

Fast R-CNN 기법을 활용한 대장 내시경 가이드 알고리즘 개발

Development of Colonoscopy Guide Algorithm based on Fast R-CNN

은성종¹, 정은영², 박동균^{3*}

Sung-Jong Eun¹, Eun Young Jung², Dong Kyun Park^{3*}

요약

본 논문은 대장암 환자의 대장 내시경 시행시 진단의에게 실시간으로 보조적인 가이드를 제공해주고자 제안되었다. 제안 방법은 두 가지의 정보를 활용하여 대장 내시경 가이드를 진행한다. 첫 번째 대장 내시경의 모션 벡터 기반 속도 가이드 방법과 두 번째로 특정 구간에서의 대장 용종 유무를 판단하여 적절한 속도 가이드를 위해 알람을 제공해주는 과정으로 진행된다. 개발 알고리즘의 정확도 및 적절성을 평가하기 위해 임상 기준과 비교 평가하였으며, 추가로 대장용종 유무 인식에 대한 정확도 판단을 위해 기존 영상 처리 방법을 활용하였다. 비교 평가 결과 평균 96%의 정확도를 도출하여 제안 방법이 보다 효과적이고 정확도가 높음을 확인할 수 있었다. 향후 연구로 추가적인 딥러닝 기술을 활용하여 내시경시 보다 환자 맞춤형 요소를 높이는 연구를 진행하고자 한다.

핵심어: 대장 내시경, 내시경 속도, 대장 용종, 합성곱 신경망, 빠른 영역기반 합성곱 신경망

Abstract

This paper was proposed to provide a real-time supplementary guide to colonoscopy diagnosis in colorectal cancer patients. The proposed method uses two kinds of information to guide the colonoscopy guide. Secondly, the procedure of motion vector based speed guide method of first colonoscopy and secondly, an alarm is provided to judge the presence or absence of colonic polyps in a specific section and provide an appropriate speed guide. In order to evaluate the accuracy and appropriateness of the developmental algorithm, we compared with the clinical criteria and used the existing image processing method to determine the accuracy of recognition of colon polyps. As a result of the comparison evaluation, the accuracy of the proposed method is more effective and accurate. Future works will focus on the use of additional depth-learning techniques to enhance patient-specific factors rather than endoscopy.

Keyword : Colonoscopy, Endoscope Velocity, Polyp, CNN, Fast R-CNN

1 Health IT Research center, Gachon University Gil Medical Center, Incheon, Korea [Researcher]
e-mail: asclephios@naver.com

2 Health IT Research center, Gachon University Gil Medical Center, Incheon, Korea [Researcher]
e-mail: eyjung@gilhospital.com

3 Health IT Research center, Gachon University Gil Medical Center, Incheon, Korea [Professor]
e-mail: pdk66@gilhospital.com (Corresponding Author)

* This work was supported by Institute for Information & communications Technology Promotion(IITP) grant funded by the Korea government(MSIT) (2018-2-00861, Intelligent SW Technology Development for Medical Data Analysis)
Received(April 15, 2019), Review Result(1st: May 01, 2019), Accepted(June 03, 2019), Published(June 30, 2019)

1. 서론

최근 건강에 대한 관심의 증가와 의료기술의 향상으로 건강검진을 통한 특정질환의 위험요소나 신체변화의 조기발견의 기회가 증가하고 있는 가운데 검진을 통해 발견되는 대장암 발생 빈도도 증가 추세에 있다[1][2]. 대표적인 서구형 암종인 대장암은 암 사망률 2위를 차지할 정도로 서양에서 흔한 암으로 알려져 있으며, 우리나라에서도 생활환경과 식생활의 변화와 더불어 해마다 발생률이 급격히 증가하고 있다. 우리나라의 대장암 조발생률은 2012년 10만 명 당 51.7건으로 전체 암 발생의 12%를 차지하고 있다. 발생 건수로는 남성의 경우 연 15,612건으로 남성의 암 중 에서 2위이고, 여성의 경우 연 10,170건 발생하여 여성의 암 중 3위를 차지할 정도로 높은 발생률을 보이고 있다[3]. 이에 국내 정부에선 2018년부터 대장암 검진에 소요되는 비용을 전액 건강보험에서 부담해 만 50세 이상 대장암 검진 대상자는 누구나 무료로 국가 대장암 검진(대변잠혈검사)을 받을 수 있으며, 대장암 예방을 위한 조기 검진에 대한 중요성이 높아지고 있다.

