

Medical Image Classification and Retrieval Using BoF Feature Histogram with Random Forest Classifier

Son Jung Eun[†] · Ko Byoung Chul^{**} · Nam Jae Yeal^{***}

ABSTRACT

This paper presents novel OCS-LBP (Oriented Center Symmetric Local Binary Patterns) based on orientation of pixel gradient and image retrieval system based on BoF (Bag-of-Feature) and random forest classifier. Feature vectors extracted from training data are clustered into code book and each feature is transformed new BoF feature using code book. BoF features are applied to random forest for training and random forest having N classes is constructed by combining several decision trees. For testing, the same OCS-LBP feature is extracted from a query image and BoF is applied to trained random forest classifier. In contrast to conventional retrieval system, query image selects similar K-nearest neighbor (K-NN) classes after random forest is performed. Then, Top K similar images are retrieved from database images that are only labeled K-NN classes. Compared with other retrieval algorithms, the proposed method shows both fast processing time and improved retrieval performance.

Keywords : Content-Based Image Retrieval, OCS-LBP, Bag-of-Feature, Random Forest, K-Nearest Neighbor

Random Forest 분류기와 Bag-of-Feature 특징 히스토그램을 이용한 의료영상 자동 분류 및 검색

손정은[†] · 고병철^{**} · 남재열^{***}

요 약

본 논문에서는 의료영상의 특성을 반영하여 픽셀 그래디언트의 방향 값을 특징으로 하는 OCS-LBP (Oriented Center Symmetric Local Binary Patterns) 특징을 개발하고 BoF(Bag-of-Feature)와 Random Forest 분류기를 이용한 영상 검색 방법을 제안한다. 학습영상에서 추출된 특징 값은 code book 으로 군집화 되고, 각 영상들은 code book을 통해 의미 있는 새로운 차원인 BoF특징으로 변환된다. 이렇게 추출된 BoF 특징은 Random Forest 분류기에 적용되고 학습된 분류기에 의해 유사한 특성을 갖는 N개의 클래스별로 분류되게 된다. 질의 영상이 입력되면 동일한 OCS-LBP특징이 추출되고 code book을 통해 BoF특징이 추출된다. 전통적인 내용기반 영상검색과는 다르게, 본 논문에서는 질의 영상에서 추출된 BoF특징이 학습된 Random Forest에 적용되어 가장 유사한 K-근접 이웃 (K-nearest neighbor) 클래스들을 선택하고 선택된 클래스들에 포함된 영상들에 대해서만 질의 영상과의 BoF 유사도 측정을 통해 최종 유사한 영상을 검색하게 된다. 실험결과에서 본 논문에서 제안하는 방법은 빠르고 우수한 검색 성능을 보여 주었다.

키워드 : 내용기반 영상 검색, OCS-LBP, Bag-of-Feature, Random Forest, K-근접 이웃

1. 서 론

최근 의료산업이 발전함에 따라 의료관련 장비에서 획득된 다양한 의료영상에 대한 관리의 필요성이 증대 되고 있다. 또한 IT산업과 의료산업의 융복합 연구에 대한 필요성에 따라 통합 의료 정보 시스템(Integrated Medical

Information System)에 대한 연구 및 개발이 활발하게 이루어지고 있다. 이러한 연구 수요를 반영하여 의학 분야에서는 영상처리, 통신, 데이터베이스 등 다양한 IT기술을 바탕으로 의료 지원 시스템인 PACS (Picture Archiving Communication System)와, 의료 영상용 표준 네트워크 프로토콜인 DICOM (Digital Imaging and Communications in Medicine)등이 제정 되었다.

하지만 현재 사용되고 있는 PACS시스템은 의료영상에 대해 관리자가 사전에 입력한 키워드에 의존하고 있으므로 영상에 포함된 다양한 의료정보를 검색할 수 없는 한계점이 있다. 또한 키워드 기반의 의료영상 검색은 부여된 키

[†] 준 회 원: 계명대학교 컴퓨터공학과 석사과정

^{**} 종신회원: 계명대학교 컴퓨터공학과 부교수

^{***} 정 회 원: 계명대학교 컴퓨터공학과 교수

논문접수: 2012년 12월 5일

심사완료: 2013년 1월 9일

* Corresponding Author: Ko Byoung Chul(niceko@kmu.ac.kr)

워드에 대해서는 정확성이 뛰어나더라도 불구하고 키워드 입력 및 관리를 위한 비용적 측면이나 시간적 측면에서 매우 비효율적인 방법이다. 이러한 한계를 극복하기 위해 의료 영상에 포함되어 있는 특징 값들을 추출하여 검색에 사용하는 내용기반 영상 검색 방법과 의료영상을 종류에 따라 분류하는 영상 분류 방법이 지난 10여 년간 꾸준히 연구되어 오고 있다.

