

# ICP 정합과 신경망을 이용한 해마의 3차원 형상 분석

김정식<sup>1</sup>, 최수미<sup>1</sup>, 김용국<sup>1</sup>, 김명희<sup>2</sup>

세종대학교 컴퓨터공학부<sup>1</sup>, 이화여자대학교 컴퓨터학과<sup>2</sup>  
jskim@sju.ac.kr, smchoi@sejong.ac.kr, ykim@sejong.ac.kr, mhkim@ewha.ac.kr

## 3D Shape Analysis for the Hippocampus Using ICP Registration and Neural Networks

Jeong-Sik Kim<sup>1</sup>, Soo-Mi Choi<sup>1</sup>, Yong-Guk Kim<sup>1</sup>, Myoung-Hee Kim<sup>2</sup>

<sup>1</sup>School of Computer Engineering, Sejong University

<sup>2</sup>Dept. of Computer Science and Engineering, Ewha Womans University

### 요 약

본 논문에서는 뇌의 하부구조인 해마를 정확하게 분석하기 위한 형상 정규화 방법과 정상인과 간질 환자의 해마를 분류하기 위한 방법을 제시한다. 해마에 대한 형상 분석 과정은 크게 형상 표현을 구축하는 과정, 형상의 유사도를 측정하는 과정, 정상인 집단과 환자 집단을 분류하는 과정으로 이루어진다. 본 연구에서는 해마의 형상 표현으로 메쉬, 골격, 복셀로 이루어진 하이브리드 옥트리 자료구조를 구축하였다. 또한 Iterative Closest Point (ICP) 알고리즘을 사용하여 해마 골격을 기반으로 한 정규화를 수행하였다. 그리고 정규화된 해마 형상을 전역적, 국부적으로 분석하여 최종적으로 입력된 해마가 정상인 또는 간질 환자에 속하는지를 학습된 데이터를 이용하여 분류하였다. 본 논문에서 제시한 ICP 기반의 정규화 방법은 3차원 해마 형상을 정확하게 분석하게 해주고, 골격의 정점 수를 조절함으로써 정규화 시간을 감소시킬 수 있다. 뿐만 아니라 3차원 해마 모델의 형상을 신경망을 통하여 학습시킴으로써 해마의 형상이 변형된 환자 집단과 정상인 집단을 분류하는데 이용할 수 있다.

### 1. 서론

정신 질환 환자들의 뇌 구조에 대하여 형태적 특성을 분석하고 그 결과로부터 병변을 진단하는 것은 의료 분야에 있어서 중요한 연구 과제로 인식되고 있다. 특히 뇌의 하부 조직인 해마의 비 정상적인 형태 변화가 간질, 기면증, 치매 등의 정신 질환의 직접적인 원인이 된다는 연구 결과가 보고 되어 왔다. 이러한 해마의 구조적 변화는 사람의 학습과 기억 장애에 밀접한 연관성을 보이기 때문에 많은 연구 들이 질환에 따른 해마의 형태 변화 패턴 분석에 관심을 기울이고 있다.

해마 조직의 형태 변화를 정확하게 평가하기 위해서는 해마의 구조적 특징을 잘 반영하는 형상 표현을 선택해야 한다. 그리고 해당 조직과 연관된 질환에 적합한 분석 방법을 채택해야 한다. 상기의 조건들을 충족시키는 형상 분석 기술은 정신 질환 환자 집단과 정상인 대조 집단을 분류하기 위한 중간과정으로 사용될 수 있다.

형상 분석의 대상이 되는 자기공명영상 (MRI)으로부터 생성되는 3차원 해마 모델은 영상 촬영 대상의 나이, 성별, 그리고 촬영 시기에 따라 그 방위와 크기가 다를 수 있다. 따라서 환자 집단과 정상인 대조 집단을 정확하게 분류하기 위해서는 최적의 형상 표현과 분석 방법 선택에 앞서 분류 대상이 되는 모델들에 대한 효과적인 포즈 정규화 작업이 선행되어야 한다. 표면 메쉬 모델에 대한 방위 정규화는 주 성분 분석 (Principal Component Analysis) 방법에 의해 처리된다. 이 방법은 모델의 표면 데이터를 정점 집합으로 간주하여 변량 함수를 정의한 후, 공 분산 행렬로부터 계산되는  $x, y, z$  축 각각에 대한 고유치 값들을 이용하여 모델의 방위를 정규 프레임으로 일치시키게 된다. PCA 정규화 방법은 3차원 모델을  $x, y, z$  축 방향으로 회전시키는 작업에는 적합하지만, 부호에 따라서 회전되는 방향이 달라지기 때문에 불안정적인 결과를 가져 온다. 또한 PCA는 모델의 무게중심을 원점으로 하여 주 축 성분들을 계산하

고 회전 변환을 수행하기 때문에 표준 모델과 그 모델에 상대적으로 국부적으로 큰 변형 정도를 보이는 모델 간의 정규화 과정은 정확한 결과를 보장하지 못한다. 따라서 해마의 국부적 형태 변화를 정확하게 분석하기 위해서는 안정적이고 정확도와 계산 효율이 높은 정규화 방법이 요구된다.

