

# SVM 을 이용한 3 차원 해마의 지능적 형상 분석

김정식, 김용국, 최수미  
세종대학교 컴퓨터 공학부  
jskim@sju.ac.kr, ykim@sejong.ac.kr, smchoi@sejong.ac.kr

## Intelligent Shape Analysis of the 3D Hippocampus Using Support Vector Machines

Jeong Sik Kim, Yong-Guk Kim, Soo Mi Choi  
School of Computer Engineering, Sejong University

### 요 약

본 논문에서는 SVM (Support Vector Machine)을 기반으로 하여 인체의 뇌 하부구조인 해마에 대한 지능적 형상분석 방법을 제공한다. 일반적으로 의료 영상으로부터 해마의 형상 분석을 하기 위해서는 충분한 임상 데이터를 필요로 한다. 하지만 현실적으로 많은 양의 표본들을 얻는 것이 쉽지 않기 때문에 전문가의 지식을 기반으로 한 작업이 수반되어야 한다. 결국 이러한 요소들이 분석 작업을 어렵게 한다. 의학 기술이 복잡해 지면서 최근의 형상 분석 연구는 점차 통계적 모델을 기반으로 진행되고 있다. 본 연구에서는 해마로부터 고해상도의 매개변수형 모델을 만들어 형상 표현으로 이용하고, 집단간 분류 작업에 SVM 알고리즘을 적용하는 지능적 분석 방법을 구현한다. 우선 메쉬 데이터로부터 물리변형모델 기반의 매개변수 모델을 구축하고, PDM (point distribution model) 방법을 적용하여 두 집단을 대표하는 평균 모델을 생성한다. 마지막으로 SVM 기반의 이진 분류기를 구축하여 집단간 분류 작업을 수행한다. 구현한 모델링 방법과 분류기의 성능을 평가하기 위하여 본 연구에서는 네 가지 커널 함수 (linear, radial basis function, polynomial, sigmoid)들을 적용한다. 본 논문에서 제시한 매개변수형 모델은 다양한 형태의 의료 데이터로부터 보편적인 3 차원 모델을 생성하고, 또한 모델의 전역적, 국부적인 특징들을 복합적으로 표현할 수 있기 때문에 통계적 형상분석에 적합하다. 그리고 SVM 기반의 분류기는 적은 수의 학습 데이터로부터 정상인 해마 집단과 간질 환자 집단간의 정확한 분류를 가능하게 한다.

Keywords : 3 차원 형상, 해마, SVM, 지능형 분석

### 1. 서 론

의료 분야에서 MRI (magnetic resonance imaging), CT (computerized tomography), PET (positron emission tomography)와 같은 여러 모달리티로부터 획득한 영상 데이터의 분석은 질환의 병변을 확인하거나, 치료 계획을 수립하는 등의 다양한 의료 기술들에 활용될 수 있다. 초기의 의료 영상 분석 연구에서는 질환과 관련된 인체 장기에 대한 영상 데이터에 전문가의 지식을 반영하여 초기화 작업을 처리하고, 분석을 위한 전체 과정에 전문가의

도움을 필요로 했다. 이러한 top-down 방식의 지식 기반 분석 작업은 의료 기술의 복잡화, 데이터의 대형화, 그리고 영상 관련 컴퓨터 기술의 발전과 함께 점차 전문가의 개입을 최소화하여 자동화된 지능형 시스템을 구축하는 bottom-up 방식으로 발전되고 있다. 이러한 지능적 분석 방법의 가장 큰 특징은 특정 의료 전문지식에 대한 의존도를 최소화하면서 자동화된 과정으로 형상을 분석할 수 있다는 점이다.

