

신경망의 결정론적 이완에 의한 자기공명영상 분류

전 준 철¹ · 민 경 필¹ · 권 수 일²

목적: 본 논문에서는 신경망을 이용한 자기공명영상의 분류에 있어 결정론적 이완 방법(deterministic relaxation)과 응집 군집화(agglomerative clustering) 방법에 의한 개선된 영상 분류방법을 제시한다. 제안된 방법은 신경망을 이용한 영상의 분류시 지역적 최소치로의 수렴문제와 입력 패턴의 증대로 인하여 수렴속도가 늦어지는 문제를 해결한다.

대상 및 방법: 신경망을 이용한 영상의 분류는 지역적 계산과 병렬 계산이 가능한 특성을 갖고 있어 기존의 통계적 방법을 대신하는 방법으로 주목을 받고 있다. 그러나 일반적으로 신경망에 의한 분류알고리즘이 지닌 문제점의 하나는 에너지함수가 항상 전역적 최소치로 수렴하지 않고 지역적 최소치로도 수렴할 수 있다는 점이고, 또 다른 문제점은 반복수렴을 수행하는 에너지함수의 수렴속도가 너무 늦다는 점이다. 따라서 지역적 최소치로의 수렴을 방지하고 전역적 최소치로의 수렴속도를 가속화시키기 위하여 본 논문에서는 결정적 이완 알고리즘의 하나인 MFA(Mean Field Annealing) 방법을 적용하여 지역적 최소치로의 수렴문제를 해결하는 방법을 제시한다. MFA는 모의 애닐링의 통계적 성질을 변수의 평균값에 적용하는 결정론적인 수정 법칙들로 대신하고, 이러한 평균값을 최소화함으로서 수렴속도를 개선한 방법이다. 아울러 신경망이 갖고 있는 문제점인 과다한 클래스 패턴의 생성에 따른 처리속도 저연의 문제점을 해결하기 위하여 응집 군집화 알고리즘을 이용하여 영상을 구성하는 군집을 결정하여 신경망에 입력되는 값을 초기화하여 영상패턴이 증가되는 것을 제한하였다.

결과: 본 논문에서 제시된 응집 군집화 방법 및 결정론적 이완 방법은 신경망에 의한 자기공명영상의 분류 시 발생할 수 있는 지역적 최적치로의 수렴 문제를 해결하여 전역적 최적화로 신속히 수렴함을 알 수 있었다.

결론: 본 논문에서는 클러스터의 분석과 결정론적 이완 방법에 의하여 신경망에 의한 자기공명영상의 분류 결과를 향상시키기 위한 새로운 방법을 소개하였으며 실험결과를 통하여 그러한 사실을 확인할 수 있었다.

서 론

의료영상의 분류는 특정 세포조직의 이상유무를 판단하거나 관심조직을 삼차원으로 가시화 하기 위하여 필요한 과정으로 정확한 분류결과를 획득하는 작업은 결과적으로 영상분석이나 3

차원 모델링의 결과를 항상시킬 수 있는 전제조건이 된다고 볼 수 있다. 의료영상 중 널리 사용되고 있는 자기공명영상의 주요 장점은 신체내부의 연 조직에 대한 영상을 생성하는 것이 가능해졌다는 점과 다 채널 영상의 특성을 갖고 있어서 영상분석을 위하여 보다 많은 정보를 제공받을 수 있다는 것이다. 반면 자기공명영상은 영상을 구성하는 조직사이의 명암도 분포가 넓게

대한자기공명의과학회지 6:137-146(2002)

¹경기대학교 정보과학부 영상처리연구실

²경기대학교 의학물리학과

접수 : 2002년 4월 26일, 채택 : 2002년 10월 15일

통신저자 : 전준철, (442-760) 경기도 수원시 팔달구 이의동 산 94-6, 경기대학교 정보과학부 영상처리연구실

Tel. (031)249-9668/9670 Fax. (031)249-9673 E-mail: jcchun@kuic.kyonggi.ac.kr

전준철 외

분포되어있지 않고 서로 다른 조직이 겹쳐있는 부분을 나타내는 화소가 많이 존재하여 세포조직간의 경계가 매우 복잡한 점 때문에 영상의 분류에 어려움이 있다 (1, 2).

자기공명영상의 정밀한 분석 및 3차원 가시화 등을 위해서는 영상이 어떤 패턴들로 구성되어있는지를 판단하고 그것을 분류하는 영상분류과정을 거쳐야 한다. 대부분의 영상분류 알고리즘들은 특성벡터에 있는 그룹들을 구별지어주기 위해서 거리측정이나 일정한 기하학 같은 방법을 이용하여 영상으로부터 데이터를 나누어준다. 다시 말해 영상분류의 목적은 데이터 집합 속에 숨겨져 있는 각 데이터 포인트들 사이의 구조적 관계를 찾아내고 강조하는 것에 있다. 따라서, 여기에 사용되는 알고리즘들은 적절한 특징추출과 이들의 거리측정에 사용되는 알고리즘에 따라 정확성과 효율성이 평가되어진다. 이러한 영상의 분류방법은 크게 교사적 방법과 비교사적 방법으로 나뉘어하는데, 이들을 구분하는 기준은 훈련에 필요한 훈련집단을 사전지식을 통해 생성하는지에 따라 결정된다. 즉, 사전지식을 사용하는 것을 교사적 방법이라 하며, 사전지식 없이 컴퓨터 알고리즘에 따라 유사성을 갖는 집단을 생성해내는 방법을 비교적 방법이라 한다.

