의 경우 연식 변화가 적기 때문에 경식변환(rigid transformation) 기법 중 하나인 반복근접점(iterative closest point)<sup>[3]</sup>을 이용하여 정합을 수행한다. 그림 1에서 보듯이 초기 영역화 결과는 뼈의 위치 및 대략적인 모양을 나타내고 있기 때문에 제한된 브랜치 앤 미컷으로 찾은  $w_{opt}$  보다 더 정확한  $w_{opt}$  를 얻을 수 있다.

$w_{opt}$  가 구해지면 이를 바탕으로 식 (2)와 (3)과 같이

$F^v(w)$ 와  $B^v(w)$ 를 정의한다.

$$F^v(w_{opt}) = -\log(f(v) \cdot p_a(v) + (1-f(v)) \cdot p_s(v)), \quad (2)$$

$$B^v(w_{opt}) = -\log(1 - (f(v) \cdot p_a(v) + (1-f(v)) \cdot p_s(v))). \quad (3)$$

이 때  $p_a(v)$ 는 복셀  $v$ 에서 외관정보를 바탕으로 정의된 전경 확률을 의미하며,  $p_s(v)$ 는 형상정보를 바탕으로 정의된 전경 확률을 의미한다.  $p_a(v)$ 는  $w_{opt}$ 가 전경이라 가리키는 부분과 배경이라 가리키는 부분의 히스토그램을 각각 만든 뒤,  $v$ 의 밝기에 따라 히스토그램들을 이용하여 정의한다.  $p_s(v)$ 는  $w_{opt}$ 이 있는 부분을 1, 없는 부분을 0으로 정의한다.  $f(v)$ 는 이 두 확률의 가중치를 결정해주는 계수로써 식 (4)와 같이 정의된다.

$$f(v) = \exp(-d(v)/\sigma), \quad (4)$$

이 때  $d(v)$ 는 템플릿 외곽경계로부터의 거리를 의미하며,  $\sigma$ 는 형상과 외관정보를 조절해주는 계수이다. 템플릿의 경계는 뼈와 정확히 일치되어 있지 않기 때문에 가까울수록 외관정보를 강조하고, 템플릿 경계에서 멀어질수록 형상정보를 강조한다. 하위단계에서 찾은 템플릿은 해상도의 영향으로 인해 위치 및 모양이 부정확할 수 있기 때문에  $\sigma$ 를 크게 하여 밝기(appearance) 정보에 좀 더 가중치를 두며 상위 단계로 갈수록  $\sigma$ 를 작게 하여 형상정보에 가중치를 준다. 쌍향 퍼텐셜은 지수함수<sup>[1][2]</sup>로 정의하며 식 (1)은 그래프 컷을 통해 최적화된다.

하위단계에서 최종적으로 얻은 영역화 결과는 중간단계로 확장되며 이는 중간단계의 초기 영역화 결과로 이용된다. 각 축으로 결과를 확장할 때(upsampling) 블록 모양으로 매끄럽지 못한 면들이 생길 수 있으므로 매끄럽게 만들어주기 위하여 확장 후 약한 쌍향(pairwise) 값을 주어 그래프 컷 영역화를 수행한다.

하위 단계 영역화의 경우 해상도가 낮아 밝기정보가 손상된 상황에서 수행되었기 때문에 결과가 부정확한 경우가 많다. 따라서 중간단계에서는 확장된 결과에 학습 집합의 뼈 템플릿들을 다시 한 번 반복근접점 기법을 통해 정합을 수행하여 최적의 템플릿  $w_{opt}$ 을 찾아낸다. 그림 1에서 보

듯이 이 때는 정합된 템플릿이 하위단계에 비해 정확하기 때문에  $\sigma$ 를 작게 하여 형상정보에 가중치를 준다. 새롭게 얻은  $w_{opt}$ 은 식 (2)와 (3)을 정의하는 데에 형상정보로 이용되며 식 (1)은 다시 한 번 그래프 컷을 통해 최적화된다. 초기 영역화 결과는 밝기 정보에 가중치가 크기 때문에 모호한 지역에서 벗어나버리는(over-segmentation) 영역화 결과가 나타나지만, 중간 단계에서는 형상 정보에 가중치가 크므로 모호한 지역에서도 벗어나지 않는 영역화 결과를 얻을 수 있다. 마지막으로 최종결과를 얻기 위해 중간단계의 결과를  $x, y$ 축에 대해 확장한다.

