

정규논문 (Regular Paper)

방송공학회논문지 제18권 제3호, 2013년 5월 (JBE Vol. 18, No. 3, May 2013)

<http://dx.doi.org/10.5909/JBE.2013.18.3.401>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

문맥 정보를 이용한 분류 기반 무릎 뼈 검출 기법

신승연^{a)}, 박상현^{a)}, 윤일동^{b)†}, 이상욱^{a)}

Classification based Knee Bone Detection using Context Information

Seungyeon Shin^{a)}, Sanghyun Park^{a)}, Il Dong Yun^{b)†}, and Sang Uk Lee^{a)}

요 약

본 논문에서는 영상 내의 문맥 특징(context feature)과 외형 특징(appearance feature)을 함께 학습함으로써 의료영상 내의 비슷한 외형 특징을 가지는 장기들을 자동으로 검출하는 기법을 제안한다. 기존 검출 기법들은 외형 특징 정보만을 학습하여 분류기(classifier)를 생성하였기 때문에 의료영상 내에 외형이 비슷한 장기들이 다수 포함되어 있는 경우 검출 오류가 발생하였다. 제안하는 기법은 외형 특징을 이용하여 학습된 분류기를 통해 얻은 확률 값들을 바탕으로 관심 복셀(voxel) 주변의 확률 분포 특징을 반복적으로 학습함으로써 문맥 정보를 포함하는 분류기를 생성한다. 또한, 실험 단계(test stage)에서 ‘지역 기반 투표 방식’(region based voting scheme)을 도입함으로써 효율성과 정확성을 향상시킨다. 제안하는 기법의 성능 평가를 위해 SKI10 무릎 관절 데이터 셋 내에서 외형 특징이 비슷한 대퇴골(femur)과 경골(tibia)을 검출하는 실험을 진행하였다. 실험 결과를 통해 제안하는 기법이 외형 특징만을 이용한 검출 기법에 비해 개선된 검출 성능을 보이고 있음을 확인할 수 있었다.

Abstract

In this paper, we propose a method that automatically detects organs having similar appearances in medical images by learning both context and appearance features. Since only the appearance feature is used to learn the classifier in most existing detection methods, detection errors occur when the medical images include multiple organs having similar appearances. In the proposed method, based on the probabilities acquired by the appearance-based classifier, new classifier containing the context feature is created by iteratively learning the characteristics of probability distribution around the interest voxel. Furthermore, both the efficiency and the accuracy are improved through ‘region based voting scheme’ in test stage. To evaluate the performance of the proposed method, we detect femur and tibia which have similar appearance from SKI10 knee joint dataset. The proposed method outperformed the detection method only using appearance feature in aspect of overall detection performance.

Keyword : Classification, Knee Bone, Detection, Context

a) 서울대학교 전기정보공학부 자동화연구소, 뉴미디어통신공동연구소 (Automation and Systems Research Institute, Department of Electrical and Computer Engineering, Seoul National University)

b) 한국외국어대학교 용인캠퍼스 디지털정보공학과 (School of Digital Information Engineering, Hankuk University of Foreign Studies)

† Corresponding Author : 윤일동(Il Dong Yun)

E-mail: yun@hufs.ac.kr

Tel: +82-2-880-8428

※ 본 논문은 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.2010-0012006).

· Manuscript received March 28, 2013 Revised May 28, 2013 Accepted May 28, 2013

1. 서론

객체 검출(object detection)은 컴퓨터 비전 분야에서 활발히 연구되는 내용 중 하나로써 다양하게 응용되고 있다. 특히, 의료 분야에서는 종양^[1,4]의 자동 검출이나, 각종 장기^[5,6,7]의 세밀한 영역화를 위한 초기 검출, 장기의 특성에 맞는 사후처리(post processing) 등을 위해 효율적으로 쓰이고 있다. 대표적인 기존 자동 기법들^[8,9]은 의료영상 내 장기들의 변화가 적다는 가정 하에 학습 집합(training set) 내의 영역화 레이블(label)들을 입력 영상으로 정합(registration)한 뒤 정합된 위치를 바탕으로 검출을 시도하였다. 하지만 학습 집합 내의 모든 영상을 입력 영상으로 정합하는 것은 높은 복잡도를 요구했을 뿐 아니라 사람 간의 가변성(variability)으로 인한 정합 오류에 취약했다.