서미숙 [1]등은 입력된 의료영상에서 초기 중요도 영역을 설정하고 영역들을 사전 정의된 기준에 따라 가중치를 부여하였다. 이후, 각 중요 영역에서 추출된 특징과 질의영역에서 설정된 중요 영역들의 특징 유사도 비교를 통해 의료영상을 검색하는 방법을 제안하였다.

박기희 [2]등은 MPEG-7에 정의되어 있는 색 구조 기술자와 질감 기술자를 이용하여 영상의 시각적 특징을 추출하고, 다중 클래스 SVM (Multi-class Support Vector Machine, MSVM)을 사용하여 영상들을 분류하였다. 각 특징 기술자에 대해 서로 다른 다중 클래스 SVM을 학습 시키고 각각의 분류기에서 나온 멤버십 스코어를 결합한 앙상블 벡터를 이용한 의료 영상 검색 방법을 제안하였다.

Uwimana[3]등도 유사하게 영상에서 색상 및 질감 특징을 추출하고 SVM 분류기를 통해 자동적으로 영상들을 분류할 수 있는 GIFT (GNU Image Finding Tool) 시스템을 제안하였다.

Avni [4]등은 X-ray영상을 지역 패치로 분할하고 각 패치로부터 특징을 추출하여 BoF (Bag-of-Feature)를 생성하였다. 또한, 생성된 BoF 특징과 커널 기반의 SVM을 학습 시켜 영상을 카테고리별로 분할하고 검색하는 알고리즘을 제안하였다. 하지만 BoF의 차원이 커질수록 SVM을 이용한 분류 성능은 향상되지만, 분류 시간이 성능과 반비례하게 증가되는 단점이 있다.

Wang [5] 등은 의료영상을 패치 단위로 나누고 각 패치들로부터 추출된 SIFT (Scale Invariant Feature Transform)특징을 이용하여 BoF를 생성하였다. 이후에 부스팅(boosting) 알고리즘을 이용하여 BoF의 각 빈(bin)에 해

당하는 visual word에 서로 다른 가중치를 부여하는 방법을 통해 영상을 검색하는 방법을 제안하였다.

Ko [6] 등은 영상 분류를 통해 의료영상을 사전에 정의된 카테고리로 분류하고, 각 영상의 신체 관계 그래프에 의해 영상 별로 주석을 부여하는 알고리즘을 제안하였다. 또한 부여된 주석에 의해 키워드를 기반으로 하는 새로운 개념의 영상 검색 방법을 제안하였다.

의료영상 중에서 X-ray와 CT영상 등은 일반적으로 그레이 영상으로 구성되고, 배경과 전경이 뚜렷이 구분되는 특징을 가진다. 따라서 일반 자연영상에 비해 적용될 수 있는 특징 값이 제한적이며 자연영상과는 다른 분류 및 검색방법이 요구되고 있다.

본 논문에서는 X-ray 및 CT영상의 특성을 반영하여 특징 추출 단계에서 색상 값을 사용하지 않고 영상의 질감 그래디언트의 방향 값을 특징으로 하는 OCS-LBP (Oriented Center Symmetric Local Binary Patterns) 특징을 개발하였다. 학습영상에서 추출된 특징 값은 Fig. 1의 BoF 생성 단계에서 code book으로 군집화 되고, 각 영상들은 code book을 통해 의미 있는 새로운 차원인 BoF (Bag-of-Feature) 특징으로 변환된다. 이렇게 추출된 BoF특징은 Fig. 1의 Random Forest 분류기 단계에 적용되고 학습된 분류기에 의해 유사한 특성을 갖는 N개의 클래스별로 분류되게 된다. 질의 영상이 입력되면 동일한 OCS-LBP특징이 추출되고 code book을 통해 BoF특징이 추출된다.

일반적으로 유사도 측정은 질의 영상이 데이터베이스의 모든 영상을 검색하는 방법을 사용하지만 본 논문에서는 질의 영상에서 추출된 BoF특징이 학습된 Random Forest에 적용되어 가장 유사한 K-인접 이웃 (K-nearest neighbor, KNN) 클래스들을 선택하고 선택된 클래스들에 포함된 영상들에 대해서만 질의 영상과의 BoF 유사도 측정을 통해 최종 유사한 영상을 검색하게 된다.

