

2 단계 결정트리 학습을 이용한 뇌 자기공명영상 분류

(Classification of Brain Magnetic Resonance Images using 2 Level Decision Tree Learning)

김형일[†] 김용욱[‡]

(Hyungil Kim) (Yonguk Kim)

요약 본 논문에서는 뇌 자기공명영상을 분류하기 위하여 결정트리 알고리즘을 2 단계로 적용하는 영상 분류 시스템을 제안한다. 영상으로부터 얻을 수 있는 정보에는 두 종류가 있다. 하나는 크기, 색상, 질감, 윤곽선 등 영상으로부터 직접 얻을 수 있는 하위레벨 특징들이고, 다른 하나는 특정 객체의 존재 유무, 여러 부위 사이의 공간적 관계 등 분할된 영상들에 대한 해석을 통해서 얻을 수 있는 상위레벨 특징들이다. 의미에 따라 영상을 분류하기 위해서는 상위레벨 특징들을 기반으로 학습 및 분류가 수행되어야 한다. 제안하는 시스템에서는 결정트리 학습을 각각의 레벨에 개별적으로 적용하며, 하위레벨 분류 결과를 이용하여 상위레벨의 특징을 추출한다. 종양이 있는 뇌 자기공명영상 집합에 대하여 분류 실험을 수행하였으며, 몇 가지 실험 결과를 통해 제안된 시스템의 효과를 확인하였다.

키워드 : 의료영상, 내용기반 영상검색, 자기공명영상, 결정트리, 기계학습

Abstract In this paper we present a system that classifies brain MR images by using 2 level decision tree learning. There are two kinds of information that can be obtained from images. One is the low-level features such as size, color, texture, and contour that can be acquired directly from the raw images, and the other is the high-level features such as existence of certain object, spatial relations between different parts that must be obtained through the interpretation of segmented images. Learning and classification should be performed based on the high-level features to classify images according to their semantic meaning. The proposed system applies decision tree learning to each level separately, and the high-level features are synthesized from the results of low-level classification. The experimental results with a set of brain MR images with tumor are discussed. Several experimental results that show the effectiveness of the proposed system are also presented.

Key words : Medical Image, Content-based Image Retrieval, Magnetic Resonance Image, Decision Tree, Machine Learning

1. 서론

80년대에는 기존에 존재하던 의료 관련 문서 및 영상과 같은 데이터들이 의료 정보화의 흐름을 타고 HIS(Hospital Information System), RIS(Radiology Information System), PACS(Picture Archiving and Communication System) 등과 같은 다양한 의료 관련 시스템들로 개발되었으며, 이를 시스템들은 각각의 고유

한 목적과 기능을 갖추고 있다. HIS는 진료 기록, 환자 기록 등과 같은 병원 업무를 관리하는 시스템이고, RIS는 방사선과에서 활용한 영상을 컴퓨터로 저장 및 검색하는 시스템이며, PACS는 병원의 내부 네트워크를 통하여 영상 자료를 주고받는 시스템이다. 90년대 중반 이후 정보의 중요성에 대한 인식이 높아지면서 정보화 관련 산업이 급성장 하였고, 이에 따라 컴퓨터 및 인터넷 그리고 광통신망의 보급이 급증하였다. 이러한 세계적인 흐름에 따라 이를 의료 시스템도 발전하였으며, 근래에 시도하고 있는 의료 정보 통합 시스템이 좋은 예이다.

이러한 통합 시스템은 임상 진료 자료뿐만 아니라 의료 영상도 공유함으로써 진료 및 연구에 도움을 줄 수 있고, 네트워크를 통해 연결된 시스템 간의 수많은 데이

[†] 정회원 : 동국대학교 컴퓨터공학과 교수
hikim@dongguk.edu

[‡] 학생회원 : 동국대학교 컴퓨터공학과
yukim@dongguk.edu

논문접수 : 2006년 6월 19일
심사완료 : 2006년 11월 9일

타를 공유할 수 있다는 장점이 있다. 그러나 X-선(X-ray), 전산화 단층 촬영(CT, computerized tomography) 및 자기공명영상(MRI, magnetic resonance image) 등의 의료 영상은 각 영상의 용량이 크고 한 사람에게서 수십장을 촬영하기 때문에 자료 검색에 많은 시간이 소요된다. 그러므로 이러한 단점을 줄이기 위해서는 의료 영상에 대한 효과적인 영상 검색 및 분류 시스템이 필요하다[1-3].

현재까지 연구된 영상 검색 시스템은 지속적으로 전문가가 개입하는 시스템과 그렇지 않은 자동화 시스템으로 분류된다[4,5]. 전자의 경우는 영상에 대한 논리적인 의미 또는 의견을 전문가가 직접 제시하는 검색 시스템으로 주석기반(annotation-based) 검색 방법이 이에 해당한다[6,7]. 주석기반 검색은 전문가가 직접 영상에 대한 주석을 제시하기 때문에 높은 정확도를 얻을 수 있지만, 수동 작업으로 인한 시간 및 인력 비용의 손실이 크다. 후자의 경우는 영상 자체로부터 특성들을 추출하여 비교하고 검색하는 시스템이다. 이런 시스템의 대표적인 검색 방법은 내용기반 영상 검색(CBIR, content-based image retrieval) 방법이다[8,9]. 내용기반 검색 방법은 초기에 전문가의 조언으로 특성을 분석한다면 자동화 시스템을 구축할 수 있다. 그러나 내용기반 검색은 색상(color), 질감(texture), 모양(shape)과 같이 이미지의 표면적인 정보만을 이용하기 때문에 영상이 나타내는 의미를 정확히 포착하기 어렵다. 최근에는 표면적인 정보 외에 공간 관계나 논리적인 정보를 속성으로 추출하여 사용하는 내용기반 영상 검색 시스템이 제시되고 있지만, 속성들의 특징을 살려서 사용하지 못하고 있다.

본 논문에서는 하나의 영상에 대하여 결정트리(decision tree) 알고리즘을 단계별로 적용하는 영상 분류 시스템을 제안한다. 단계를 분리하는 이유는 초기 단계에서 분류한 결과를 이용하여 다음 단계에서는 초기 단계보다 영상 분류에 논리적이고 의미 있는 특징 추출에 이용하기 위함이다. 본 논문에서 제안한 시스템은 먼저 영상 처리를 수행하여 하나의 영상을 여러 개의 객체들로 조각낸 후, 객체 학습에서 해부학적 명칭에 대한 학습을 수행하고 영상 학습에서 질병에 대한 학습을 수행한다.

첫 번째 단계인 객체 학습은 객체들에서 추출한 색상, 모양 등의 속성들을 이용하여 명칭을 학습한다. 그리고 그 결과로 명칭을 분류하는 모델을 생성한다. 분류 종류는 회백질(white matter), 백질(gray matter), 뇌척수액(CSF, cerebrospinal fluid), 이상 객체로 네 가지이다. 두 번째 단계인 영상 학습에서는 객체의 분류 결과와 객체들 간의 논리적인 속성을 활용하여 질병에 대한 학

습을 수행한다. 논리적인 속성은 이상 객체의 존재와 같이 영상의 의미적인 내용이나 객체들 사이의 공간적인 관계 등을 나타낸다.