최근에는 이러한 단점을 극복하고자 분류(classification), 회귀(regression) 등의 관리적 학습(supervised learning) 기법을 이용한 검출 기법들이 제안되었다^[10,11,12]. 관리적 학습 기법은 주어진 학습 집합으로부터 새로운 실험 집합(test set)에도 적용할 수 있는 식별 모델(discriminative model)을 만들어 냄으로써 영상 간의 가변성에 강인하였으며, 정합 과정으로 인한 연산 시간을 크게 줄여주었다. 하지만, 대다수의 기존 관리적 학습 기반 검출 기법들은 분류기를 생성할 때 복셀의 밝기(intensity)와 경사도(gradient)와 같은 영상의 외형 정보만을 학습하는 경우가 많았기 때문에, 외형

이 비슷한 장기들을 다수 포함하고 있는 의료영상의 경우 장기의 분류가 잘못되거나 모호한 경계에서 오류들이 발생하였다(그림 1). 이에 따라 밝기 분포의 모호성이나 이미지 간의 가변성이 존재하더라도 변하지 않고 유지되는 영상 내 객체들의 배치와 구도와 같은 전역적인 문맥 정보를 학습해야 할 필요성이 대두되었다^[6].

본 논문에서는 문맥 특징과 외형 특징을 함께 학습함으로써 의료영상 내의 장기들이 비슷한 외형을 가지더라도 이들을 강인하게(robust) 검출할 수 있는 기법을 제안한다. 일차적으로 외형 특징을 이용하여 학습된 분류기를 통해 모든 복셀에 대해 각 클래스에 포함될 확률 값을 얻어낸 뒤, 관심 복셀 주변의 확률 값들을 이용하여 문맥 특징을 추출하고 이들을 반복적으로 학습한다. 관심 복셀 주변의 확률 값 분포는 영상 내 장기들의 상대적인 위치, 구도와 같은 문맥 정보를 나타내주기 때문에 이들을 특징으로 이용하여 생성된 분류기는 외형이 모호한 곳에서도 강인한 결과를 얻어낸다. 제안하는 기법은 2절, 실험결과는 3절에 언급한다.

II. 문맥 정보를 이용한 검출 기법

그림 2는 제안하는 기법의 학습과정과 실험과정을 보여준다. 학습 과정에서는 학습데이터를 바탕으로 외형 정보




그림 1. 입력 영상(좌), 외형 정보만으로 학습한 분류기를 통해 얻은 대퇴골(중) 및 경골(우)의 확률 값. 중간과 우측 영상은 0~1 사이의 확률 값을 0~255 사이의 수로 정규화(normalization)하여 영상화 한 것으로 흰색에 가까울수록 높은 확률을, 검은색에 가까울수록 낮은 확률을 의미한다. 대퇴골과 외형 특징이 유사한 좌우 배경과 대퇴골과 경골이 인접한 부분 등에서 잘못된 확률분포가 나타난다.

Fig. 1. Input image(left), the probabilities of femur(middle) and tibia(right) acquired by the appearance-based classifier. The middle and right images have the values between 0 and 255, normalized from the probability values between 0 and 1, so the closer to white means a higher probability and the closer to black means a lower probability. Since the appearances of the left and right background part of femur and the adjacent part of tibia are similar to that of femur, wrong probabilities appear.

