

논문 2007-44SC-5-7

# 의료영상 분할을 위한 3차원 능동 모양 모델

## ( Three-Dimensional Active Shape Models for Medical Image Segmentation )

임 성 재\*, 정 용 연\*\*, 호 요 성\*\*\*

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

### 요 약

본 논문은 관심 객체 분할을 위한 통계적 모양 모델에 기반한 3차원 능동 모양 모델링 기법을 제안한다. 3차원 모양 모델을 만들려면 포인트 분산 모델(PDM)의 생성이 필수적인데, 이를 위해서는 모든 학습(training) 데이터에 대응하는 특징점(landmark)을 잘 선택해야 한다. 현재까지도 3차원 데이터에서 대응하는 특징점을 선택하는 방법은 주로 수동적으로 선택하거나 2차원 기반 기법 또는 제한된 3차원 기법이 사용되고 있다. 본 논문에서는 최근에 제안된 “3차원 통계적 모양 모델의 자동 생성 기법”의 거리 변환(distance transform)과 사면체(tetrahedron) 알고리즘을 사용하여 3차원 통계적 모양 모델을 생성하고, 2차원 능동 모양 모델의 모양 모델 학습과 그레이레벨(gray-level) 모델 학습을 개선하여 확장하고, 스케일(scale)과 그레이레벨 모델을 결합한 3차원 능동 모양 모델 알고리즘으로 관심 객체를 분할한다. 본 논문에서는 제안한 방법을 영역 기반, 윤곽선 기반 기법 및 2차원 능동모양모델 기법과 그 성능을 비교하여 평가했다.

### Abstract

In this paper, we propose a three-dimensional (3D) active shape models for medical image segmentation. In order to build a 3D shape model, we need to generate a point distribution model (PDM) and select corresponding landmarks in all the training shapes. The manual determination method, two-dimensional (2D) method, and limited 3D method of landmark correspondences are time-consuming, tedious, and error-prone. In this paper, we generate a 3D statistical shape model using the 3D model generation method of a distance transform and a tetrahedron method for landmarking. After generating the 3D model, we extend the shape model training and gray-level model training of 2D active shape models(ASMs) and we use the integrated modeling process with scale and gray-level models for the appearance profile to represent the local structure. Experimental results are comparable to those of region-based, contour-based methods, and 2D ASMs.

**Keywords :** 능동모양모델, 3차원 모델 생성, 의료영상 분할

### I. 서 론

모델 기반 영상 분할은 객체의 모양과 명암 패턴 정보를 통해 영상을 분할하는 기법으로 관심 객체의 경계

정보가 불확실하거나 상실된 경우에도 모델의 연결성 특징을 이용하여 이러한 문제점을 극복할 수 있다. 능동모양 모델(Active Shape Model, ASM)<sup>[1]</sup>과 같은 통계적 모델 기반 기법은 학습(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

\* 정회원, 한국전자통신연구원 (ETRI),

\*\* 정회원, 전남대학교 의과대학-교신저자 (CNU, Medical School)

\*\*\* 정회원, 한국전자통신연구원 (ETRI),

으로 묘사된다. 영상을 탐색하는 동안 특징점은 객체 경계를 찾아 가깝게 이동하고 모델은 새로운 특징점 위치에 맞게 갱신된다. 이때 현재의 모양이 학습 데이터의 평균 모양과의 유사성을 유지하도록 모양 계수들로 제한한다. 2차원 기반 능동 모양 모델은 의료영상과 같은 볼륨(volume) 데이터에서 각 슬라이스 사이의 변이가 큰 객체의 분할에는 한계를 갖는다. 3차원 모델 기반 기법은 더 실제적인 모양 억제력으로 객체를 인식한다는 점에서 2차원 모델 기반 기법에 비해 더 효과적이다. 그러나 3차원 모델 기법은 객체의 분할된 학습 데이터로부터 3차원 모양 모델을 생성해야 한다는 점이 현재까지도 커다란 과제로 남아있다.