본 논문에서 제안한 시스템에서는 결정트리[10-12]를 이용한 학습 모듈을 사용한다. 학습 모듈은 의료 영상을 분류하고 학습하기에 적합한 속성을 추출하고, 이에 따라 객체, 영상 분류 규칙들을 생성한다. 결정트리는 학습 모델 생성이 빠르면서도 규칙으로의 전환 및 결과 모델의 판독이 쉽다는 장점이 있다.

2. 의료 영상 검색

본 장에서는 기본적인 의료 영상에 대한 학습으로써 일반적인 의료 영상이 나타내는 특징을 제시하고, 실험에 사용한 자기공명영상만이 지니는 특징을 설명하며, 대표적인 뇌 질환인 두개강내 종양에 대하여 설명한다. 그리고 영상이 지닌 속성을 추출하는 방법과 추출된 속성들에 대해 설명한다.

2.1 의료 영상의 특징

의료 영상은 병력, 이학적 검사 및 신경학적 검사 다음과으로 질병의 종류, 병소의 위치, 크기, 종류 등을 이용하여 질환을 추측하는데 있어 효과적인 도구이다. 현재 사용하고 있는 의료 영상은 여러 가지가 있으나 대표적인 것은 X-선, 전산화 단층 촬영, 자기공명영상이 있다.

일반적인 의료 영상은 꽃이나 건물처럼 다양한 색상 및 질감을 나타내는 일반적인 영상과는 달리 대부분이 회백색 색상이고 질감의 특징이 두드러지지 않는다[13]. 또한 영상에 나타나는 각 부위가 불확실한 경계를 갖는다. 의료 영상에 나타나는 신체, 혈관 등의 구조적인 형태 및 관계가 매우 복잡하다. 그러므로 그 특징이 나타내는 값들 간의 차이도 미세하다.

본 논문에서 사용한 자기공명영상은 인체에 해가 없는 자석(magnet)과 고주파(radio frequency)만을 이용하여 신체 조직의 원자핵에 핵자기 공명을 일으켜 그 원자핵의 밀도 및 물리화학적 특성을 영상화한 것이다. 자기공명영상은 영상 촬영 요소(parameter)가 다양하고, 공간 해상력(spatial resolution)과 대조 해상력(contrast resolution)이 뛰어나며, 또한 촬영 방향이 다양하다. 자기공명영상은 횡단 영상(axial image) 뿐만 아니라 관상 영상(coronal image)과 시상 영상(sagittal image)들을 얻을 수 있는 장점이 있다. 그러므로 최근에는 중추신경계 질환의 영상진단에서 진단 가치가 높다고 평가하고 있다[14]. 그림 1은 자기공명영상의 예이다[15].

2.2 뇌 질환의 종류

본 논문의 실험에서 사용한 영상은 두개강내 종양(intracranial neoplasm)에 대한 자기공명영상이다. 두개강내 종양이란 뇌조직이나 뇌를 싸고 있는 막으로부터



그림 1 자기공명영상의 예

발생하는 원발성 두개강내 종양(primary intracranial neoplasm)과 두개골이나 그 주변 구조물 또는 두부에서 멀리 떨어진 부위에서 뇌나 경막으로 전이된 이차성 두 개강내 종양(secondary intracranial neoplasm)을 총칭하여 일컫는 말이다.

두개강내 종양은 다른 장기에서 발생하는 종양에 비해 몇 가지 특징이 나타난다. 종양이 견고한 두개골 내에서 발생하므로 종양의 크기가 증가하면서 초기에 신경학적 증상이 나타날 수 있고 두개강내압 항진 증상을 보인다. 또한 종양이 뇌척수액의 흐름을 차단하여 뇌수종을 일으킬 수 있다. 그러나 중추신경계 밖으로 종양이 전이하는 경우는 매우 드물다[13,14]. 또한 두개강내 종양은 전 연령층을 대상으로 할 때 전신에서 발생하는 종양 중에 세 번째로 많이 발생한다. 두개강내 종양이 소아에게 발생하는 비율은 전체 악성 종양의 20~40%를 차지하며, 소아연령층에서는 악성 종양 중에 두 번째로 많이 발생한다.

뇌종양의 형태적인 측면으로 양성 종양과 악성 종양을 구분하면 양성 종양은 통상 구형(spheric)이거나 난형(ovoid)이며, 비교적 잘 한국(well circumscribed)되어 있다. 또한 주위 비종양성 조직과는 명료하게 구분되고 대부분 피막화(encapsulated) 되어 있다. 이에 비해 악성 종양은 양성 종양에 비해 그 형태가 더욱 불규칙하며, 불량하게 한국(poorly circumscribed)되는 성질을 지닌다. 또한 주위 비종양성 조직과 경계가 불명瞭하고 원칙적으로 피막화 되어있지 않다.

2.3 영상 정보를 이용한 검색

컴퓨터를 이용하여 영상을 검색하고 분류하기 위해서는 서로 다른 영상들을 구분할 수 있는 특징 정보를 추출해야 한다. 내용기반 영상 검색 분야에서는 영상을 구별하기 위해 색상, 질감, 모양 등의 정보를 기본적으로 활용한다. 그러나 영상에 대한 검색이나 분류에서는 영상의 표면적인 정보 자체보다는 그 정보들이 종합적으로 결합하여 나타내는 영상의 의미가 더욱 중요하다. 그러므로 본 논문에서 제안한 시스템은 영상에 대해 단계적으로 분석한다. 그리고 분석을 통하여 얻어낸 정보를 영상 하위레벨(low-level) 정보와 영상 상위레벨(high-

level) 정보로 나눈다.

2.3.1 하위레벨 정보의 사용

영상이 내포하는 표면적인 정보를 본 논문에서는 영상의 하위레벨 정보라 한다. 하위레벨 정보는 색상, 질감, 모양, 위치 정보 등과 같이 영상 자체가 지니는 표면적인 정보이기 때문에 영상이 어떤 색상과 모양을 나타내는지는 알 수 있지만, 그 영상이 무엇을 의미하는지는 알 수가 없다. 이는 사람이 영상을 보았을 때 영상의 각 부분의 의미를 인식하기 전까지 얻은 정보와 같다. 이러한 하위레벨 정보의 종류는 크게 색상, 질감, 모양이 있으며, 형태적인 면에서 윤곽선, 원형 정도, 네모난 정도, 면적, 지름, 길이 등이 존재한다[16].

내용기반 영상 검색 방법은 영상으로부터 이러한 하위레벨 정보를 자동적으로 추출하여 검색에 활용하는 방법이다. 이 방법의 특징은 영상 자체로 검색을 수행할 수 있으며, 전문가의 개입이 없는 자동화 시스템을 만들 수 있다는 장점이 있다. 하지만 영상의 의미적인 면이나 논리적인 면을 제외하기 때문에 의미가 같은 다른 모양의 영상이 있을 경우 정확도가 떨어지는 경향이 있으며, 영상이 내포한 의미는 알 수가 없다는 단점이 있다. 예를 들어, 호랑이의 정면 영상을 이용하여 영상을 검색했을 경우, 호랑이의 옆모습이 담긴 영상은 검색되지 않는다는 것이다.