와 문맥 정보를 순차적으로 학습하여 일련의 분류기를 생성한다. 먼저, 외형 정보를 포함하는 특징들을 추출하여 외형 분류기를 학습하며(II.1절), 이 분류기를 통해 모든 복셀에 대해 각 클래스에 속하게 될 확률 값들을 포함하는 확률 지도(probability map)를 얻어낸다. 이후 확률 지도 내에서 관심 복셀 주변의 확률 값들을 특징으로 하여 일차 문맥 분류기를 학습한다(II.2절). 학습된 일차 문맥 분류기를 통해 다시 새로운 확률 지도를 얻어내고 또 다시 지도 내에서 관심 복셀 주변의 확률 값들을 특징으로 하여 이차 문맥 분류기를 생성한다. 문맥 분류기는 확률 지도의 확률 값들이 수렴할 때까지 반복적으로 생성한다. 실험 과정에서는 학습 과정에서 획득한 일련의 분류기를 이용하여 입력 영상을 순차적으로 분류한다. 즉, 초기에는 학습해 놓은 외형 분류기로 입력영상의 모든 복셀을 분류하고 각 클래스에 포함될 확률 값들을 얻는다. 이후 확률 값으로 만들어진 관심 복셀의 문맥 특징들을 일차 문맥 분류기로 다시 분류하여 새로운 확률 값을 얻는다. 이 같은 작업을 마지막 문맥 분류기까지 반복하여 최종 확률 값을 얻어내며, 획득한 확

률 값이 일정 문턱치 이상인 복셀들을 모두 포함하도록 만든 경계상자를 최종 검출 결과로 한다. 그림 2의 상단에서 업데이트되는 확률 지도들과, 마지막 확률 지도를 바탕으로 만든 최종 경계상자를 확인할 수 있다. 기법의 효율성과 정확성을 위해 실험 영상은 과 영역화(over-segmentation) 하여 이용하고 과 영역화 된 각각의 지역으로부터 일부 복셀들을 샘플링하고 샘플링 된 복셀들의 분류 결과를 바탕으로 해당 지역의 분류 결과를 정해주는 ‘지역 기반 투표 방식’^[13] (II.3절)을 적용한다.

1. 외형 정보만을 이용한 검출

외형 분류기를 생성하기 위해 학습 집합 내의 영상들로부터 외형 특징을 추출한 뒤 이들을 랜덤 포레스트 기법(random forest)^[11]을 이용하여 학습한다. 외형 특징으로는 관심 복셀을 둘러싸는 11X11X11 크기 패치의 밝기 값 히스토그램(10bin)과 복셀의 절대 좌표(x,y,z)를 연결한 13차원의 특징 벡터를 사용한다. 그림 3(a)는 전경과 배경에

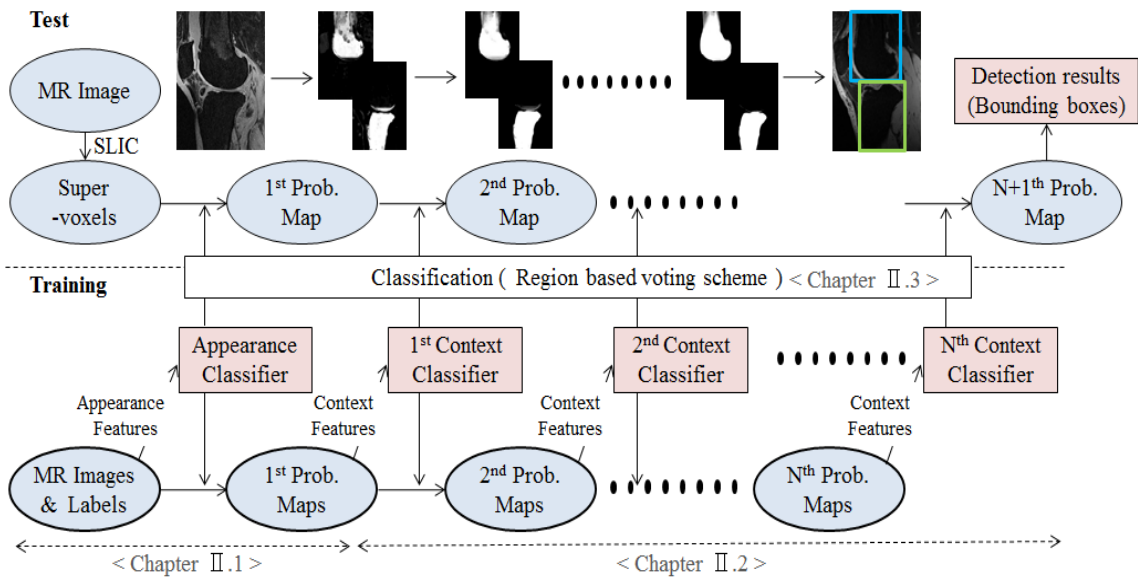


그림 2. 제안하는 기법의 블록선도. 청색 타원은 입력 및 중간 결과물, 적색 사각형은 학습과 실험 과정 각각에서의 최종 결과물을 나타낸다. 상단의 그림은 반복 과정의 진행에 따라 업데이트되는 확률 지도들과, 마지막 확률 지도를 바탕으로 만든 최종 경계상자를 보여준다.