한편 영상분류 방법중 신경망을 이용한 분류 방법은 특히 비교사적 영상분류 방법에 적합한 구조를 갖고 있으며, 지역적 계산과 병렬계산이 가능하다는 특징을 갖고 있어 기존의 통계적 방법의 문제점을 극복할 수 있는 방법으로 주목받고 있다. 일반적으로 패턴인식분야에 사용되는 신경망으로 자기조직망, 퍼셉트론, 흡필드망 등이 소개되고 있으며, 이에 기반 하여 의료영상을 대상으로 한 영상의 분류에 관한 연구 및 분류결과를 향상시키기 위한 연구가 활발히 진행되고 있다 (3, 4, 5). 그러나 일반적으로 신경망을 사용하는 분류알고리즘은 다음의 두 가지의 문제점을 내포하고 있다. 그중 하나는 에너지함수가 항상 전역적 최소치로 수렴하지 않고 지역적 최소치로도 수렴할 수 있다는 점이고, 다른 하나는 반복수렴을 수행하는 에너지함수의 수렴속도가 너무 늦다는 점이다. 수렴속도가 늦게 되는 주요 원인 중 하나는 영상에서 추출될 수 있는 가능한 영상 패턴의 형태(configuration)가 방대한 것도 한 이유이다. 예를 들어 $M \times M$ 크기의 영상에 L 개의 클래스가 존재한다면, 생성 가능한 패턴의 형태는 무려 L^M 가 되며 이는 결과적으로 신경망에 의한 영상분류 시 학습 및 인식에 걸리는 시간을 증대시키고 수렴속도를 늦게 하는 부담으로 작용한다.

따라서 본 논문에서는 다 채널 의료영상을 신경망을 이용해 분류함에 있어서 앞서 언급된 두 가지 문제점을 해결하는 방법을 제시한다. 특히 영상의 잡음이나 손상된 영상에 대하여 복원능력이 있는 방법인 흡필드 신경망을 적용하여 영상을 분류하였다. 첫째, 최적의 분류결과를 얻기 위해서 신경망의 내부상태를 나타내는 에너지함수를 사용하여 이 함수의 수렴여부를 평가하는 방법을 적용하였다. 최적화 문제의 해결방안으로 결정적 이완 알고리즘의 하나인 MFA(Mean Field Annealing) 방법을 적용하여 지역적 최소치로의 수렴문제를 해결하는 방법을 제시한다. 둘째, 신경망이 갖고 있는 문제점인 과다한 클래스 패턴

의 생성에 따른 처리속도 지연의 문제점을 해결하기 위하여 응집 군집화(agglomerative clustering) 알고리즘을 이용하여 신경망에 입력되는 값을 초기화하여 영상패턴이 증가되는 것을 제한하였다.

연구 배경

1. 관련연구

신경망을 이용한 영상의 분류는 앞서 지적한 바와 같이 지역적 계산과 병렬 계산이 가능한 특성을 갖고 있어 기존의 통계적 방법을 대신하는 방법으로 주목을 받고 있다. 영상의 분류란 서로 다른 클래스들간의 최소거리를 찾는 최적화문제로 볼 수 있으며, 특히 최근에는 최적화문제 해결에 적합하고 영상의 잡음이나 손상된 영상에 대하여 복원 능력이 있는 방법인 흡필드(Hopfield) 신경망을 이용한 다중에코 자기공명영상의 분류 및 최적의 분류결과를 획득하고자하는 연구가 활발히 진행되고 있다.

Amartur(3)는 흡필드 신경망의 에너지함수를 최소화 시켜는 방법에 의한 비교사적 영상분류 방법을 제시하였으나, 영상분류 결과는 잡음이 심하여 후처리 분류과정을 필요로 하였다. Sammouda(4)는 다 채널 자기공명영상의 분류 및 최적화를 위하여 흡필드 신경망과 볼쓰만 머신을 이용해 에너지 함수가 지역적 최소치에 수렴하는 것을 방지하기 위한 방법을 제시하였다. 그러나 이 방법은 에너지 함수의 수렴시간이 너무 오래 걸리는 문제점을 야기하였다. Hishitani(5)는 자기공명영상 분류의 최적화를 위하여 에너지함수의 수렴과정에서 일시적으로 잡음을 발생하는 함수를 에너지 함수에 침가하는 방법으로 영상분류결과가 최적화 된 결과에 근접한 값을 얻을 수 있었다. 흡필드 신경망의 사용 시 이완을 통해 지역적 최소치 문제를 해결해주는 연구(6)는 영상분류의 최적화문제를 해결할 수 있는 도움을 주었다.