본 연구의 구성은 다음과 같다. 2장에서는 OCS-LBP 특징 추출 방법을 설명하고 이를 이용하여 BoF를 생성하는 방법을 설명한다. 3장에서는 Random Forest 분류기를 학습

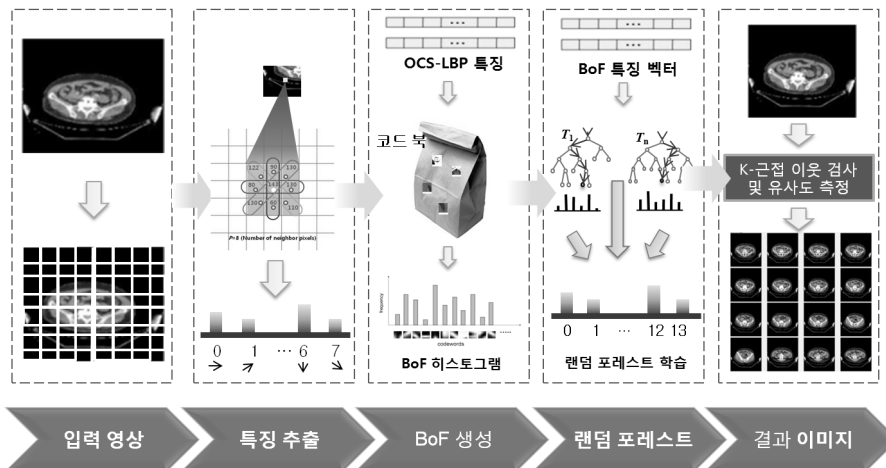


Fig. 1. Overall flowchart of the proposed image retrieval system

하고 학습된 Random Forest를 이용하여 데이터베이스 영상을 분류하는 방법 및 질의 영상을 특정 클래스로 분류하는 방법을 설명한다. 4장에서는 기존의 영상 검색 알고리즘과의 비교실험을 통해 본 논문에서 제안한 기법의 우수성을 입증하고, 5장에서 결론 및 향후 연구방향을 제시한다.

2. OCS-LBP를 이용한 특징 추출 및 BoF 생성

영상검색, 물체인식 등에서 가장 많이 사용되는 SIFT [7] 특징은 영상의 중요한 특징 점을 추출하고 이를 중심으로 그래디언트의 방향정보와 크기를 특징 정보로 사용한다. 하지만 자연영상과 달리 의료영상에는 의학적으로 중요한 영역에 중요 특징 점이 존재하지 않는 경우가 많으므로 SIFT 특징만으로는 유사한 영상을 검색하기에는 한계가 있다. 따라서 본 논문에서는 영상으로부터 특징점을 추출하지 않고, 기존의 의료영상 검색 방법[4-6]과 마찬가지로 영상을 서브영역으로 분할하고 패치 단위로 특징을 추출하는 방법을 사용하였다.

본 논문에서는 기존 방법[4-6]들과 마찬가지로 패치단위로 특징을 추출하지만, 서브 영역을 두어 각 패치단위에서 추출된 특징을 하나의 서브영역단위로 결합하는 과정을 거치도록 하여 특징의 차원을 줄이도록 하였다. Fig. 2A와 같이 영상을 2 × 2 서브 영상으로 분할하고 각 서브 영상을 다시 4 × 4로 분할하여 각 패치를 구성하고 각 패치에서 추출된 특징은 하나의 서브영역 특징으로 결합되어 사용된다.

영상 검색에서 영상의 질감 성분을 분석하고 표현하기 위해 SIFT 특징 이외에도 지역적 이진패턴 기법인 LBP (Local Binary Patterns)가 주로 사용된다[8]. LBP는 중심 픽셀에 대해 이웃하는 픽셀들의 관계를 나타내는 일종의 연산자로서 중심 픽셀을 반경이 R인 원을 P개의 균등한 좌표로 나눈 밝기 값 (P, R)로 표현한다. 하지만 이 방법의 경우 특징벡터가 2⁸(256) 차원으로 각 패치마다 추출된 특징을 결합하면 하나의 서브 영역의 차원이 4096 (4×4×256)차원이 됨으로 실시간 검색을 위해서는 적합하지 않다. 이러한 문제점을 해결하기 위해 [5]의 연구에서는 LBP와 비슷한 성능을 가지면서 더 적은 특징 차원을 갖는 질감 특징인 CS-LBP (Center-symmetric LBP)[9]를 사용하였다. CS-LBP는 중심 픽셀의 이웃하는 픽셀들의 관계를 나타내는 일종의 연산자이다. 중심 픽셀과 거리가 1인 이웃하는 4개의 픽셀들의 차를 계산하고, 그 결과를 반시계 방향으로 정렬하여 중심 픽셀에 대한 CS-LBP값을 얻는다. LBP의 경우 총 256차원이 필요하지만, CS-LBP는 동일한 성능을 보이면서 총 2⁴(16)차원으로 서브영역으로 합칠 경우 256(4×4×16)차원으로 줄어들기 때문에 실시간 처리에 적합하다.