능동 모양 모델을 위한 통계적 모양 모델 생성의 첫 번째 필수 단계는 포인트 분산 모델(point distribution model, PDM)을 생성하는 것이다. 포인트 분산 모델 생성을 위해 모든 학습 데이터에서 대응하는 특징점을 잘 선택해야 하지만, 이러한 특징점을 수동으로 결정하는 것은 많은 시간과 노력이 소요되며, 많은 오류를 발생할 수 있다. 특히, 3차원 데이터의 경우에는 모양을 묘사하고 분석하기 위해 필요한 특징점의 수가 현저하게 증가하기 때문에 특징점의 수동 결정은 거의 불가능하다<sup>[2]</sup>. 2차원 모델에서 특징점을 결정하기 위한 여러 가지 기법<sup>[3-5]</sup>들이 소개되었다. Davies<sup>[3]</sup>는 최소 묘사 길이(minimum description length) 기법에 기반한 정보 이론적 목적(objective) 함수를 최적화하는 방법으로 대응하는 특징점을 찾았다. Frangi<sup>[4]</sup>는 학습 데이터로부터 계산된 평균 이진화 볼륨에서 밀집한 삼각형 분할의 평균을 취함으로써 특징점을 선택하였다. Hill<sup>[5]</sup>의 방법은 모양 모델의 전체 변이를 최소화시킴으로써 특징점을 선택하는 직접적인 기법을 사용하였다. 그러나 위와 같은 기법들은 2차원 기반 알고리즘이거나 그의 확장 또는 등거리 기법이어서 객체의 모양, 기하학 및 위상학적으로 많은 제한점이 있다.

3차원 의료영상 분할 및 분석을 위해 Stegmann<sup>[6]</sup>은 최대 직교(orthomax) 기준에 기반하여 주요 요소(principal components)를 회전하는 간단한 기법을 제안했고, Zheng<sup>[7]</sup>은 회전 분할(loop subdivision)을 사용하여 정렬된 학습 데이터로부터 조밀한 표면 포인트 분포 모델을 생성하는 기법을 제안했다.

모양 모델 생성 후, 2차원 능동모양 모델을 모양 모델 학습과 그레이레벨(gray-level) 모델 학습을 개선 및 확장하고 스케일(scale)과 그레이레벨 모델을 결합한 3차원 능동모양 모델 알고리즘으로 관심 객체를 분할하는 3차원 능동모양 모델 기법을 제안한다.

본 논문의 II장에서 3차원 통계적 모델 생성 알고리즘을 설명하고, III장에서 능동모양 모델 영상 분할 알고리즘을 제안한다. IV장에서는 제안한 알고리즘의 성능을 평가하기 위한 실험 결과를 보인다. 그리고 V장에서 본 논문의 결론을 맺는다.

## II. 3차원 통계적 모델 생성

본 논문에서는 의사-특징점(pseudo-landmark), 즉 객체의 표면 위에 존재하며 객체의 외형을 결정짓는 특징점을 사용하여 모델을 생성하는 알고리즘에 대해 설명한다<sup>[8]</sup>. 제안된 3차원 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 학습 데이터를 3차원 공간 변환(affine transform)을 통해 정렬하고 스케일링(scaling)한다.

각 학습 데이터를 정렬한 후, 하나의 공통 좌표축 위에 있는 모든 학습 데이터에 거리 변환을 수행한다. 거리 변환을 수행한 후의 각 데이터의 경계선 안쪽은 음의 값을, 바깥쪽은 양의 값을 갖게 된다. 그 다음 식 1을 사용하여 모든 거리 변환된 데이터의 평균 모양을 얻는다.