Fig. 2. Block diagram of the proposed method. The blue ellipses mean input and intermediate outputs, and the red squares are the final results in training and test stages. The upper part of this figure shows the updated probability maps during the iteration and the final bounding boxes made from the final probability map.

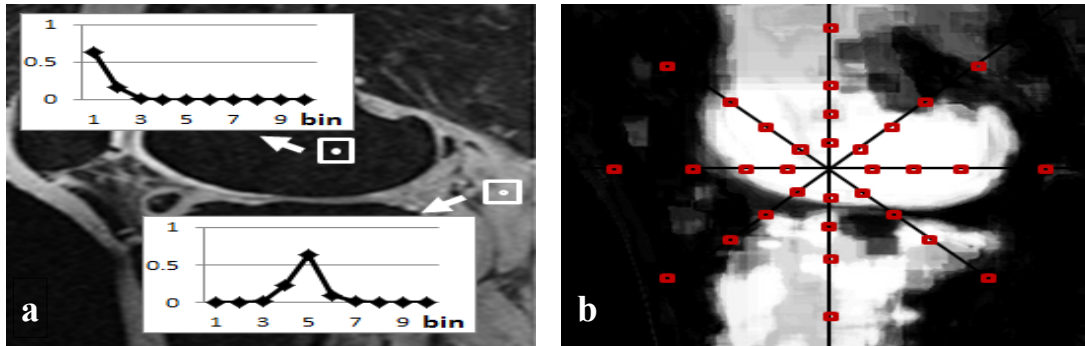


그림 3. (a) 전경과 배경에서의 임의의 패치에 대한 밝기 값 히스토그램 예시. (b) 문맥 특징의 추출.
 Fig. 3. (a) Examples of the intensity histograms of randomly selected patches from the foreground and background regions. (b) The extraction of the context information.

서의 임의의 패치에 대한 밝기 값 히스토그램을 각각 보여 준다. 영상 내의 모든 복셀로부터 외형 특징을 추출하여 학습 데이터로 사용하는 것은 복잡도가 높기 때문에 각 축에 대해 일정한 간격으로 샘플링(sampling) 된 복셀에서만 외형 특징들을 추출하며 학습 데이터로 사용하였다. 이진 랜덤 포레스트 기법은 다중 클래스를 분류해 주지 못하기 때문에 관심 클래스를 제외한 모든 클래스를 배경으로 처리하는 ‘1-vs-all’ 방식을 채택하여 클래스 개수만큼의 분류기를 학습하였다. 따라서 학습된 분류기를 이용하여 각 복셀을 분류할 경우 각 클래스에 속하게 될 확률 값들을 얻게 된다. 학습 기법 및 방식은 이하의 문맥 정보 기반의 분류기 학습 시에도 동일하게 적용한다.

2. 문맥 정보의 활용

그림 1과 그림 3(a)로부터 대퇴골과 경골의 외형은 상당히 비슷함을 확인할 수 있다. 따라서 외형의 구분이 모호한 부분에서도 정확한 분류를 해주기 위해 외형 분류기를 이용하여 얻은 확률 지도 내에서 관심 복셀 주변의 확률 분포 정보를 문맥 특징으로 이용한다. 문맥 특징을 추출하기 위해 그림 3(b)와 같이 관심 복셀로부터 주위의 26방향(2차원 영상의 경우 8방향)으로 일정한 거리 {1,2,3,5,7,10,15,20,30,40,...}에 있는 복셀들을 샘플링(sampling)^[14] 한 뒤 이들의 확률 값(각 클래스에 대한 모든 확률 값)을 모두 연결한 벡터를 생성한다. 연결한 벡터는 랜덤 포레스트 기법으로

