

개선된 신경망 알고리즘을 이용한 영상 클러스터링

Image Clustering using Improved Neural Network Algorithm

박 상 성, 이 만 희, 유 현 우, 문 호 석, 장 동 식^{*}
 (Sang Sung Park, Man Hee Lee, Hun Woo Yoo, Ho Seok Moon, and Dong Sik Jang)

Abstract : In retrieving large database of image data, the clustering is essential for fast retrieval. However, it is difficult to cluster a number of image data adequately. Moreover, current retrieval methods using similarities are uncertain of retrieval accuracy and take much retrieving time. In this paper, a suggested image retrieval system combines Fuzzy ART neural network algorithm to reinforce defects and to support them efficiently. This image retrieval system takes color and texture as specific feature required in retrieval system and normalizes each of them. We adapt Fuzzy ART algorithm as neural network which receive normalized input-vector and propose improved Fuzzy ART algorithm. The result of implementation with 200 image data shows approximately retrieval ratio of 83%.

Keywords : image retrieval, content-based, color, texture, features, neural network, ART, Fuzzy ART

I. 서론

컴퓨터와 인터넷의 발달로 이를 기반으로 하는 멀티미디어 응용이 크게 주목을 받기 시작하였다. 최근 컴퓨터와 통신기술의 발달과 더불어 영상 및 비디오, 오디오 등을 중심으로 한 멀티미디어 정보 서비스에 대한 요구가 증가하고 있다. 그래서 이를 제공하기 위한 멀티미디어 검색 기술의 필요성이 대두되고 있다. 멀티미디어 매체 중에서도 특히 이미지 정보는 사람의 시각으로 인지되는 매체로서 멀티미디어 정보 가운데에서도 많은 비중을 차지하며, 다른 매체에 비해 정보의 전달 효과가 크기 때문에 이미지 매체를 이용한 다양한 응용들이 개발되고 있다. 이처럼 다양한 응용을 목적으로 이미지 데이터에 대한 요구가 증가함에 따라 데이터베이스 측면에서 신속, 정확하게 이미지 데이터를 검색할 수 있는 새로운 방법이 절실히 요구된다. 내용기반 이미지 검색기법은 복잡한 구조를 지닌 이미지 데이터를 효율적으로 접근하기 위해 제시된 대표적인 방법이다. 내용기반 이미지검색이란 이미지에서 내용을 표현하는 특징들을 추출한 후, 추출된 특정 데이터들을 기반으로 이미지를 검색하는 방법을 말한다. 대용량성과 비정형성의 특징을 지니고 있는 대량의 이미지 데이터를 대상으로 하는 내용기반 이미지 검색 시스템에서 중요한 문제는 검색의 효율성이며, 이를 위해 적절한 색인 기법을 설계해야 한다. 내용기반 이미지 검색을 위한 전형적인 색인 구조는 이미지 데이터로부터 고차원의 특징 데이터를 추출한 후, 추출된 특

징 데이터를 하나의 차원으로 간주하여 이미지 데이터를 색인 하는 방법을 주로 사용하고 있다[1]. 이러한 이미지 색인 구조에서는 수십 또는 수백 개의 특징들로 표현되는 이미지를 색인 해야 한다. 또 내용기반 이미지 검색을 위해 기존 다차원 색인 구조를 사용하는 방법에 대해 많은 연구가 진행되어 왔다. 그러나 이러한 다차원 색인 기법들은 특징 데이터의 수가 증가함에 따라 검색시간이나 기억공간에 대한 요구가 지수적으로 증가되어 고차원 데이터에 대해서는 순차적으로 탐색하는 것에 미치지 못하는 결과를 초래하여 색인구조로서의 기능을 상실하게 된다. 따라서 기존에 제시된 다차원 색인 기법들은 고차원의 이미지 데이터를 색인 하기에 적합한 색인구조라고 할 수 없다. 이와 같은 문제를 해결하기 위해 본 논문에서 제시된 방법은 Fuzzy ART(adaptive resonance theory) 신경망 모델을 이용하여 각각의 영상에 대해 오프라인에서 영상들이 가지고 있는 특징벡터를 신경망 모델의 입력벡터로 넣어 준다. 신경망의 학습을 통해 대량의 영상 데이터는 유사한 영상들로 클러스터링 된다. 최근 신경망을 이용하여 클러스터링 하는 연구로는 SOM(self organizing map)을 이용하여 이미지 데이터베이스를 클러스터링 한 것과 유사도 피드백에서 가중치를 신경망 학습을 통해 조정해 주는 것이 있다[2]. 그러나 SOM을 이용한 내용기반 영상검색 시스템의 경우 사용자가 인터페이스에서 지속적인 분류작업을 하여야 한다. 즉, 유사한 영상들을 체크하면 그와 유사한 영상을 다시 분류해서 인터페이스를 통해서 보여준다. 사용자는 생성된 디스플레이 영상에서 다시 분류 작업을 한다. 그래서 SOM을 이용한 검색시스템은 이러한 작업을 반복적으로 실행하여야 하는 단점이 있다. BP를 이용한 검색시스템의 경우 전체적인 검색시스템에 활용되는 것이 아니라 단지 기존 검색 시스템에서 검색된 영상을 대상으로 유사한 영상을 골라서 재검색을 하는 유사도 피드백에만 사용이 국한되어 있다[3]. 본 논문에서 사용한 신경망 알고리즘은 특징치로 추출

* 책임저자(Corresponding Author)

논문접수 : 2003. 12. 5., 채택확정 : 2004. 5. 13.