의료 영상 데이터로부터 자동화된 지능적 형

상분석 작업을 적용하여 신뢰성 있는 결과를 얻기 위해서는 크게 두 가지 조건을 만족해야 한다. 첫째, 의료 영상 데이터로부터 인체 장기의 형상을 분석을 위해서는 충분한 임상 데이터가 필요하지만 현실적으로 많은 양의 데이터를 얻는 것이 쉽지 않다. 따라서 적은 수의 의료 영상 데이터로부터 표본 집단에 대한 정확한 통계적 정보를 구축할 수 있어야 한다. 둘째, 최근 의료 분야에서 사용 가능한 영상 모달리티가 다양화 됨에 따라서 보편적으로 적용 가능하고 전문가의 개입을 최소화할 수 있는 모델 표현 방법이 요구된다.

본 연구에서는 인체의 뇌 하부구조인 해마에 대한 3 차원 형상의 자동화된 지능적 분석 방법을 구현한다. 정확한 분석을 위해 형상 특징의 공간 복잡도를 축소하는 PCA 기법을 적용하는 대신에, 해마 형상으로부터 고해상도의 매개변수형 모델과 PDM 기반의 통계 모델을 구축하고 그것을 형상 특징으로 사용하여 SVM 분류기의 학습과 정상인 해마 집단과 간질 환자의 해마 집단간 분류 작업을 수행한다. 매개변수형 모델은 다양한 영상 모달리티로부터 3 차원 모델을 생성하기 때문에 형상의 전역적, 국부적 특성들을 복합적으로 잘 표현할 수 있기 때문에 통계적 형상 분석의 기하학적 모델링 방법으로 주로 채택되고 있다. 또한 형상 표본 데이터로부터 구축된 PDM 모델은 집단을 대표하기 때문에 새로운 영상으로부터 추출된 형상이 특정 집단에 분류될 수 있는 평가치 데이터를 계산하는데 용이하다. 최근 의료분야, 통계학, 컴퓨터 비전 등 많은 분야에서 사용되고 있는 SVM 알고리즘은 선형 혹은 비선형 패턴을 갖는 두 표본 집단을 분류하는데 매우 효과적이다.

본 논문의 나머지 구성은 다음과 같다. 2 장에서는 지능적 형상 분석을 위한 기존 연구들을 소개하고, 3 장에서는 본 연구에서 구현한 SVM 기반의 지능적 형상 분석을 수행하기 위해 적용한 방법들을 설명한다. 4 장에서는 실험 및 결과를 보여주고, 마지막으로 결론 및 향후 연구를 제시한다.

## 2. 관련연구

통계 모델 기반의 지능적 형상 분석은 의료

영상 데이터로부터 추출한 인체 장기에 대한 질병 진단 및 치료에 대한 비침습적 연구의 유용한 도구로서 사용되고 있다. 통계적 형상 분석을 위한 주요 과정은 크게 효과적인 형상 표현을 구축하는 단계와 집단간 분류를 위한 통계 모델을 생성하는 작업으로 나눌 수 있다.

통계적 모델 기반의 형상 분석에 주로 이용되는 모델은 3 차원 PDM, 매개변수형 모델, 골격 모델 등이 있다. PDM 은 평균, 표준 편차 등의 통계 정보를 사용하여 표본 집단의 기하학적 평균 모델을 만드는데 유용하다. 그리고 매개변수형 모델은 deformable 모델링 방법을 사용하여 생성되는데 국부적 변형에 따른 형상 차이를 분석하는 작업에 유용하고 어파인 변환에 강인한 모습을 보여준다. Zhu 는 바나나 형태를 갖는 뇌 하부 구조인 lateral ventricle 의 볼륨 영상으로부터 매개변수형 모델을 만들고, 그 결과를 통계적 형상 분석에 적용하는 방법을 제안하였다[1]. 그리고 Martin 은 Spherical Harmonics (SPHARM)에 의한 매개변수형 모델링 방법을 해마 모델에 대한 통계적 형상 분석에 적용하였다[2].