학습되고 문맥정보를 포함하는 문맥 분류기가 생성된다. 구체적으로, 본 논문의 실험에서는 대퇴골과 경골, 배경까지 총 세 개의 클래스가 정의되었고 26개의 방향, 10개의 거리마다의 확률 값을 연결한 780차원의 벡터를 생성하였다($3 \times 26 \times 10 = 780$). 획득한 문맥 분류기를 이용하여 외형 분류기로부터 얻은 확률 지도를 분류하면 새로운 확률 지도를 얻을 수 있으며 이 지도는 두 번째 문맥 분류기를 학습하기 위한 문맥 특징 추출을 위해 사용된다. 이와 같은 문맥 분류기의 학습 과정은 검출 성능의 개선이 없을 때까지 반복된다. 전체 학습 과정을 거치고 나면 일련의 분류기를 획득할 수 있으며, 실험 과정에서는 입력 영상을 일련의 분류기를 이용하여 순차적으로 분류한다.

3. 지역 기반 투표 방식

실험 단계에서 모든 복셀을 대상으로 분류를 실행하는 것은 효율성이 떨어질 뿐만 아니라, 객체 사이의 경계와 같은 모호한 영역에 있어서 잘못된 분류 결과를 얻게 될 가능성을 내포하고 있다. 이러한 단점을 극복하기 위해 ‘지역 기반 투표 방식’(region based voting scheme, RBVS)^[13]을 이용한다. 먼저, 비관리적(unsupervised) 영역화 알고리즘을 통해 영상을 과 영역화(over-segmentation) 시킨 후 각각의 지역에서 일정 비율의 복셀만을 임의로 추출한다(그림 4). 이후 선택된 복셀들에 대해서만 분류를 시행하고 분류된 값들의 평균으로 해당 지역 전체의 분류 확률을 정의한

다. 이 기법은 일부 복셀에 대해서만 분류를 수행하기 때문에 복잡도를 크게 낮추며, 과 영역화 알고리즘을 이용하여 얻은 밝기 기반의 영역화 결과에 순응한 분류를 함으로써 전체적인 검출 성능 향상을 도모할 수 있다.




그림 4. SLIC 기법^[15]에 의해 생성된 과 영역화 결과와 각 영역에서 랜덤 샘플링된 복셀들
 Fig. 4. Over-segmentation result by 'SLIC' algorithm^[15] and randomly sampled voxels in each segmented regions

III. 실험 결과 및 분석

제안하는 기법의 성능 평가를 위해 T1 및 T2-가중치 영상들로 구성되어 있는 SKI10 무릎 관절 데이터 셋^[16,17] 내에서 20개의 영상을 추출하였으며 영상 내부에서 대퇴골과 경골을 검출하는 실험을 진행하였다. 20개 중 10개의 데이터를 학습 집합으로 나머지 10개를 실험 집합으로 사용하였다. 과 영역화 결과를 얻기 위해 SLIC(simple linear iterative clustering)^[15] 기법을 사용하였으며, 과 영역화 된 각각의 지역에서 5.5%의 복셀을 임의로 추출하여 분류에 사

용하였다. 또한 각 클래스에 대해 확률 값이 0.6 이상인 곳을 포함하는 경계 상자를 만들고 이를 최종 분류결과로 하였다.

기법의 검증을 위해 학습 과정 중 첫 번째로 만들어지는 외형 분류기만을 이용하여 얻은 검출 결과(APP)와 외형 분류기 뿐 아니라 확률 값이 수렴할 때까지 얻어낸 다수의 문맥 분류기를 함께 이용하여 얻은 검출 결과(APP+CON)를 비교하였다. 또한 지역 기반 투표 방식(RBVS)을 적용하지 않았을 때와 했을 때의 결과를 각각 비교하였다. 본 실험에서는 '지역 기반 투표 방식'의 적용 유무에 따라 수렴하기까지 각각 2개와 4개의 분류기가 생성되었으며 모든 분류기를 통과해서 나온 검출 결과로 평가를 수행하였다. 평가를 위해 Cuingnet 등이 제시한 평가 방법과 같이 경계 상자의 '면 위치 오류'와 '중심 위치 오류'를 측정^[7]하였다. '면 위치 오류'는 검출한 경계 상자와 참값(ground truth) 경계 상자의 모든 면(wall) 위치 차를 합산한 값이며, '중심 위치 오류'는 검출한 경계 상자의 중심 위치와 참값 경계 상자의 중심 위치 차이이다.