해마 조직의 전역적, 국부적인 형상 변형 정도를 정확하게 평가하는 작업은 최종적으로는 정상인 대조 집단과 간질이나 치매 등의 징후를 보이는 환자 집단을 분류하기 위한 기본적인 정보를 제공하기 위한 중간 과정이 된다. 따라서 서로 다른 집단들을 분류하기 위해서는 분류 기준이 되는 통계적 모델을 구축하기 위한 방법이 요구된다.

본 연구의 목적은 정상인 대조 모델과 간질 환자의 모델간에 나타나는 전역적, 국부적인 형상 변형 정도를 정확하게 계산하고, 이러한 결과를 바탕으로 하여 새롭게 입력되는 해마 조직 예제들이 어느 집단에 포함되는지를 자동으로 판별하도록 해주는 분류기를 구축하는 것이다. 본 논문에서는 정확한 형상 분석 결과를 제공하기 위해 본 연구의 이전 방법에서 채택했던 PCA 기반의 정규화 과정 대신에 ICP 기반의 정규화 알고리즘을 채택하여 구현한다[1]. 또한 정상인 집단과 간질 환자 집단을 분류하기 위하여 신경망 학습 알고리즘을 이용한 분류기를 구현한다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구를 소개하고, 3장에서는 해마에 대한 하이브리드 형상 표현 방법, ICP 알고리즘 기반의 모델 정규화 과정, 전역 및 국부적 형상 분석 방법, 신경망 기반의 분류기 구현에 대하여 설명한다. 4장에서는 실험 및 결과를 분석하고, 마지막으로 5장에서는 결론 및 향후 연구 방향을 제시한다.

## 2. 관련 연구

해마 조직에 대한 형태 변형 정도를 측정하는 연구는 MRI를 이용한 2차원 접근 방법으로부터 출발하였다. 관련 연구자들은 1990년 초반부터 MRI를 이용하여 해마 조직의 부피와 형태 변화를 전역적 관점에서 평가함으로써 많은 정신 질환 환자에게서 나타나는 비 정상적

특성을 보여 왔다[2-4]. 해마 조직은 상대적으로 낮은 명도 대비를 가지기 때문에 정확하고 정교하게 전체 형상의 경계면을 정의하는 것이 어렵다. 또한 뇌 전체 용적에 비하여 상대적으로 작은 부분을 차지한다. 이러한 해마 조직의 특성들은 해마 조직 자체의 자동적인 분할을 어렵게 할 뿐만 아니라 해마 조직 영역에 대한 정확한 크기 측정 및 부피 측정을 어렵게 한다. 그리고 체적 변화를 분석하기 때문에 해마의 국부적 형태 변화를 표현하기에는 한계가 있다.

최근에는 기존의 해마 조직의 형상 분석에 사용된 2차원 접근 방법이 갖는 문제점들을 보완하기 위한 방법으로 3차원 오브젝트 표현과 통계적인 분석 방법을 이용한 연구들이 발표되었다. 이러한 연구들은 spherical harmonics를 이용한 매개변수형 표면 표현 (SPHARM)[5]이나 샘플링 된 골격 정보를 이용한 중간선 표현(M-rep)[6]을 통계적 형상 분석의 입력으로 사용한다. 이때 사용되는 통계적 형상 분석은 정상인 대조 집단과 정신 질환 환자 집단간에 나타나는 해마 모델에서의 형상 변화를 구분하기 위한 학습 함수 모델을 구축하는 작업으로 정의될 수 있다. 통계적 형상 분석 방법에 주로 적용되는 통계적 모델 구축 알고리즘에는 PCA 기법이 있다. 이 방법은 SPHARM이나 M-rep와 같은 형상 표현으로부터 추출된 비교 대상이 되는 두 모델의 형상 특징들을 landmark, high dimensional warping, MDL refinement 등의 surface correspondence 방법들을 이용하여 정규화하고 PCA에 의한 차원 감소 작업을 거쳐서 중간 템플릿 모델을 구축한다. 이 과정 중에서 비교 대상이 되는 각 모델의 표면 데이터에 대하여 PCA 방법을 기반으로 방향, 위치, 크기를 정규화한다. 이렇게 결정된 템플릿 모델은 새로운 모델 예제가 입력되었을 때 정상인 집단과 환자 집단 각각에 해당되는 클래스의 범주 내에 포함되는 변량을 계산하여 입력 모델을 두 집단 중에 하나로 분류하게 된다.

SPHARM은 3차원 모델의 surface boundary 정보를 이용한 통계적 모델링 방법으로 매개변수를 이용한 형상 표현이다. 대표적인 연구로 Shenton 등[7]은 정신분열증(schizophrenia) 환자의 뇌 구조에서 나타나는 비대칭성을 분석하기 위하여 고해상도 MR 데이터와 3차

원의 SPHARM 표현을 이용한 형상 분석 방법을 소개하였다. 이 연구에서는 정신분열증 환자에게서 나타나는 amygdala hippocampal complex 구조의 형상 변이에 대한 통계적 분석 방법을 통하여 기존의 MRI에 의한 부피와 표면의 크기 및 길이 정보로 평가 할 수 없었던 좌-우 비 대칭적 패턴을 분석하였다. 또한 해마 부위의 형상 변형 여부를 자동 평가하고, 실제 질환에 의해 이상 징후를 보이는 부위를 확인하도록 하였다. 그러나 뇌 구조 전반에 대한 형상분석을 위한 보편적 방법을 제공하지 못했으며, 구조적 변화를 반영하기 위한 부분적 형상 분석 방법을 채택하지 않은 한계점을 가진다.