### III. 실험결과

제안하는 기법의 성능을 확인하기 위해 2010년에 열린 MICCAI 워크샵 중 하나였던 SKI 2010 웹사이트<sup>[4]</sup>에 공개되어 있는 무릎 MR 데이터들을 실험에 이용하였다. [4]에는 대퇴골(femur)과 경골(tibia)뼈의 참값(ground truth) 및 MR 영상을 포함하고 있는 학습(train) 데이터 100개와 MR 영상만을 포함하고 있는 테스트(test) 데이터 50개가 공개되어 있다. 테스트 데이터의 경우 참값(ground truth)이 공개되어 있지 않기 때문에 영역화 성능을 비교하기 위하여 SKI 웹사이트에 결과를 제출하여 성능을 평가 받았으며, 이 결과는 [4]에 공개되어 있다.

뼈 영역화 결과의 정확성을 판단하기 위해 평균대칭표면거리(average symmetric surface distance: AvgD)와 제곱루트평균표면거리(root-mean-square symmetric surface distance: RMSD)를 측정한다. 평균대칭표면거리는 영역화 결과의 경계위에 있는 복셀들에 대하여 참값과의 매칭점들을 찾은 뒤, 두 점의 거리들을 계산하여 평균을 내줌으로써 얻어낸다. 제곱루트평균표면거리는 비슷한 방법으로 구하되, 거리들을 제곱하여 합한 뒤 루트연산을 수행함으로써 얻어낸다. 따라서 두 결과 모두 0으로 다가갈수록 좋은 결과를 의미한다.

그림 2의 (a)와 (b)는 각각 제안하는 기법과 제한된 브랜치 앤 민컷을 이용하여 얻은 대퇴골과 경골의 평균대칭표면거리와 제곱루트평균표면거리 결과를 박스 플롯(box

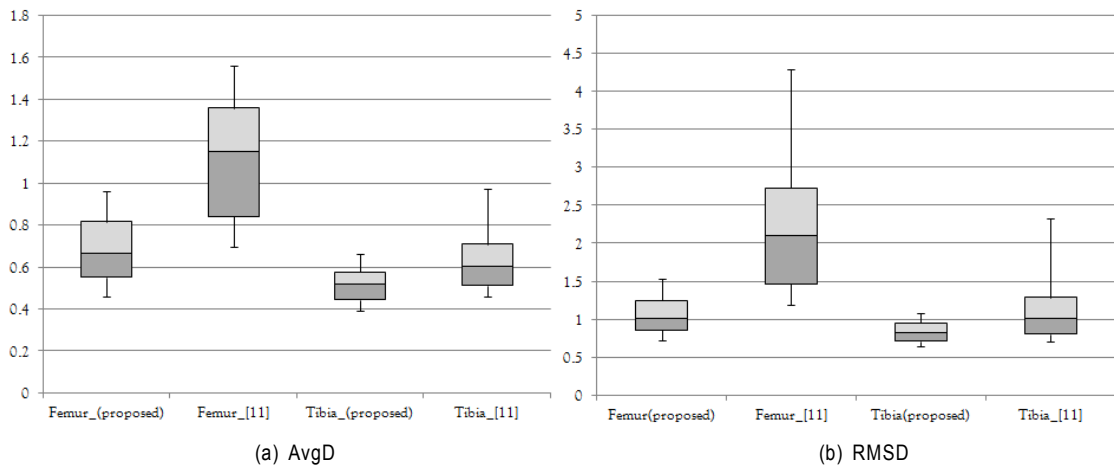


그림 2. 50개 테스트 영상에 대한 영역화 결과. (a) 평균대칭표면거리(AvgD) 결과. (b) 제곱루트평균표면거리(RMSD) 결과. 박스의 중간선은 중간값, 박스의 위와 아래 선은 각각 상위와 하위 25%값, 위스커(whisker)는 각각 상위와 하위 10%값을 나타낸다. \_(proposed)는 제안하는 기법의 결과를, \_[11]은 제한된 브랜치 앤 민컷의 결과를 보여준다.