하위레벨 속성을 이용한 영상 검색 시스템으로는 QBIC, VIR, Visual Retrieval Ware 등이 있다. QBIC(query by image content)은 IBM에서 개발한 영상 검색 시스템으로 사용자가 색상 비율, 분포, 위치 및 그래픽으로 표현된 영상 질감을 이용하여 영상을 검색할 수 있도록 하였다[5].

2.3.2 상위레벨 정보의 사용

영상을 구성하는 객체들 간의 논리적인 구조나 관계는 영상이 나타내는 의미(semantic) 정보를 내포하고 있다. 이를 본 논문에서는 영상 상위레벨 정보라고 한다. 영상의 상위레벨 정보의 종류에는 각 객체 간의 거리, 전체 영상 상에서 각 객체의 방향, 각 객체의 겹침 정도, 제한적인 도메인에서는 객체의 위치를 통한 객체 명칭 등 여러 가지가 있다.

기준이 주석기반 영상 검색에서는 사용자가 직접 영상의 논리적인 속성, 영상 설명, 영상 분류 체계 등의 상위레벨 정보를 구성하여 분류 및 검색하는 방법을 적용하였다. 이 접근 방법은 의미 있는 정보를 추출하고 이에 따라 검색 및 분류를 수행하기 때문에 높은 정확도를 얻을 수 있는 장점이 있다. 그러나 대부분 논리적인 속성을 추출하는데 전문가의 도움이 필요하고, 유사한 영상 간의 적절한 의미나 단어 선정이 어렵기 때문에 주관적이라는 단점이 있다.

반면 최근에는 내용기반 방법을 사용하면서 반자동 또는 자동적으로 영상의 상위레벨 정보를 추출하려는 시도가 늘고 있다. 이러한 예로는 ASSERT, KMeD 시스템이 있다[3]. ASSERT는 폐 부위에 대한 HRCT (high resolution computed tomography) 영상을 검색하는 시스템이다[18]. 의료 영상에서는 질환 부위가 영상 검색에 중요한 요소인데, 영상 처리만으로는 질환 부위를 알 수 없다. 그러므로 ASSERT는 전문의가 수작업으로 질환 부위를 표시하고 그 영역에 대한 하위레벨 속성을 추출하여 영상 검색에 활용한다. 이 시스템은 영상 검색을 위하여 색상에 대한 히스토그램의 평균과 편차, 절감에 대한 명암과 동질성, 윤곽선의 면적과 폐의 소엽으로부터의 거리 정보들을 속성으로 사용한다. 그리고 영상 간의 유사도 측정을 위해 유클리드 거리(euclidean distance)를 활용한다. ASSERT는 전문가가 질환과 영상 내에서의 질환 부위에 대한 정보를 제공하기 때문에 동일한 질환에 대한 서로 다른 형태의 영상이라도 효과적으로 검색할 수 있다. 그러나 지속적으로 전문가가 개입해야 하는 단점이 존재한다. KMeD(Knowledge-based Multimedia Medical Distributed Database) 시스템은 영상과 문자를 사용하여 의료용 멀티미디어 분산 DB에 질의하는 시스템으로 영상 처리 시 기본 속성으로 윤곽선(contour), 면적(area), 원형률(circumference), 모양 등을 사용하고 논리적 속성으로 객체 쌍으로부터 방향(direction) 등을 사용한다. 분류 방법은 자체 개발한 사례-기반(Instance-based) MDISC (Multiple Distribution Sensitive Clustering) 알고리즘을 사용하고, 결과로 TAH(Type Abstraction Hierarchy)를 생성한다[17].

3. 결정트리를 이용한 의료 영상 학습 및 분류

본 장에서는 의료 영상 데이터를 학습할 때 사용하는 알고리즘을 설명하며, 하위 및 상위레벨에 대한 각 속성 추출 방법과 그에 따른 단계적 학습 및 분류 방법을 제시한다. 학습 전의 영상 처리 단계에서는 입력된 영상을 정규화하고, 영상을 구성하는 각 부위를 단면화한다. 이 때 분할하기 전의 원본 영상에서 얻은 하위레벨 속성을

전역 영상(global image) 속성이라 하고, 원본 영상을 전역 영상이라 한다. 분할된 작은 영상에서 얻은 하위레벨 속성을 지역 영상(local image) 속성 또는 객체 속성이라 하고, 분할된 작은 영상을 지역 영상 혹은 객체라 한다. 이 두 가지 종류의 영상 속성 중에 전역 영상 속성은 영상 학습에서 각 객체의 관계를 추출할 때 사용하고, 객체 학습에서는 지역 영상들의 하위레벨 속성만 사용한다.

3.1 결정트리 학습

조건에 따라 데이터를 분할-정복(divide and conquer) 방식으로 분류하여 결과 클래스를 얻을 수 있도록 만든 트리를 결정트리라고 한다. 결정트리는 일반적으로 현실 세계에서 추출할 수 있는 데이터에 대해 뛰어난 성능을 보이며, 규칙으로의 전환이 쉬운 것이 특징이다[11,12].

결정트리 알고리즘은 결과를 분류할 수 있는 최적의 트리를 생성하는 것이 목적이다. 결정트리에서는 속성을 선정하는 순서가 중요하다. 왜냐하면 속성 선정 순서에 따라 트리의 복잡도가 달라지기 때문이다.

결정트리 알고리즘에서 속성 순서를 결정하기 위하여 주로 사용하는 방법은 엔트로피(entropy)를 이용하는 것이다. 엔트로피 값은 식 (1)과 같이 정의된다. 식 (1)에서 S 는 전체 데이터 집합이고 c 는 클래스를 나타낸다. P_i 는 전체 데이터 집합 S 에 대한 i 번째 클래스(c) 집합의 확률이다.

$$\text{Entropy}(S) = \sum_{i=0}^c (-p_i \log_2 p_i) \quad (1)$$

엔트로피란 현재 상태에서 서로 다른 부류의 클래스들이 섞여 있는 정도를 의미한다. 즉, 여러 종류의 클래스들이 섞여 있을수록 엔트로피는 높으며, 섞여있는 각 클래스들의 데이터 수가 비슷할 때 엔트로피는 더 커진다.

정보 획득(information gain)은 현재 상태에서 어떤 속성 하나를 선정하여 데이터를 분류하였을 때 엔트로피가 줄어든 정도이다. 엔트로피가 줄어든 정도가 높다는 것은 그 속성을 사용하였을 경우 그만큼 데이터를 명확하게 분류할 수 있다는 것을 의미한다. 그러므로 속성을 선정하기 위해서는 현재 상태에서 각 속성에 대하여 정보 획득값을 구하고 그 중 값이 가장 높았던 속성을 먼저 선정하여 데이터를 분리하여야 한다. 정보 획득값은 엔트로피 감소량의 기대치로 식 (2)와 같이 계산된다.