박상성 : 고려대학교 산업시스템정보공학과 (hanyul@korea.ac.kr)

이만희 : 삼성테크윈 (sunvee@dreamwiz.com)

유현우 : 연세대학교 인지과학연구소 (paulyhw@yonsei.ac.kr)

문호석, 장동식 : 고려대학교 산업시스템정보공학과

(bawooi@korea.ac.kr/jang@korea.ac.kr)

※ 본 연구는 한국문화콘텐츠진흥원 디지털문화콘텐츠기술개발 사업(2-02-2002-001-1037-27-0002)의 지원에 의해서 수행되었음.

된 입력 벡터가 0과 1사이의 아날로그 값이므로 이러한 데이터를 입력 벡터로 받을 수 있는 Fuzzy ART를 사용하였고 ART의 장점인 적응성과 안정성을 더욱 보강하기 위해 신경망 알고리즘을 개선하여 영상을 자동으로 클러스터링 되도록 알고리즘을 제안하였다.

II. 영상 특징 추출

1. 색상 특징 추출

내용기반 영상검색에서 대표적인 색상 특징으로는 RGB, HSV, YIQ, YUV 등과 같은 모델이 있다. 본 논문에서는 이 중에서도 특히 인간의 시각 능력에 유사한 색상 모델인 HSV모델을 사용하여 영상의 색상 정보 추출을 하였다. (1)-(2)에 의하여 RGB모델을 HSV모델로 변환하여 얻은 색도(hue), 채도(saturation), 명도(value)를 색상 특징으로 이용했다.

$$H = \begin{cases} \Theta & , G \geq B \\ 2\pi - \Theta & , G \leq B \end{cases} \quad (1)$$

여기서 $\Theta = \cos^{-1} \left[\frac{\frac{1}{2}[(R-G)+(B-G)]}{[(R-G)^2+(B-G)(G-B)]^{\frac{1}{2}}} \right]$

$$S = 1 - \frac{3}{R+G+B} [\min(R, G, B)] \quad (2)$$

$$V = \frac{1}{3}(R+G+B) \quad (3)$$

영상의 지역적 정보를 특징치로 쓰기 위해 본 논문에서는 영상을 3×3 개의 일정한 크기의 영역으로 나눴으며 각 영역에서 HSV의 연합된 히스토그램(Joint Histogram)을 구하고 그중에 가장 두드러진 h , s , v 를 구해서 그 영역에서의 대표적 특징값으로 삼았다. 그리하여 h , s , v 각각에서 총 27 개의 입력벡터를 구하였다.

2. 질감 특징 추출

영상에 있어서 질감의 분석은 컴퓨터 비전에서 상당히 중요한 분야이다. 대부분의 자연 영상은 질감을 포함하고 있으며 이러한 영상으로는 나무, 잔디가 포함된 영상을 들 수 있다. 이러한 영상들은 색상과 모양 정보보다는 질감정보를 사용하여 구분하는 것이 매우 편리하다. 따라서 질감의 특징을 영상검색에 사용하였다. 질감 특징으로는 gray-level co-occurrence matrix를 이용하여 얻을 수 있는 여러 개의 질감 특징 중 영상의 혼잡도를 나타내는 엔트로피 특징을 추출하였다. 질감 특징을 얻기 위해 한 영상을 3×3 , 즉 9개의 영역으로 나누어 각 영역의 4방향($0^\circ, 90^\circ, 45^\circ, 135^\circ$)에 대해 정규화된 gray-level co-occurrence matrix를 계산해야 한다. 먼저 정규화(normalization)되기 전 co-occurrence matrix의 각 엔트리(entry)의 값(frequency)은 아래와 같은 정의에 의해 얻을 수 있다.

예를 들어 $\{(0, 0, 1), (0, 0, 1), (0, 2, 2)\}$ 라는 3×3 matrix 가 있을 때 0° 방향에 대한 matrix의 1행 1열은 4가 된다. 왜냐하면 수평방향에 대해 왼쪽, 오른쪽으로 각각 2개씩 있기 때문이다. 이런 방법으로 4방향($0^\circ, 90^\circ, 45^\circ, 135^\circ$)에 대한

각각의 gray level co-occurrence matrix를 얻을 수 있다. 각각의 엔트리를 이용하여 다음과 같이 엔트로피를 구한다.

여기서 $p(i,j)$:gray-level co-occurrence matrix의 (i,j) 째 엔트리 각 방향 entropy를 구한 후 평균하여 평균 entropy를 구한다. 각각의 값들을 다시 정규화 하여 9개의 블록에서

$$\begin{aligned} P(i, j, d, 0^\circ) &= \text{num}\{(k, l), (m, n) \in (Ly \times Lx) \times (Ly \times Lx) \\ &\quad | k-m=0, |l-n|=d, I(k, l)=i, I(m, n)=j\} \\ P(i, j, d, 45^\circ) &= \text{num}\{(k, l), (m, n) \in (Ly \times Lx) \times (Ly \times Lx) \\ &\quad | (k-m=d, l-n=-d) \text{ or } (k-m=-d, l-n=d), I(k, l)=i, I(m, n)=j\} \\ P(i, j, d, 90^\circ) &= \text{num}\{(k, l), (m, n) \in (Ly \times Lx) \times (Ly \times Lx) \\ &\quad | |k-m|=d, l-n=0, I(k, l)=i, I(m, n)=j\} \\ P(i, j, d, 135^\circ) &= \text{num}\{(k, l), (m, n) \in (Ly \times Lx) \times (Ly \times Lx) \\ &\quad | (k-m=d, l-n=d) \text{ or } (k-m=-d, l-n=-d), I(k, l)=i, I(m, n)=j\} \end{aligned}$$