한편, 모의 에닐링의 변형인 MFA는 여러 최적화문제의 해결에 성공적으로 적용되었다 (7-10). MFA의 개념은 다른 변수의 확률분포를 계산할 때 에너지 필드에서 발생하는 스핀 변수를 그것의 평균값으로 대체하는 원리에서 유래된 평균 필드 근사에 바탕을 두고 있다. MFA는 모의 에닐링의 통계적 성질을 결정론적 수정 법칙의 집합으로 대체 하였으며, 결정론적 이완 방법을 통하여 복잡한 최적화 문제 해결에 빠르게 수렴할 수 있게 하였다. MFA는 영상회복 혹은 영상의 잡음제거 문제와 같은 다양한 분야에 사용되었는데, Zhou는 MFA에 기반한 에지 검출 알고리즘을 이용하여 CT 영상의 회복에 사용하였다 (10). 특히 주요 신경망 모델이 MFA의 주요 특성과 밀접한 관계를 갖는 관계로 VLSI 설계 및 진역(seismic) 데이터 처리 등 신경망을 이용한 최적화문제 해결에 MFA를 이용한 연구가 진행되었다 (7, 11).

2. Hopfield 신경망

홉필드 신경망의 기본구조는 일반적인 신경망과 같이 입력 값에 가중치들을 계산한 후 적당한 임계함수를 통해 출력하는 노드들이 여러 개 있고, 이들이 상호 연결되어 있는 구조로 되어 있으며, 다른 신경망과 비교되어지는 부분은 출력 값이 다시 입력되는 동적인 순환단층구조로 되어있다는 점이다 (12, 13). 만일 $V_i(t+1)$, $i=1, 2, \dots, N$ 을 네트워크의 입력으로 정의하고, 외부에서 뉴런에 제공되는 입력을 ϕ_i 그리고 뉴런 i 와 j 의 연결 가중치를 ω_{ij} 그리고 H 를 스텝함수라고 했을 시간($t+1$)에서 특정 뉴런 V_i 의 값은 다음과 같이 정의되며 이를 특별히 이산 흑필드 신경망이라고 부른다.

$$V_i(t+1) = H \left(\sum_{j \neq i, j=1}^N \omega_{ij} V_j(t) + \phi_i \right) \quad (1)$$

이러한 흑필드 신경망의 작동과정은 일반적으로 네트워크의 에너지 함수를 통하여 설명될 수 있다. 즉, 흑필드 망을 통해 얻어진 값이 최적화 된 결과인지의 여부는 내부상태를 나타내는 에너지함수 [2]의 수렴상태를 통해 알 수 있다.

$$E = -\frac{1}{2} \sum_{k=1}^N \sum_{l=1}^N T_{kl} V_k V_l - \sum_{k=1}^N I_k V_k \quad (2)$$

식[2]에서 I_k 는 편향(bias) 항이며, T_{kl} 은 k 번째 뉴런과 l 번째 뉴런간의 상호연결 가중치이다. 이 에너지함수를 간략히 하면 식[3]과 같이, k 번째 뉴런의 V_k 값의 변화에 따라 값이 변한다는 점과 단조감소함수라는 점을 알 수 있다.

$$\Delta E = - \left[\sum_{j \neq i}^N T_{ij} V_j + I_i \right] \Delta V_i \quad (3)$$

따라서, 흑필드 신경망은 에너지함수와 관련된 최적화 문제에 적용될 수 있다.

비록 신경망이 통계적 분류방법의 문제를 해결할 수 있고, 전역적 최적화 문제를 해결할 수 있다는 장점을 갖고 있기는 하지만, 본 연구를 통해서 드러난 흑필드 망에 의한 영상분류는 앞서 언급했듯이 크게 두 가지의 단점을 보여주었다. 첫 번째는 에너지함수가 최소치로 수렴하기까지의 반복수렴과정이 너무 많은 시간을 소요된다는 점이고, 두 번째는 에너지함수가 항상 전역적 최소치로 수렴하지 못하고 지역적 최소치로 수렴하는 경우가 생긴다는 점이다. 이상의 문제점을 보완하기 위해 영상의 분류에 있어서 다음의 과정을 포함한 새로운 분류과정을 사용한다. 우선 과다한 영상패턴의 생성을 방지하여 처리속도를 향상시키기 위하여 흑필드 신경망의 초기입력 뉴런에 할당되는 영상의 클래스 값을 임의로 설정하는 대신 응집 군집화 알고리즘에 의해 결정된 값을 입력하고, 지역적 최소치로 수렴하는 문제를 해결하기 위해 최적화 알고리즘인 MFA 알고리즘을 이용하여 에너지함수가 전역적 최소치로 수렴하도록 유도하는 방법을 사용한다. 다음 절에서는 이상의 문제를 해결하기 위한 구체적인 방법을 제시한다.