일단 3 차원 형상에 대한 매개변수형 모델을 생성한 후에는 기계 학습 방법을 사용한 통계적 모델 기반의 집단간 분류 기능을 적용한다. 가장 일반적으로 사용되는 알고리즘에는 선형 분류기인 PCA 방법과 선형의 매개변수형 분류기인 FLD (fisher linear discriminant) 방법이 있다[3]. 형상을 표현하는 공간을 축소하는 PCA 방법은 주요 형상 특징들을 추출하여 선형 방정식을 적용한 이진 분류를 가능하게 하지만 효과적인 maximum likelihood 분류기를 구축하기에는 표본 데이터의 양이 적다는 한계를 가진다. 또한 PCA 기반의 형상 분석에서는 이용하는 표본 데이터가 기본적으로 가우시안 확률 분포 형태로 구축되어야 한다는 점을 가정하고 있다. 따라서 이 방법을 통하여 좋은 분류 결과를 얻게 되더라도, 그 입력 데이터가 가우시안 분포 조건을 어길 경우, 전체 집단을 대표하기에는 한계가 있다. 그래서 최근에는 인공 신경망이나 SVM 을 이용한 분류기가 형상 분석에 많이 사용되고 있다[4, 5]. 본 연구에서는 분석

대상이 되는 형상 집합으로부터 물리 변형 모델 기반의 매개변수형 모델을 구축하고, 그 데이터에 PDM 방법을 적용하여 통계적 모델을 구축한다. 그리고 의료 데이터 수집의 한계를 극복하고, 이진 분류에 강인한 SVM 을 사용하여 집단간 분류 모델을 형상 분석 작업에 적용한다.

### 3. SVM 기반의 지능적 형상 분석

일반적으로 SVM 기반의 지능적 형상분석 방법은 크게 세 단계의 주요 작업들로 구성된다. 우선 관심 대상이 되는 의료 영상 데이터로부터 형상에 대한 정량적인 형상 특징을 추출한다. 이렇게 수집된 데이터는 표본 집단을 이루는 모델들의 variation 을 이용하여 생성 모델(generative model)을 만들거나, 형상 변형 차이를 통해 두 표본 집단간 분류를 수행하는 판별 모델(discriminative model)을 생성하는 데 이용된다. 본 연구에서는 판별 모델을 통계적 형상분석 방법에 적용한다. 그림 1 은 본 연구에서 구현한 통계적 형상분석 작업 수행을 위한 전체 과정을 보여준다. 통계적 형상 분석을 수행하기 위해 우선 형상을 표현하는 메쉬 모델을 입력 받아서 표본 집단 및 평가 대상이 되는 형상에 대한 매개변수형 모델들을 생성한다. 그런 후에 두 표본 집단의 모델들로부터 PDM 방법을 적용하여 각 집단을 대표하는 통계 모델을 구축한다. 두 표본 집단으로부터 생성된 매개변수형 모델의 데이터는 SVM 분류기에 입력으로 이용되어 집단 분류 모델을 생성하는데 사용된다.