M-rep 형상 표현은 모델의 국부적인 형상 차이를 분석하는 연구들에 주로 이용되고 있다. 대표적으로 Styner 등[8]은 정신분열증 환자의 해마 부위에서 나타나는 형상적 이상 징후에 대한 분석을 위하여 M-rep을 채택하였다. M-rep는 중앙 축을 중심으로 국부적인 거리와 두께에 대한 측정값을 제공한다. 따라서 M-rep를 이용한 형상 분석 결과는 해마 모델의 두께와 위치의 차이 정도를 정량적으로 평가하기 위한 정보를 제공한다. 여기에서 두께의 차이는 해마 형상의 부분적인 성장 정도에 따른 변화 정도를 나타내며, 위치의 변화는 부분적 형상 변형 정도를 표현한다. M-rep는 다양한 레벨에서의 형상이 갖는 구부러짐이나 팽창 및 수축 등의 변화를 감지하는데 유용하다. 또한 형상 표현의 연속성을 보장하고, 형상의 표면에 대한 함축적 표현을 가능하게 한다. 하지만 작고 큰 형상적 차이를 반영하는 SPHARM 형상 분석 표현 방법과는 달리 형상의 작은 차이만을 반영하는 한계를 지닌다. 또한 M-rep 표현이 골격을 구성하는 medial atom에 의한 샘플링 표현을 사용하기 때문에 자동화된 부분적 형상 분석에는 적합하지만, 해마의 전반적 표면에서의 세밀한 변화를 반영하지 못한다.

본 연구에서는 PCA 기반의 형상 정규화 방법이 갖는 한계점을 개선하기 위하여 골격 표현에 대하여 ICP 정합 알고리즘을 적용한 정규화 방법을 제안한다. 또한 다 해상도 기반의 형상 분석을 위하여 분석 대상이 되는 3차원 메쉬 모델을 intermediate 복셀과 골격 데이터와 통합함으로써 coarse-to-fine 형태의 형상 표현을 제안한다. 또한 해마의 전역적 표면 영역에서의 세밀한 변화

를 반영하기 위하여 옥트리 기반의 자료 구조를 형상 분석에 사용하여 전역적 형상 분석뿐만 아니라 사용자 인터랙션을 포함한 계층적인 국부적 형상 분석을 가능하게 한다.

### 3. 해마의 3차원 형상 분석

#### 3.1 형상 분석을 위한 모델 표현 방법

본 연구에서는 해마 조직에 대한 형상 분석을 위하여, 간질 환자의 뇌 MRI 데이터로부터 해마 부위를 수동으로 분할하여 해마 볼륨을 구축하고 이렇게 생성된 해마 볼륨에 대하여 마칭큐브 알고리즘을 적용하여 3차원 메쉬 모델을 생성한다[1].

일반적으로 의료영상으로부터 재 구성된 3차원 해부학적 모델을 정확하게 분석하기 위해서는 효과적인 형상 표현 방법의 적용이 필수적이다. 본 연구에서는 기본적으로 복셀, 메쉬, 골격의 세 가지 다른 유형의 데이터를 형상 분석에 활용한다. 우선 메쉬 표현은 본 연구의 형상 변형 정도를 측정하기 위한 형상 특징 데이터로 사용되고, 복셀은 해마 형상의 골격 추출 및 의료 영상 데이터와의 연동을 용이하게 하기 위한 중간 표현이 된다. 그리고 골격 데이터는 메쉬 표현으로부터 형상 특징을 추출하는 샘플링 작업과 메쉬 모델의 정규화 과정에 사용된다. 본 논문에서 채택한 3차원 골격 생성은 볼륨 슬라이스 기반의 골격화 알고리즘을 이용한다[1]. 그리고 옥트리 자료구조를 이용하여 하이브리드 형상 표현들을 공간적으로 분할하여 계층적으로 저장함으로써, 전역적 형상 분석의 시간 복잡도를 줄이고 국부적 형상 분석을 위한 형상 특징 접근을 가능하게 한다. 구성이 완료된 옥트리의 루트 노드는 해당 모델의 모든 메쉬들을 포함하게 되며, 중간 레벨 노드들은 3차원 공간 상에서 계층적으로 세부 분할된 메쉬들을 표현한다.

그림 1은 옥트리 기반의 하이브리드 표현을 나타낸다. 그림 1의 (a)는 메쉬와 골격을 표현한 것이고 (b)부터 (d)는 각각 메쉬, 골격, 복셀 데이터를 옥트리 레벨 1로 나누어지는 8개의 하위 노드 공간에 분할한 모습을 보여 준다. (a)는 메쉬 및 골격 표현이고, (b)~(d)는 차례로 메쉬, 골격, 복셀을 옥트리 구조를 이용하여 공간적

으로 분할한 모습이다.




그림 1 옥트리 기반의 하이브리드 해마 표현

### 3.2 ICP 알고리즘 기반의 모델 정규화 과정

본 장에서는 정확한 형상 분석 결과를 제공하기 위해 채택한 ICP 기반의 모델 정규화 방법을 소개한다. Besl 등[9]이 1992년에 제안한 ICP 알고리즘은 least square 정합 작업을 반복적으로 수행하여 정합과정 중에 발생하는 에러를 최소화하는 최적화 기법이다. 이 방법은 정합 대상이 되는 표현의 종류와는 무관하게 보편적으로 적용 가능한 정합 알고리즘이다. 따라서 서로 다른 기하학적 요소들로 표현된 모델들 사이의 일치성을 결정하는 데 유용하다. 특히 형상 표현의 해상도에 강인한 정합 결과를 제공한다. 따라서 복잡한 구조를 갖는 모델에 대해서도 비교적 빠른 정합 결과를 가져온다.