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

여기서  $b'_i$ 는 정렬된 모양,  $b_m$ 은 평균 모양을 나타낸다. 평균 거리 영상에서 최소 '0'의 값을 갖는 화소 집합인 이진 영상을 얻기 위해 평균 영상을 '0'으로 이치화한다. 그림 1은 20개의 복부 CT 데이터에서 얻은 20개의 간(liver) 객체의 평균 거리 영상을 나타낸다. 모든 학습 모양 데이터 위의 대응하는 특징점들은 위 평균




그림 1. 간의 3차원 평균 거리 맵  
Fig. 1. Average distance map of liver.




그림 2. 사면체 기법  
Fig. 2. Tetrahedron method.

과 같은 방법으로 자동 결정한다. 제안하는 알고리즘은 평면을 이용한 표면의 하위 분할과 그 평면으로부터 특정 허용 한계 값  $\delta$ 를 만족하는 가장 먼 거리에 위치한 포인트를 검출하는 과정을 반복적으로 수행한다. 이때 검출된 포인트를 특징점으로 인식한다. 본 논문의 알고리즘은 객체의 표면 곡률에 기반하여 특징점을 자동적으로 결정한다. 즉, 표면의 곡률이 낮으면 적은 수의 특징점이 선택되고, 곡률이 높으면 더 많은 수의 특징점이 선택된다.

주요 요소 분석(principal component analysis, PCA)을 통해 주요 관성 축 위의 점  $L_1, L_2$ 를 표면 위에서 찾고 직선  $L_1L_2$ 에서 가장 먼 포인트  $L_3$ 를 표면 위에서 찾아 평면  $L_1L_2L_3$ 를 구성한다. 이 평면은 그림 3과 같이 3차원 객체를 상부와 하부로 분할한다.

그림 2에서 평면  $L_1L_2L_3$ 로부터 허용 한계값  $D$ 를 만족하는 가장 먼 거리에 위치한 점  $L_4$ 를 표면 위에서 찾고  $L_1L_2L_3$ 과  $L_4$ 를 포함하는 사면체를 구성한다. 이 사면체는 평면  $L_1L_2L_4, L_1L_3L_4, L_2L_3L_4$ 를 포함하고, 각 평면으로부터 수직 방향으로 허용 한계를 만족하며, 가장 먼 거리에 위치한 점을 표면에서 반복적으로 검출하게 된다. 이 기법은 표면 위에서 가장 먼 점을 검출함으로써




그림 3. 사면체 기법의 2차원 표현  
Fig. 3. The illustration for a 2-D shape of the tetrahedron method.

결정하기 위해 반복적으로 사면체를 생성하고 적용하기 때문에 우리는 이를 사면체 기법이라 정의한다.

그림 3은 사면체 기법을 2차원으로 표현한 것이다. 그림 3과 같이 객체의 모양이 요면을 포함한 복잡한 모양인 경우에는 사면체의 각 평면  $L_1L_2L_4, L_1L_3L_4, L_2L_3L_4$ 에서 특징점을 찾은 후에, 요면 표면의 연결성 정보를 이용하여 사면체 내부에 새로운 사면체를 생성하여 단순 모양에서와 같은 방법으로 특징점을 찾는다.

위 기법을 통해 객체의 모양에 제한받지 않고 객체의 곡면 특징들에 상응하는 특징점을 찾을 수 있으며, 사면체 기법을 통해 결정된 특징점을 이용하여 3차원 객체를 표현할 수 있다.

### 3. 특징점 전파

모든 학습 데이터에서 대응하는 특징점을 결정해야 하므로, 사면체 기법을 통해 찾은 특징점을 각 학습 데이터에 전파한다. Souza와 Udupa<sup>[9]</sup>는 2차원 모양에서 특징점 전파를 위해 '광선 투사(ray cast)' 방법을 사용했다. 각 특징점으로부터 평균 모양의 경계선에 수직방향으로 '광선'이 투사된다. 이렇게 투사된 '광선'이 주어진 영상의 경계선과 처음으로 만나는 점이 바로 특징점에 대응하는 주어진 영상에서의 특징점이 된다.