신경망에 의한 영상분류의 최적화

1. 영상의 군집화

영상 군집화의 주요 임무는 영상 데이터를 특성에 따라 적절한 범위로 나누는 작업으로 나뉘어진 집단은 영상분류에 중요한 사전 정보를 제시해 주는 것이다. 본 절에서 소개될 응집 알고리즘은 계층적 군집화 알고리즘으로서 비교사적 훈련방법에 의해 영상에서 군집의 중심과 분포를 찾아내고 이들로부터 추출된 매개변수를 영상분류작업에 사용하는 방법이다. 본 알고리즘의 기본적 수행은 다음과 같다. 알고리즘의 수행을 위해서 우선 영상을 $n \times n$ 크기의 블록으로 나눈 후 각 블록에 대한 평균벡터 m 와 공분산 C 을 계산한다. 초기 집단은 영상에서 동일한 성질을 갖고 있는 영역에 속한 블록들을 선택하여 결정한다. 따라서 블록의 크기는 영상의 동질성이 유지될 수 있는 3×3 의 크기로 선정하였다. 일단 초기의 블록이 형성된 후 영상을 대표할 수 있는 최종 군집이 형성될 때까지 동일한 성질을 갖는 블록은 결합된다. 한 블록이 동일한 성질을 갖는다는 것은 공분산의 대각선에 있는 다음의 계수 합(T_{var})이 임계값보다 작은 값을 가질 경우를 의미한다. 이때 (x, y) 는 $n \times n$ 블록의 시작 지점이며 g_{ij} 는 화소의 밝기값을 각각 의미한다.

$$T_{var} = -\frac{1}{n^2} \sum_{i=x}^{x+n} \sum_{j=y}^{y+n} (g_{ij} - m)^2 \quad (4)$$

초기에 선택된 군집들은 그들간에 일련의 통합과정을 거쳐 분류에 필요한 최소의 군집들을 이루게 된다. 다시 말해 총괄적인 기초군집을 생성할 때까지 반복적인 병합과정을 통해 계층적 군집들을 생성하는 과정을 이용한다. 블록들 간의 통합과정은 일련의 분리기준(separability measure) 원칙에 의하여 결합되어 진다. 일반적으로 최적의 특성 벡터를 평가하는데 사용되는 원칙 가운데 하나는 베이지의 오류를 근거로 할 수 있다. 그러나 실세계에서 특성 값의 사후 분포를 측정하는 문제는 용이하지 않으며, 보다 실질적인 분리원칙을 필요로 하며, Euclidean 거리 혹은 Bhattacharyya 거리 등을 고려할 수 있다 (14). 두 분포의 평균의 거리를 나타내는 Euclidean 거리는 클래스 평균값을 이용하여 다음과 같이 쉽게 계산될 수 있다.

$$E_{pq} = \sqrt{(m_p - m_q)^T (m_p - m_q)} \quad (5)$$

그러나 이 방법은 두 분포간의 공분산을 고려하지 않기 때문에 측정된 거리가 멀다고 하여 단순히 두 분포가 겹치지 않는다고 단정할 수 없는 문제가 있다. 반면 Bhattacharyya 거리는 분포의 평균과 공분산을 모두 이용하여 분리기준을 고려하는 방법으로, 두 분포사이의 거리는 다음과 같다.

$$B_{pq} = \frac{1}{8} (m_p - m_q)^T \left(\frac{C_p + C_q}{2} \right)^{-1} (m_p - m_q) + \frac{1}{2} \ln \frac{\frac{C_p + C_q}{2}}{\sqrt{|C_p||C_q|}} \quad (6)$$

블록의 통합과정에서 결합된 클래스의 평균 m_{pq} 와 공분산 C_{pq} 는 통합이전 군집들의 평균과 공분산(m_p , m_q 와 C_p , C_q)을 이용하여 다음과 같이 계산한다.

$$m_{pq} = \frac{n_p m_p + n_q m_q}{n_p + n_q}$$

$$C_{pq} = \frac{n_p(C_p + m_p m_p^T) + n_q(C_q + m_q m_q^T)}{n_p + n_q} + m_{pq} m_{pq}^T \quad [7]$$

결국 이상의 통합 과정은 영상의 특성을 대표하는 군집이 생성될 때까지 앞서 설명된 분리원칙에 의하여 반복 수행된다. 소개된 알고리즘은 유사한 영역끼리 합병하는 과정이 순서에 제약을 받지 않는 장점이 있다. 이상의 과정을 통해서 획득된 동일한 성질의 군집들은 신경망의 입력 노드에 초기 값으로 입력된다.

2. 신경망에 의한 영상분류 방법

군집의 분석에 의해서 획득된 영상분포의 정보는 신경망을 이용한 영상분류 시 초기 입력 패턴으로 사용된다. 본 논문에서 사용되는 신경망의 입력노드에 대한 값은 각 클래스들의 평균값과 각 화소의 값과의 거리측정방법에 의해 설명되어진다. 여기에 사용되어지는 거리측정방법은 특징벡터에 대한 평균벡터와 공분산 벡터를 이용하여 최소거리를 구하는 마할노비(mahalanobis) 측정 법을 사용하였으며, 거리측정은 식[7]에 의해 구해진다. 이 측정 법은 다른 특징 값들 사이의 상호관계를 수정할 수 있다는 점, 직선경계뿐 아니라 곡선의 경계까지 제공한다는 점, 그리고 좌표축에 대한 크기변환을 자동적으로 설명할 수 있다는 점에서 기존의 유클리디안 측정법의 한계를 제거하였다.

$$R_{ki} = \|X_k - X_i\| A_i \quad [8]$$

이때, X_k 는 k 번째 화소의 값이고 X_i 는 클래스 i 의 평균값이며, A_i 는 공분산 행렬을 의미한다. 본 논문에서 사용되어지는 영상은 SD, T2 두 개의 컴포넌트로 구성된 멀티에코 영상이므로 여기서 사용되어지는 값은 2차원 벡터 값을 사용한다.

$$E = -\frac{1}{2} \sum_{k=1}^N \sum_{l=1}^N R_{kl} V_{kl}^2 \quad [9]$$

지금까지 구해진 에너지함수 [9]를 이용하여 다음과 같은 알고리즘을 통해 함수 값이 최소 값으로 수렴할 때까지 반복적으로 수행한다.