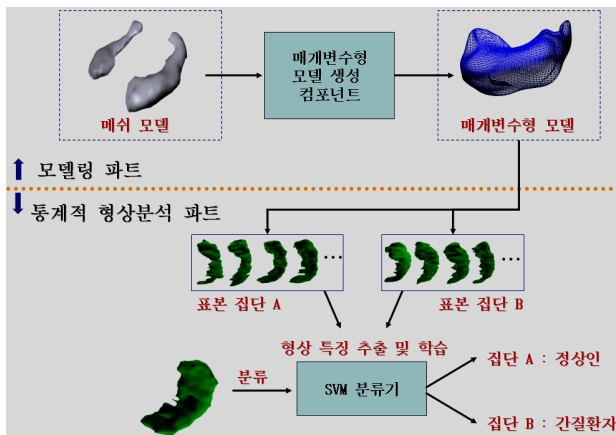


그림 1 통계적 형상분석 수행을 위한 전체 구조

### 3-1 매개변수형 3 차원 모델 생성

본 방법에서는 지능적 형상 분석에 사용될 매개변수형 모델을 생성하기 위해서 우선 전차리 과정으로 MRI 영상으로부터 관심 영역을 분할하여 볼륨 데이터로 구성한 후, 해당 볼륨에 마칭큐브 알고리즘을 적용하여 3 차원 삼각 메쉬 데이터를 생성한다. 이때 메쉬 모델의 해상도와 부드러운 정도를 변화시키기 위해 마칭큐브 방법을 적용할 때 grid 값과 smoothness 값을 매개변수로 사용한다. grid 값은 각 메쉬에 대응하는 단위 복셀의 개수를 나타내는데 grid 1 과 grid 2 로 지정될 수 있다. 또한 smoothness 는 0 부터 4 까지 지정된다. 그림 2 는 grid 와 smoothness 값에 따라 정의된 해상도와 부드러운 정도를 나타낸다.




그림 2 메쉬 모델 해상도/부드러운 정도

Physics-based deformable modeling 방법에 의해 생성되는 매개변수형 모델은 일반적인 3 차원 형상 매칭 뿐만 아니라 통계적 형상 분석에 주로 채택되는 형상 표현이다[6]. 매개변수형 모델을 생성하는 과정은 다음과 같다. 우선 3 차원 모델의 무게 중심을 구하고 표면 정점들의 주 축을 결정한다. 이러한 정보는 변형 모델 표면을 구성할 초기 superellipsoid 모델을 생성하는데 사용된다. 그런 후 superellipsoid 의 표면을 구성하는 정점 집합은 유한 요소 모델 (finite element model: FEM) 방법을 통하여 3 차원 메쉬 모델에 가장 근접한 형태를 얻게 되는데 이 과정을 작업을 일반적으로 적합(fitting)이라고 한다. 본 모델링 방법에서는 Galerkin의 표면 보간 방법을 사용하여 적합을 수행하는데, 이때 superellipsoid 의 표면 정점에서의 볼륨 요소의 변위들과 노달 (nodal) 정점 변위들 사이의 관계를 찾아낸다. 그리고 본 방법에서는 3

차원 가우시안 함수를 사용하여 반복 적용하는 방법으로 변형 모델을 생성한다. 식 1 은 3 차원 가우시안 기반 보간 함수를 정의한 것이다.  $n$  은 FEM 노드의 개수이고,  $q_{ik}$ 는 보간 함수의 특성을 만족하는 계수이다.

$$\begin{aligned}
 h_i(x, y, z) &= \sum_{k=1}^n q_{ik} g_k(x, y, z), \quad g_k(x, y, z) \\
 &= e^{-\left[ \frac{(x-x_i)^2}{2\sigma_x^2} + \frac{(y-y_i)^2}{2\sigma_y^2} + \frac{(z-z_i)^2}{2\sigma_z^2} \right]}
 \end{aligned} \quad (\text{식 1})$$

본 연구에서는 물리 기반 형상 변형을 위해 평형식(equilibrium equation)을 통하여 모드 형상 벡터들을 계산한다. 그 벡터들은 식 2 의 damping 을 제거한 동적 평형식의 일반화된 고유벡터들에 해당한다. 식 2 에서 3 차원 질량 행렬  $M$  은 보간 행렬  $H$  에 의해 직접 계산될 수 있으며,  $\sigma$  는 질량 밀도가 된다. 3 차원 강성 행렬  $K$  는 아래의 식 3 에 의해 계산된다. 식 2 는 연산 규모를 줄이면서도 모드 방정식을 사용하여 closed-form 의 해를 구할 수 있는 형태로 변환될 수 있다. 최종 형상의 변형된 정점들의 위치는 에너지 값이 지정된 임계치보다 작거나 반복 횟수가 지정된 수를 넘어갈 때 결정된다.

$$MU'' + KU = 0, \quad U = \phi \sin w(t - t_0) \quad (\text{식 2})$$

$$M = \int_V \rho H^T H dV \quad \text{and} \quad K = \int_V B^T C B dV \quad (\text{식 3})$$