여기서 $P(i, j, d, \text{방향})$: 각 방향에 대한 matrix i행 j열 entry의 값
 $Lx = \{1, 2, \dots, Nx\}$, $Ly = \{1, 2, \dots, Ny\}$, $G = \{1, 2, \dots, Ng\}$
 $image I$: $Ly \times Lx \rightarrow G$
 Nx : 영상의 가로방향 픽셀수
 Ny : 영상의 세로방향 픽셀수
 Ng : gray levels
 d : 계산에 고려할 이웃 픽셀과의 거리
 num : 정의를 만족하는 개수

$$Entropy = - \sum_i \sum_j p(i, j) \log(p(i, j)) \quad (4)$$

각각의 특징치를 얻는다.

III. Fuzzy ART 알고리즘과 문제점

1. ART

우리의 두뇌는 숫자등 확실한 개념보다는 예를 들어 「키가 큰 사람들의 모임」, 「1보다 훨씬 큰 수들의 모임」 등과 같은 불분명한 개념들을 더욱 쉽게 분류, 정리하고, 판단 결정하는 특별한 능력을 가지고 있다. 이러한 인간의 애매한 표현을 수학적으로 접근한 것이 1965년 Zadeh에 의해 도입된 퍼지 집합 이론이다. 패턴 분류 측면에서 볼 때, 이 퍼지 집합 이론을 이용하게 되면 일반적으로 패턴 분류 체계에 존재하는 여러 가지 한계점을 효과적으로 처리할 수 있다. 예를 들어, 부류 할당(class labelling)시 고전적인 패턴 인식에서는 부류 소속 정도(class membership)을 0과 1 오직 이진 수로 나타내는 단순 라벨링(hard labelling)를 사용하기 때문에 패턴을 엄격히 분류하는 것이 불가능하다. 반면에 퍼지 집합이론에서의 소속 함수(membership function)를 도입함으로써 해결될 수 있다. 즉, 퍼지 라벨링은 부류에 소속정도를 0에서 1까지 실수값으로 나타낼 수 있기 때문에 분류결과를 유연성있게 해석할 수 있는 장점을 지니고 있다. 따라서 Fuzzy ART 모델은 ART1모델의 장점인 안정성(stability)과 적응성(plasticity)해결 능력을 지니면서 이진값만을 처리할 수 있는 단점을 보완하기 위해 이러한 퍼지이론을 이용하여

표 1. ART1과 Fuzzy ART 유사 비교.

Table 1. A similarity comparison between ART1 and fuzzy art.

종류 항목	ART1	Fuzzy ART
카테고리 선택	$T_j = \frac{ I \cap W_j }{\alpha + W_j }$	$T_j = \frac{ I \cap W_j }{\alpha + W_j }$
경계 범위 검사	$\frac{ I \cap W_j }{ I } \geq \rho$	$\frac{ I \cap W_j }{ I } \geq \rho$
학습 ($\beta=1$: 고속 학습)	$W_j^{(new)} = I \cap W_j^{(old)}$ \cap : 논리곱 연산자	$W_j^{(new)} = I \wedge W_j^{(old)}$ \wedge : 퍼지 최소값 연산자

실수값(analog)을 처리 할 수 있도록 하였다[4]. 예를 들면, ART1에서 사용되는 논리곱 연산자 \cap 를 퍼지 집합이론의 최소값 연산자 \wedge 로 대체하여 사용함으로써 퍼지 연산자가 갖는 특성인 0과 1사이의 실수값을 처리할 수 있도록 하였다. Fuzzy ART은 구조상 ART1과 매우 유사한 특징을 갖는다. 표 1은 ART1과 Fuzzy ART의 유사성을 비교한 것으로 논리곱 연산자(\cap)가 퍼지 집합이론의 퍼지 최소값 연산자(\wedge)로 바뀐다는 것을 제외하면 이들 구조는 서로 유사하다.[5]

2. 기존 Fuzzy ART의 문제점

그림 1은 Fuzzy ART의 구조를 나타낸 것으로써, 입력층인 F0층, 비교층인 F1층, 출력층인 F2층으로 구성되어 있으며 각각 M, 2M, N개의 노드를 갖고 있다. 입력층(F0)에서는 입력벡터 a 를 상보부호화(complement coding) 입력벡터 I 로 변화시키는 전처리 작업이 이루어진다. 비교층(F1)과 출력층(F2)에서는 ART1에서와 같이 F1층과 F2층 사이에는 하향 연결강도와 상향 연결강도로 연결돼 있으며, F1층은 하향 연결강도벡터와 입력벡터 I 사이의 일치 정도를 비교하고, F2층은 상향 연결강도를 통해 집중된 가장 큰 값을 갖는 노드를 선택한다.