표 1은 10개의 실험영상에 대하여 제안하는 기법을 적용하여 얻은 경계 상자의 평균 위치 오류를 보여준다. 문맥 분류기를 이용하였을 때 외형 분류기만을 이용했을 때에 비해 38.0%의 면 위치 오류, 20.5%의 중심 위치 오류 감소율을 나타냈으며 '지역 기반 투표 방식'을 적용하였을 때에는 이 차이가 더 커져서 각각 56%, 45%의 오류 감소율을 나타냈다. '지역 기반 투표 방식'을 적용하였을 때 적용하지 않은 결과에 비해 외형 분류기만을 이용한 결과의 성능은 나빠졌고 문맥 분류기를 모두 이용한 결과의 성능은 향상되었다. 모든 문맥 분류기를 통과한 후의 결과를 살펴보면 중

표 1. 경계 상자의 면 및 중심 위치 오차. 표 내부의 값은 복셀 단위 오차 값을 의미하며 평균±표준편차(중간값)이 나타나 있다. APP는 외형 분류기만 사용했을 때의 검출 결과를, APP+CON은 외형 및 문맥 분류기를 순차적으로 사용했을 때의 결과를 보여준다.

Table 1. Localization error of walls and center of bounding box. The values in table correspond to errors(in voxels) and have form of Mean±Standard-deviation(Median). 'APP' shows the detection results when only use the appearance-based classifier, and 'APP+CON' shows the results when sequentially use the appearance-based and the context-based classifiers.

Error (voxels)	without RBVS[13]		with RBVS[13]	
	APP	APP+CON	APP	APP+CON
Walls	39.8±19.8(36)	24.6±13.6(19.5)	51.8±29.8(47.5)	22.6±21.6(12)
Center	7.8±6.8(4.9)	6.2±4.6(4.9)	11.3±7.7(10.6)	6.2±6.4(3.4)

심 위치 오류는 비슷하지만 면 위치 오류 값이 8% 정도 감소되는 것을 확인할 수 있었다.

순차적으로 분류기를 통과함에 따라 변화하는 검출 성능은 그림 5에서 확인할 수 있다. ‘지역 기반 투표 방식’을 적용하지 않았을 시에는 4번째 분류기에 이르러 성능이 수렴하는 반면, 적용하였을 시에는 2번째 분류기 만에 수렴하는 결과를 확인할 수 있었다. 통과시켜야 하는 분류기가 적

을수록 알고리즘의 복잡도가 감소하기 때문에 지역 기반 투표 방식을 적용했을 때 적은 수행 속도로 높은 정확도를 가지는 검출 결과를 얻어낼 수 있었다.

그림 6은 정성적인 검출 결과를 보여준다. 외형 특징만을 이용했을 때에 비해 문맥 정보를 함께 활용했을 때 상자가 참값 경계에 가깝게 나오고 있음을 확인할 수 있다. 그림 7은 ‘지역 기반 투표 방식’을 적용함으로써 개선된 검출 결