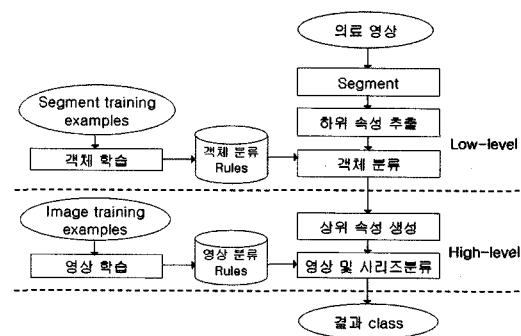
$$\text{Gain}(S, A) = \text{Entropy}(S) - \sum_{v \in \text{Values}(A)} \frac{|S_v|}{|S|} \text{Entropy}(S_v) \quad (2)$$

식 (2)에서 S 는 전체 데이터 집합을 의미하며, A 는

속성을 의미한다. $Gain(S, A)$ 는 전체 데이터 집합 S 에서 속성 A 를 선택하여 분류하였을 경우, 얻을 수 있는 정보 획득량을 의미한다. v 는 속성 A 에 속하는 각각의 속성 값들을 의미하며, S_v 는 속성 A 의 특정 속성 값 v 를 지니는 데이터들의 집합이다. 그리고 $Entropy(S_v)$ 는 S_v 에 대한 엔트로피이다.

3.2 학습 및 분류 레벨의 분리

본 논문에서 활용한 결정트리는 영상에서 추출한 내용기반 하위레벨 속성을 이용하여 객체 학습을 수행하고, 객체 분류 규칙을 생성한다. 그리고 결정트리는 객체 분류의 결과를 활용하여 상위레벨의 속성을 추출하고, 상위레벨 속성을 이용해 영상 학습을 수행하여 영상 분류 규칙을 생성한다. 이와 같이 단계적 결정트리를 사용하는 이유는 속성들의 특성을 최대한 유지하고 효과적으로 영상을 검색하기 위함이다. 그림 2에 단계적 학습 및 분류 과정을 나타내었다.



3.3 객체 학습 및 분류

객체 학습의 목적은 영상 객체의 해부학적인 명칭에 대한 규칙을 생성하여 뇌 구조와 형태에 대한 지식베이스를 생성하는 것이다. 영상은 영상 처리를 통하여 회백질, 백질, 뇌척수액 부위로 분할된다. 결정트리는 영상

처리를 통하여 얻은 조각난 영상 객체의 하위레벨 정보를 입력받아 학습하고, 조각난 객체들의 해부학적인 명칭을 분류할 수 있는 규칙(rule)을 생성한다.

하위레벨 속성으로 사용하는 것은 표 1에 나타난 것처럼 윤곽선 길이(contour length), 밝기(bright), 면적(area), 중심점(center), 돌출도(extrusive), 원형률(roundness), MBR(minimum bounding rectangle)이다.

윤곽선 길이는 객체 윤곽선의 픽셀 수이다. 밝기는 각 객체의 256가지 회백색 색상에 대한 히스토그램값 평균이다. 면적은 각 분할된 객체의 전체 픽셀 수이다. 면적 속성을 활용한 이유는 영상의 MBR 좌표값이 같을 경우 면적을 이용하면 객체의 크기와 밀도를 계산할 수 있기 때문이다. 중심점은 각 분할된 객체의 중심을 나타내며, 중심점은 기본적으로 객체의 위치를 나타내고 돌출도와 원형률을 위한 기본 속성으로 활용된다. 돌출도는 객체의 모난 정도로 돌출도를 구하는 방법은 객체의 중심점에서 윤곽선까지의 길이를 구하고 그 길이의 편차를 아래의 식(4)를 이용하여 나타낸다. 만약 객체가 완전한 원형이면 돌출도는 0이다. 돌출도는 원형률과 같이 질환 부위를 구별할 경우에 사용한다. 일반적으로 뇌 영상을 보면 회백질과 백질의 조각난 객체는 모난 정도가 심한 반면 뇌척수액과 종양 부위는 돌출 정도가 심하지 않다. 아래의 수식에서 center는 중심점이고 $contour(x_i)$ 는 윤곽선의 i 번째 좌표값이다. i 의 범위는 1부터 윤곽선 좌표점들의 총수 n 만큼이다. 식 (3)의 average는 평균 거리이다.

$$\text{Average} = \frac{\sum_{i=1}^n \text{Distance}(\text{center}, \text{contour}(x_i))}{n} \quad (3)$$

$$\text{Extrusive} = \frac{\sum_{i=1}^n (\text{Average} - \text{Distance}(\text{center}, \text{contour}(x_i)))^2}{n} \quad (4)$$

원형률은 그 객체가 얼마나 등근 형태인가를 나타낸다. 원형률을 구하는 방법은 식 (7)과 같으며, 이것은 식 (6)에 제시한 객체의 외접원 면적(outercircle)에 대한

표 1 객체에 사용하는 속성

속성	속성 변수 이름	자료형	설명
ID	ID	정수형	환자의 영상 식별값
객체 ID	OID	정수형	각 객체의 식별값
밝기	Bright	실수형	색상 히스토그램 값
면적	Area	정수형	각 객체의 면적
중심점	Center_X Center_Y	정수형	각 객체의 중심점 좌표
돌출 정도	Extr	실수형	객체의 모난 정도
원형률	Round	실수형	객체의 등그런 정도
MBR	MBR_ULX, MBR_ULY MBR_DRX, MBR_DRY	정수형	최소 외접 사각형의 좌표

식 (5)에 제시한 내접원 면적(innercircle)의 비율이다. 만약 객체가 완전한 원형이면 원형율은 1이다. 원형율은 앞서 말한 돌출도와 같이 사용된다. 원형율에 의하면 종양과 같은 이상 부위의 값이 1에 가장 근접한다. 아래의 식에서 *center*는 중심점이고 *contour(*x_i*)*는 윤곽선의 *i* 번째 좌표값이다. *i*의 범위는 1부터 윤곽선 좌표점들의 총수만큼이다.

$$\text{Innercircle} = \text{MIN}(\pi \times \text{Distance}(\text{center}, \text{contour}(\text{x}_i))^2) \quad (5)$$

$$\text{Outercircle} = \text{MAX}(\pi \times \text{Distance}(\text{center}, \text{contour}(\text{x}_i))^2) \quad (6)$$

$$\theta \neq ss = \frac{\text{Innercircle}}{\text{Outercircle}} \quad (7)$$

MBR은 분할된 객체의 최소 외접 사각형의 좌상단과 우하단 좌표이다. MBR로 객체의 전체 영역을 알 수 있다. 그러므로 MBR을 이용하면 백질을 쉽게 구분해 낼 수 있다.

영상 처리를 통해 얻은 하위 속성은 속성 처리 모듈을 통하여 학습기에 적합한 구조로 변환되고, 각 속성은 객체 학습기에 적용되어 객체 분류 규칙을 생성한다. 객체 학습은 신체의 특정 부분인 뇌에 대한 구조와 형태를 학습한다. 학습은 하위레벨 속성만을 이용하여 이루어지고 각 부분의 해부학적 명칭을 구조화하는 것이 목적이다.

