

논문 2006-43SP-6-4

능동모양모델 알고리즘을 위한 삼차원 모델생성 기법

(Three-dimensional Model Generation for Active Shape Model Algorithm)

임성재*, 정용연**, 호요성***

(Seong-Jae Lim, Yong-Yeon Jeong, and Yo-Sung Ho)

요약

통계적 데이터를 이용하여 모양 변이가 가능한 능동모양모델(Active Shape Model, ASM)은 이차원 영상의 분할 및 인식에 성공적으로 사용되고 있다. 삼차원 모델 기반 기법은 객체 경계의 인식 및 묘사(delineating)를 위한 더욱 현실적인 모양 억제력(constraint)을 갖는다는 점에서 이차원 모델 기반 기법에 비해 좋은 결과를 가져온다. 그러나 삼차원 모델 기반 기법을 위해서는 분할된 객체들의 집합인 훈련(training) 데이터로부터 삼차원 모양모델을 생성하는 것이 가장 중요하고 필수적인 단계이며, 현재까지도 커다란 도전 과제로 남아있다. 삼차원 모양모델 생성에서 가장 중요한 단계는 포인트 분산모델(PDM)을 생성하는 것이다. PDM 생성을 위해서는 상응하는 특징점(landmark)을 모든 훈련 데이터의 대응하는 위치에서 선택해야 한다. 그러나 현재까지 많이 사용되는 특징점의 수동 선택 기법은 시간이 많이 소비되며, 많은 오류를 발생한다. 본 논문에서는 삼차원 통계적 모양모델의 생성을 위한 새로운 자동 기법을 제안한다. 주어진 삼차원 훈련 모양 데이터에서, 삼차원 모델은 다음 방법에 의해 생성된다. 1) 훈련 모양 데이터의 거리 변환(distance transform)으로부터 평균(mean) 모양 생성, 2) 평균 모양에서 자동적으로 특징점을 선택하기 위한 사면체(tetrahedron) 기법 사용, 3) 거리 표식(distance labeling) 기법을 통한 각 훈련 모양에서 특징점의 전파(propagating). 본 논문에서는 50명의 복부 CT 영상으로부터 간(liver)을 위한 삼차원 모델을 생성하고, 평가를 위해 정확성과 밀집도(compactness)를 조사한다. 기존의 삼차원 모델 생성 기법들은 객체의 모양과 기하학적 및 위상학적으로 심각한 제한을 갖지만, 본 논문에서 제안한 기법은 위와 같은 제한 없이 어느 데이터 집합에도 적용할 수 있다.

Abstract

Statistical models of shape variability based on active shape models (ASMs) have been successfully utilized to perform segmentation and recognition tasks in two-dimensional (2D) images. Three-dimensional (3D) model-based approaches are more promising than 2D approaches since they can bring in more realistic shape constraints for recognizing and delineating the object boundary. For 3D model-based approaches, however, building the 3D shape model from a training set of segmented instances of an object is a major challenge and currently it remains an open problem. In building the 3D shape model, one essential step is to generate a point distribution model (PDM). Corresponding landmarks must be selected in all training shapes for generating PDM, and manual determination of landmark correspondences is very time-consuming, tedious, and error-prone. In this paper, we propose a novel automatic method for generating 3D statistical shape models. Given a set of training 3D shapes, we generate a 3D model by 1) building the mean shape from the distance transform of the training shapes, 2) utilizing a tetrahedron method for automatically selecting landmarks on the mean shape, and 3) subsequently propagating these landmarks to each training shape via a distance labeling method. In this paper, we investigate the accuracy and compactness of the 3D model for the human liver built from 50 segmented individual CT data sets. The proposed method is very general without such assumptions and can be applied to other data sets.

Keywords : Active shape model, 3-D 모델 생성, 영상 분할, CT

* 정회원, 한국전자통신연구원 (ETRI)

** 정회원, 전남대학교 의과대학 (CNU, Medical School)

*** 평생회원, 광주과학기술원 정보통신공학과 (GIST)

※ 이 논문은 2006년 정부(교육인적자원부)의 재원으로 한국학술진흥재단(KRF-2006-521-D00624) 지원과 광주과학기술원(GIST) 실감방송연구센터(RBRC)를 통한 정보통신부 대학 IT연구센터(ITRC)의 지원을 받아 수행된 연구임.