- ① 입력뉴런의 값을 임의로 초기화한다.
- ② 각 뉴런에 대한 출력 값의 계산을 통해 해당되는 클래스를 할당한다.

$$V_{kn}(t+1) = 1 \text{ if } U_{kn} = \text{MAX}\{U_{kl}(t) : \forall l\}, \\ V_{kn}(t+1) = 0 \text{ if otherwise}$$

- ③ 각 클래스에 대한 평균벡터와 공분산을 구한다.

$$X_i = \left[\sum_{k=1}^N X_k V_{ki} \right] / n_i$$

$$\Sigma_i = \left[\sum_{k=1}^N V_{ki} (X_k - X_i)(X_k - X_i)^T \right] / (n_i - 1)$$

- ④ 각 뉴런에 대한 새로운 입력 값을 할당한다.

$$U_{ki}(t+1) = 1 \cdot U_{ki}(t) - R_{ki} V_{ki}$$

- ⑤ 식 [9]의 값이 수렴한다면 수행을 중단하고 그렇지 않다면 두 번째 단계부터 반복 수행한다.

3. MFA(Mean Field Annealing)에 의한 최적화

통계적 방법을 응용한 모의 에닐링 알고리즘의 가장 중요한 특징은 시간의 제한만 없다면 최적의 답을 얻을 수 있다는 것을 보장한다는 점이다. 이 방법을 이용하면 비록 지역적 최소치를 탈출하여 전역적 최소치로의 수렴이 가능하다고는 하지만, 수렴에 너무 많은 시간의 소요되는 단점이 있다. 따라서 본 연구에서는 이러한 단점을 보완한 Mean Field Annealing(MFA) 알고리즘을 적용하여 최적의 답을 유도해본다. MFA는 전역적 최적화 알고리즘으로 평균 필드 근사 법의 개념에 기초를 두고 있기 때문에 변수 그 자체보다는 변수들의 평균값에 따라 실행되어지며, 이러한 이유로 기존의 모의 에닐링 보다 훨씬 빠르게 안정상태로 수렴할 수 있게 되었다 (6, 7). 이 알고리즘의 가장 큰 특징은 흡필드 망의 특징과 모의 에닐링의 특장을 모두 갖고 있다는 점이다. 우선 모의 에닐링과는 동일한 냉각 스케줄 [10]을 사용한다는 점에서 공통점을 찾을 수 있다.

$$T = \frac{\tau}{\ln(i+1)}, \quad i = 1, \dots \quad [10]$$

이때 τ 는 상수이고 i 는 반복 사이클이다. 또한 MFA에서 사용되는 개선 규칙은 비용 함수가 흡필드 망의 에너지함수와 유사할 때 쉽게 얻어질 수 있다. MFA 알고리즘은 이진 벡터를 갖는 기준함수에 의해 표현되는 아이징(Ising) 모델을 통해 유도될 수 있고 에너지함수는 다음과 같다.

$$E[U] = \frac{1}{2} \sum_{k=1}^S \sum_{l \neq k} \beta_{kl} u_k u_l + \sum_{k=1}^S h_k u_k \quad [11]$$

위식에서 h_k 는 바이어스 항, β_{kl} 은 뉴런 k 와 l 간의 상호 연결 가중치를 의미하며, u_k 는 각 단계의 값으로 0 또는 1의 값을 갖는다. 흡필드 망이 다양한 최적화 문제를 해결하기 위해 사용되어지기는 하지만 흡필드 망의 시뮬레이션 결과 작은 크기의 문제에 대해 적당한 결과를 얻지만, 커다란 크기의 문제에 대해서는 적당한 값을 얻기가 어렵다는 사실을 드러냈다 (6). 그러므로 흡필드 망은 경험적 최적화 알고리즘에 가장 중요한 작업기준인 스케일링 특징을 갖고있다고 할 수는 없다. 그런 면에서 MFA는 흡필드 망에 최적화를 이룰 수 있는 방법으로 제시되었다.

다. 과거에는 MFA가 이진 벡터 값으로 국한되어 있었지만 근래에는 연속적인 변수를 갖고 있는 문제 영역에까지 넓게 사용되어지고 있다. MFA는 작은 지역에서 지역적 반복을 수행하는 MRF(markov random field)에 유효하므로 평균과 평균 필드에러의 계산은 종종 핍스분포(15)를 따르기도 한다. 적용된 MFA 알고리즘은 다음과 같다.