객체 학습에서 학습을 통해 생성된 규칙들은 규칙 파일로 저장된다. 이 규칙 파일은 객체 분류에서 객체에 해부학적 명칭을 부여할 때 사용된다. 뇌의 구조는 매우 세밀하고 복잡하기 때문에 본 시스템에서는 백질, 회백질, 뇌척수액, 이상 객체의 기본 구조로 분류한다. 그림 3에 뇌 구조에 따라 조각난 영상 객체와 구축된 규칙을

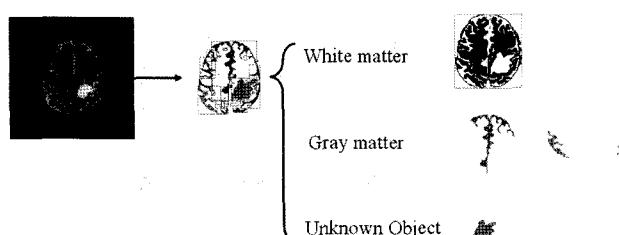
나타내었다.

3.4 영상 형태 학습 및 분류

객체 학습이 이루어진 후, 각 객체와 속성들은 영상 학습에 이용된다. 영상 학습의 목적은 분류된 객체 간의 관계에서 상위레벨 속성을 추출하여 질환이나 형태 등의 특정 의료 영상에 따라 영상 분류를 할 수 있는 결정트리를 생성하는 것이다. 영상 학습에서는 추가 속성 생성기를 사용하여 각 객체 간의 논리적인 관계를 추출한다.

추가적인 속성은 표 2에 나타난 것처럼 뇌척수액 유무, 뇌 영역 중심과 이상 객체 중심 거리, 이상 객체의 방향, 이상 객체와 뇌척수액과의 인접 관계, 분할 객체들의 밝기 비율과 면적 비율 등이 있다.

뇌척수액 유무는 뇌척수액이 존재하는지 그렇지 않은지에 대한 속성이다. 뇌척수액의 존재 유무에 따라 뇌의 중간 부위인지 아닌지를 판별할 수 있다. 또한 뇌 영역의 중심과 이상 객체 중심 사이의 거리를 측정한다. 전체 뇌가 크고 이상 객체가 큰 경우와 전체 뇌가 작고 이상 객체가 큰 경우는 염연히 다르기 때문에 단순히 이상 객체의 면적을 이용하기보다는 이상 객체의 면적 비율을 사용하는 것이 효과적이다. 사람 혹은 활영한 기계에 따라서 영상마다 밝기값이 다르게 나타나며, 이와 같은 이유로 색상을 임의적으로 조정하면 원본 영상을 훼손시킬 가능성이 있기 때문에 각 객체들의 밝기 비율을 사용하는 것이 효과적이다. 방향 정보는 머리 중심에 대한 객체의 방향을 나타낸다. 이것은 그림 4에서 보듯이 머리 중심을 기준으로 뇌를 일정하게 8 방향으로 나눈다. 그리고 객체 중심점이 8 방향 중 어느 구역에 속하는지를 검사하여 방향을 결정하도록 한다. 객체 중심점 위치의 라디안값 측정에는 아크탄젠트를 사용한다.



```

0 IF Bright <= 116.571426 THEN NODE
1   IF Bright <= 114.85714 THEN CLASS white (1731.0/3.0)
1   ELSEIF Bright > 114.85714 THEN NODE
2     IF Len <= 16 THEN NODE
3       IF Bright <= 115.428574 THEN NODE
4         IF Dev <= 6.073622 THEN CLASS white (9.0)

```

그림 3 객체와 분류 규칙의 예

표 2 영상 학습에 사용하는 속성

속성	속성 변수 이름	자료형	설명
ID	ID	정수형	환자의 영상 식별값
객체 존재 유무	ExitofCSF	정수형	뇌척수액의 존재 유무
	ExitofUO	정수형	이상 객체의 존재 유무
면적 비율	AreaRatio_UO	실수형	뇌 전체 면적에 대한 이상 객체의 면적 비율
	AreaRatio_W_G	실수형	백질과 회백질의 면적 비율
밝기 비율	BrightRatio_UO_W	실수형	이상 객체와 백질의 밝기 비율
	BrightRatio_UO_G	실수형	이상 객체와 회백질의 밝기 비율
이상 객체 방위	UO_Direction	문자형	이상 객체의 방위
공간 관계	SpatialRel_CSF_UO	문자형	뇌척수액과 이상 객체 간의 공간 관계
중심 거리	Distance_UO_C	실수형	이상 객체 중심점과 뇌 중심점 간의 거리

각 방향 경계 사이의 라디안 값은 $\pi/4$ 이지만, X축이나 Y축을 경계로 하여 방향을 잡지 않고 그림 4와 같이 축을 포함하는 대칭형 방법으로 방향을 잡는다. 그 이유는 방위를 전두엽(frontal lobe), 측두엽(temporal lobe), 후두엽(occipital lobe)과 일치시켜 활용하기 위해서다.

상위레벨 속성 추출에서는 이상 객체에 대한 방향 정보만을 속성으로 추출한다. 그리고 이상 객체가 여러 부분에서 발생할 가능성을 고려하여 각 방향에 대한 이상 객체의 존재 여부를 속성으로 활용한다. 마지막으로 뇌

척수액과 이상 객체의 공간 관계는 그림 5에 나타난 것과 같이 이상 객체가 뇌척수액을 침윤하였는지 아닌지를 판별한다. 침윤 판별은 뇌척수액 객체의 윤곽선과 이상 객체의 윤곽선이 만나는 지점이 존재하는지 확인함으로써 이루어진다.

재구성 및 추출된 상위 및 하위 수준 속성을 적용하여 영상 학습을 하고 그 결과로 그림 6과 같은 분류 규칙을 생성한다. 이 규칙에 따라 각 전역 영상들은 영상 카테고리에 할당된다.

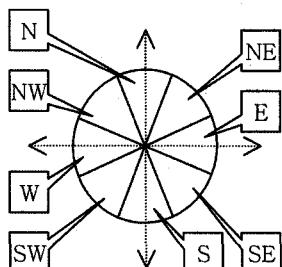


그림 4 방향 정보

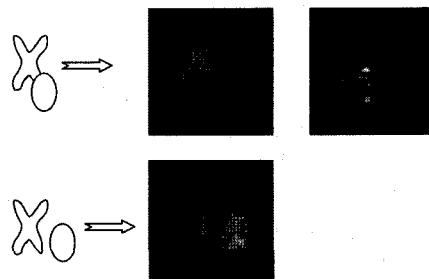


그림 5 공간 관계

Metastasis :



Glioblastoma :



```

2      ELSEIF Direction = se  THEN CLASS metastasis (2.0)
2      ELSEIF Direction = sw  THEN CLASS metastasis (4.0)
1      ELSEIF AreaRatio_W_G > 0.364807 THEN NODE
2          IF AreaRatio_UO <= 0.132929 THEN NODE
3              IF AreaRatio_UO <= 0.051012  THEN CLASS glioblastoma (2.0)
3                  ELSEIF AreaRatio_UO > 0.051012  THEN CLASS homangioblastoma
2                      ELSEIF AreaRatio_UO > 0.132929  THEN CLASS meningioma (4.0)

```

그림 6 영상과 분류 규칙의 예

4. 시스템 구현

본 논문에서 제안한 영상 분류 시스템은 크게 영상 처리, 학습기, 분류기, 편집기로 나뉘며, 시스템 구조도를 그림 7에 나타내었다.