접수일자: 2006년2월14일, 수정완료일: 2006년10월12일

I. 서 론

의료영상은 일반적으로 모양 변이(shape variability)가 큰 복잡한 객체들을 포함하고 있다. 이러한 영상에서 특정한 객체의 존재를 측정하거나 추출하는 시도는 매우 힘든 작업이다. 객체들의 고유 변이성은 일반적인 분할 및 검출 기법들을 이용하여 인식 및 분할 작업을 수행하는데 커다란 장애물이다. 그러나 모양 변이를 쉽게 다룰 수 있는 모델 기반 기법들을 사용함으로써 복잡한 의료영상을 성공적으로 분석할 수 있다.

모델 기반 영상 분할은 객체 모양과 명암 패턴 정보를 통해 영상을 분할하는 기법으로 객체의 어느 한 부분의 경계 정보가 불확실하거나 상실된 경우에도 모델의 연결성 특징을 이용하여 이러한 문제점을 극복할 수 있다. 능동모양모델(Active Shape Model, ASM)^[1]과 같은 통계적 모델 기반 기법은 훈련(training) 데이터로부터 얻은 모양 및 명암 패턴 정보와 같은 사전 지식을 이용하여 유동적이며 제한된 모델로 관심 객체를 찾고, 모양과 외관(appearance)에 대해 변이를 갖는 능동모양 모델과의 비교를 통해 관심 객체를 분할한다. 능동모양 모델은 객체를 레이블된 점들, 즉 특징점(landmark)의 집합으로 표현하고 다수의 훈련 데이터로부터 객체 좌표의 통계치를 얻는다. 모양 클래스의 특정 패턴은 평균 모양 벡터와 평균 모양 변이 고유벡터의 선형 조합으로 묘사된다. 영상 탐색 동안 특징점은 객체 경계를 찾아 가깝게 이동하고 모델은 새로운 특징점 위치에 맞게 경신된다. 이때 모양 계수들은 현재의 모양이 훈련 데이터의 평균 모양과의 유사성을 유지하도록 제한된다. 능동모양모델을 위한 통계적 모양모델 생성의 첫 번째 필수 단계는 포인트 분산 모델(point distribution model, PDM)을 생성하는 것이다. 포인트 분산 모델 생성을 위해 모든 훈련 데이터에서 상응하는 특징점이 대응하는 위치에서 선택되어야 하지만, 특징점의 수동 결정은 많은 시간과 노력이 소요되며, 많은 에러를 유발시킬 수 있다. 특히, 3차원 데이터의 경우에는 모양을 묘사하고 분석하기 위해 필요한 특징점의 수가 현저하게 증가하기 때문에 특징점의 수동 결정은 거의 불가능하다^[2]. 이차원 모델에서 특징점을 결정하기 위한 여러 가지 기법^[3-5]들이 소개되었다. Davies^[3]는 최소 묘사 길이(minimum description length) 기법에 기반한 정보이론적 목적(objective) 함수를 최적화하는 방법으로 상응하는 특징점을 찾았다. Frangi^[4]는 훈련 데이터로부터 계산된 평균 이진화 볼륨에서 밀집한 삼각형 분할의 평

균을 취함으로써 특징점을 선택하였다. Hill^[5]의 방법은 모양모델의 전체 변이를 최소화시킴으로써 특징점을 선택하는 직접적인 기법을 사용하였다. 그러나 위와 같은 기법들은 이차원 기반 알고리즘이거나 그의 확장 또는 등거리 기법이어서 객체의 모양, 기하학 및 위상학적으로 많은 제한점이 있다.

본 논문에서는 ASM을 위한 새로운 삼차원 통계적 모양모델 생성 기법을 제안한다. 주어진 삼차원 훈련 데이터에서, 1) 거리 변환 기법(distance transform)을 통한 평균(mean) 모양 생성, 2) 사면체(tetrahedron) 기법을 이용한 특징점 자동 결정, 3) 거리 표식(distance labeling) 기법을 통한 각 훈련 데이터로의 특징점 전파(propagation) 과정의 세 단계를 이용하여 삼차원 모델을 생성한다.

본 논문은 II장에서 제안하는 알고리즘을 설명하고, III장에서 제안한 알고리즘의 성능을 평가하기 위한 실험결과를 보인다. 그리고 IV장에서 결론을 맺는다.