기존 Fuzzy ART 학습시 문제점은 표 1에서 보았듯이 대표패턴 벡터 W_j 가 ART1의 하향 연결강도벡터와 상향 연결강도벡터를 모두 포함한다. 따라서 학습 중에 선택된 F2층의 노드 J 와 관련된 하향 연결강도벡터 t_j 및 상향 연결강도벡터 b_j 의 수정이 다음과 같이 동일한 방법을 사용한다는 것이다.

$$t_j^{(new)} = \beta (I \wedge t_j^{(old)}) + (1 - \beta) t_j^{(old)} \quad (5)$$

$$b_j^{(new)} = \beta (I \wedge b_j^{(old)}) + (1 - \beta) b_j^{(old)} \quad (6)$$

여기서 $\beta \in [0, 1]$ 를 만족하는 학습률 매개변수이며, 상향 연결강도벡터와 하향 연결강도벡터는 같은 값을 갖기 때문에 어느 것이나 노드 J 를 대표하는 대표패턴(prototype)으로 볼 수 있다. 따라서 한 개의 연결강도벡터만 수정하면 되므

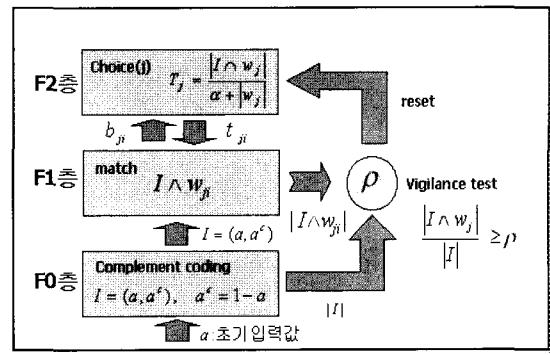


그림 1. Fuzzy ART의 기본 구조.

Fig. 1. A basic structure of fuzzy art.

로 그만큼 빠른 학습을 할 수 있다. 그러나 학습률 매개변수의 범위에 따른 기존 Fuzzy ART 학습 알고리즘은 다음과 같은 여러 가지 문제점을 갖고 있다. 먼저 $\beta=1$ 인 고속학습(fast learning)의 경우 대표패턴은 입력벡터와 연결강도벡터 사이의 퍼지 최소값 연산자(\wedge)만으로 수정되므로 빠르게 안정되지만 입력벡터에 의해 직접적인 영향을 받아 급격한 변화가 발생한다. 따라서 잡음 있는 입력벡터를 학습할 때 잘못 인식하여 원하지 않는 새로운 카테고리수가 급격히 증가되는 단점을 갖고 있다. 두번째로 $0 < \beta < 1$ 인 저속학습(slow learning)인 경우 대표패턴이 일종의 가중치 값 역할을 하기 때문에 입력벡터의 영향을 적게 받지만 너더기게 안정되는 문제가 발생된다. 마지막으로 고속수용 저속재부호(fast-commit slow recode)방법은 비수용노드에 대해서는 고속학습을 하고 수용노드에 대해서는 저속학습을 한다. 이 방법은 대표패턴이 잡음 있는 입력벡터의 영향을 적게 받으면서 어느 정도는 빠르게 안정화 할 수 있다. 이상과 같이 기존 Fuzzy ART 학습 알고리즘을 사용할 경우 잡음 없는 입력패턴에 대해서는 좋은 성능을 보이지만, 잡음 있는 입력벡터를 학습할 때에는 상향 연결강도벡터와 하향 연결강도벡터는 입력벡터와 자체의 연결강도벡터 사이의 퍼지 최소값 연산자(\wedge)에 의해 연결강도벡터가 과도하게 수정되므로 경계값변수가 커짐에 따라 원하지 않는 카테고리수가 급격히 증가되어서 결국 잡음 여유도가 작은 특성을 갖게 된다. 따라서 잡음 있는 입력패턴에 대해서 경계값변수가 커져도 카테고리수가 증가하지 않고 안정된 학습을 할 수 있는 알고리즘이 필요하다.

IV. 개선된 Fuzzy ART 학습 알고리즘

1. 개선된 Fuzzy ART 학습 알고리즘

본 논문에서 제안하는 학습 알고리즘의 학습 과정을 흐름도로 나타내면 그림 2와 같다. 제안된 Fuzzy ART 학습 알고리즘은 기존 학습 알고리즘과는 달리 상향 연결강도벡터와 하향 연결강도벡터를 새로운 학습방법으로 다르게 수정함으로써 잡음있는 입력벡터에 의한 연결강도벡터의 급격한 변화를 막을 수 있어 잡음환경에서 불필요한 카테고리수의 증가 문제를 효과적으로 극복할 수 있다. 학습 알고리즘의 단계별 학습 과정은 다음과 같다.

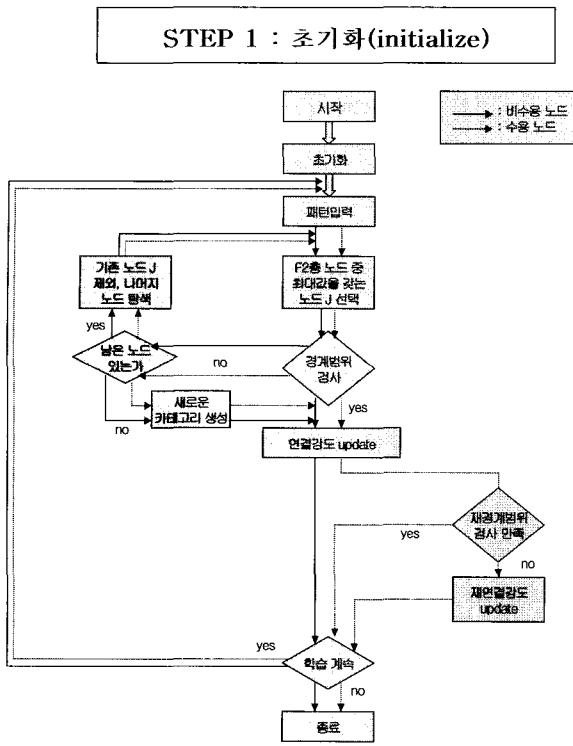


그림 2. 제안된 Fuzzy ART 학습 알고리즘 흐름도.