- ① 초기값 T_0 를 설정한다. $T=T_0$
- ② 온도 T 를 냉각스케줄에 따라 주어진 영역내에서 생신하며 ③-⑤의 알고리즘을 반복한다.
- ③ 주어진 온도상에서 안정된 상태에 도달할 때까지 ④-⑤의 알고리즘을 반복한다.
- ④ mean field 를 계산한다.

$$\Phi_i = E[U] \mid u_i=0 - E[U] \mid u_i=1$$

- ⑤ 평균값을 생신한다.

$$\langle u_i \rangle = e^{x_i T} / (1 + X_i / T)$$

실험 및 평가

제안된 영상분류의 평가를 위하여 본 연구에서는 제안된 분류 알고리즘과 대표적인 통계적 분류방법의 하나인 k-평균 알고리즘을 자기공명영상과 모의영상에 적용하여 그 결과를 비교한다. 일반적으로 환자의 영상분석에 관한 실제 클래스 맵을 얻는 것은 어려운 일이기 때문에 특히 알고리즘의 성능평가를 위하여 영상에 대한 정확한 사전 정보를 갖고 있는 임의의 다 채널 실험영상을 생성하여 실험을 하였으며, 아울러 자기공명 영상에 적용하였다.

1. 모의영상의 생성 및 분류 결과

영상분류를 위해 제안된 알고리즘들은 실제로 사용되기 전에 모의 데이터를 통해서 성능을 평가할 필요가 있다. 영상의 생성 방법으로는 whitening 변환을 이용하여 각 클래스에 해당되는 화소의 값들은 표준정규분포를 따르며 5개의 클래스를 기준으로 생성한다. 본 논문에서는 평균 벡터가 M 이고 공분산 벡터가 Σ 인 정규분포를 따르는 실험 데이터를 생성하여 성능을 평가하도록 한다. 일반적으로 실험 데이터들은 변수들의 상호관계로 인해서 생성하기가 복잡하다. 하지만 평균 벡터를 0으로 하고 공분산 행렬을 단위행렬로 갖는 정규분포의 실험 데이터 생성은 whitening 변환 알고리즘을 이용하여 생성할 수 있다 (14). 평균이 Mx 이고 공분산이 Σ_X 인 n 차 벡터 X 를 다른 n 차 벡터인 Y 로 변환하고자 할 때 변환 식은 다음과 같다.

$$Y = \Pi^T X$$

$$\Sigma_y = \Pi^T \Sigma_x \Pi = A \quad (12)$$

위의 식[11]에서 $n \times n$ 의 행렬일 경우 Π , A 는 각각 고유값 $\lambda_1, \dots, \lambda_n$ 과 고유벡터 π_1, \dots, π_n 에 대한 행렬이다. 식[11]에 변환식 $A^{-1/2}$ 을 적용하면 단위행렬 값을 갖는 공분산 행렬을 구할 수 있다.

$$Y = A^{-1/2} \Pi^T X = (\Pi A^{-1/2})^T X$$

$$\Sigma_y = A^{-1/2} \Pi^T \Sigma_x \Pi A^{-1/2} = A^{-1/2} A A^{-1/2} = I \quad (13)$$

위의 식[13]에서 $\Pi A^{-1/2}$ 을 whitening 변환이라 하며, 실험 데이터 생성 알고리즘은 다음과 같다.

영상분류의 정확성을 평가하기 위해 정확한 사전 정보를 알고 있는 실험 데이터를 만들어 영상분류를 실험해볼 필요가 있다. 실험 데이터 생성은 앞에서 소개한 방법을 이용하여 5개의 클래스로 이루어진 2차원 영상(90×90)을 생성하였다. 각 클래스에 대한 다 채널 영상의 평균값은 $M_1=(50, 45)$, $M_2=(100,$




그림 1. 정규분포 값으로 구성된 멀티 채널 실험영상

(평균값: 50, 100, 150, 200, 240
공분산: $\sqrt{1000}$ 평균값: 45, 80, 120,
195, 225 공분산: $\sqrt{1000}$)

① 공분산 Σ 이 주어졌을 때 whitening 변화를 구한다.

$$Y = A^{-1/2} \Pi^T X = (\Pi A^{-1/2})^T X$$

② N개의 다채널 영상을 생성하기 위해서 평균이 0이고 분산이 1인 표준 정규분포를 따르는 데이터 y_i 를 생성한다.

$$Y_1, \dots, Y_N, \quad Y = \{y_1, \dots, y_N\}$$

③ Y 공간에서 생성된 데이터를 X 공간으로 다시 전환시킨다.

$$X_i = \Pi^T A^{1/2} Y_i$$

④ X 공간에서 생성된 실험 데이터에 각 클래스에 대해 임의로 설정한 평균값 M 을 더한다.

$$X_i + M$$

80), $M_3 = (150, 120)$, $M_4 = (200, 195)$, $M_5 = (240, 225)$ 이며, 공분산은 $\sigma_{11} = \sigma_{22} = \sqrt{1000}$ 로 설정하였다. 그림 1은 다 채널 모의영상을 구성하는 2개의 컴포넌트 영상으로 자기공명 영상의 SD/T2에 해당되는 영상이다. 그림 2는 모의영상을 k -평균 알고리즘과 제안된 방법에 의한 영상분류 결과이다.

영상분류결과 가시적으로 나타나는 클래스 맵의 경우 제안된 알고리즘에 의한 영상분류결과 노이즈가 거의 없음을 알 수 있었다.