학습기는 객체 학습기와 영상 학습기 두 단계로 이루어져 있고 분류기도 객체 분류기와 영상 분류기로 이루어져 있다. 영상 처리기는 학습과 분류에 공통적으로 사용된다. 결정트리 모델은 각각 객체 분류를 위한 모델과 영상 분류를 위한 모델로 구성된다. 편집기는 생성된 규칙들을 확인하고 수정하기 위한 도구이다.

영상 처리에서는 색상 히스토그램 정보를 활용하여 머리 영역, 회백질, 백질, 뇌척수액 객체를 단계적으로 추출한다. 머리 영역을 구하기 위해서는 명암값이 작은 배경을 제거한다. 회백질인 뇌 영역을 구하기 위해서 콘트라스트를 증가시켜 명암값이 두드러지게 한 후, 히스토그램 분석을 통해 머리의 외피와 뇌 영역을 분할한다. 이러한 처리 과정을 거친 후에도 제거되지 않은 눈과 외피가 존재하면 평균 두피와 근육층의 길이를 계산하여 런.LENGTH(run-length) 알고리즘으로 제거한다. 그리고 뇌 영역에 대한 반전 영상과 원시 영상과의 차이를 구하면 회백질 영역은 가장 낮은 명암값인 0으로 표현된다. 이 특징을 이용하여 백질 영역과 회백질 영역을 분리하고 각각에 대하여 블립 칼라링(blob coloring) 알고리즘을 적용하여 각 객체를 생성한다. 이렇듯 순서적으로 처리하는 이유는 관련 연구에서 언급했듯이 뇌 부분이 매우 복잡하고 비슷한 흑백의 색상으로 표현되기 때문에 영상 임계치를 정하여 동시 처리할 수가 없기 때문이다.

학습기는 속성 전처리기, 객체 학습기, 추가 속성 추출, 영상 학습기로 이루어진다. 속성 전처리기는 영상 처리를 통하여 입력된 속성을 학습기에 적용하기 적합한 구조로 변환한다. 객체 학습기는 결정트리 알고리즘을 이용하여 속성으로 표현된 객체들을 학습한다. 객체 학습기는 학습 결과 모델과 규칙들을 저장하고 객체의 속성값들을 추가 속성 추출 모듈에 전해준다. 추가 속성 추출 모듈은 객체 학습에 적용된 학습 데이터에서 영상 학습에 적용할 상위레벨 속성을 추출하기 위한 모듈이다. 추가 속성 추출 모듈은 새롭게 추가된 속성을 영상 학습기에 전달한다. 영상 학습기는 결정트리 알고리즘을 이용하여 상위레벨 속성으로 표현된 영상들을 학습하고, 그 결과 모델을 저장한다.

분류기는 학습 과정에서 저장한 규칙들을 이용하여 데이터를 분류한다. 분류 단계도 학습 단계와 동일한 절차를 따른다. 속성 전처리기는 학습 과정에서와 동일한 과정을 수행한다. 분류 과정의 속성 처리기와 학습 과정의 속성 처리기가 다른 점은 분류 과정에서는 분류 결과 클래스를 알 수 없다는 것이다. 객체 분류기는 속성으로 표현된 객체를 객체 분류 규칙들에 적용한다. 그리고 분류 결과를 속성에 추가하여 추가 속성 추출기로 보낸다. 추가 속성 추출기는 학습 과정에서의 추가 속성 추출과 동일한 작업을 수행하고 그 결과를 영상 분류기에 전달한다. 영상 분류기는 영상 분류 규칙을 이용하여 추가 속성으로 표현된 영상을 분류한다.

5. 실험 결과

본 실험에서는 기존의 내용기반 기법들과 본 논문에

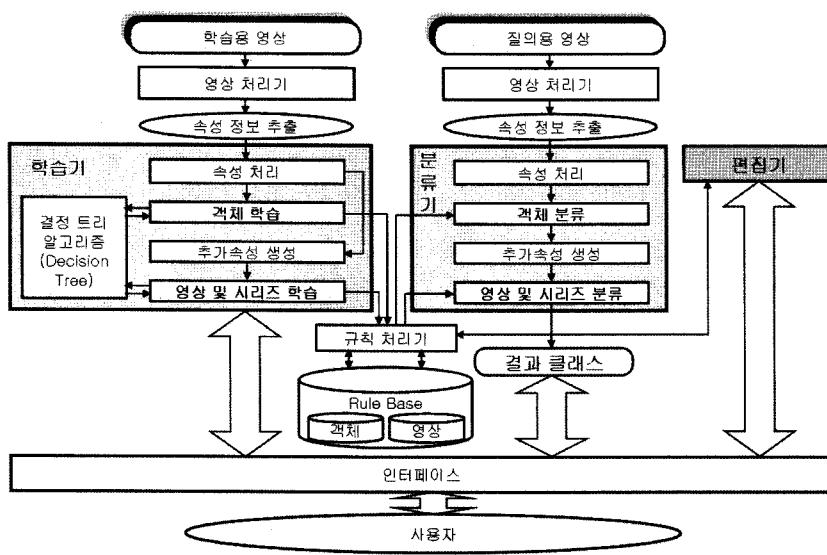


그림 7 시스템 구조도

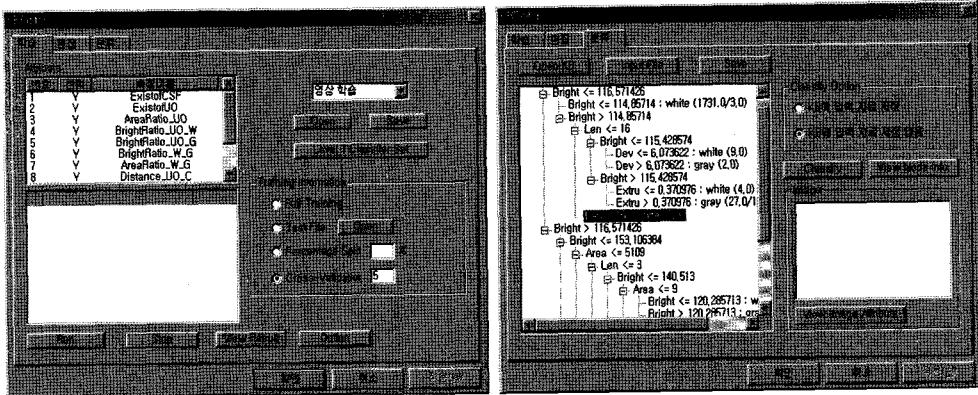


그림 8 학습기와 분류기

서 제시한 기법을 비교하였다. 실험에서는 10명의 정상인에게서 추출한 100개의 자기공명영상과 환자 30명에게서 추출한 300개의 자기공명영상을 실험용 데이터로 사용하였다. 환자 영상에서는 6가지 질병에 대해 질환부위가 찍힌 영상을 추출하여 활용하였다. 6가지 질병은 Craniopharyngioma, Glioblastoma, Hemangioblastoma, Metastasis, Meningioma, Oligodendroglioma이다.