Fig. 2. A diagram of learning algorithm using proposed fuzzy art.

1) 매개변수(parameter)값 초기화

선택 매개변수 $\alpha \in (0, \infty)$ 학습률 매개변수 $\beta \in [0, 1]$ 경계값 매개변수 $\rho \in [0, 1]$ 가중치 매개변수 $\eta \in [0, 1]$

2) 새로운 입력 벡터의 초기화

각 성분 a_i 가 $[0, 1]$ 사이의 실수값을 가지는 새로운 입력 벡터 $a = (a_1, a_2, \dots, a_M)$ 가 들어왔을 때, F0 층에서는 아래 (7)과 같이 상보 부호화(complement coding)를 통해 실질적인 상호 부호화 된 입력 벡터 I 로 변환시킨다.

$$I = (a, a^c) = (a_1, a_2, \dots, a_M, a_1^c, a_2^c, \dots, a_M^c) \quad (7)$$

여기에서 $a_k^c = 1 - a_k$ 이고 상보 부호화된 입력 벡터 I 는 $2M$ 차원을 갖는다. 이렇게 상호 부호화 된 입력 벡터 I 는 F1층에 제공된다.

3) 연결 강도(weights) 초기화

각각의 F2층의 카테고리 노드 $j(j=1, 2, 3, \dots, N)$ 단, 노드수는 임의로 설정한다)에 대하여, 연결강도는 다음과 같이 초기화된다.

$$b_{ji} = t_{ji} = 1, (1 \leq i \leq 2M, 1 \leq j \leq N) \quad (8)$$

여기서 b_{ji} 와 t_{ji} 는 F1층의 i 번째 노드와 F2층의 j 번째 노드사이의 상향과 하향연결강도이다. 한편 F2층의 카테고리는 초기에는 사전에 입력패턴에 의해 선택된 경우가 없는 비수용(uncommitted)되었다고 가정한다.

STEP 2 : 카테고리 선택

이 단계는 입력벡터 I 에 대해서 F2층의 노드 중에서 승자독점(winner-take-all)방법에 부합된 노드를 선택하여 이 노드와 연결된 하향연결강도(대표패턴)와 입력패턴을 비교하기 위한 사전 단계로서, F2층의 j 번째 노드에 대한 선택함수 T_j 는 다음과 같이 구해진다.

$$T_j(I) = \frac{|I \wedge b_j|}{\alpha + |b_j|} \quad (9)$$

여기서 b_j 는 F2층의 j 번째 노드로 집중된 상향 연결강도 벡터이고, 퍼지 최소값 연산자(\wedge)로 결합된 $(a \wedge b)_j = \min(a_j, b_j)$ 로 정의된다.

따라서 (9)에서 구한 T_j 중에서 최대값을 갖는 카테고리 승자노드(winning node) J 가 F2층에서 최종적으로 선택된다.

$$T_J = \max\{T_j : j = 1, 2, \dots, N\} \quad (10)$$

단, 선택된 최대값 T_J 중에서 2개 이상이 같을 경우, j 의 값이 작은 순서로 선택한다.

STEP 3 : 경계범위 검사(vigilance test)

이 단계에서는 STEP 2로부터 선택된 카테고리 노드에 연결된 하향 연결강도(대표패턴)와 입력패턴을 경계범위 검사를 통해 비교하여 입력패턴을 기존 카테고리에 분류할 것인가 아니면 새로운 카테고리를 생성할 것인가를 검사하게 된다.

1) 적응공명(resonance)

적응공명은 선택된 카테고리 승자노드(winning node) J 에 대해 다음의 경계범위 검사를 만족하면 발생한다.

$$\frac{|I \wedge t_J|}{|I|} \geq \rho \quad (11)$$

이 경우는 승자노드에 연결된 하향연결강도벡터(대표패턴)과 입력패턴(벡터)과의 norm를 비교한 경계값 검사를 만족한 것으로써, 이는 STEP 2에서 선택된 승자노드 J 가 기존 카테고리안에 존재한다는 것을 의미한다. 따라서 STEP 4로 이동하여 Fuzzy ART는 입력값에 대한 학습 즉 하향 연결강도벡터(t_i)를 수정하게 된다.

2) 재설정(reset)

재설정은 (11)의 경계범위 검사를 만족하지 않은 경우로서, 선택된 승자노드 J 즉, 선택된 카테고리가 입력 패턴과 서로 다르기 때문에 새로운 카테고리를 다시 선택하도록 하는 과정이다. 재설정이 발생할 경우에는 기존 승자노드 J 가 다시 승자노드 후보가 되는 것을 막기 위해 선택된 카테고리에 대한 T_j 값을 -1로 설정한 후 J 번째 노드를 경쟁에서 제외시키고 나머지 다른 노드중에서 STEP 2의 새로운 최대 선택함수값을 갖는 노드를 다시 찾는다. 이 과정은 STEP 3의 경계범위 검사를 만족하는 J 번째 노드가 선택될 때까지 계속된다. 모든 카테고리 노드를 탐색했을 때도, 경계범위 검사를 만족하는 카테고리가 존재하지 않으면 새로

운 카테고리를 생성하고 STEP 1로 돌아가서 새로운 입력패턴을 받는다.