그러나 '광선 투사' 기법은 3차원 영상에서 적용할 때 몇 가지 문제점을 갖는다. 첫 번째로 주어진 학습 모양이 평균 모양과 비교적 큰 편차를 갖는 경우에는 어떤 특징점에서는 교차점을 찾을 수 없다. 두 번째는 알고리즘이 디지털 공간에서 수행되므로 객체의 표면을 이루는 두 픽셀 사이를 '광선'이 통과하는 경우가 발생

(labeling) 기법을 사용한다. 평균 모양 위의 각 특징점을 표시한 후, 거리 값을 증가시키며 학습 데이터에서 처음 교차하는 점을 평균 모양 위의 특징점에 대응하는 특징점으로 설정한다.

#### 4. 3차원 통계적 모델 생성

모든 학습 데이터에서 각 특징점에 대한 정보로부터 통계적 모양 모델을 생성하기 위해 일반적인 능동 모양 모델 기법을 사용한다. 정렬된 모양 벡터에 주요 요소 분석을 적용하여 평균 모양  $\bar{x}$ , 공분산 행렬  $S$ 와  $S$ 의 고유 벡터와 고유 값을 얻는다.  $S$ 의 고유 벡터  $\phi_i$ 는 데이터의 모양 편차의 모드를 규정하고, 가장 큰 고유 값  $\lambda_i$ 에 대응하는 고유 벡터는 가장 큰 변이를 나타낸다. 주요 요소 분석을 통해 다음과 같은 식을 얻을 수 있다.

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

여기서,  $\Phi$ 는 공분산 행렬의 고유 벡터 행렬이고  $b$ 는 모델 계수의 벡터를 나타낸다.  $b$  값을 조정하여 평균 모양으로부터 변이된 모양  $x$ 를 얻을 수 있다.

### III. 능동모양 모델 영상 분할

3차원 능동 모양 모델의 학습 처리 과정은 2차원 능동모양 모델의 모양 모델 학습과 그레이레벨(gray-level) 모델 학습 과정의 개선 및 확장이 필요하다. 모양 모델 학습 과정을 위해 앞에서 생성한 3차원 통계적 모양 모델을 사용한다. 각 특징점을  $x, y, z$  좌표로 사상하여 그레이레벨 정보를 얻고, 표면에 대한 법선 벡터를 계산하여 각 특징점에 대한 프로파일 정보를 얻는다. 이는 2차원 능동 모양 모델과는 다르게 이웃하는 여덟 개의 점을 중심으로 삼각형화 기법을 이용하여 특징점의 표면에 대한 법선 벡터를 예측한다. 그레이레벨 모델은 객체 표면에 수직 방향인 프로파일을 따라 모든 학습 데이터에서 대응하는 위치의 그레이 정보를 샘플링한다. 프로파일 생성 후, 각 특징점의 그레이레벨 모델은 식 3과 같이 후보 프로파일  $g_s$ 와 평균 프로파일  $\bar{g}$ 의 마할라노비스(Mahalanobis) 거리 함수에 의해 구




그림 4. 2차원 CT 영상의 스케일 모델  
Fig. 4. Scale models of 2D CT images.




그림 5. 스케일 모델 위의 프로파일 명암 분포  
Fig. 5. Intensity along profile on a scale model.

지역적 구조를 표현하는 외관 모델을 생성하기 위해 스케일(scale)과 그레이레벨 모델을 결합한 모델링 과정을 제안한다. 스케일은 모든 화소에서 지역적 구조의 크기를 결정하기 위해 제안되었다<sup>[10]</sup>. 모든 픽셀에서 스케일은 화소를 중심으로 한 가장 큰 볼(ball)의 반지름으로 정의되고 볼의 내부에 있는 모든 화소는 미리 정의된 동질 명암 기준을 만족한다. 그레이레벨 외관과 유사하게 스케일 또한 지역적 구조를 표현하기 위한 형태 측정(morphometric) 외관 모델을 생성하기 위해 사용된다. 그러나 그레이레벨 모델과는 달리 스케일 모델은 더 조밀하며 경계선에 근접한 영역에 더 많은 정보를 갖고 경계선에서 먼 영역은 적은 정보를 갖는 특징이 있다. 이러한 특징을 갖는 스케일 모델은 영상 분할을 위한 가중치 함수로 사용될 수 있다.