Zhang[10]은 Besl의 방법을 로봇의 네비게이션 목적에 맞추어 수정한 알고리즘을 제안하였다. 일반적으로 네비게이션의 표현은 모션 데이터의 형태를 갖는다. 이러한 데이터는 free-form 커브 형태로 정의된다. Zhang은 연속된 프레임에 존재하는 모션들의 차이가 작다는 점을 이용하여 첫 번째 프레임에 존재하는 커브의 정점들을 두 번째 프레임에 있는 커브의 가장 가까운 점들에 일치시킴으로써 두 프레임에 존재하는 커브가 더욱 가까워지도록 하는 모션을 찾아 내었다.

본 연구에서는 Zhang의 ICP 알고리즘을 이용하여 모델의 정규화 작업을 수행한다. 그 과정은 크게 세 단계로 구성된다. 우선 해마의 복셀로부터 3차원 골격을 추출한다. 그런 후에 ICP 알고리즘을 적용하여 least square 에러가 최소가 되는 최적의 회전 및 이동 변환 행렬을 계산한다. 마지막으로 이렇게 구해진 변환 파라미터들을 초기의 메쉬 모델에 적용하여 이동 및 회전 변환을 수행함으로써 모델 정규화 과정을 마치게 된다.

본 논문에서는 해마의 이진 복셀로부터 추출한 골격 데이터들을 free-form 커브로 간주한다. 이때 첫 번째 골격 정점 집합을 “Model”[9]이라고 하고, 두 번째 골격 정점 집합을 “Shape”[9]이라고 정의한다. 여기서 “Model”은 절대 변화하지 않는 고정된 커브가 된다. 따라서 “Shape” 정점 집합이 ICP 알고리즘을 통하여 최적의 정합 결과를 갖도록 평가된 회전과 이동 변환들이 적용되는 대상이 된다. 그림 2는 본 연구에서 두 골격 정점 집합을 이용한 모델간 정규화를 수행하기 위해 사용하는 Zhang의 ICP 알고리즘을 나타낸다.

1. Input model shape  $X=\{x_i\}$ , data point set  $Y=\{y_i\} (i=1, \dots, N_k)$
2. Initialize the follows
  - 1)  $D_{max} = \text{larger } D$
  - 2) Compute the tangent at each point of “Model” and “Shape”
  - 3)  $Y_0=Y, H=I$  (Identity transformation),  $k=0$
3. Iteration // until convergence of the computed motion
  - 1) Find the closest points:  $Z_k = C(Y_k, X)$
  - 2) Pseudo point matching
  - 3) Updating the matching
  - 4) Compute the motion:  $(H_k, d_k)=M(Y_0, Z_k)$
  - 5) Apply the motion to all points:  $Y_{k+1}=H_k(Y_0)$
  - 6) Terminate when  $d_k-d_{k+1} < \text{threshold}$

그림 2 골격 정점 집합들에 적용한 ICP 주요 과정

해마 모델로부터 추출된 두 개의 골격  $C_i (i=1, \dots, m)$ 와  $C_k (k=1, \dots, n)$ 이 주어졌을 때, 모델 정규화를 수행하기 위해서는 두 골격이 일치하기 위한 모션을 정의하는 이동 변환  $t$  및 회전 변환  $R$ 을 찾아주는 목적함수가 필요하다. 식 1은 목적함수를 정의한 것이다.  $d(x, C)$ 는 정점  $x$ 에서 커브  $C$ 에 이르는 거리를 나타낸다.  $p_{i,j}$ 는  $x_{i,j}$ 가 커브  $C$ 에 대하여 closest point를 가질 경우 값 1을 취하고 그렇지 않을 경우 값 0을 취한다( $q_{k,i}$ 에도 적용됨). 함수  $F$ 의 값이 최소화될 때 최적의 정합 결과를 가져 온다. 식 1의 함수  $F$ 의 최소화는 식 2의 결과가 최대가 될 때 수렴한다.

$$F(R, t) = \sum_{j=1}^m \sum_{i=1}^{N_j} p_{i,j} d^2(Rx_{i,j} + tC'_k) + \sum_{k=1}^n \sum_{l=1}^{N_k} q_{k,l} d^2(R^T x'_{k,l} - R^T t, C_l) \quad (1)$$

$$\sum_{i=1}^m \sum_{j=1}^{N_j} p_{i,j} + \sum_{k=1}^n \sum_{l=1}^{N_k} q_{k,l} \quad (2)$$

식 3은 해마로부터 추출되는 두 개의 골격 정점 집합으로부터 closest points를 결정한다.  $x$ 는 정합을 위한 변환 대상인 “Shape” 정점 집합의 각각의 요소가 되고,  $C'_k$ 는 고정된 형태의 “Model” 정점 집합이 된다. 따라서  $x$ 와  $C'_k$ 의 모든 정점들 사이에서 가장 작은 직선거리 값을 갖는 “Model” 정점 집합상의 요소를 찾는 것이 closest point를 찾는 핵심이다.