5.1 객체 학습 및 분류에 관한 실험

객체 학습 및 분류 실험에서는 정상인 10명과 환자 30명의 영상에서 추출한 4,998개의 객체를 활용한다. 본 실험에서는 실험 데이터를 균등하게 10개의 집단으로 나눈 후, 9개의 집단으로 학습을 수행하고 나머지 1개의 집단을 이용하여 테스트를 수행하는 10회-교차검증을 이용한다.

객체 학습 및 분류 실험은 실험을 위한 준비 과정과 학습 및 분류 단계로 구성된다. 준비 과정은 객체의 하위레벨 정보를 얻는 것으로 영상 처리와 객체의 해부학적인 명칭 부여 과정이다. 영상 처리는 자기공명영상을 여러 개의 객체 조각으로 분할하여, 원본 영상과 객체 조각들에 대한 하위레벨 속성을 자기공명영상에서 추출한다. 그림 9는 영상 처리를 수행하여 추출한 뇌척수액, 백질, 회백질 영역의 객체 조각들이다. 각 부위들은 여러 개의 객체 조각들로 구성되며 백질의 경우 평균 10개 조각 정도이고 회백질의 경우 평균 23개 조각 정도로 구성된다. 영상 처리 과정이 끝나면 학습을 위하여

전문가의 조언과 의학 자료에 따라 각 객체의 해부학적인 명칭을 검증하여 이상 객체를 선정한다. 객체 학습은 명칭이 부여된 각각의 객체 조각들을 학습하여 결정트리 모델을 생성하고, 객체 분류는 생성한 결정트리 모델을 활용하여 객체 조각들을 분류한다.

표 3에 전체 분류 결과와 객체별 상세 분류 결과를 함께 나타내었다. 전체 분류 결과는 97.86%로 높은 정확도를 나타났으며, 상세 분류 결과에서는 회백질과 백질의 정확도가 98.28%와 98.43%를 나타내어 다른 부위보다 상대적으로 높은 정확도를 보였다. 표 3의 결과에 따르면 이상 객체는 회백질로 분류되는 경우가 있고, 회백질은 뇌척수액, 백질, 이상 부위로 분류되는 경우가 있다. 이와 같은 결과가 발생한 이유는 회백질의 속성값이 뇌척수액 또는 이상 부위와 백질 사이의 속성값을 지니기 때문이다. 즉, 회백질의 히스토그램값은 뇌척수액과 백질 사이의 값을 보이기 때문이다.

표 4는 내용기반 영상 분류 기법을 적용한 결과이다. 내용기반 영상 분류 기법에서는 최근접 이웃을 사용하였으며, 유사도 측정에는 유clidean 거리를 사용하였다. 내용기반 기법은 94.02%의 정확도를 나타내어 결정트리 기법보다 정확도가 3.84% 낮았다. 그러나 이상 객체의 분류에서는 내용기반 기법이 결정트리 기법보다 6.11% 높은 정확도를 나타냈다.

5.2 영상 학습 및 분류에 관한 실험

본 실험에서는 16명의 환자에게서 촬영한 자기공명영상을 활용하였고, 실험에 사용된 자기공명영상 총수는 32장이다. 본 실험에서는 10회-교차검증 방법을 이용하였으며, 실험에 사용한 질병은 총 6가지이다. 정상인의 경우 이상 객체의 유무에 따라 극명하게 나뉘기 때문에 실험에서는 제외하였다.

실험 결과를 표 5에 나타냈고, 실험 결과에 따르면 전체 질병에 대한 분류 정확도는 71.88%로 나타났다. 표



(a) 뇌척수액 (b) 백질 (c) 회백질
그림 9 분할된 객체들의 예

표 3 결정트리를 이용한 객체 분류

		분류 결과				오분류	정확도
		뇌척수액	회백질	백질	이상객체		
데 이 터	뇌척수액	97	15	0	5	20	82.90%
	회백질	13	2,980	23	16	52	98.28%
	백질	0	28	1,755	0	28	98.43%
	이상객체	0	7	0	59	7	89.39%
	Total		4,998			107	97.86%

표 4 최근접 이웃을 이용한 객체 분류

		분류 결과				오분류	정확도
		뇌척수액	회백질	백질	이상객체		
데 이 터	뇌척수액	93	13	0	7	20	82.90%
	회백질	8	2,916	103	5	116	96.20%
	백질	0	160	1,623	0	160	91.00%
	이상객체	0	3	0	63	3	95.50%
	Total		4,998			299	94.02%

표 5 영상 분류 결과 표

		분류 결과						오분류	정확도
		A	B	C	D	E	F		
데 이 터	A(=Craniopharyngioma)	1	0	0	1	0	0	1	50.0 %
	B(=Glioblastoma)	0	8	1	0	0	1	2	80.0 %
	C(=Hemangioblastoma)	0	1	0	1	0	0	2	0.0 %
	D(=Metastasis)	0	0	0	10	0	0	0	100.0 %
	E(=Meningioma)	0	0	0	1	3	0	1	75.0 %
	F(=Oligodendroglioma)	0	0	0	3	0	1	3	5.0 %
	Total				32			9	71.88%

5에서 음영으로 나타낸 수치는 올바르게 분류된 영상의 수이다. 실험 결과로 볼 때 Glioblastoma와 Metastasis는 비교적 높은 정확도를 나타냈지만, Hemangioblastoma와 Oligodendroglioma의 경우에는 낮은 정확도를 나타냈다.

표 6은 단일 단계 내용기반 영상 분류 방법과 논문에서 제안한 2 단계 결정트리 분류 방법을 비교 실험한 결과이다. 실험을 위하여 이미지에서 추출한 내용기반의 하위레벨 속성은 객체 학습 및 분류에서 사용한 속성과 동일한 종류를 사용한다. 내용기반 이미지 분류에서는 하나의 영상이 하나의 속성 집합으로 표현되어야 한다. 그러므로 속성 집합은 영상 처리를 통하여 영상을 뇌 전체 부위, 백질, 회백질, 뇌척수액의 네 가지 객체로 분할하고, 각 객체에 대하여 히스토그램의 평균과 편차, 면적, 둘둘도, 원형율을 추출하여 하나의 속성 집합으로 표현한다. 이상 부위는 영상 처리만으로 판별할 수 없으므로 분할하는 객체에서 제외된다. 이미지 분류는 최근접 이웃과 결정트리를 적용하여 분류하였다. 최근접 이웃 방법에서 영상을 간의 유사도 측정은 내용기반 영상 검색에서 대표적으로 활용되는 유클리드 거리를 사용한다. 본 실험에서는 질병별로 2명씩 총 12명의 환자로부터

터 질환 부위가 포함된 자기공명영상 110개를 추출하여 실험하였다.