본 논문에서는 특징 차원을 줄이고 효과적으로 영상의 그래디언트 방향 정보를 추출할 수 있도록 CS-LBP를 개선한 Oriented CS-LBP를 제안한다. OCS-LBP는 Fig. 2B에서 보는 것과 같이 각 대칭이 되는 영역들의 픽셀 값을 비교하고

수식 (1)에 의해 값의 차이가 임계값 T 이상일 경우 큰 값을 갖는 방향을 찾고 수식 (2)를 이용하여 차이 값을 누적시키도록 하였다.

$$s(x) = |x| \text{ if } |x| > T \tag{1}$$

$$OCS-LBP_{R,N}^k(x,y) = s(n_i - n_{i+(N/2)}) \tag{2}$$

(0 < i < (N/2) - 1, k = 0...7)

수식 (2)에서 n_i와 n_{i+(N/2)}는 R영역 안에 포함된 전체 픽셀 N에서 서로 대칭되는 픽셀의 값을 의미한다.

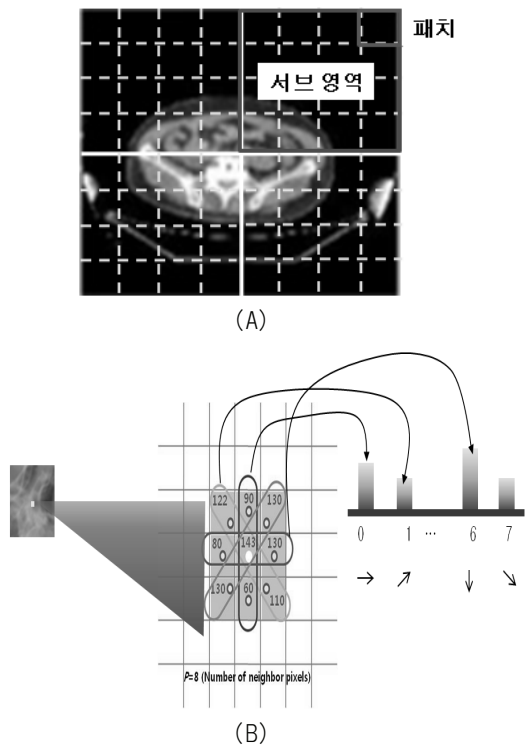


Fig. 2. Proposed OCS-LBP histogram generation (Fig. 2A) splitting subregion and patch (Fig. 2B) OCS histogram binning

본 논문에서는 영상의 국부적인 변형에 강인한 검색 알고리즘을 개발하기 위해 영상을 2×2 영역으로 분할하고 각 서브 영역마다 4×4의 패치로 분할되어 각 패치마다 8개의 OCS-LBP 패턴을 추출한다. 이렇게 추출된 각 서브 영역의 패치들은 결합 과정을 거쳐 서브 영역마다 128(4×4×8) 차원의 히스토그램이 생성되고, 따라서 한 영상에서 추출되는 총 특징 차원은 2×2×128=512차원의 특징이 생성된다. 하지만 특징벡터의 차원이 너무 클 경우 실시간 영상검색이 불가능하므로 추가적으로 BoF 히스토그램 [10]알고리즘을 적용하여 특징 차원을 의미 있는 축소된 차원으로 변형하는 작업을 추가한다.

우선 각 학습 영상으로부터 추출된 512차원의 특징들을 K-mean 클러스터링을 적용하여 K개의 클러스터를 생성하

고 각 클러스터의 중심 벡터들을 모아 code book을 생성한다. code book에서 각 클러스터의 중심 벡터는 code word로 불린다. 이후 입력영상에서 동일한 OCS-LBP특징을 추출하고 code book에 적용시켜 거리가 가장 유사한 code word에 누적(voting)시키는 방법으로 Fig. 3과 같이 BoF히스토그램을 생성한다. 본 논문에서는 code book의 크기가 200일 때 가장 좋은 성능을 보였다.