$$d(x, C'_k) = \min_{l \in \{1, \dots, N_k\}} d(x, x'_{k,l}) \quad (3)$$

Pseudo point matching은 closest points 계산 후에 결정되는 정점쌍 집합에 여러 제약 조건을 부여하여 잘못된 정점쌍을 제거하기 위한 방법으로써, 제약 사항으로서 정점간 거리에 대한 최대 수용값인  $D_{max}$ 와 방위의 견고함을 보장하기 위한 제한각  $\theta$ 를 적용한다. 본 방법에서는 이 방법을 사용하여 정점쌍의 거리값들에 대한 통계치를 분석하여 일부를 매칭 작업에서 제외시킨다. “Model” 정점들과 “Shape” 정점들로부터 계산된 closest points, 그리고 그것들로부터 구해진 거리값들을 각각  $\{x_i\}$ ,  $\{y_i\}$ ,  $\{d_i\}$ 라고 할 때,  $\{d_i\}$ 의 중간값과 편차를 계산함으로써, 정합의 진행 정도에 따라서  $D_{max}$ 의 값을 유연하게 변경하여 매칭 작업에 적용하도록 한다. 식 4는  $\{d_i\}$ 로부터 계산되는 중간값  $\mu$ 과 편차  $\sigma$ 를 정의한 것이다. 그리고 그림 3은  $D_{max}$ 의 값을 중간값과 편차를 이용해서 변경하는 알고리즘을 기술한 것이다.

$$\mu = \frac{1}{N} \sum_{i=1}^N d_i \quad (4)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (d_i - \mu)^2}$$

```

If  $\mu < D$  // the registration is quite good
     $D_{max} = \mu + 3\sigma$ 
Else If  $\mu < 3D$  // the registration is still good
     $D_{max} = \mu + 2\sigma$ 
Else If  $\mu < 6D$  // the registration is not too bad
     $D_{max} = \mu + \sigma$ 
Else // the registration is quite good
     $D_{max} = \xi$  //  $\xi$  is the median of all the distances
Endif

```

그림 3 매칭 정점 집합을 수정하는 알고리즘

본 연구에서 적용한 ICP 방법은 “Model” 데이터의 정점 수에 따라서 그 전체 탐색 시간이 선형으로 증가한다. 따라서 “Model” 데이터와 “Shape” 데이터의 정점들을 구성하는 골격 표현을 다해상도로 구성하여 coarse-to-fine 전략을 이용하여 정규화 작업의 소요 시간을 줄인다. 우선 ICP의 첫 몇 번 동안의 반복과정에서는 낮은 해상도를 갖는 골격 샘플들을 매칭 작업에 사용하고, 알고리즘이 최소치에 수렴할 때, 정확한 정규화를 위해 사용 가능한 모든 골격 정점들을 사용한다.

### 3.3 전역 및 국부적 형상 분석 방법

본 연구에서는 자동화된 전역적 형상 분석뿐만 아니라 인터랙티브한 국부적 형상 분석 방법을 제공하기 위하여 옥트리 자료구조에 저장된 메쉬, 골격 표현으로부터 샘플 메쉬들을 생성하고, 이렇게 추출된 형상 특징 데이터에 대하여  $L_2$  Norm을 계산한다.

형상 특징 추출 과정은 골격점과 원형 맵의 정점들이 이루는 광선과 오브젝트 메쉬간의 충돌을 검사하는 방법으로 진행된다. 우선 시스템 초기화 과정에서 골격점과 광선의 개수를 지정하고 해당 골격점 각각에 대하여 원형 맵을 구성하여 각 골격점을 원점으로 하여 광선을 방사한다. 방사된 모든 광선은 모델을 구성하는 메쉬들과 충돌되는지 검사되고, 충돌 감지된 메쉬들이 거리에 따라 계산하기 위해 사용된다.

국부적 형상 분석 방법에서는 사용자의 마우스 피킹

인터랙션에 따라 샘플 매쉬를 포함하고 있는 옥트리의 세부 노드나 3차원 골격점을 지정하여 관심 영역에 대한 형상 변형 정도를 평가한다.

3 차원 형상 모델간의 형상적 차이를 정량적으로 측정하기 위해서는 유사 정도를 평가하는 측도가 필요하다. 따라서 본 연구에서는 기본적인 어파인 변환들(회전, 이동, 스케일)에 강인한 특성을 보이는  $L_2$  Norm을 측도로 이용한다.  $L_2$  Norm은 입력된 두 모델로부터 추출한 3차원 형상 특징인 샘플 매쉬간 거리를 측정하기 위해 사용된다. 식 6은  $L_2$  Norm을 정의한 것이다. 본 논문에서는  $L_2$  Norm의 입력으로 비교 대상이 되는 두 모델의 샘플 매쉬의 중심점을 선택한다.

$$L_2(x, y) = \left( \sum_{i=0}^t |x_i - y_i|^2 \right)^{1/2} \quad (6)$$

### 3.4 신경망 알고리즘 기반의 분류기

본 논문에서는 해마 조직에 대한 3차원 형상적 변화를 정량적으로 평가하고 그 결과를 정성적으로 시각화함으로써 해마와 그 조직과 관련된 정신 질환간의 상관관계를 평가한다. 이렇게 분석된 결과들은 최종적으로 임의의 해마 조직 예제에 대하여 해당 모델이 정신 질환 환자 집단과 정상인 대조 집단 중 어느 곳으로 분류되어야 하는지를 결정하는데 이용된다. 따라서 본 장에서는 정상인과 정신 질환 환자들을 분류하기 위한 분류기로서 신경망 기반의 분류기를 설계하고 구현한다.