### 3-2 SVM 기반의 이진 분류기 구축

SVM 은 통계적 학습 이론 분야에서 최근 커다란 진전을 보인 새로운 학습 시스템 중 하나이다. 특히 분류와 회귀에 응용할 수 있는 지도학습 (supervised learning) 알고리즘이다[7]. 기본적인 분류를 위해 SVM 은 입력공간에 maximum-margin hyper-plane 을 만든다. 그런 후 0 또는 1 의 값이 주어진 training 샘플로부터, 가장 가까이 있는 margin 에서 hyper-plane 까지의 거리가 최대가 되도록 training 샘플들을 0 과 1 로 나누게 되고, 그것이 maximum-margin hyper-

plane 이다. Vladimir Vapnik 이 1963 년에 발표한 초기 SVM 모델은 선형 분류기(linear classifier) 였다. 그러나 1992 년 Bernhard Boser 등은 maximum-margin hyper-plane 에 커널 트릭을 응용하여 비선형 분류기를 구현할 수 있게 되었다.

본 연구에서는 비선형 SVM 분류기를 구현하여 집단간 분류 작업을 지원한다. 사용되는 training 예제들의 집합  $X$  와 초평면(hyper-plane)인  $H(w, b)$  는 아래의 식 4 처럼 정의된다. 식 4 에서  $x$  값들은 초평면 상에 맵핑되는 정점들이 되며,  $w$  는 초평면에 대한 normal 벡터가 된다. 그리고  $|b|/\|w\|$ 는 초평면으로부터 원점까지의 직각 거리가 된다.  $(w^T x_i + b)/\|w\|$  는 하나의 정점  $x$ 로부터 초평면  $H(w, b)$  까지의 부호있는 거리가 되기 때문에 선형 분류의 문제에서의 초평면  $H(w, b)$  는 아래의 식 5 에 의해 결정된다. 선형 SVM의 목적은 최대 마진( $\|w\|^2/2$ )을 갖는 초평면을 결정하는 것이다. 선형 분류 시나리오인 training 예제들이 식 6 의 제약사항을 어기는 정도를 표현하는 non-negative slack 변수인  $\xi_i$  에 의해 확장될 수 있다. 따라서 최적화 문제는 제약사항을 표현하는 식 7 에 따라 식 6 을 최소화되도록 변환하는 작업으로 나타낼 수 있다. 식 6 에서  $C$  는 제약사항 위반에 대한 비용을 조절하는 사용자 정의된 매개변수이다. 이러한 최적화 문제는 Lagrange multiplier를 사용한 quadratic programming 방법에 의해 해결된다. 최대 마진이 되는 최종 초평면  $H(w, b)$  를 기반으로 하여, 새로운 예제  $x$ 는 함수  $f(x) = \text{sign}(w^T x_i + b)$ 를 계산함으로써 이진 분류될 수 있다.

$$\begin{aligned}
 X &= \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}, \\
 \text{where } x_i &\in R^n \quad \text{and} \quad y_i \in \{-1, 1\}
 \end{aligned} \quad (\text{식 4})$$

$$H(w, b) \equiv \{x \mid w^T x + b = 0\}$$

$$(w^T x_i + b) * y_i \geq 1, \quad i = 1, \dots, l. \quad (\text{식 5})$$

$$\|w\|^2 / 2 + C \left( \sum_i \xi_i \right) \quad (\text{식 6})$$

$$(w^T x_i + b) * y_i \geq 1 - \xi_i, \quad i = 1, \dots, l. \quad (\text{식 } 7)$$

본 연구에서는 다양한 커널 함수들을 사용한 비선형 맵핑을 이용하여 선형 분류 방법을 확장한 형태의 분류기를 구축한다. 비선형 SVM의 핵심 코드는 SVM-light5.0 라이브러리를 이용한다[8]. 해당 라이브러리에서는 학습 및 분류 과정에서의 에러율 및 precision / recall 결과를 모두를 효과적으로 평가하기 위하여 XiAlpah-estimates 방법을 사용한다. 본 과제에서는 선형 및 비선형 SVM 기반의 분류기의 성능 평가를 위해 총 네 개의 커널 (linear, RBF, polynomial, sigmoid)을 채택하여 실험을 수행한다. 식 8은 RBF, polynomial, sigmoid 함수를 정의한 것이다.