STEP 4 : 학습(연결강도벡터 수정)

학습은 적응-공명의 상태에서 발생하는데 제안된 학습알고리즘에서는 입력패턴의 형태에 관계없이 다음과 같이 F2층에서 선택된 카테고리 승자노드를 비수용노드와 수용노드로 구분하여 학습한다

1) 비수용노드(uncommitted node)

비수용노드(uncommitted node)란 F2층의 카테고리 노드 $j(j=1, 2, 3, \dots, N)$ 중에서 선택된 카테고리 승자노드가 이전에 이 노드의 대표패턴과 입력패턴의 경계범위 검사를 만족하여 학습한 경험이 없는 노드로서, 이 경우는 새로운 카테고리가 형성되고 이미 형성된 카테고리에는 영향을 주지 않는다. 따라서 패턴이 입력되어 비수용노드일 때는 기존의 학습방법처럼 $\beta = 1$ 인 고속학습을 한다.

$$t_j^{(new)} = \beta (I \wedge t_j^{(old)}) + (1-\beta) t_j^{(old)} \quad (12)$$

$$b_j^{(new)} = \beta (I \wedge b_j^{(old)}) + (1-\beta) b_j^{(old)} \quad (13)$$

2) 수용노드(committed node)

수용노드(committed node)란 이전에 선택된 노드가 이 노드의 대표패턴과 입력패턴과의 경계범위 검사를 만족하여 학습한 경험이 있는 노드로서, 이 경우는 선택된 카테고리만 학습을 하고 다른 카테고리에는 영향을 주지 않는다. 제안된 학습방법에서는 선택된 노드가 수용노드일 경우 다음과 같이 t_j , b_j 를 다른방법으로 수정한다. 즉 하향 연결강도벡터 t_j 는 (14)처럼 입력벡터와 자체벡터의 기중치에 의해 수정되고, 상향 연결강도벡터 b_j 는 (15)와 같이 앞서 수정된 하향 연결강도벡터와 자체벡터 사이의 퍼지 최소값 연산자(\wedge)에 의해 수정된다.

$$t_j^{(new)} = \eta I + (1-\eta) t_j^{(old)} \quad (14)$$

$$b_j^{(new)} = t_j^{(new)} \wedge b_j^{(old)} \quad (15)$$

여기서 (14)의 기중치는 잡음있는 입력벡터에 대해 하향 연결강도벡터의 갑작스런 변화를 막는 완충역할을 하고, (15)의 퍼지 최소값 연산자(\wedge)는 하향 연결강도벡터가 불안정하게 되는 것을 막는다. (14)와 (15)로부터 상향 연결강도벡터만이 단조감소하여 안정화되므로 이 벡터를 대표패턴으로 간주한다. 그런데 만약 입력벡터가 서서히 단조증가한다면, 대표패턴 b_j 가 선택된 카테고리 영역밖에 놓이는 문제가 발생한다.

STEP 5 : 재경계범위 검사(re-vigilance test)

몇 재학습(재연결강도벡터 수정)

이러한 카테고리 증가문제를 해결하기 위해 다음과 같은 경계범위 검사를 다시 실시한다.

$$\frac{|b_j^{(new)} \wedge t_j^{(new)}|}{|I|} \geq \rho \quad (16)$$

만약 (16)의 재경계범위 검사를 만족하지 않으면 b_j 는 선택

된 카테고리 영역밖에 존재하기 때문에 아래와 같이 b_j 를 다시 수정하여 카테고리 영역안에 존재하도록 만든다.

$$b_j^{(new)} = t_j^{(new)} \quad (17)$$

2. 입력패턴에 대한 경계값 매개변수 설정

Fuzzy ART에서 p 는 경계값변수(vigilance parameter)로 임의의 입력패턴과 저장된 카테고리과의 불일치 허용도를 결정하는 일종의 threshold 역할을 하며, 경계값변수 범위에 따라 입력패턴에 대한 시스템 성능이 직접적인 영향을 받는다. 예를들어 경계값변수가 크면 입력패턴과 기대패턴 사이에 약간의 차이만 있어도 새로운 카테고리로 분류하게 되며, 반대로 경계값변수가 작으면 입력패턴과 기대패턴 사이에 많은 차이가 있더라도 허용되므로 입력패턴을 대략적으로 나누게 된다. 따라서 인식성능 측면에서 볼 때, 입력패턴이 정상패턴 뿐만 아니라 잡음있는 패턴의 경우에서 경계값변수가 커져가도 원하지 않는 카테고리수의 증가가 발생되지 않고 인식률이 높은 경계값을 최적 경계값변수를 설정한다. 이에 대한 성능 실험은 5장에서 보이기로 한다.

V. 실험 및 결과

1. 실험 환경

실험을 위해 펜티엄III900, RAM 256M 사양의 PC를 이용했으며, 실험 데이터로 192×128 크기의 24bit BMP 포맷의 영상 200개를 사용하였다. 실험을 위한 인터페이스는 아래의 그림과 같다.

2. 실험결과

본 연구에서는 2가지의 실험을 하였다. 먼저 F2층(클러스터)의 개수에 따른 검색률을 비교하여 보았고, 그리고 기존의 Fuzzy ART와 개선된 Fuzzy ART에서 시스템의 성능비교를 해보았다. 내용 기반 영상 검색에 있어 검색 성능은 precision과 recall을 이용하여 판단한다. 그런데 본 연구에서는 DB내에 존재하는 유사한 영상 중에서 요구된 개수 안에 검출되어진 질의 영상과 유사한 영상의 개수에 대한 비율을 나타내는 recall을 검출율로 사용하였다. 검출율 계산식은 (18)과 같다.

$$\text{검출율} = \frac{\text{검출되어진 유사영상의 수}}{\text{DB내에 존재하는 유사영상의 수}} \quad (18)$$

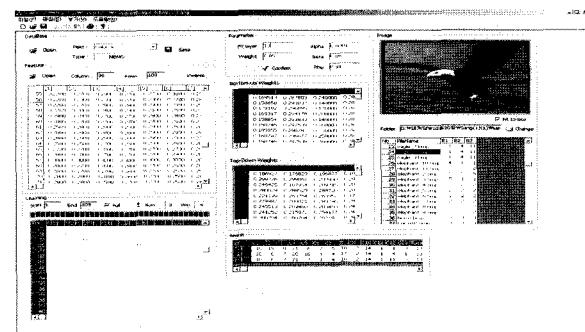


그림 3. 클러스터링 인터페이스.