인공 신경망은 실제 인간과 흡사한 구조와 기능을 갖는 수학적 모델로서, 패턴 인식이나 분류기, 데이터 압축 및 최적화 등에 널리 응용되고 있다. 본 연구에서는 감독 학습 방법을 기반으로 하는 역전파 신경망 알고리즘을 이용하여 정상인과 정신 질환 환자들을 해당 집단으로 분류하는 방법을 채택한다. 그림 4는 본 논문에서 설계한 역전파 신경망의 전체구조를 나타낸다. 그림 4에서의 입력 레이어는 총 80개의 입력 유닛으로 구성된다. 그리고 입력 레이어의 입력 값들로 골격 데이터를 사용한다. 그리고 신경망의 중간에는 하나의 히든 레이어를 갖는다. 히든 레이어를 구성하는 유닛의 수는 입력

유닛에서 히든 유닛으로의 유닛 감소율과 히든 유닛에서 출력 유닛으로의 유닛 감소율이 같도록 구성한다. 최종 출력 레이어는 해마 모델을 그룹화하는 경우의 수가 2가지뿐 이기 때문에 하나의 유닛으로 구성된다. 출력 레이어로부터 결정되는 출력값은 정상해마와 환자해마의 구분을 결정하는 Activation Function의 입력값으로 사용된다. 본 연구에서는 정상인 해마의 경우 1.0의 값을 갖도록 하고 환자 해마의 경우 0.0의 값을 갖도록 하였다.




그림 4 해마 집단 분류 위한 역전파 신경망의 전체구조

신경망 기반의 분류기를 구축하기 위하여 본 연구에서는 템플릿으로 정상인과 간질 환자의 해마 모델 2개와 함께 각 모델들을 국부적으로 변형시킨 총 80개의 학습 및 테스트 데이터를 구성하였다. 본 연구에서는 실제 환자 및 정상인의 해마 임상 데이터를 얻기 쉽지 않았기에 신경망에서의 cross-validation 기법을 사용하여 신경망 학습을 수행할 수 있을 만큼의 학습 데이터와 테스트 데이터를 구성하였다. 이 방법은 학습 데이터와 테스트 데이터의 비율을 9 대 1 정도로 구성한 후, 각 데이터들을 섞어서 학습 및 테스트를 위한 데이터의 크기를 10배 정도 증가시켰다. 본 방법은 수집한 훈련 데이터들을 하나씩 차례대로 입력하면서 입력된 모델이 정상인 해마에 가까운지 환자의 해마에 가까운지를 알려주는 target 값을 동시에 입력한다. 이때 출력 유닛에서 발생하는 에러값을 신경망의 입력과 출력 사이에 존재하는 가중치 값들을 변경시키는데 사용함으로써 학습을 수행한다. 학습 완료 후에 준비된 80개의 테스트 데이터를 이용하여 정상인과 환자의 해마를 분류 빈도를 계산함으로써 분류기의 정확도를 평가한다.

#### 4. 실험 및 결과

본 장에서는 크게 두 가지의 실험을 수행하였다. 첫째로 해마 모델들에 대하여 ICP 기반의 모델을 정규화한 결과를 통하여 채택한 알고리즘의 성능을 평가하고, 또한 정상인 집단과 간질 환자 집단간의 분류를 담당하는 신경망 기반의 분류기의 성능을 테스트 하기 위한 결과를 제공한다. 실험을 위하여 정상인과 간질 환자의 해마 자기공명영상으로부터 마칭큐브 기반의 그리드 1과 그리드 2의 두 가지 해상도를 갖는 템플릿 매쉬 모델을 생성하였다. 그리고 추가적으로, 템플릿 모델에 대하여 국부적으로 크기를 변형시킴으로써 총 80개의 모델을 ICP 알고리즘을 이용한 형상 분석 실험 신경망 기반의 분류기 작동 실험에 적용하였다. 그림 5는 형상 분석의 실험에 사용한 모델들의 일부를 보여 준다.





그림 5 정상인과 간질환자의 해마 실험 모델 예시

그림 6은 3차원 해마 모델에 대한 다해상도 골격 표현을 보여 준다. 이 표현은 형상 분석을 위한 형상 특징의 추출에 사용된다. 또한 ICP 기반의 모델 정규화를 위한 입력 정점 집합으로 사용되며, 신경망 기반의 분류기의 학습을 위한 입력으로도 사용된다. 그림 6의 (a)부터 (c)는 정상인의 오른쪽 해마 모델로부터 각각 6개, 30개, 100개의 골격 정점의 수를 달리하여 추출한 골격 표현을 나타낸다. 빨간색은 “Model” 정점 집합이고, 파란색은 “Shape” 정점 집합이다. 그리고 보라색 정점들은 “Model”과 “Shape” 정점들이 겹쳐져 있음을 보여 준다. 본 연구에서는 이처럼 다양한 해상도를 갖는 골격 표현을 사용하여 해마의 형상 분석과 ICP 기반 모델 정규화, 그리고 신경망 기반의 분류기 훈련 방법 등에 coarse-

to-fine 전략을 적용한다.