Fig. 3. BoF histogram voting using a code book

3. Random Forest를 이용한 영상 분류 및 검색

Random Forest 분류기 [11]는 결정 트리 앙상블을 이용한 분류기로, 이진 결정 트리들의 결합을 기본으로 하고 있기 때문에 정확하고 빠른 훈련 속도를 가지며 많은 양의 데이터를 실행시키는데 탁월한 분류기로 알려져 있다 [12].

본 논문에서는 학습데이터에 대해 BoF히스토그램을 추출하고 Fig. 4의 알고리즘을 이용하여 Random Forest 분류기를 학습시켰다. 본 논문에서 사용한 CT영상은 신체 부위별로 단층 촬영된 영상으로 부위에 따라 14개의 클래스로 분류하도록 구성 되었다. 따라서, Random Forest 분류기도 14개를 클래스를 분류하도록 학습되었으며, 학습을 위해 각 부위별로 샘플링된 총 499장의 영상 데이터를 사용하였다. Random Forest를 학습하는 과정은 Fig. 4와 같다.

본 논문에서는 분류를 위한 Random Forest를 학습하기 위해서 각 서브 트리마다 1.0%의 학습 데이터 집합을 사용하였고, 총 40개의 결정 트리를 생성하여 Random Forest 분류기를 구성하였다.

Random Forest 분류기가 학습된 이후에, 모든 데이터베이스 영상을 Random Forest에 적용시켜 각 영상들에 대해 클래스 인덱스를 부여하는 작업을 off-line으로 실시하였다.

Fig. 5는 데이터베이스 영상의 분류과정을 보여준다. Fig. 5에서 입력된 영상은 Random Forest 분류기에 의해 각 트리 t 마다 클래스 C_i 에 대한 확률 값 $P(c_i|l_t)$ 을 갖게 되고, 총 T 개의 트리 확률 값을 산술평균하여 최종적으로 각 클래스 C_i 에 대한 확률 값을 수식 (3)을 통해 얻을 수 있다.

$$P(c_i|L) = \frac{1}{T} \sum_{t=1}^T P(c_i|l_t) \quad (3)$$

1. Set the number of tree T for Random Forest
2. Select m random number from the set of BoF histogram. At the node n , the training data is iteratively split into left and right subsets and by using the threshold, t , and split $f(v)$ function, for the feature vector, v .
3. Each tree grows as the following manner:
 - a. Select n new bootstrap samples from training set S_n and grow an unpruned tree using the n bootstrap samples.
 - b. At each internal node, each node selects m variables randomly and determines the best split function using only these variables.
 - c. Grow the tree within the maximal tree depth.
4. If the number of tree is below T , go to step 2.

Fig. 4. Random Forest learning process




Fig. 5. Image classification using BoF histogram and Random Forest

수식 (3)에서 $L = \{l_1, l_2, \dots, l_t\}$ 은 전체 트리 집합을 의미한다.

데이터베이스 영상에 대한 분류 작업이 끝나면 각 i 번째 영상들은 $I^i = [p^i, c]$ 과 같이 200차원의 BoF 히스토그램(p^i)과 클래스 레이블의 집합으로 구성된다.

학습이 이루어진 Random Forest에 대해 새로운 질의 영상이 입력될 경우 동일한 방법으로 512차원의 OCS-LBP특징이 추출되고, code book에 적용하여 200차원의 BoF히스토그램을 생성한다. 이 후 질의 영상의 BoF히스토그램은 Random Forest 분류기에 입력되고 분류기에 의해 14개의 클래스 중에서 가장 유사한 K-인접 이웃 (K-NN) 클래스를

선택한다. 본 논문에서 가장 유사한 한 개의 클래스를 사용하지 않고 K개의 클래스를 선택하는 이유는 학습과정에서 유사한 형태를 갖는 데이터베이스 영상이 서로 다른 클래스에 분류될 수 있으므로 오 분류에 의한 검색성능의 저하를 막기 위해서이다. 본 논문에서는 K가 2일때 가장 좋은 성능을 보였다. 이에 대한 실험결과는 4장에서 설명하도록 한다.