2. 자기공명영상의 분류 결과

모의 영상의 평가에 이어 제시된 최적화 방법은 자기공명영상에 적용되었다. 다음 그림 3은 영상분류에 사용될 두 종류의 자기공명 영상을 제시하고 있다.

영상 분류는 앞서 제시된 방법과 같이 실험 영상으로부터 군집의 분석을 통하여 영상을 구성하는 기본적인 군집들의 형태 및 정보를 추출한 후 신경망에 적용하였다. 신경망과 MFA을 이용한 최적화 단계에서 냉각 스케줄에 적용될 초기 온도 값 T_0 는 100으로 설정해 주었으며 온도의 변화는

$$T = 0.9 \times T_0$$

로 정의하였다. 그림 4는 실험 영상 I의 분류 및 최적화 과정에서 에너지 함수 값의 변화 과정을 제시한 그림으로 반복 과정에서 영상의 분류결과 최적화 상태로 에너지가 수렴하고 있음을 보여주고 있다.

그림 5는 각각 k 평균 알고리즘 및 제시된 방법에 의한 영상 분류 결과를 제시하고 있다.

k 평균 알고리즘에 제공되는 실험 영상은 배경을 제외한 모두 6개의 클래스로 구성되며 이값은 영상의 군집화 과정을 통하여 획득하였다. 한편 의료정보의 공유 등으로 발생하는 문제중의




그림 2. k -평균 알고리즘(왼쪽)과 제안된 알고리즘(오른쪽)에 의한 영상분류




그림 3. 자기공명 실험 영상 (I, II)

하나는 이러한 의료영상의 전송 보관 중에 발생하는 영상의 손상 문제라 할 수 있으며 이러한 측면에서 제시된 알고리즘이 잡음에 의해 손상된 영상에 어떻게 반응하는가를 부가적으로 실험




그림 4. 에너지 함수값의 변화과정

하였다. 의료영상의 경우 제안된 방법이 영상의 훼손이나 잡음이 내포된 영상의 분류에 영향을 주지 않음을 보여주기 위해서 사람의 뇌 영상인 PD (or SD), T2 영상에 가우시안 잡음 생성기를 이용하여 30%의 잡음을 생성한 뒤 분류하도록 한다. 그럼 k 평균 알고리즘과 제안된 알고리즘을 이용하여 영상을 분류한 것으로서 잡음이 생성된 영상에 대해서도 제시된 영상이 분류결과가 우수함을 알 수 있었다. k 평균 알고리즘의 경우 영상분류 결과가 지역적 최소치로 수렴할 수 있으나 제안된 방법에 의하면 전역적 최적화 결과를 얻을 수 있었다.

결 론

영상의 분류란 영상을 각각의 특성에 맞게 일정한 영역으로 나누어주는 과정을 말한다. 이러한 작업은 화소의 밝기, 스펙트럼 값, 또는 텍스처 요소 등과 같은 영상의 속성을 기준으로 거리측정이나 일정한 기하학적 방법을 이용하여 이루어진다. 분류작업은 단일작업이기 보다는 일종의 전처리과정으로 많이 사용된다. 즉, 영상을 정확히 이해하여 어떤 영상인지를 판단하는 영상인식작업이나 2차원 영상들의 분류 데이터를 이용한 삼차원 가시화를 위해 주로 사용되고 있다. 인간의 뇌의 경우는 구조상의 복잡성으로 인하여 전체적인 조직과 구조를 정확히 촬영하기가 어렵다. 최근에는 다른 촬영기법보다는 정확한 영상데이터를 출력하는 MR 촬영 법이 많이 사용되고 있다. 그러나 MR




그림 5. k 평균 알고리즘에 의한 영상분류 결과 (상), 제안된 방법에 의한 영상분류 결과 (하)




그림 6. 잡음 영상의 분류 결과 및 3차원 클래스 맵 (k 평균 알고리즘 (상) 및 제안된 알고리즘 (하))

영상은 조직들 사이의 혼합된 부분이 넓게 퍼져있기 때문에 경계가 불분명하여 기존의 영상분류 알고리즘으로는 정확한 분류 값을 얻기가 어렵다. 이러한 점을 해결하기 위하여 영상을 분류하는 알고리즘으로서 인간의 뇌신경을 모방한 신경망 중 최적화 작업에 적합한 흡필드 망을 이용하였다. 기존의 여러 종류의 신경망 가운데 구조가 간단하면서도 상대적으로 강력한 수행 능력을 보이고, 잡음 등에 의해 손상된 영상의 복원능력도 갖고 있다는 점에서 활용의 가치가 있다고 판단된다. 그러나 앞서 언급하였듯이, 흡필드 망은 수렴속도의 문제와 지역적 최소치로의 수렴할 수 있다는 단점을 나타냈으며, 이를 해결하기 위해서 먼

저 과다한 클래스 맵의 생성과, 처리속도의 향상을 위해 초기 값을 임의로 설정하는 대신 최소거리의 군집끼리 병합해 가는 응집 군집화 알고리즘에 의해 초기 값을 설정해주었다. 지역적 최소치로의 수렴을 해결하기 위해서는 일반적인 모의 애닐링 알고리즈다 처리속도가 빠른 MFA 알고리즘을 이용하여 에너지 값을 냉각 스케줄에 따라 감소시켜주면서 에너지함수가 전역적 최소치로 수렴하도록 유도하는 방법을 이용하였다. 자기공명영상과 실험영상에 제안된 분류방법을 적용한 결과 개선된 영상분류결과를 유도할 수 있었으며 영상에 잡음이 있을 경우에도 기존의 분류방법에 비해 효율적인 영상분류결과를 얻을 수 있었다.