II. 제안한 알고리즘

Bookstein^[6]은 의학 및 생물학 영상에서 모양 변환을 쉽게 확인하고, 모양 및 변환을 표현 할 수 있는 중요한 포인트를 가리키는 용어로 “특징점”을 사용했다. 이는 각 훈련 데이터의 모양을 정확하게 표현할 특징점의 수가 신뢰성 있는 모양모델 생성에 큰 영향을 미치므로 적당한 수의 특징점을 결정하는 것은 매우 중요하다. 그러므로 이 논문에서는 pseudo-landmark, 즉 객체의 표면 위에 존재하며 객체의 외형을 결정짓는 특징점을 고려한다.

제안하는 삼차원 모델 생성 기법은 1) 평균 모양 생성, 2) 특징점 자동 결정, 3) 특징점 전파의 세 가지 과정으로 구성된다.

1. 평균 모양 생성

평균 모양을 생성하기 위해, 모든 훈련 데이터 집합은 삼차원 공간 변환(affine transform)을 통해 정렬되고 스케일링(scaling)된다.

(1) 데이터 정렬

먼저, 그림 1에서와 같이 principal component analysis (PCA)를 사용하여 세 개의 주요 관성(inertia) 좌표축 위의 6개의 초기 주요 포인트를 얻는다.

그 다음 각 훈련 데이터에서 6개의 초기 주요 포인트




그림 1. 데이터 정렬을 위한 주요 좌표축
Fig. 1. Principle axes for data alignment.

사이의 거리를 비교하여 scaling하고, 각 훈련 데이터의 중심 좌표를 평균 위치로 이동시킨다. 마지막으로 훈련 데이터 중에서 하나의 임의 데이터를 초기 평균 모양으로 설정하여 다른 모든 데이터를 singular value decomposition (SVD)을 이용하여 회전 정렬시키고, 새롭게 계산된 평균 모양에 다시 모든 데이터를 정렬시킨다. 이 과정을 일정한 임계값에 수렴할 때까지 반복적으로 수행함으로써 모든 훈련 데이터를 정렬시킨다.

(2) 평균 모양

삼차원 공간 변환을 사용하여 각 훈련 데이터를 정렬한 후에, 모든 훈련 데이터는 하나의 공통 좌표축 위에 있게 되며, 정렬된 각 데이터에 거리 변환을 수행한다. 거리 변환을 수행한 후의 각 데이터의 경계 안쪽은 음의 값을, 바깥쪽은 양의 값을 갖게 된다. 그 다음 식 1을 사용하여 모든 거리 변환된 데이터의 평균 모양 얻는다.

$$DT(b_m) = \frac{1}{n} \sum_{i=1}^n DT(b'_i) \tag{1}$$

위 식에서 b'_i 는 정렬된 모양을 가리킨다.

평균 거리 영상에서 최소 '0'의 거리 값을 나타내는 픽셀들의 집합으로 구성된 이진 영상을 얻기 위해 평균 영상을 '0'으로 이치화 한다. 그림 2는 20개의 복부 CT 데이터에서 얻은 20개의 간 이진 영상의 평균 거리 영상을 나타낸다. 모든 훈련 모양 데이터 위의 상응하는 특징점들은 위 평균 모양에 의해 제한된다.

2. 특징점 결정

전문가에 의해 윤곽선을 따라 균등하게 결정하는 수동




그림 2. 간의 삼차원 평균 거리 맵
Fig. 2. Average distance map of liver.

특징점 결정은 매우 시간 낭비이며 주관적이다. 게다가, 3차원 모델의 경우에 수동 특징점 결정은 거의 불가능하다. 최근 자동으로 특징점을 결정하는 알고리즘들이 제안되었지만, 주로 2차원 기반 최적화 문제로 접근하는 방법들이거나 같은 수의 특징점을 같은 거리로 결정하는 등거리 기법이다. 이들 기법들은 객체의 모양이나 위상학적, 기하학적 제한 요소를 갖는다.