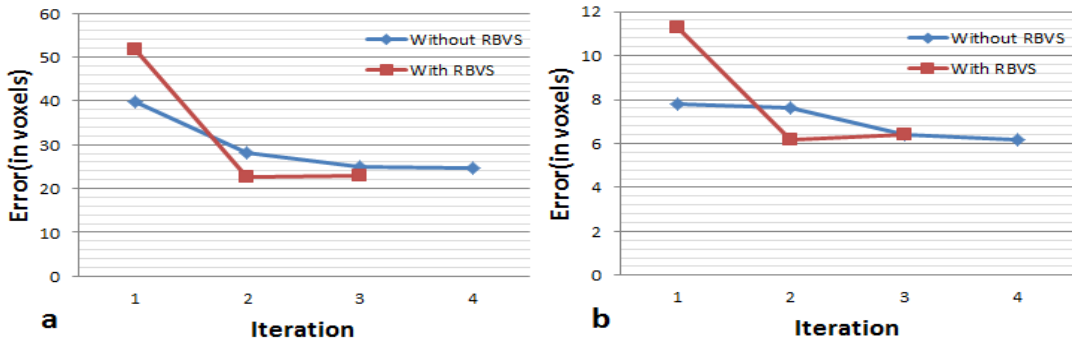


그림 5. 문맥 정보의 반복적 학습에 따른 경계 상자 위치 오류. (a) 면 위치 오류 (b) 중심 위치 오류. 반복 과정의 진행에 따라 오류가 점차적으로 감소하며, 지역 기반 투표 방식을 적용할 경우(빨간색 실선) 적용하지 않았을 때(파란색 실선)와 비교하여 더 빠르게 성능이 수렴함을 확인할 수 있다.

Fig. 5. Localization error of bounding box regarding repetitive learning of contextual information. (a) Walls position error (b) Center position error. It demonstrates that errors progressively decrease during the iteration and the performance with RBVS(red line) converges more faster compared to that without RBVS(blue line).




그림 6. 외형 특징만을 학습한 분류기(1행)와 외형 및 문맥 특징까지 학습한 분류기(2행)의 검출 결과 예시. 흰색 선은 뼈의 경계를, 청색은 대퇴골의 경계 상자를, 녹색은 경골의 경계 상자를 의미한다. 외형 특징만 이용하였을 경우 뼈의 경계와 같이 외형이 불분명한 곳에서 경계 상자가 잘 위치하지 못하지만 문맥 특징을 같이 이용하면 경계에 더 가깝게 위치함을 확인할 수 있다.

Fig. 6. Examples of detection results by using the classifier based on only appearance features (1st row) and the classifier based on both context and appearance features (2nd row). The white lines are the boundaries of the bones, and the blue and green correspond to the bounding box of femur and tibia respectively. The bounding box is not-well positioned in the regions which have unclear appearance, such as the boundary of the bone, when only use appearance features, while it is located near the boundary by using both context and appearance features.




그림 7. 지역 기반 투표 방식을 통한 개선된 검출 결과 (미적용 : 첫 번째, 세 번째, 적용 : 두 번째, 네 번째)
 Fig. 7. Improved detection results through 'region based voting scheme' (Not adopted : 1st, 3rd, Adopted : 2nd, 4th)

과를 보여준다. 과 영역화 알고리즘을 이용하여 얻은 밝기 기반의 영역화 결과에 순응한 분류를 함으로써 객체의 경계 부분에서 검출 성능이 향상됨을 확인할 수 있다.

IV. 결론

본 논문에서는 기존의 분류 기반 객체 검출 기법에서 검출의 정확도를 높이고자 영상의 문맥 정보를 활용하는 기법을 제안하였다. 이를 무릎 관절 영상에 적용해 본 결과 외형 정보만을 활용한 것에 비해 성능이 향상된 것을 확인할 수 있었다. 또한, 지역 기반 투표 방식을 도입함으로써 효율성과 정확성을 높여주었다. 이 기법은 정밀한 객체 검출 및 영역화를 달성하는데 기여할 수 있을 것으로 예상된다.