2단계 결정트리를 적용한 기법의 평균 정확도는 65.8%로 가장 높았으며, 결정트리를 활용한 단일 단계 내용기반 기법은 46.8%의 정확도를 나타내어 본 논문에서 제안한 기법보다 19% 낮은 정확도를 나타냈다. 최근접 이웃을 사용한 내용기반 기법은 33.56%의 정확도를 나타내어 가장 낮은 정확도를 나타냈다. 질병별 정확도에서도 2단계 결정트리를 적용한 기법이 대부분 높은 결과를 보였다. 그러나 Hemangioblastoma에서 최근접 이웃을 사용한 내용기반 기법과 2단계 결정트리를 적용한 기법은 Hemangioblastoma를 모두 Glioblastoma로 분류하여 정확도가 0%로 나타났다. 이와 같은 결과가 발생한 이유는 실험에 사용된 Hemangioblastoma 영상이 Glioblastoma와 유사한 상위레벨 속성값을 소유하였기 때문이다. 반면 결정트리를 사용하는 내용기반 기법에서는 27.3%의 정확도를 나타내어 낮은 정확도 이지만 분류 가능함을 보였다.

6. 결론 및 향후 연구

본 논문에서는 뇌 자기공명영상을 분류하기 위하여

표 6 단일 레벨과 2단계 레벨의 영상 분류 비교

	1 Level Content Based		2 Level Decision Tree
	KNN(K=1)	Decision Tree	
Craniopharyngioma	0.0 %	20.0 %	66.7 %
Glioblastoma	70.0 %	61.1 %	64.3 %
Hemangioblastoma	0.0 %	27.3 %	0.0 %
Metastasis	66.7 %	62.5 %	88.9 %
Meningioma	64.7 %	60.0 %	100.0 %
Oligodendroglioma	0.0 %	50.0 %	75.0 %
평균정확도	33.6 %	46.8 %	65.8 %

결정트리 알고리즘을 2 단계로 적용하는 영상 분류 시스템을 제안한다. 본 논문에서 제안한 영상 분류 시스템은 영상 처리를 통하여 영상을 각각의 작은 객체들로 나누고, 각 객체들로부터 하위레벨 속성을 추출하여 학습 및 분류를 수행한다. 다음으로 각 객체들 사이의 관계 그리고 원본 영상과 객체들 사이의 관계에서 논리적인 속성인 상위레벨 속성을 추출하여 영상을 학습 및 분류한다. 본 논문에서 제안한 시스템은 기존의 내용기반 영상 분류 시스템과는 달리 하위레벨 속성과 상위레벨 속성을 개별적이고 단계적으로 적용함으로써 효과적인 학습 및 분류를 수행할 수 있는 장점이 있다.

객체 학습 및 분류에 관한 실험에서 본 논문에서 제안한 기법은 97.86%의 정확도를 나타내어 내용기반 기법보다 3.84% 높은 정확도를 나타냈다. 영상 학습 및 분류에 관한 실험에서는 본 논문에서 제안한 기법이 65.8%의 정확도를 나타내어 최근접 이웃을 이용한 내용기반 기법과 결정트리를 이용한 내용기반 기법에 비해 각각 32.2%와 19.0% 더 높게 나타났다. 본 논문에서 제안한 2단계 결정트리 학습을 이용한 뇌 자기공명영상 분류 기법이 내용기반 기법들 보다 높은 정확도를 나타내는 이유는 자기공명영상에서 추출한 속성들을 표면적 속성과 논리적 속성으로 나누고, 각 속성들의 특성에 맞게 학습에 활용하게 때문이다.

질환별로 나타나는 발생 부위, 호발 연령대, 남녀 비율과 같은 특징을 속성으로 활용할 수 있다면 의료 영상 분류에 효과적으로 적용될 수 있을 것이며, 이와 같은 통계학적 기법 적용이 향후 연구로 필요하다.

참 고 문 헌

- [1] Sauer, F. and Kabuka, M., "Multimedia technology in the radiology department," *Proceedings of the second ACM international conference on Multimedia*, pp.263-269, 1994.
- [2] Sonka, M., Hlavac, V., and Boyle, R., *Image Processing Analysis and Machine Vision*, PWS Publishing, 1999.
- [3] Chu, W. W., Cardenas, A. F., and Taira, R. K., "KMED: A knowledge-based multimedia medical distributed database system," *Information Systems*, Vol.20, No.2, pp.75-96, 1995.
- [4] Rui, Y., Huang, T. S., and Chang, S. F., "Image Retrieval: Current Techniques, Promising Directions and Open Issues," *Journal of Visual Communication and Image Representation*, Vol.10, No.4, pp.39-62, 1999.
- [5] Flickr, M. et al, "Query by image content: The QBIC System," *IEEE Computer Special issue on Content Based Retrieval*, Vol.28, No.9, pp.23-32, 1995.
- [6] Chang, N. S. and Fu, K. S., "Query-by pictorial-example," *IEEE Transactions on Software Engineering*, Vol.6, No.6, pp.519-524, 1980.
- [7] Chang, S. K. and Hsu, A., "Image information systems: Where do we go from here?," *IEEE Transactions on Knowledge and Data Engineering*, Vol.4, No.5, pp.431-442, 1992.
- [8] Gudivada, V. N. and Raghavan, J. V., "Special issue on content-based image retrieval systems," *IEEE Computer Magazine*, Vol.28, No.9, pp.18-62, 1995.
- [9] Niblack, W., Barber, R., Equitz, W., Flickr, M., Glasman, E., Petkovic, D., Yanker, P., Faloutsos, C., and Taubin, G., "Efficient and effective querying by image content," *Journal of Intelligent Information Systems*, Vol.3, No.3, pp.231-262, 1994.
- [10] Quinlan, J. R., *C4.5: Programs for machine learning*, Morgan Kaufmann, 1993.
- [11] Witten, I. H. and Frank, E., *Data Mining: Practical Machine Learning Tools and Techniques with JAVA Implementations*, Morgan Kaufmann, 2000.
- [12] Mitchell, T. M., *Machine learning*, McGraw-Hill, New York, 1997.
- [13] 송곡아생, 뇌종양, 대학서림, 1991.
- [14] 대한신경외과학회, 신경 외과학, 대한신경외과학회, 2000.
- [15] The Whole Brain Atlas, <http://www.med.harvard.edu/AANLIB>
- [16] Ogle, V. E. and Stonebraker, M., "Chabot : Retrieval from a relational database of images," *Proceedings of International Conference on IEEE Computer*, Vol.28, No.9, pp.40-48, 1995.

- [17] Chu, W. W., Hsu, C. C., Ieong, I. T., and Taira, R. K., "Content-based Image Retrieval Using Metadata and Relaxation Techniques," *Managing Multimedia Data*, McGraw-Hill, 1998.
- [18] Shyu, C. R., Brodley, C. E., Kak, A. C., Kosaka, A., Aisen, A., and Broderick, L., "Assert: A physician in-the-loop content-based retrieval system for HRCT image databases," *Computer Vision and Image Understanding*, Vol.75, No.12, pp.111 - 132, 1999.



김 형 일

1996년~1998년 (주)경기은행. 2004년 동국대학교 컴퓨터공학과(공학박사). 2005년~2006년 동국대학교 컴퓨터공학과 IT 분야 교수요원(정보통신부). 관심분야는 지능형 에이전트, 기계학습, 정보검색, 게임, 의료영상



김 용 육

2001년~현재 동국대학교 컴퓨터공학과 (박사과정). 2003년~현재 (주)보이스웨어 연구원. 관심분야는 의료영상, 기계학습, 데이터마이닝, 정보검색, 음성인식