Souza와 Udupa^[7]는 이차원 모델에서 Douglas-peucker의 선 단순화 알고리즘(line simplification algorithm)^[8]에 기반한 다각형화(polygonization) 기법을 사용하여 특징점을 결정하였다. 본 논문에서는 삼차원 모양을 단순 모양 (simple shape)과 요면(concave)을 갖는 복잡 모양 (complicated shape)으로 분류하여 특징점을 결정한다. 특징점은 평균 모양의 표면에서 다음과 같은 방법으로 자동적으로 결정된다. 제안하는 알고리즘은 평면을 이용한 표면의 하위 분할과 그 평면으로부터 특정 허용 한계 값 δ 를 만족하는 가장 먼 포인트를 검출하는 과정을 반복적으로 수행한다. 이때 검출된 포인트가 특징점으로 인식된다. 본 논문에서 제안하는 알고리즘은 객체의 표면 곡률에 기반하여 특징점을 자동적으로 결정한다. 즉, 표면의 곡률이 낮으면 적은 수의 특징점이 선택되고, 곡률이 높으면 더 많은 수의 특징점이 선택된다.

(1) 단순 모양에서의 특징점 결정

PCA를 통해 주요 관성 축 위의 포인트 v_1, v_2 를 표면위에서 찾고 직선 v_1v_2 에서 가장 먼 포인트 v_3 를 표면위에서 찾아 평면 $v_1v_2v_3$ 를 구성한다. 이 평면은 그림 3과 같이 삼차원 객체를 상, 하부로 분할하고, 그림 4는 객체의 상부를 나타낸다.




그림 3. 단순 모양의 객체 분할
Fig. 3. Object splitting of simple shape.




그림 5. 복잡 모양의 객체 분할
Fig. 5. Object splitting of complicated shape.




그림 4. 단순 모양을 위한 4면체 기법
Fig. 4. Tetrahedron method for simple shape.

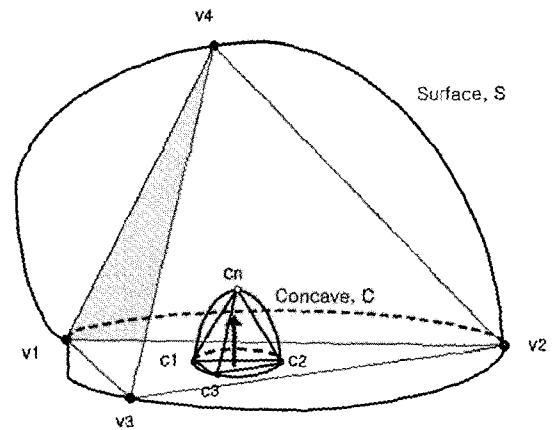


그림 6. 복잡 모양을 위한 4면체 기법
Fig. 6. Tetrahedron method for complicated shape.

그림 4에서 평면 $v1v2v3$ 로부터 허용 한계 값 D 를 만족하는 가장 먼 포인트 $v4$ 를 표면 위에서 찾고 $v1, v2, v3$ 와 $v4$ 를 포함하는 사면체를 구성한다. 이 사면체는 평면 $v1v2v4, v1v3v4, v2v3v4$ 를 포함하고, 각 평면으로부터 수직 방향으로 허용 한계를 만족하며 가장 먼 포인트를 표면에서 반복적으로 검출하게 된다. 이 기법은 표면 위에서 가장 먼 포인트를 검출함으로써 표면의 내부를 사면체로 분할하고, 이 과정은 허용 한계값 δ 를 만족하는 포인트가 더 이상 존재하지 않을 때 까지 반복 된다. 이렇게 검출된 포인트가 삼차원 객체의 주요 곡면 특징들에 상응하는 특징점이 된다. 특징점을 결정하기 위해 반복적으로 사면체를 생성 및 적용하기 때문에 우리는 이를 사면체 기법이라 정의한다.

(2) 복잡 모양에서의 특징점 결정

그림 5와 같이 객체의 모양이 요면을 포함한 복잡한 모양인 경우에는 사면체 기법을 다음과 같이 적용한다. 사면체의 각 평면 $v1v2v4, v1v3v4, v2v3v4$ 에서 특징점을 찾은 후에, 요면과 같은 표면이 사면체 내부에 존재하는 경우가 있다. 이런 경우 요면 표면의 연결성 정보를 이용하여 사면체 내부에 새로운 사면체를 생성하여

단순 모양에서와 같은 방법으로 특징점을 찾는다. 그림 6은 복잡한 모양에서의 사면체 기법을 나타낸다.

위 기법을 통해 객체의 모양에 제한받지 않고 객체의 곡면 특징들에 상응하는 특징점을 찾을 수 있으며, 사면체 기법을 통해 결정된 특징점을 이용하여 삼차원 객체를 표현할 수 있다.