Fig. 3. An Interface for clustering.

표 2. F2층 개수에 따른 영상 검출률.

Table 2. An image retrieval ratio depending on number of F2-layers.

	F2 = 9	F2 = 10	F2 = 11	F2 = 12	F2 = 13	F2 = 14	평균검출률
비행기(10)	1.000	1.000	1.000	1.000	1.000	1.000	1.000
독수리(15)	0.800	0.800	0.800	0.733	0.733	0.733	0.767
코끼리(10)	0.700	0.800	0.700	0.700	0.700	0.700	0.717
말(20)	0.950	0.950	0.950	0.950	0.950	0.950	0.950
사자(4)	0.750	0.750	0.750	0.750	0.750	0.750	0.750
북극곰(19)	0.947	0.947	0.947	0.895	0.842	0.842	0.903
장미(19)	0.789	0.684	0.632	0.737	0.737	0.737	0.719
얼룩말(6)	0.000	0.000	0.833	0.833	0.833	0.833	0.555
호랑이(20)	0.700	0.750	0.850	0.900	0.850	0.850	0.817
계곡(20)	0.850	0.900	0.900	0.900	0.900	0.850	0.883
일몰(15)	0.733	0.733	0.800	0.800	0.800	0.800	0.778
돌고래(20)	0.600	0.600	0.700	0.650	0.650	0.650	0.642
원숭이꽃(10)	0.800	0.800	0.800	0.900	0.800	0.700	0.800
곰(12)	0.833	0.833	0.833	0.833	0.833	0.833	0.833
평균검출률	0.747	0.753	0.821	0.827	0.813	0.802	0.794

2.1 F2층의 개수에 따른 영상 검출률 비교

본 실험을 하기에 앞서 많을 실험을 통해 최적의 선택 매개변수, 가중치 매개변수, 학습률을 다음과 같이 구하였다. (선택 매개변수 $\alpha = 0.0001$, 학습률 매개변수 $\beta = 0.85$, 가중치 매개변수 $\eta = 0.85$, 학습률 $\rho = 0.91$) 학습은 각각의 실험 조건에 대해 3번씩 시켰다. 본 시스템은 약 3번의 학습이면 클러스터링이 완벽하게 된다. 아래의 표는 마지막 3 번째 나타나는 클러스터링 결과이며 데이터는 파일 이름순으로 정렬된 상태에서 시스템에 입력되었다.

이 실험에서 색상의 분포와 객체의 분포가 크게 변화가 없는 비행기, 말, 북극곰의 영상은 90%이상의 검출율을 보여주고 있다. 하지만 얼룩말은 사자와 말, 코끼리 영상의 객체와 배경과 유사한 점이 많아서 출력층이 10개 일 때까지 영상을 검출하지 못했으나 11개의 출력층이 구성된 다음부터는 검출율이 좋아졌다.

2.2 기존 Fuzzy ART와 개선된 Fuzzy ART의 성능 비교

이번 실험에서는 개선된 Fuzzy ART 알고리즘이 얼마나 효율적인지를 알아보기 위하여 기존 Fuzzy ART와 개선된 Fuzzy ART를 이용한 영상검색의 결과를 비교한다. 이때 실험 성능의 평가는 3회의 학습을 통한 영상의 검출율로 한다. 선택 매개변수, 가중치 매개변수, 학습률 그리고 F2 층은 다음과 같이 구하였다. (선택 매개변수 $\alpha = 0.0001$, 학습률 매개변수 $\beta = 0.85$, 가중치 매개변수 $\eta = 0.85$, 학습률 $\rho = 0.91$, F2 층 $n = 12$)

대응비교에 의한 두 모평균의 추론을 해보면, 개선된 Fuzzy ART가 기존에 쓰이고 있는 고속재부호방식(FCSR)인 Fuzzy ART로 실험으로 나온 평균검출률 데이터의 차이 값이 같다는 귀무가설과 개선된 Fuzzy ART가 기존 Fuzzy ART 보다 더 크다는 대립가설을 세울 수 있다. 즉, 기본 가설은 $H_0 : \mu_1 - \mu_2 = 0$, $H_1 : \mu_1 - \mu_2 > 0$ 이다. 정렬된 데이터가 더 좋은 검출율을 보이는지를 유의수준 5%에서 검정해 보면, 검정통계량은 약 3.517로 유의수준 5%의 임계값 1.771 보다 크므로 귀무가설을 기각한다. 따라서 개선된

표 3. 기존 Fuzzy ART(FCSR)와 개선된 Fuzzy ART의 성능 비교.

Table 3. A performance comparison between fuzzy art and enhanced fuzzy art.