Fig. 2. The segmentation result of 50 test images. (a) The result of average symmetric surface distance. (b) The result of root-mean-square symmetric surface distance. Three horizontal lines of the box represent the upper quartile, the median, and the lower quartile and whiskers indicate the top 10 percent value and the bottom 10 percent value. \_(proposed) shows the result of the proposed method and \_[11] shows the result of branch and mincut.

plot)으로 보여준다. 박스의 중간선은 50개의 테스트 결과 중 중간값(median)을 의미하며, 박스의 위와 아래 선은 각각 상위와 하위 25%값을, 박스의 위 아래로 있는 위스커(whisker)는 각각 상위와 하위 10% 값을 나타낸다. 제한된 브랜치 앤 민컷의 경우 [11]과 같이 각 축을 반으로 줄인 해상도에서 수행되었으며 이후 원해상도로 확장한 결과를 최종 결과로 하였다.

50개의 테스트 데이터에 대해 평균대칭표면거리의 경우 제안하는 기법은 평균 0.699/0.531(대퇴골/경골), 중간값 0.665/0.52을 얻은 반면, 제한된 브랜치 앤 민컷은 평균 1.14/0.674, 중간값 1.15/0.605를 얻었다. 제곱루트평균표면거리의 경우에는 제안하는 기법은 평균 1.09/0.87, 중간값 1.01/0.82를 얻은 반면, 제한된 브랜치 앤 민컷은 평균 2.30/1.215, 중간값 2.11/1.01을 얻었다.

그림 1은 반복적으로 정합과 영역화가 수행되면서 점차 뼈 영역화 결과가 나아짐을 정성적으로 보여주고 있다. 원본 영상에서 보듯이 대퇴골의 위 부분은 경계가 매우 모호하다. 하위단계에서의 초기 영역화 결과들은 초기 검출된 템플릿이 좋지 않기 때문에 외곽으로 벗어나는 결과가 나타났지만,

반복적 정합과정을 통해 템플릿이 점차 정확히 정합됨으로써 영역화 결과가 향상되고 있는 것을 확인할 수 있었다.

제안하는 기법의 수행시간의 경우, 대퇴골에 대하여 하위, 중간, 상위단계에서 각각 4~6분, 20~30초, 20~30초 정도가 소요되어 총 6~7분 정도가 소요되었다. 반면 제한된 브랜치 앤 민컷의 경우에는 트리검색의 수렴속도에 따라 3~7분 정도가 소요되었다. 두 기법의 수행시간의 차이가 적어보이지만 기존의 제한된 브랜치 앤 민컷에서는 단 하나의 평균 형상의 제한된 위치변형 템플릿만으로 트리를 구성했다. 공정한 비교를 위해 중간단계에서 제안하는 기법과 같은 트리구성(81000개의 템플릿)으로 제한된 브랜치 앤 민컷을 수행해 본 결과 1시간 이상의 시간이 소요됨을 확인할 수 있었다.

#### IV. 결론

본 논문에서는 반복적인 영역화와 정합을 다중해상도 상에서 수행함으로써 3차원 MR 영상으로부터 뼈를 자동으로 영역화 해내는 기법을 소개하였다. 복잡도가 높은 제한된 브

랜치 앤 민컷 기법을 하위단계에서만 사용함으로써 수행속도를 향상시켰고, 이후 점차 정합이 잘 된 템플릿들을 찾음으로써 정확성을 향상시켰다. 몇몇 데이터의 경우 밝기차가 모호한 지역에서 에러가 발생되기도 했지만 평균 0.699/0.531값의 평균대칭표면거리를, 1.09/0.87값의 제곱루트평균표면거리를 얻을 수 있었다. 추후 현재보다 정확한 정합 기법을 이용하거나  $\sigma$ 를 잘 구해줄 수 있는 방법을 개발한다면 영역화 성능을 더욱 향상시킬 수 있을 것으로 예상된다. 마지막으로 본 논문에서 구한 뼈 영역화 결과는 골다공증을 판단하기 위해 필요한 연골 영역화에 도움을 줄 수 있을 것으로 예상되고, 학습을 통해 뼈의 질환이나 이상부위를 자동으로 판단해주는 것도 가능해 질것으로 보인다.