참고 문헌

- [1] Dolejsi, M., Kybic, J., Tuma, S., Polovincak, M., "Reducing false positive responses in lung nodule detector system by asymmetric adaboost", ISBI 2008. pp.656-659, 14-17 May 2008.
- [2] Pescia, D., Paragios, N., Chemouny, S., "Automatic detection of liver tumors", ISBI 2008. pp.672-675, 14-17 May 2008.
- [3] Wels, M., Carneiro, G., Aplas, A., Huber, M., Hornegger, J., Comaniciu, D., "A discriminative model-constrained graph-cuts approach to fully automated pediatric brain tumor segmentation in 3D MRI", MICCAI 2008.
- [4] Freiman, M., Edrei, Y., Shmidmayer, Y., Gross, E., Joskowicz, L., Abramovitch, R., "Classification of liver metastases using fMRI images: A machine learning approach", MICCAI 2008.
- [5] Zhan, Y., Zhou, X.S., Peng, Z., Krishnan, A., "Active scheduling of organ detection and segmentation in whole-body medical images", MICCAI 2008
- [6] Criminisi, A., et al., "Decision Forests with Long-Range Spatial Context for Organ Localization in CT Volumes", MICCAI Workshop PMMIA 2009
- [7] Cuingnet, R., Prevost, R., Lesage, D., Cohen, L.D., Mory, B., Ardon, R., "Automatic Detection and Segmentation of Kidneys in 3D CT Images Using Random Forests", MICCAI 2012, pp.66-74.
- [8] Fenchel, M., Thesen, S., Schilling, A., "Automatic Labeling of Anatomical Structures in MR FastView Images Using a Statistical Atlas", MICCAI 2008, Part I. vol. 5241, pp. 576 - 584.
- [9] Isgum, I., Staring, M., Rutten, A., Prokop, M., Viergever, M.A., Van Ginneken, B., "Multi-Atlas-Based Segmentation With Local Decision Fusion—Application to Cardiac and Aortic Segmentation in CT Scans", IEEE Transactions on Medical Imaging, vol.28, no.7, pp.1000-1010, July 2009.
- [10] Vapnik, V., "Estimation of Dependences Based on Empirical Data", Springer-Verlag New York, Inc., Secaucus, NJ, USA., 1982.
- [11] Breiman, L., "Random forests", Machine Learning, 45(1), pp.5 - 32, October 2001.
- [12] Criminisi, A., et al., "Decision forests for classification, regression, density estimation, manifold learning and semi-supervised learning", Technical report, Microsoft Research 2011
- [13] Jiang, J., Tu, Z., "Efficient scale space auto-context for image segmentation and labeling," CVPR 2009, pp.1810-1817, 20-25 June 2009.
- [14] Wolf, L., Bileschi, S., "A Critical View of Context", International Journal of Computer Vision, vol. 69(2), pp. 251-261, August 2006.
- [15] Radhakrishna, A., Shaji, A., Smith, K., Lucchi, A., Fua, P., Susstrunk, S., "SLIC Superpixels", EPFL Tech. Rep. no. 149300, June 2010.
- [16] Heimann, T., Morrison, B.J., Styner, M.A., Niethammer, M., Warfield S.K., "Segmentation of Knee Images: A Grand Challenge", In: Proc. MICCAI Workshop on Medical Image Analysis for the Clinic, pp. 207-214, 2010.
- [17] <http://www.ski10.org/>

저 자 소 개



신 승 연

- 2012년 2월 : 한양대학교 전자통신공학과 학사
- 2012년 3월 ~ 현재 : 서울대학교 전기·정보공학부 석박통합과정
- 주관심분야 : 컴퓨터비전, 의료영상처리



박 상 현

- 2008년 2월 : 연세대학교 전기전자공학부 학사
- 2008년 3월 ~ 현재 : 서울대학교 전기·정보공학부 석박통합과정
- 주관심분야 : 컴퓨터비전, 의료영상처리, 영역화



윤 일 동

- 1989년 2월 : 서울대학교 제어계측공학과 공학사
- 1991년 2월 : 서울대학교 제어계측공학과 공학석사
- 1996년 8월 : 서울대학교 제어계측공학과 공학박사
- 1997년 3월 ~ 현재 : 한국외국어대학교 디지털정보공학과 교수
- 주관심분야 : 영상처리, 컴퓨터비전



이 상 옥

- 1973년 : 서울대학교 전기공학부 학사
- 1976년 : 미국 Iowa 주립대 전기공학과 석사
- 1980년 : 미국 Univ. of Southern California, 전기공학과 박사
- 1981년 : General Electric Co. 연구원
- 1983년 : M/A-COM Research Center 선임연구원
- 1983년 ~ 현재 : 서울대학교 전기공학부 정교수
- 주관심분야 : 영상처리, 컴퓨터비전