(a) 6개 정점을 갖는 골격 (b) 30개 정점을 갖는 골격 (c) 100개 정점을 갖는 골격

그림 6 해마모델로부터 생성된 다해상도 골격 표현

ICP 기반의 모델 정규화 방법의 성능을 평가하기 위하여 본 실험에서는 해마 모델로부터 추출한 다해상도 골격 샘플들에 대하여 최적의 정합 변환 (회전, 이동)을 계산하고, 해당 변환 결과를 매쉬 모델에 적용하였다. 그림 7은 골격 정점의 개수에 따른 모델 정합 결과를 보여준다. 그림 7에서 (a)부터 (d)까지의 각 그림의 왼쪽은 정규화 이전의 모델들이고, 오른쪽은 정규화 이후의 모델들이다. “Model” 모델은 빨간색으로, “Shape” 모델은 파란색으로 표시하였고, 직관적인 정합 결과를 확인하기 위하여 각 모델에 투명도를 부여하였다. 실험 결과를 통해서 본 연구에서 구현한 정규화 방법은 골격 해상도와 무관하게 거의 유사한 정규화 결과를 보여 준다. 그림 8은 골격 해상도에 따른 정규화 소요 시간을 측정된 결과이다. 결과적으로 본 방법은 골격의 해상도와는 무관하게 균일한 처리 시간을 보장한다.




그림 7 골격 해상도에 따른 정규화 결과




그림 8 골격 해상도에 따른 ICP 알고리즘 속도 비교

본 연구에서는 전역적인 분석뿐만 아니라 옥트리와 골격을 이용한 계층적이고 국부적인 형상 분석 방법을 제공한다. 그림 9는 정상인 오른쪽 해마 모델과 간질 환자 오른쪽 해마 모델간의 형상 차이를 전역적인 접근 방법과 국부적인 접근 방법(골격 기반, 옥트리 기반)들을 이용한 평가 결과를 보여 준다. 그림 9의 (a)는 전역적 형상 분석 결과이고, (b)와 (c)는 각각 골격과 옥트리를 이용한 국부적 형상 분석의 결과를 보여준다. 전역적 형상 분석은 자동화 과정으로 이루어진다. 그에 반해 국부적 형상 분석은 사용자의 마우스 피킹 인터랙션 기법을 활용하여 골격점을 포함하는 평면상의 메쉬 형상에서의 국부적 형상 변형 정도를 파악하거나, 옥트리를 구성하는 노드 공간을 계층적으로 접근함으로써 관심 영역에 대한 세밀한 형상 분석을 가능하도록 한다.



그림 9 해마에 대한 전역적-국부적 형상분석 결과

표 1은 정상인의 왼쪽 해마(N\_L)와 N\_L의 위쪽 부위를 변형한 해마 모델(T1, T2, T3) 사이의 동일 그룹간 전역적 형상의 변화 정도를 평가한 결과이다. 표 1을 통하여 대상 모델 T1과 T3이 참조 모델 N\_L에 비하여 전역적 범위에서 각각 5.7%와 11.2% 정도 작은 형상을 가지며, T2는 9.3% 정도 큰 형상을 가짐을 정량적으로 평가할 수 있었다. 표 2는 참조 모델(P\_L, N\_R)과 변형된 대상 모델(T4 ~ T9)간의 국부적 형상을 분석한 결과를 요약한 것이다. P\_L과 N\_R은 각각 간질 환자의 왼쪽 해마와 정상인의 오른쪽 해마 모델이다. 또한 T4부터 T9는 각각 특정한 부위(그림 9-c 참조)에서의 형상 변형을 적용한 모델들이다. 표 2에 제시된 결과를 통하여 형상이 변형된 부위에서의 에러가 그 외의 에러 값들보다 높게 나타남을 알 수 있다. 이것은 본 연구에서 제안한 형상 분석 방법이 특정한 국부적 부위에서의 형상적 차이를 정확하게 평가할 수 있음을 보여 준다.

표 1 동일 해마 그룹간 전역적 형상 분석

	$L_2$ Norm	볼륨 차이	순위
N_L:T1	1.220	94.3%	1
P_L:T2	1.554	109.3%	2
N_L:T3	2.420	88.8%	3

표 2 정상인과 간질 환자의 해마의 국부적 형상 분석

	A	B	C	D	E	F	G	H
P_L:T4	0.15	0.77	0.84	3.15	0.00	0.00	0.00	0.15
P_L:T5	1.20	0.00	0.00	0.00	3.12	2.00	1.00	1.44
P_L:T6	0.09	0.05	0.16	0.42	0.62	0.05	0.35	2.28
N_R:T7	0.00	0.00	0.00	0.00	1.54	1.31	1.313	1.54



N_R:T8	0.06	1.02	0.06	0.00	0.00	0.12	0.00	0.00
N_R:T9	0.96	1.02	0.00	0.00	0.00	0.11	0.00	0.00

그림 10은 역전과 구조를 갖는 신경망 기반의 분류기를 이용하여 40개의 정상인 해마 모델 집단과 간질 환자의 해마 모델 집단간의 분류한 실험의 결과를 보여 준다. 그림 10을 통하여 본 방법은 학습 횟수가 증가할수록 출력 에러가 0에 수렴하고, 동시에 집단 분류의 정확도가 100%에 수렴하는 것을 확인 할 수 있다.