$$\begin{aligned} \text{RBF} &: e^{-(g * |u-v| * |u-v|)} \\ \text{polynomial} &: (a * b + c)^d \\ \text{sigmoid} &: \tanh(a * b + c) \end{aligned} \quad (\text{식 } 8)$$

#### 4. 실험 및 결과

본 실험에서는 매개변수형 모델링 방법과 SVM 분류기의 성능을 평가한다.

우선 본 실험에서는 해마 모델을 실험 데이터로 사용한다. 해마 데이터는 정상인들의 해마 MR 영상 다섯 케이스와 간질 환자들의 영상 다섯 케이스로부터 구성된다. 그림 3은 영상 볼륨 데이터로부터 구축된 해마 메쉬 데이터의 일부를 보여준다.




그림 3 해마 메쉬 모델 구축의 예

본 실험에서는 매개변수형 모델을 생성하기 위하여 각각의 모델들에 대하여 모델의 변형 반복 횟수와 진동 모드, superellipsoid의 샘플링 레벨을 달리하여 모델링 작업을 수행한다. 그림 4의

(가)부터 (라)까지는 변형 반복 횟수를 달리했을 때의 결과이며, 그림 4의 (마)부터 (미)까지는 진동모드를 달리했을 때의 모델 생성 결과이다.

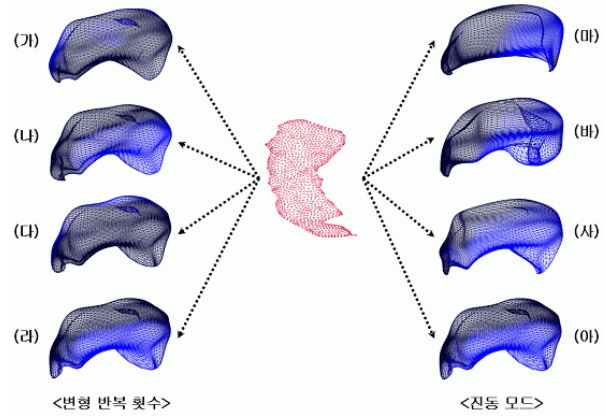


그림 4 매개변수형 모델 생성의 예

PDM 기반의 평균 모델링 방법은 실제 MR 해마 볼륨 데이터로부터 추출된 매개변수형 모델들을 표본 데이터로 사용하여 평균과 표준편차, 공분산 등의 통계정보를 계산하여 생성 모델을 생성할 수 있도록 해준다. 본 실험에서는 좌, 우가 분할된 총 20개의 모델들을 네 개의 표본 집단 (정상인 왼쪽, 오른쪽 해마 모델 집단, 간질 환자 왼쪽, 오른쪽 해마 모델 집단)으로 분류한 후, 각 집단의 평균 모델과 주성분 분석 (PCA)로부터 계산된 고유치 벡터와 고유치 값들을 이용하여, 각 집단의 형상 범주를 대표하는 통계 모델들을 구축하는 실험을 수행한다. 이렇게 생성된 각 집단의 통계 모델은 SVM 분류기의 학습 및 분류 실험에 사용되는 형상 특징을 구성하는데 이용된다.

SVM 기반의 이진 분류기의 학습 및 테스트 과정과 그 성능을 평가하기 위하여 본 실험에서는 두 개의 실제 임상 해마 데이터로부터 부분적으로 변형 작업을 수행하여 획득한 정상인 해마 집단 40개, 간질 환자 해마 집단 40개를 학습 및 테스트에 이용하였다. 두 집단의 분류 성능 평가를 위해 선형 SVM 함수와 비선형 커널 (RBF, polynomial, sigmoid)을 적용하였고, 그 결과 polynomial 함수를 사용한 분류기가 가장 좋은

성능을 보여주었다. 그림 5 는 네 개의 커널 함수들을 적용한 분류 결과를 나타낸다.