질의 영상이 입력되면 모든 데이터베이스 영상에 대해 검색을 실시하는 것이 아니라, Fig. 5와 동일한 방법으로 Random Forest에 적용하고, 가장 근접한 2개의 클래스를 선택한다. 이후에, 가장 근접한 2개의 클래스로 레이블된 영상에 대해서만 유사도 거리 측정을 실시한다. 본 논문에서는 유사성 측정을 위해 전통적으로 사용되는 Euclidean 거리 측정 방법 보다 우수한 것으로 알려진 Bhattacharyya 거리[13]를 사용한다. Bhattacharyya 거리 측정 방법은 본 연구의 특성에 맞게 수식 (4)와 같이 수정하여 적용하였다.

만약 $BoF(q) = \{BoF_u(q)\}_{u=1, \dots, m}$ 을 m차원의 질의 BoF 히스토그램이라고 하고, $BoF(t)$ 를 k번째 클래스에 속하는 데이터베이스 영상의 BoF 히스토그램이라고 한다면, 두 특징간의 거리는 각 히스토그램의 관계와 k번째 클래스에 대한 분류 확률 $P(c_k|L)$ 에 의해 결정되며 결과 값이 작을수록 유사성이 높은 영상으로 검색된다.

$$\rho[BoF(q), BoF(t)] = (1 - P(c_k|L)) \times \left[1 - \sum_{u=1}^m \sqrt{BoF_u(q) BoF_u(t)} \right]^{1/2} \quad (4)$$

4. 실험 및 성능평가

본 논문에서 성능평가를 위해 사용된 의료 데이터베이스는 CT 영상으로 신체 부위별로 14개의 클래스로 구성되며 총 1080장의 영상을 포함하고 있다.

첫 번째 실험에서는, 본 논문에서 제안한 OCS-LBP특징의 성능을 비교하기 위해, Bhattacharyya 거리를 기본 거리 측정 방법으로 사용하고, 본 논문에서 제안한 OCS-LBP와 Ko [6]등의 논문에서 사용된 CS-LBP 및 Wang [5]등의 논문에서 사용된 SIFT특징을 이용한 검색결과를 분석하였다. Fig. 6의 검색 결과에서 알 수 있듯이 본 논문에서 제안하는 OCS-LBP 특징은 기존의 특징에 비해 최소 9%에서 최대 32%의 성능을 향상 시키고 있음을 알 수 있다. 이것은 OCS-LBP특징이 영상의 그래디언트 방향과 크기를 정량화하여 의료영상의 특성을 잘 반영하고 있음을 보여준다.

두 번째 실험에서는 각 특징 별로 Random Forest를 적용하여 영상 검색의 성능을 측정하였다. Random Forest는 각 특징 별로 사전에 학습되어 있으며, 질의 영상이 입력되면 앞에서 설명된 것처럼 질의 영상을 특정 클래스에 분류하고 상위 2개의 클래스에 대해 수식 (4)을 적용하여 가장 값이 작은 영상을 상위 K개만큼 순서대로 보여주도록 하였다. Fig. 7에의 실험결과에서는 Fig. 6의 결과와 마찬가지로 OCS-LBP특징이 가장 좋은 성능을 보여주고 있다. Fig. 7에




Fig. 6. Performance comparison between three different features




Fig. 7. Performance comparison using combination of Random Forest and three different features according to the increasing of Top K

서 알 수 있듯이 제안한 알고리즘(RF+OCS-LBP)은 평균 81%의 precision을 보여주고 있는데 이 결과는 Random Forest를 적용하기 전의 precision 보다 28% 정도 향상된 수치이다.

세 번째 실험에서는 질의 영상에 대해 14개의 클래스 중에서 가장 유사한 K-인접 이웃 클래스 (K-nearest neighbor class)를 선택하는 알고리즘에서 K의 수를 결정하기 위한 실험을 진행하였다. Fig. 8에서 보는 것과 같이 K=2일 때 검색 성능과 속도면에서 가장 효율성이 높은 것을 알 수 있다. K값은 검색 시간에 영향을 미치는데, K가 적을수록 검색 속도는 우수하지만 성능이 떨어지고 K가 커질수록 성능은 비례하여 조금 증가하지만 K=2부터는 같은 값으로 수렴한다. 따라서 본 논문에서는 K=2로 설정하였다.