식 4는 스케일 프로파일  $f_s$ 와 가중치 요소  $\alpha$ 로 구성된 모델링 처리 함수를 나타낸다. 그림 4는 2차원 영상의 스케일 모델을 나타내고, 그림 5는 스케일 모델에서 프로파일 명암 값을 보인다.

$$f_n(g_s) = \alpha \cdot f_n(g_s) + (1 - \alpha)f_s(g_s) \tag{4}$$

를 최적화하여 새로운 볼륨 데이터 위에 있는 특징점의 초기 위치를 갱신하고, 주요 요소 분석 공간에서 조절한 모양 계수들을 학습하여 생성한 모양 모델에 따라 특징점 집합을 조절한다. 마지막으로 분할 과정에서는 위 두 함수를 볼륨 내에서 모든 특징점이 객체의 표면 위에 위치할 때까지 반복 실행하여 정확한 경계점을 찾는다.


#### IV. 실험 결과 및 분석

실험을 위해 조영제가 투입된 정맥기의 30개 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 학습 데이터는 live-wire<sup>[11]</sup> 기법을 통해 절편 기반으로 간 영역이 분할된 것이다.

##### 1. 3차원 통계적 모델 평가

그림 6(a)는 반지름이 50mm이고 허용 한계 값이 5mm인 구(sphere)를 이용한 실험 결과를 나타낸다. 구의 경우는 요면 없이 모든 표면이 일정하므로 균등 거리에서 특징점이 선택된다.

그림 6(b)는 간에서의 특징점 검출 결과를 나타낸다.



(a) 구의 특징점 검출 결과




그림 7. 평균 모양 재구성

Fig. 7. Surface representation of landmarks via convex hull.

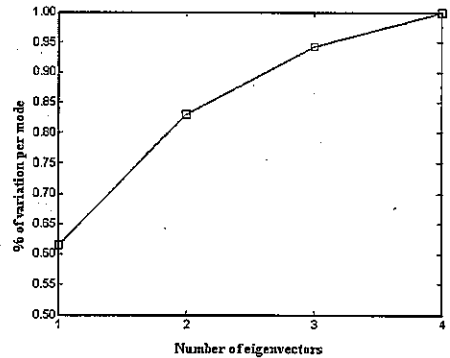


그림 8. 고유 벡터에 의한 변이성

Fig. 8. Portion of variability captured by the first 4 eigenvectors.

이때 특징점의 수는 170개이고, 표면 크기는 12757 픽셀이다. 170개의 특징점과 세 개의 주요 편차 모드를 사용하여 95%의 모양 변이를 나타낼 수 있다.

그림 7은 평균 모양(가운데)과 첫 번째 모드의 두 주요 편차  $-3\sqrt{\lambda_1}$  과  $3\sqrt{\lambda_1}$  를 컨벡스 헐(Convex Hull) 알고리즘을 사용하여 표면을 재구성한 것이다.

모델의 밀집도(compactness)는 얼마나 적은 모드를 사용하여 모양의 변이를 묘사할 수 있는지를 평가하는 척도이다. 그림 8은 제안하는 알고리즘에 의해 생성된 모델에서 각 모드 변이의 밀집도를 나타낸다. 그림 8은 처음 4개의 고유 벡터에 의한 변이 정도를 나타내며, 처음 3개의 고유 벡터를 통해 약 94%의 모양 편차를 표현할 수 있는 것을 알 수 있으며 그만큼 밀집도가 높다는 것을 의미한다.