또한 이러한 의료분야에 IT기술에 접목 연구들이 많은 상황이며, 딥러닝 기술의 경우 GPU 등 컴퓨터 연산력의 급격한 발전은 음성인식, 자연어처리, 언어 번역, 이미지 내 사물 인식, 로봇공학, 자율주행 등 다양한 분야에서의 큰 진보를 이루어 내었다. 의학 분야에서도 많은 연구 성과가 나오고 있는데, 주로 암 진단, 예측, 관리 분야에 접목하여 연구가 진행되어 오고 있다. 본 논문은 암 질환 중 발생건수가 높고 국가적으로 치료 및 예방에 대한 높은 중요성을 언급하고 있는 대장암 진단에 도움이 될 수 있는 프로그램을 개발하고자 한다. 진단에 보조적인 수단으로 실제 임상이가 대장 내시경 검사시에 대장 용종 및 대장암의 정확한 발견, 진단을 위해 내시경 가이드를 지원하는 알고리즘으로, 내시경 카메라의 모션 벡터 정보 및 대장 용종 정보를 Fast R-CNN(Region Convolutional Neural Network)[4]을 통해 학습하여 적절한 내시경 카메라의 속도를 실시간으로 가이드해주는 방법이다. 본 연구는 실제 의료현장에서의 임상의 수요가 높은 분야로 딥러닝 기술을 접목하여 높은 정확도로 진단 보조를 지원해주고자 하였다. 제안 방법에 대한 내용은 각 장에서 단계별로 설명하도록 한다.

2. 관련 연구

2.1 CNN기반의 객체 검출 연구

최근 고성능 하드웨어(GPU)와 빅 데이터(Big Data)의 영향으로 기계학습 분야에서 성능이 입증된 심화 학습(Deep Learning)를 통해 이미지 인식, 음성 분류 및 인식, 객체 검출 등의 기술을 적용한 다양한 의료분야 연구가 진행되고 있다. 이중 영상 인식 분야에 기본적으로 활용되고 있는

CNN(Convolution Neural Network)는 기존 인공신경망의 구조를 통해 과적합(overfitting), 지역 최적해(local optimum) 수렴, 그라디언트 소실(vanishing gradient) 등의 문제를 극복하기 위해 제안된 딥러닝 모델이다. [5]는 필기체를 인식하기 위해 흑백 필기 영상을 32x32크기로 구성하여 모델에 입력 후 10개의 숫자를 출력으로 구성하였지만 학습이 오래 걸리는 문제로 큰 주목을 받지 못하였다. 현재 하드웨어의 고성능화 및 빅데이터의 발전으로 CNN의 속도를 크게 향상시켰다. ImageNet[6], 사진 공유 서비스를 제공하는 Flickr[7], INRIA Person dataset[8] 등 지도 학습(supervised learning) 및 비지도 학습(unsupervised learning) 학습에 필요한 데이터를 쉽게 수집할 수 있으며 기존 과적합 문제에 대해 [9]에서 제시한 알고리즘 소개로 많은 문제가 해결되어 객체 분류 및 객체 검출에 뛰어난 성능을 보이고 있다. 기존 객체 검출 및 학습 방법과 다르게 CNN은 입력 영상에 대하여 특징을 자동으로 생성하는 능력이 뛰어나며, 특징 추출과 학습이 하나의 구조에서 이루어지는 장점을 가진다.

2.2 R-CNN

R-CNN은 Regions with CNN features로 영역 기반 심화학습기법 중 하나로 각 학습 영역을 어파인 이미지 워핑(Affine imagewarping)을 수행 후 선택적 정보 탐색(Selective Search)을 이용하여 제안 영역(Region Proposal)을 생성한다. 선택적 정보탐색 알고리즘[10]은 bottom-up 접근 방식으로 각 영역에 대해 유사도를 측정하여 영역을 병합하거나 제거한다. 선택적 정보탐색 알고리즘을 수행한 학습 영역을 CNN 구조를 통해 고정 길이의 227x227 특징 벡터를 추출 후 선형 독립적인 SVM(Support Vector Machine)을 이용하여 분류한다[11]. 입력영상의 각 학습 영역을 어파인 이미지 워핑(warp)과 크롭(crop)을 하기 때문에 이미지 변형 및 손실 문제와 학습 영역 개수만큼 CNN구조를 제공하기 때문에 복잡한 구조를 가지고 각 영역을 검증하기 위해 2,000개의 후보 영역을 생성하여 계산량이 증가하는 단점이 있다.