3. 특징점 전파

모든 훈련 데이터에서 유사한 위치에서 대응하는 특징점이 결정되어야 하므로, 각 훈련 데이터에 사면체 기법을 통해 찾은 특징점을 전파한다. Souza와 Udupa^[7]는 이차원 모양에서 특징점 전파를 위해 'ray cast' 방법을 사용하였다. 그림 7에서와 같이 각 특징점 p_j 로부터 평균 모양 \bar{x} (가는 윤곽선)의 경계에 수직방향으로 'ray'가 투사된다. 이렇게 투사된 'ray'가 주어진 영상 (굵은 윤곽선)의 경계와 처음으로 만나는 점이 바로 특징점 p_j 에 대응하는 주어진 영상에서의 특징점 p_a 이 된다.

그러나 'ray cast' 기법은 삼차원 영상에서 적용할 때 몇 가지 문제점을 갖는다. 첫 번째로 주어진 훈련 모양이 평균 모양과 비교적 큰 편차를 갖는 경우에는 그림




그림 7. 특징점 전파
Fig. 7. Illustration of landmark propagation.




그림 8. (a) 편차 문제와 (b) 디지털 공간 문제
Fig. 8. Deviation and Digital space problem.




그림 9. 거리 레이블링 기법
Fig. 9. Distance labeling method.

8(a)와같이 어떤 특징점에서는 교차점을 찾을 수 없다. 두 번째는 알고리즘이 디지털 공간에서 수행되므로 그림 8(b)와같이 객체의 표면을 이루는 두 복셀 사이를 'ray'가 통과하는 경우가 발생한다. 이런 경우에도 훈련 데이터에서 대응하는 특징점을 찾을 수 없다.

본 논문에서는 모든 삼차원 훈련 데이터에서 효율적으로 대응하는 특징점을 찾기 위해 거리 레이블링 기법을 제안한다. 이는 평균 모양의 표면위의 각 특징점에 가장 가까운 포인트를 각 훈련 데이터에서 찾는 방식이다. 평균 모양위의 특징점으로부터 거리 값은 점차적으로 증가하며, 각 특징점에 대한 레이블을 설정하여 훈련 데이터에서 처음 교차하는 포인트를 평균 모양위의 특징점에 대응하는 특징점으로 설정한다. 그림 9는 삼

차원 모양에서 거리 레이블링 기법을 사용한 특징점 전파를 나타낸다.

4. 삼차원 통계적 모델 생성

모든 훈련 데이터에서 각 특징점에 대한 정보로부터 통계적 모양모델을 생성하기 위해 ASM 기법을 사용한다. 정렬된 모양 벡터에 PCA를 적용하여 평균 모양 \bar{x} , 공분산 행렬 S 와 S 의 고유벡터와 고유 값을 얻는다. S 의 고유벡터 Φ 는 데이터의 모양 편차의 모드를 규정하고, 가장 큰 고유 값 λ 에 대응하는 고유 벡터는 가장 큰 변이를 나타낸다. PCA를 통해 다음과 같은 식을 얻을 수 있다.

$$x = \bar{x} + \Phi b \tag{2}$$

여기서, Φ 는 공분산 행렬의 고유벡터 행렬이고 b 는 모델 계수의 벡터를 나타낸다. b 값을 조정하여 평균 모양으로부터 변이된 모양 x 를 식 (2)로부터 얻을 수 있다.

III. 실험 결과

실험을 위해 조영제가 투입된 정맥기의 50개 복부 CT 스캔 데이터가 사용되었다. 각 CT 데이터는 약 3.8mm의 절편(slice) 간격과 약 1.00mm x 1.00mm의 픽셀 크기를 가지고 있는 최대 71개의 절편으로 구성된다. 모든 훈련 데이터는 live-wire^[7] 기법을 통해 절편 기반으로 간 영역이 분할된 것이다.

(1) Qualitative 평가

그림 10과 그림 11은 단순 모양으로 구(sphere)를 이용한 실험 결과를 나타낸다. 구의 반지름은 50mm이며, 그림 10의 허용 한계 값은 15mm이고, 그림 11은 5mm이다. 구의 경우는 요면 없이 모든 표면이 일정하므로 균등 거리에서 특징점이 선택된다.

그림 12은 간에서의 특징점 검출 결과를 나타낸다. 이때 특징점의 수는 120개이고, 표면 크기는 12757 복셀이다.