그림 10 신경망 기반의 분류 실험 결과

## 5. 결론 및 향후 연구 과제

본 연구에서 제안한 전역적, 국부적 형상 분석 방법은 실제 간질 환자와 정상인의 뇌 영상으로부터 구축된 3차원 해마 모델로부터 생성된 다해상도의 골격 데이터를 사용한 ICP 기반 모델 정규화 작업을 통하여 정확하면서도 계산 시간을 줄일 수 있는 형상 분석 작업을 가능하게 하고, 분석 대상이 되는 3차원 메쉬 모델을 intermediate 복셀과 골격 데이터와 통합함으로써 coarse-to-fine 형태의 형상 표현을 제안한다. 그리고 해마의 전역적 표면 영역에서의 세밀한 변화를 반영하기 위하여 옥트리 기반의 자료 구조를 형상 분석에 사용하여 전역적 형상 분석뿐만 아니라 사용자 인터랙션을 포함한 계층적인 국부적 형상 분석을 가능하게 한다. 또한 이러한 분석 과정에서 생성되는 골격 정점과 샘플 메쉬간 거리값들을 정상인과 간질 환자 집단간 분류를 위한 학습에

활용함으로써 강인한 분류 방법을 제공한다.

향후 연구 과제로는 첫째, 본 연구에서 채택한 ICP 정규화 알고리즘은 형상의 전역적인 범위에서의 최적화를 보장한다. 하지만 해마의 특정 부위가 급격히 변형된 경우에는 국부적인 최적화 경향을 보였다. 따라서 향후에는 간질이나 치매와 같은 정신 질환에서 중요하게 고려되어야 하는 형상 부위에 가중치를 부여하여 해당 부위에서의 정확한 정합을 보장하는 수정된 형태의 ICP 알고리즘을 형상 정규화에 적용할 것이다.

둘째, ICP 알고리즘, 형상 분석 방법 그리고 신경망 기반의 분류기 구축 방법에 대한 임상 실험 데이터를 충분히 확보해야 한다. 따라서 두 방법에 적용할 좀더 많은 임상 데이터를 수집하여 신뢰성 있는 결과를 제공할 것이다.

마지막으로 본 논문에서 제안한 신경망 기반의 분류기가 물론 정상인과 환자 집단간의 정확한 구분 방법을 제공하지만, 결국 이 분류기의 학습에는 오직 10%의 실제 임상 데이터만이 이용되었다. 따라서 신뢰성 있는 집단간 분류 방법을 구현하기 위해서는 지속적으로 다양한 분류기 학습 알고리즘을 적용해봄으로써, 적은 수의 학습 데이터들을 이용하면서도 강력한 분류 기능을 제공하는 새로운 방법을 개발할 필요가 있을 것이다. 따라서 향후에는 해마에 대한 실제 임상 데이터들을 충분히 수집한 후에 Support Vector Machines (SVM) 알고리즘을 본 연구에 적용하여 현재 구현된 신경망 기반의 방법과의 비교 평가 작업을 수행할 것이다.

## [감사의 글]

본 논문은 과학기술부 국가지정연구실 사업(M1-0204-00-0169)과 한국학술진흥재단 (KRF-2005-205-D00105)의 지원으로 수행되었습니다

## [참고문헌]

[1] K. Jeong-Sik, C. Soo-Mi, C. Yoo-Joo and K. Myoung-Hee, Global and Local Shape Analysis of the

Hippocampus based on Level-of-Detail Representations, LNCS, Springer-Verlag, 2004. 12.

[2] C.R. Jack. MRI-based hippocampal volume measurements in epilepsy, *Epilepsia*, 35: S21-S29, Suppl. 6 1994.

[3] C.R. Jack, M.D. Bentley, C.K. Twomey, et al. MR imaging-based volume measurements of the hippocampal-formation and anterior temporal-lobe-validation studies, *Radiology*, 176(1): 205-209, July 1990.

[4] D. Dean, P. Buckley, F. Bookstein, J. Kamath, D. Kwon, L. Friedman and C. Lys. Three dimensional MR-based morphometric comparison of schizophrenic and normal cerebral ventricles, *Vis. In Biom. Computing, Lecture Notes in Comp. Sc.*, p. 363-372, 1996.

[5] C. brechbühler, G. Gerig, and O. Kübler, Parametrization of closed surfaces for 3-D shape description, *Computer Vision, Graphics, Image Processing: Image Understanding*, Vol. 61, pp. 154-170, 1995.

[6] S.Pizer, D. Fritsch, P. Yushkevich, V. Johnson, and E. Chaney, Segmentation, registration, and measurement of shape variation via image object shape, *IEEE Trans. Med. Imaging*, Vol. 18, pp. 851-865, 1999.

[7] Shenton ME, Gerig G, McCarley RW, Szekely G, Kikinis R, Amygdala-hippocampal shape differences in schizophrenia: the application of 3D shape models to volumetric MR data, *Psychiatry Research Neuroimaging*, Vol. 115, pp. 15-35, 2002.

[8] M. Styner, J. A. Lieberman, G. Gerig, Boundary and Medial Shape Analysis of the Hippocampus in Schizophrenia, *MICCAI*, No. 2, pp. 464-471, 2003

[9] P.J. Besl and N.D. McKay, A Method for Registration of 3-D Shapes, *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 14, no. 2, pp. 239-256, Feb. 1992.

[10] Z. Zhang. Iterative point matching for

registration of freeform curves and surfaces. *International Journal of Computer Vision*, 13(2):119-152, 1994.