	Improved Fuzzy ART	평균검출율	Fuzzy ART (FCSR)	평균검출율
비행기(10)	10	1.000	10	1.000
독수리(15)	11	0.733	8	0.533
코끼리(10)	7	0.700	7	0.700
말(20)	19	0.950	18	0.900
사자(4)	3	0.750	3	0.750
북극곰(19)	17	0.895	17	0.895
장미(19)	14	0.737	12	0.632
얼룩말(6)	5	0.833	4	0.667
호랑이(20)	18	0.900	16	0.800
계곡(20)	18	0.900	18	0.900
일몰(15)	12	0.800	8	0.533
돌고래(20)	13	0.650	10	0.500
원숭이꽃(10)	9	0.900	9	0.900
곰(12)	10	0.833	8	0.667
평균검색률		0.827		0.741

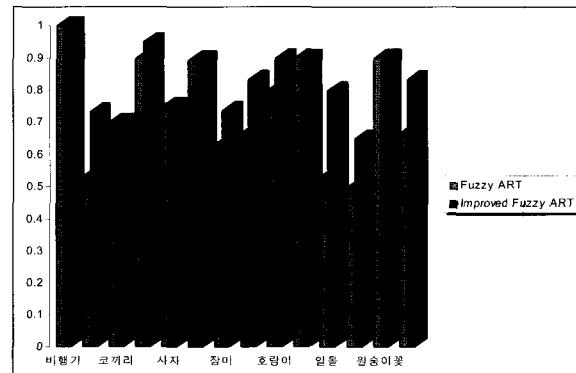


그림 4. 기존 Fuzzy ART와 개선된 Fuzzy ART의 성능 비교.

Fig. 4. A performance comparison between fuzzy art and enhanced fuzzy art.

Fuzzy ART가 기존 Fuzzy ART보다 검출율이 좋다. 실험을 통하여 개선된 Fuzzy ART가 기존 Fuzzy ART 보다 약 10%의 검색률 향상을 보임을 알 수 있다.

VI. 결론 및 향후과제

본 논문에서는 정지 영상을 구성하고 있는 주요 객체들의 대표 색상 및 질감 형태 특징치를 VQ(Vector Quantization) 알고리즘을 이용하여 빠르게 추출하였으며 한 영상의 내용을 적절하게 표현하는 대표 특징치를 내용 기반 검색에 이용함으로써 정지영상의 내용에 근거한 검색을 가능하게 했고 이러한 특징치를 입력 벡터로 하여 개선된 Fuzzy ART에 적용시켜 영상을 검색하도록 하였다. 영상의 특징으로 색상과 질감 특징을 이용하였다. 색상 특징으로는 RGB 색상 모델을 HSV 색상 모델로 변환함으로써 얻을 수 있는 색도, 채도, 명도를 이용하였고, 질감 특징으로는 gray-level

co-occurrence matrix를 이용하여 얻을 수 있는 entropy를 이용했다. 실험을 통하여 개선된 Fuzzy ART가 기존 Fuzzy ART보다 더 좋다는 것을 통계적 검정으로 확인하였으며 데이터의 정렬을 통하여 더 좋은 검출율을 높일 수 있음을 검증하였다.

향후 과제는 영상을 온라인상에서 입력을 받아 실시간으로 학습을 할 수 있는 시스템을 구현함으로써 ART의 특징인 적응성과 안정성을 갖도록 하여야 할 것이다. 또 유사도 피드백에 ART를 적용시켜 검색 후 재검색시 더 좋은 검출율을 가질 수 있는 시스템에 관한 연구가 필요하다.

참고문헌

- [1] W. Niblack and et. al., "The QBIC Project : Querying Images By Content Using Color, Textures and Shape," *SPIE Storage and Retrieval for Image and Video Databases*, vol 1908, pp.173-187, 1993.
- [2] J. Laaksonen, M. Koskela, S. Laaksonen and E. Oja, "Self-Organising Maps as a Relevance Feedback Technique in Content-Based Image Retrieval", *Pattern Analysis & Applications*, vol. 4, pp. 140-152, 2001.
- [3] J. Fournier, M. Cord, S. Philipp-Foliguet, "Back-Propagation Algorithm for Relevance Feedback in Image Retrieval", *Conference on International Image Processing*, 2001.
- [4] C. J. Lin and C. T. Lin, "Reinforcement Learning for an ART-Based Fuzzy Adaptive Learning Control Network", *IEEE Trans. Neural Networks*, vol. 3, no. 3, pp. 709-731, 1996.
- [5] G. A. Carpenter, S. Grossberg and D. B. Rosen, "Fuzzy-ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system", *Neural Networks*, vol. 4, pp.759-771, 1991.



박상성

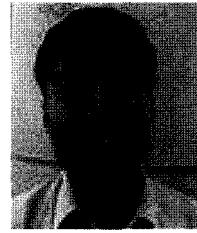
1975년 8월 28일생. 동양대학교 산업공학과 졸업(2001). 고려대학교 산업공학과 졸업(2003). 현재 고려대학교 산업시스템정보공학과 박사과정. 관심분야는 이미지 프로세싱, 패턴인식, 뉴럴네트워크, 컴퓨터 비전.

이만희

제어·자동화·시스템공학 논문지 제 5 권 제 4 호 참조.

장동식

제어·자동화·시스템공학 논문지 제 7 권 제 4호 참조.



문호석

1971년 10월 9일생. 육군사관학교 화학과 졸업(1994). 고려대학교 전자컴퓨터공학과 졸업(2003). 현재 고려대학교 산업시스템정보공학과 박사과정. 관심분야는 신호처리, 영상검색, 3D 그래픽.

유현우

제어·자동화·시스템공학 논문지 제 7 권 제 4 호 참조.