그림 13는 평균 모양을 Delaunay Triangulation 기법과 Convex Hull 알고리즘을 사용하여 재구성한 결과를 나타낸다. 그림 14는 가장 큰 고유 값에 대응하는 첫 번째 모드의 두 주요 편차 $-3\sqrt{\lambda_1}$ 과 $3\sqrt{\lambda_1}$ 를 표면 재구성한 것을 나타낸다. 그림 14(a)는 Delaunay




그림 10. 구의 특징점 검출 결과 ($\delta=15$)
 Fig. 10. Landmark of the sphere ($\delta=15$).




그림 11. 구의 특징점 검출 결과 ($\delta=5$)
 Fig. 11. Landmark of the sphere ($\delta=5$).

Triangulation 기법의 재구성 결과를 나타내고, 그림 14(b)는 Convex Hull 알고리즘의 재구성 결과를 나타낸다.

그림 15(a)는 가장 큰 고유 값에 대응하는 두 번째 모드의 두 주요 편차 $-3\sqrt{\lambda_2}$ 과 $3\sqrt{\lambda_2}$ 를 표면 재구성한 것이고, 그림 15(b)는 가장 큰 고유 값에 대응하는 세 번째 모드의 두 주요 편차 $-3\sqrt{\lambda_3}$ 과 $3\sqrt{\lambda_3}$ 을 표면 재구




그림 12. 간의 특징점 검출 결과
 Fig. 12. Landmark of the liver.






그림 13. 평균 모양 재구성
 Fig. 13. Representation of the mean shape.



(a) Delaunay triangulation 기법



(b) Convex Hull 알고리즘

그림 14. $-3\sqrt{\lambda_1}$ 과 $3\sqrt{\lambda_1}$ 의 표면 재구성
 Fig. 14. Landmark converted to surface representation.
 ($-3\sqrt{\lambda_1}$ and $3\sqrt{\lambda_1}$)




그림 15. 두 번째와 세 번째 모드의 표면 재구성
 Fig. 15. Surface representation of the second and third mode.




그림 16. 공분산 행렬의 고유 값 크기
 Fig. 16. The magnitude of the eigenvalues of cov. matrix.

성한 결과를 나타낸다. 그림 16은 Delaunay Triangulation 기법을 사용하여 재구성했다.

(2) Quantitative 평가

모델의 밀집도(compactness)는 얼마나 적은 모드를 사용하여 모양의 변이를 묘사할 수 있는지를 평가하는 척도이다. 그림 16과 그림 17은 제안하는 알고리즘에 의해 생성된 모델에서 각 모드의 변이의 밀집도를 나타낸다. 그림 16은 고유 값의 크기를 나타낸다.




그림 17. 고유 벡터에 의한 variability
 Fig. 17. Portion of variability captured by the first 4 eigenvectors.

그림 17은 처음 4개의 고유 벡터에 의한 변이 정도를 나타낸다. 처음 3개의 고유 벡터를 통해 약 94%의 모양 편차를 표현할 수 있는 것을 알 수 있으며 그만큼 밀집도가 높다는 것을 의미한다.

(3) 처리 시간

제안하는 알고리즘은 1.7GHz Pentium 4 Mobile Processor, 768 RAM의 PC에서 실험 되었고, 특징점 전파 과정을 제외한 다른 모든 과정은 60초미만의 처리 시간이 소요되었다. 특징점 전파는 각 특징점 및 각 훈련 데이터별로 거리 레이블링 과정에 의해 데이터 당 약 5분미만의 처리 시간이 소요되었다.

IV. 결 론

본 논문에서는 능동모양모델(Active Shape Model, ASM) 알고리즘을 위한 자동 삼차원 모델 생성 알고리즘을 제안하였다. 특징점의 자동 검출을 위한 사면체(tetrahedron) 기법은 모양, 기하학적 및 위상학적 제한을 극복하는 새로운 방법이다. 본 논문에서 제안한 삼차원 모델 생성을 위한 세 가지 주요 과정은 기존의 알고리즘과는 다른 새로운 기법이다. 즉, 특징점 검출을 더욱 신뢰성 있게 하는 거리 변환(distance transform) 기법을 통한 평균(mean) 모양 생성, 평균 모양에서 자동적으로 특징점을 검출하는 새로운 사면체 기법과 모든 훈련(training) 데이터에 대응하는 특징점 전파(propagation)하는 거리 표식(distance labeling) 기법은 본 논문에서 제안하는 알고리즘의 핵심이다. 제안

한 알고리즘은 삼차원 모델 생성을 위해 어느 응용분야에서도 사용할 수 있을 것이며, 위의 여러 가지 실험을 통해 밀집도(compactness) 및 효율적인 면들을 확인할 수 있다.