네 번째 실험으로 기존의 영상검색에 가장 많이 사용되고 있는 분류기인 MSVM을 사용한 박기희 [2]등의 논문과 성능을 비교하여 보았다. 실험은 제안하는 방법과 마찬가지로 미리 학습시킨 MSVM에 의해 데이터베이스 영상을 클래스별로 분류하고 질의 영상에 대해 같은 과정을 거쳐 K-인접 이웃 클래스에 대해서만 Bhattacharyya 거리를 구하는 방식

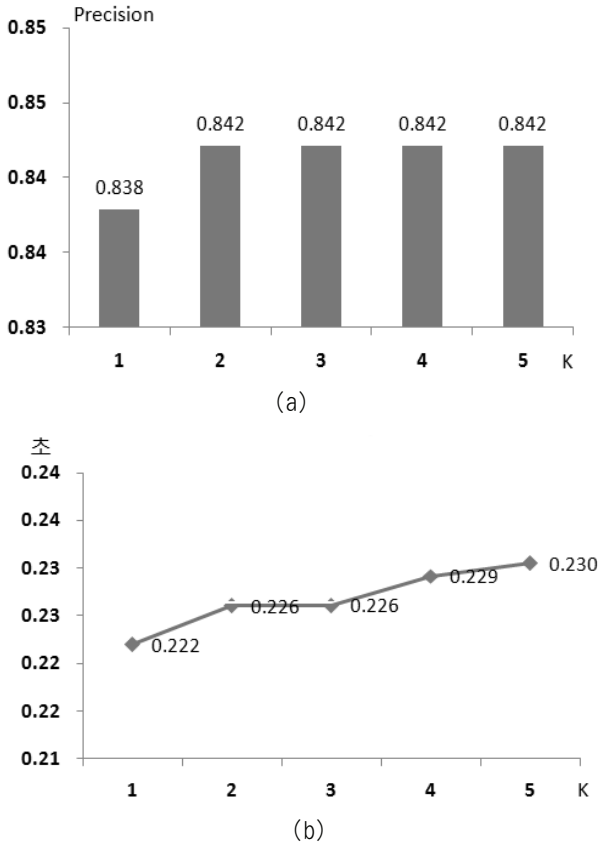


Fig. 8. Performance evaluation according to the variation of Top k and searching time (Fig. 8A) precision on variation of Top k (Fig. 8B) searching time on variation of Top k

으로 진행되었다. Fig. 9에서 보는 것과 같이 MSVM의 경우 Top K의 수가 증가할수록 검색율이 떨어지는 것을 알 수 있다. MSVM의 경우에도 전체적으로 72% 정도의 좋은 성능을 보여주지만 제안하는 방법에 비해서는 약 9%의 성능이 뒤처지는 것을 알 수 있다.

의료 영상검색에서 Random Forest 분류기를 적용한 것은 검색 성능의 향상뿐만 아니라 검색 시간의 단축을 위한




Fig. 9. Performance comparison between two classifier methods using MSVM and the proposed method

Table 1. Searching time comparison between a retrieval method without using Random Forest and a retrieval method applying Random Forest (seconds)

Feature kinds	Without Random Forest	Applying Random Forest
OCS-LBP	0.451	0.226

방법임으로, 다섯 번째로, Random Forest를 적용하기 전과 적용한 후의 평균 검색 시간을 측정해 보았다.

Table 1에서 보는 것과 같이 Random Forest 분류기를 사용했을 경우가 사용하지 않은 경우보다 검색시간이 약 0.26초 향상 되는 것을 알 수 있었다. 따라서 사진에 데이터 베이스 영상을 클래스별로 분류하고 질의영상에 대해 검색을 수행할 경우 검색성능 뿐만 아니라 검색속도에서도 효율성을 증가시킬 수 있다.

Fig. 10은 본 연구에서 제안하는 시스템의 인터페이스와 검색 결과 화면을 보여주고 있다.




Fig. 10. System interface and one example of retrieval results.

5. 결론

본 논문에서는 의료 영상을 효과적으로 검색하기 위해 의료 영상에 적합한 새로운 OCS-LBP특징을 개발하고, 특징 차원을 효과적으로 줄이기 위해 BoF를 적용하였다. 또한, 검색 속도와 성능을 향상시키기 위해 질의 영상에 대해 전체 영상을 매칭 하는 대신 Random Forest 분류기를 통해 분리된 K-근접 이웃 클래스에 대해서만 Bhattacharyya 거리 측정에 의해 상위 K개의 검색결과를 보여주는 검색 방법을 제시하였다.

실험을 통해 여러 가지 유사성 거리 측정 알고리즘 중에서 Bhattacharyya 거리 측정 방법이 가장 우수함을 실험을 통해 증명하였고, 마찬가지로 제안하는 Random Forest 분류기와 Bhattacharyya 거리 측정 방법이 결합되었을 때 성능이 약 28%까지 증가됨을 증명하였다. 또한, 실험 결과에서 보듯이 제안하는 특징은 기존의 특징에 비해 향상된 검색 결과를 보여 주었으며, 제안하는 시스템은 검색 성능뿐만 아니라 검색 시간도 효과적으로 향상시킬 수 있었다.