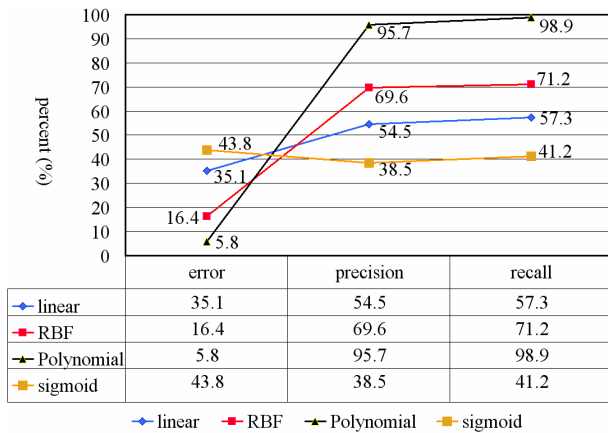


그림 5 SVM 분류기 성능 실험 결과

### 5. 결론

본 연구에서는 해마 모델에 대한 두 집단간 형상 차이를 분석하기 위하여 매개변수형 모델과 SVM 기반의 지능적 형상 분석을 위한 프레임워크를 제시하고, 구현하였다. 실험을 통하여 적용한 매개변수형 모델링 방법은 모델 집단으로부터 통계 모델을 구축하는 데 효과적임을 확인하였다. 또한 polynomial 커널을 사용한 SVM 기반의 이진 분류기는 정상인 해마 집단과 간질 환자의 해마 집단간 분류를 효과적으로 수행함을 확인할 수 있었다.

현재 적용하고 있는 매개변수형 모델링 방법은 해마와 같이 형태의 형상에 적합하다. 따라서 향후에는 현재의 방법을 일반적 형태의 모델들에 적용할 수 있도록 개선할 것이다. 그리고 SVM 분류기의 성능을 평가하기 위하여 사용했던 artificial 데이터 대신에 실제 표본 데이터들을 좀 더 수집하여 현재 방법의 신뢰성을 확보할 것이다.

### [참고문헌]

[1] L. Zhu and T. Jiang, Parameterization of 3d brain structures for statistical shape analysis. In Proc. of SPIE Medical Imaging, Vol. 5370, pp. 1254–1262, 2004.  
 [2] M. Styner, G. Gerig, J. Lieberman, D. Jones, D. Weinberger, Statistical shape analysis of neuro-

anatomical structures based on medial models. Medical Image Analysis, vol. 7, pp. 207-220, 2003.

[3] J. G. Csernansky, et.al., Hippocampal Morphometry in Schizophrenia by High Dimensional Brain Mapping. In Proc. of National Academy of Science, Vol. 95, No. 19, pp. 11406-11411, 1998.

[4] P. Golland, W. E. L. Grimson, M. E. Shenton and R. Kikinis, Small Sample Size Learning for Shape Analysis of Anatomical Structures. To Appear in MICCAI'2000:

[5] Li Shen, et.al., Shape-based Discriminative Analysis of Combined Bilateral Hippocampi using Multiple Object Alignment. SPIE2004, pp. 274-282, 2004

[6] J-Y. Park, et.al., A Non-self-intersecting Adaptive Deformable Surface for Complex Boundary Extraction from Volumetric Images. Computers & Graphics, Vol. 25, No. 3, pp. 421-440, 2001.

[7] E. Boser, I. Guyon, V. Vapnik, A Training Algorithm for Optimal Margin Classifiers. COLT 1992, pp. 144-152.

[8] T. Joachims. SVM<sup>light</sup>: Support Vector Machine, 2004. Software available at <http://svmlight.joachims.org>.