참 고 문 헌

[1] T.F. Cootes, C.J. Taylor, D.H. Cooper and J. Graham, "Active Shape Models - Their training and application", Comput. Vis. Image Understanding, vol. 61, no. 1, pp. 38-59, 1995.

[2] A.F. Frangi, D. Rueckert, J.A. Schnabel, and W.J. Niessen, "Automatic Construction of Multiple-Object Three-Dimensional Statistical Shape Models: Application to Cardiac Modeling," IEEE Trans. Med. Imag., vol. 21, pp. 1151-1166, Sep. 2002.

[3] R.H. Davies, C.J. Twining, P.D. Daniel, T.F. Cootes, and C.J. Taylor, Building optimal 2D statistical shape models, Image and Vision Computing, 21, pp. 1171-1182, 2003.

[4] A.F. Frangi, D. Rueckert, J.A. Schnabel, and W.J. Niessen, Automatic 3D ASM construction via atlas-based landmarking and volumetric elastic registration, IPMI 2001 Conference Proc., 2082, pp. 78-91, 2001.

[5] A. Hill and C.J. Taylor, Automatic landmark generation for point distribution models, British Machine Vision Conference, pp. 429-438, 1994.

[6] F.L. Bookstein, Morphometric Tools for Landmark Data, Cambridge Univ. Press, London/New York, 1991.

[7] A. Souza, and J.K. Udupa, "Automatic Landmark Selection for Active Shape Models," SPIE Proc. 5747, pp. 1377-1383, 2005.

[8] D.H. Douglas, and T.K. Peucker, Algorithms for the reduction of the number of points required to represent a digitized line or its caricature, Canadian Cartographer, 10(2), pp.112-122, 1973.

[9] A.X. Falcao, J.K. Udupa, S. Samarasekera, and S. Sharma, "User-Steered Image Segmentation Paradigms: Live Wire and Live Lane," Graphical Models and Image Processing, vol. 60, pp. 233-260, 1998.

저 자 소 개



임 성 재(정회원)

1999년 2월 전남대학교 컴퓨터 공학과 졸업(학사).
 2001년 8월 전남대학교 대학원 컴퓨터공학과 졸업(석사).
 2004년 10월~2005년 10월 미국 University of Pennsylvania, Medical School, Visiting Scholar.


2006년 8월 광주과학기술원 정보통신공학과 졸업(박사).
 2006년 7월~현재 한국전자통신연구원 연구원.
 <주관심분야: 컴퓨터 비전, 의료영상처리, 다시점 비디오 신호처리, 영상신호 처리 및 압축>



정 용 연(정회원)

1988년 2월 전남대학교 의과대학 졸업(학사).
 1991년 2월 전남대학교 대학원 의과대학 졸업(석사).
 1997년 2월 전남대학교 대학원 의과대학 졸업(박사).

1996년 2월~1998년 1월 전남대학교 의과대학 진단방사선과 전임강사.
 1999년 1월~2000년 2월 미국 Thomas Jefferson University 연구원.
 1998년 2월~2005년 1월 전남대학교 의과대학 진단방사선과 조교수.
 2005년 2월~현재 전남대학교 의과대학 진단방사선과 부교수.
 <주관심분야: 복부CT 진단, 복부 MR 진단, 컴퓨터보조진단(CAD), 분자영상>



호 요 성(평생회원)

1981년 2월 서울대학교 전자공학과 졸업(학사).
 1983년 2월 서울대학교 대학원 전자공학과 졸업(석사).
 1983년 3월~1995년 9월 한국전자통신연구원 선임연구원.

1989년 12월 미국 University of California, Santa Barbara Department of Electrical and Computer Engineering(박사),
 1990년 1월~1993년 5월 미국 Philips 연구소 Senior Research Member.
 1995년 9월~현재 광주과학기술원 정보통신공학과 교수.
 <주관심분야: 디지털 신호처리, 영상신호 처리 및 압축, 초저속 영상통신, 디지털 TV와 고선명 TV, MPEG 표준, 다시점 비디오 부호화, 실감방송>