참 고 문 헌

1. Torf Finn Taxt, "Multispectral Analysis of the Brain Using Magnetic Resonance Imaging", IEEE Trans. on Medical. Imaging, Vol. 13, No. 3, pp. 470-481, 1994
2. N. Shareef and D. L. Wang, "Segmentation of Medical Images Using LEGION", IEEE Trans. on Medical Imaging, Vol. 18, No. 1, pp 74-91, 1999
3. S.C. Amartur, D. Piraino, and Y. Takefuji, "Optimization Neural Networks for the Segmentation of Magnetic Resonance Images", IEEE Trans. on Medical. Imaging, Vol 11, No. 2, pp. 215-220, 1992
4. R. Samouda, N. Niki, "Optimization Neural Networks for the Segmentation of Brain MRI Images", CAR' 95, Berlin, pp. 671-680, 1995
5. R. Sammouda, N. Niki, and H. Nishitani, "Neural Networks for the Segmentation of Magnetic Resonance Images", in Image Analysis Application and Computer Graphics eds, Springer Lecture Notes in Computer Science Vol. 1024, pp. 339-346, 1995
6. Shiaw-Shian Yu and Wen-Hsiang Tsai, "Relaxation by the Hopfield Neural Network", Pattern Recognition, Vol. 25, No. 2, pp. 197-209, 1992
7. Carlos Calderon-Macias, Mrinal K. Sen, and Paul L. Stoffa, "Hopfield neural networks, and mean field annealing for seismic deconvolution and multiple attenuation", Geophysics, Vol. 62, No. 3, pp. 992-1002, 1997
8. Bilbro, G., Synder, W., Garmer, S., and Gult, J., "Mean Field Annealing: A Formalism for constructing GNC-like algorithm" IEEE Trans. on Neural Networks, Vol. 3, pp131-138, 1992
9. Bart Kosko, Neural Networks for Signal Processing, Prentice Hall, New Jersey, 1992
10. Zhou, C., Cai, W. Lou, Y., Shuster, G. T., and Hassanzadeh, S., "Acoustic wave-equation traveltime and waveform inversion of crosshole seismic data", Geophysics, Vol. 60, pp. 765-773, 1995
11. Christopher M. Bishop, Neural Networks for Pattern Recognition, Clarendon Press, New York, 1995
12. Robert Schalkoff, Pattern Recognition: statistical, structural and neural approaches, John Wiley & Sons, Canada, 1992
13. J.J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities", in Proc. Nat. Acad. Sci., Vol 79, pp. 2554-2558, 1982
14. Keinosuke Fukunaga, Introduction to Statistical Pattern Recognition, Academic Press, San Diego, 1990
15. J.C Chun,, Ian R. Greenshields, "Classification Algorithm for Multi-Echo Magnetic Resonance Images Using Gibbs distributions," in Image Analysis Application and Computer Graphics eds, Springer Lecture Notes in Computer Science Vol. 1024, pp. 419-426, 1995

Classification of Magnetic Resonance Imagery Using Deterministic Relaxation of Neural Network

Junchul Chun¹, Kyongpil Min¹, Soo Il Kwon²

¹Department of Computer Science, Kyonggi University

²Department of Medical Physics, Kyonggi University

Purpose : This paper introduces an improved classification approach which adopts a deterministic relaxation method and an agglomerative clustering technique for the classification of MRI using neural network. The proposed approach can solve the problems of convergency to local optima and computational burden caused by a large number of input patterns when a neural network is used for image classification.

Materials and methods : Application of Hopfield neural network has been solving various optimization problems. However, major problem of mapping an image classification problem into a neural network is that network is opt to converge to local optima and its convergency toward the global solution with a standard stochastic relaxation spends much time. Therefore, to avoid local solutions and to achieve fast convergency toward a global optimization, we adopt MFA to a Hopfield network during the classification. MFA replaces the stochastic nature of simulated annealing method with a set of deterministic update rules that act on the average value of the variable. By minimizing averages, it is possible to converge to an equilibrium state considerably faster than standard simulated annealing method. Moreover, the proposed agglomerative clustering algorithm which determines the underlying clusters of the image provides initial input values of Hopfield neural network.

Results : The proposed approach which uses agglomerative clustering and deterministic relaxation approach resolves the problem of local optimization and achieves fast convergency toward a global optimization when a neural network is used for MRI classification.

Conclusion : In this paper, we introduce a new paradigm to classify MRI using clustering analysis and deterministic relaxation for neural network to improve the classification results.

Index words : Classification
Deterministic Relaxation
Neural network

Address reprint requests to : Junchul Chun, Department of Computer Science, Kyonggi University,
San 94-6 Yiui-dong, Paldal-gu, Suwon 442-760, Korea.
Tel. 82-31-249-9668/9670 Fax. 82-31-249-9673 E-mail: jcchun@kuic.kyonggi.ac.kr