향후 연구에서는 CT, X-ray영상 이외에 MRI, PET 영상들과 같이 다양한 의료영상에 대해서도 우수한 성능을 보여 줄 수 있는 범용적인 특징을 개발하고 이를 활용하여 효과적인 검색환경을 지원하는 시스템을 설계할 것이다.

참 고 문 헌

- [1] Mi-suk Seo, Byoung-Chul Ko, Yu-ik Son, Hee - Juhn Park, Jae-Yeal Nam, "The human visual system and the MPEG-7 visual descriptors using a region of interest based Medical Image Retrieval" Burns Society of Korea Journal, Vol.13, No.2, pp.120-130, 2007.
- [2] Gi-hui Park, Byoung-Chul Ko, Jae-Yeal Nam, "Medical image automatic annotation generated code using an array of multi-class SVM and comments," Journal of the Korea Information Processing Society B, Vol.16, No.4, pp.281-288, 2009.
- [3] E. Uwimana and M. E. Ruiz, "Integrating an automatic classification method into the medical image retrieval process," AMIA Annual Symposium 2008, pp.747-751, 2008.
- [4] U. Avni, M. Sharon, and J. Goldberger, "X-ray Image Categorization and Retrieval using Patch-based Visual Words Representation," International Conference on biomedical imaging, pp.350-353, 2009.
- [5] J. Wang, Y. Li, Y. Zhang, H. Xie, and C. Wang, "Boosted learning of visual word weighting factors for bag-of-features based medical image retrieval", Sixth International Conference on Image and Graphics, pp.1035-1040, 2011.
- [6] B.C. Ko, J.-H. Lee, and J.-Y. Nam, "Automatic medical image annotation and keyword-based image retrieval using relevance feedback," Journal of Digital Imaging, Vol.25, No.4, pp.454-465, 2012.
- [7] D. G. Lowe, "Object recognition from local scale-invariant features," IEEE International Conference on Computer Vision, Vol.2, pp.1150-1157, 1999.
- [8] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.24, pp.971-987, 2002.
- [9] M. Heikkilä and M. Pietikainen, "Description of Interest Regions with Local Binary Patterns," Pattern Recognition Vol.42, pp.425-436, 2009.
- [10] Y. G. Jiang C. W. Ngo, and J. Yang, "Towards Optimal Bag-of-Features for Object Categorization and Semantic Video Retrieval," 6th ACM international conference on Image and video retrieval, pp.494-501, 2007.
- [11] L. Breiman, "Random Forests," Machine Learning Vol.45, pp.5-32, 2001.
- [12] B. C. Ko, J.-H. Lee, and J.-Y. Nam, "Automatic medical image annotation and keyword-based image retrieval using relevance feedback," Journal of Digital Imaging, Vol.25, No.4, pp.454-465, 2012.
- [13] P. Bhattacharya and M. M. Rahman, "Image Representation and Retrieval Using Support Vector Machine and Fuzzy C-means Clustering Based Semantical Spaces," International Conference on Pattern Recognition, Vol.2, pp.1162-1168, 2006.



손 정 은


e-mail : wjddms7392@naver.com

2013년 2월 계명대학교 컴퓨터공학과

2013년 3월~계명대학교 컴퓨터공학과

석사과정

관심분야: 컴퓨터 비전 및 패턴인식



고 병 철

e-mail : niceko@kmu.ac.kr

1998년 경기대학교 전자계산학과(이학사)

1998년~2000년 연세대학교 컴퓨터과학

(공학석사)

2000년~2004년 연세대학교 컴퓨터과학

(공학박사)

2004년 3월~2005년 8월 삼성전자 통신연구소 책임연구원

2005년 9월~현재 계명대학교 컴퓨터공학과 부교수

관심분야: 내용기반 영상검색, 컴퓨터 비전 및 패턴인식



남 재 열

e-mail : jynam@kmu.ac.kr

1983년 경북대학교 전자공학과업(공학사)

1985년 경북대학교 전자공학(공학석사)

1991년 University of Texas at
Arlington 전기공학(공학박사)

1985년 5월~1987년 7월 한국전자통신
연구소 연구원

1991년 9월~1995년 2월 한국전자통신연구소 선임연구원

1995년 3월~현 재 계명대학교 컴퓨터공학과 교수

관심분야: 영상압축, 영상통신, 멀티미디어 시스템