##### 2. 3차원 능동모양 모델 알고리즘 평가

그림 9는 3Dviewpix<sup>[11]</sup>의 live-wire (LW) 기법을 사용하여 전문가가 수작업으로 분할한 간 객체를 나타낸다. 본 논문에서는 전문가의 수작업 객체 분할 결과를





그림 9. LW 기법을 사용하여 전문가의 수동 분할 객체  
Fig. 9. Liver segmented manually by using the LW method.

표 1. FPVF와 TPVF의 평균과 편차  
Table 1. Mean and standard deviation of FPVF and TPVF.

|      | Region     | Contour    | 2D ASM     | 제안한 기법     |
|------|------------|------------|------------|------------|
| FPVF | 0.82±0.05  | 0.79±0.07  | 0.94±0.03  | 0.91±0.05  |
| TPVF | 88.15±1.42 | 90.71±1.93 | 89.26±1.52 | 93.95±1.11 |



itive volume fraction, TPVF)의 척도로 정확성을 측정한다. FPVF는 관심 객체가 아닌 부분을 객체로 오인한 오류율이고, TPVF는 관심 객체의 분할율을 나타낸다. 표 1은 제안된 기법과 영역기반, 윤곽선 기반 기법 및 2차원 능동 모양 모델 기법과의 비교 결과를 나타내며 제안한 기법이 정확성과 효율성 측면에서 더 좋은 결과를 보인다.

## V. 결 론

본 논문에서는 3차원 능동모양 모델(Active Shape Model, ASM) 영상 분할 알고리즘을 제안하였다. 3차원 객체 분할을 위해 최근에 제안된 "3차원 통계적 모양 모델 생성 기법"을 사용하였다. 특징점의 자동 검출을 위한 사면체(tetrahedron) 기법은 모양, 기하학적 및 위상학적 제한을 극복하는 새로운 방법이며, 어떤 객체의 모델링에도 응용될 수 있다. 본 논문은 외관 프로파일 생성을 위해 스케일(scale) 모델과 그레이 레벨(gray-level) 모델을 결합한 모델링 처리 과정을 제안하였다. 스케일 모델의 조밀성과 경계에 근접한 영역에 더 많은 정보를 갖는 특성을 이용하여 기존의 능동 모양 모델에 비해 더 정확하며 효율적으로 관심 객체를 분할한다. 본 논문에서 제안한 방법은 영역 기반, 윤곽선 기반 기법 및 2차원 능동모양 모델 알고리즘과 비교하여 우수함을 보였다.

## 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. Imag. 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. 1151-1160, Sep. 2002.
- [3] R. H. Davies, C. J. Twining, P. D. Daniel, T. I. Cootes, and C. J. Taylor, "Building Optimal 2D Statistical Shape Models," *Image and Visio*

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] M.B. Stegmann, K. Sjostrand, and R. Larsen, "Sparse Modeling of Landmark and Texture Variability using the Orthomax Criterion," Proc. of SPIE, vol. 6144, 2006.
- [7] G. Zheng, and K.T. Rajamani, "An Optimal Three-stage Method for Anatomical Shape Reconstruction from Sparse Information using a Dense Surface Point Distribution Model," Proc. of SPIE, vol. 6141, 2006.
- [8] S.J. Lim, J.K. Udupa, A. Souza, D. Torigian, Y.Y. Jeong, and Y.S. Ho, "A New General Method of 3-D Model Generation for Active Shape Image Segmentation," Proc. of SPIE : Medical Imaging, vol. 4298, pp.48-55, 2006.
- [9] A. Souza, and J.K. Udupa, "Automatic Landmark Selection for Active Shape Models," SPIE Proc. 5747, pp. 1377-1383, 2005.
- [10] P.K. Saha, J.K. Udupa, and D. Odhner, "Scale-based Fuzzy Connected Image Segmentation : Theory, Algorithms, and Validation," Computer Vision and Image Understanding, vol. 77, pp. 145-174, 2000.
- [11] 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, 컴퓨터 그래픽스>



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 정보통신