### 참 고 문 헌

[1] V.Lempitsky et al., "Image segmentation by branch-and-mincut", in ECCV, 2008, pp. IV15-29

[2] Y. Boykov and G. Funka-Lea, "Graph cuts and efficient n-d image segmentation," IJCV, vol. 70(2), pp. 109-131, Feb. 2006.

[3] P. J. Besl. et al., "A method for registration of 3-D shapes," IEEE Trans. PAMI, vol. 14, pp. 239-256, Feb. 1992.

[4] <http://www.ski10.org/>

[5] J. Fripp, S. Crozier, S. K. Warfield, and S. Ourselin, "Automatic segmentation of the bone and extraction of the bone-cartilage interface from magnetic resonance images of the knee," Physics in Medicine and Biology 52, pp. 1617 - 1631, 2007.

[6] J. Schmid and N. Magnenat-Thalmann, "Mri bone segmentation using deformable models and shape priors," in International Conference on Medical Image Computing and Computer Assisted Intervention, pp. 119 - 126, 2008.

[7] P. Bourgeat, J. Fripp, P. Stanwell, S. Ramadan, and S. Ourselin, "Mr image segmentation of the knee bone using phase information," Medical Image Analysis 11, pp. 325 - 335, 2007.

[8] H. Shim, C. Kwok, I. Yun, S. Lee, and K. Bae, "Simultaneous 3-d segmentation of three bone compartments on high resolution knee mr images from osteoarthritis initiative (oai) using graph-cuts," in Medical Imaging: Physics of Medical Imaging, Proceedings of the SPIE, 2009.

[9] L. Liu, D. Raber, D. Nopachai, P. Commean, P. Sinacore, F. Prior, R. Pless, and T. Ju, "Interactive separation of segmented bones in ct volumes using graph cut," in International Conference on Medical Image Computing and Computer Assisted Intervention, LNCS 5241, pp. 296 - 304, 2008.

[10] S. Y. Ababneh, J. W. Prescott, and M. N. Gurcan, "Automatic graph-cut based segmentation of bones from knee magnetic resonance images for osteoarthritis research," Medical Image Analysis 15, pp. 438 - 448, 2011.

[11] S. Lee, S. Park, H. Shim, I. Yun, and S. Lee, "3-d segmentation of knee bones on mr images by constrained branch-and-mincut," in Probabilistic Models for Medical Image Analysis, Workshop of International Conference on Medical Image Computing and Computer Assisted Intervention, 2009.

### 저 자 소 개



#### 박 상 현

- 2008년 2월 : 연세대학교 전기전자공학부 학사
- 2008년 3월 ~ 현재 : 서울대학교 전기 컴퓨터공학과 석박통합과정
- 주관심분야 : 컴퓨터비전, 의료영상처리, 영역화



#### 이 수 찬

- 2004년 2월 : 서울대학교 전기 컴퓨터공학부 학사
- 2011년 2월 : 서울대학교 전기 컴퓨터공학부 박사
- 2011년 3월 ~ 현재 : 삼성전자
- 주관심분야 : 영상처리, 컴퓨터비전

---

저 자 소 개

---



**윤 일 동**

- 1989년 2월 : 서울대학교 제어계측공학과 공학사
- 1991년 2월 : 서울대학교 제어계측공학과 공학석사
- 1996년 8월 : 서울대학교 제어계측공학과 공학박사
- 1997년 3월 ~ 현재 : 한국외국어대학교 디지털정보공학과 교수
- 주관심분야 : 영상처리, 컴퓨터비전



**이 상 욱**

- 1973년 : 서울대학교 전기공학부 학사
- 1976년 : 미국 Iowa 주립대 전기공학과 석사
- 1980년 : 미국 Univ. of Southern California, 전기공학과 박사
- 1981년 : General Electric Co. 연구원
- 1983년 : M/A-COM Research Center 선임연구원
- 1983년 ~ 현재 : 서울대학교 전기공학부 정교수
- 주관심분야 : 영상처리, 컴퓨터비전