3. Fast R-CNN기반의 대장 내시경 가이드 알고리즘 개발

진단에 보조적인 수단으로 실제 임상이가 대장 내시경 검사시에 대장 용종 및 대장암의 정확한 발견, 진단을 위해 내시경 가이드를 지원해주는 알고리즘으로, 내시경 카메라의 모션 벡터 정보 및 대장 용종 정보를 Fast R-CNN(Region Convolutional Neural Network)[12]을 통해 학습하여 적절한 내시경 카메라의 속도를 실시간으로 가이드해주는 방법이다. 본 논문의 제안 알고리즘 개발 개념은 다음 [그림 1]과 같이 나타낼 수 있다.

본 논문은 대장 내시경의 적절한 속도 가이드를 위한 알고리즘을 제안하였다. 적절한 속도 가이드를 위해서 본 논문에서 제안한 두가지 방법으로, 첫 번째 모션 벡터 기반의 속도 가이드 기술과

두 번째로 Fast R-CNN을 통한 현재 화면에서의 대장 용종 유무에 대한 판단을 통한 속도 가이드 방법을 복합하여 가이드한다. 모션 벡터의 가이드는 프레임간의 모션벡터 차이값을 계산하여, 설정해놓은 임계값을 벗어나는 경우 알람을 주는 방식이다. 용종 유무에 대한 가이드는 현재 화면에서의 대장 용종 유무를 판단하여, 용종이 있는 경우 속도를 늦추는 개념으로 알람을 나타나게 하였다. 해당 두가지 방법에 개별적으로 조건에 부합되거나, 두가지 조건을 동시에 해당되는 경우에도 알람을 주어 임상자에게 적절한 속도 가이드를 하게끔 제안하였다. 제안 알고리즘 개념은 상기 [그림 1]에서 나타내었으며 자세한 프로세스 설명은 다음 챕터에서 단계별로 언급한다.



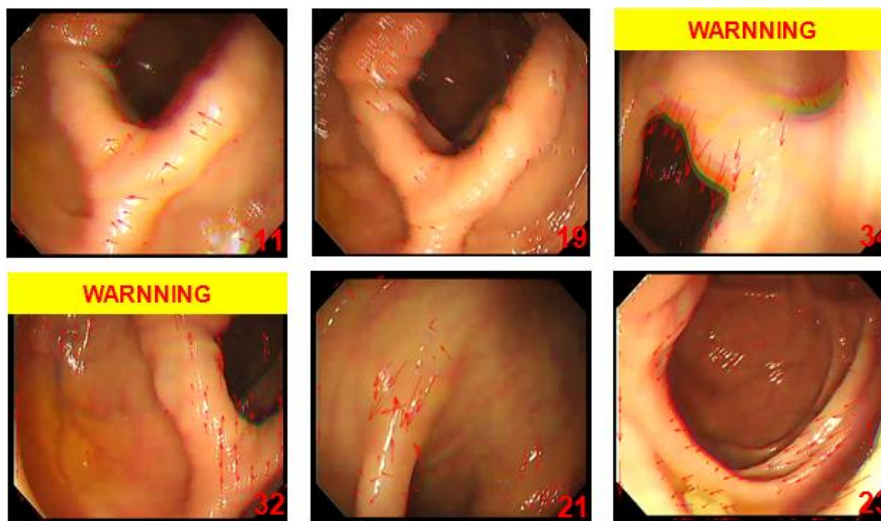
[그림 1] 대장 내시경 가이드 프로그램 개념도
 [Fig. 1] The Concept of Colonoscopy Guide Program

3.1 모션 벡터(Motion Vector) 기반의 내시경 속도 가이드 기술

먼저 입력되는 내시경 영상을 분석하여 속도를 가이드해주는 기술을 개발한다. 본 내시경 영상 조건으로 초당 30프레임의 영상이 입력되며, 각 프레임간의 모션 벡터(Motion Vector) 차이를 계산하여 특정 프레임 이상 임계값 이상의 벡터값이 도출되는 경우 알람을 주는 알고리즘이다. 모션 벡터의 계산은 크게 화소반복법과 블록정합법이 있으며, 본 논문에선 잡음과 움직임에 보다 강한 블록정합법을 활용하였다. 블록정합법은 블록내의 모든 화소는 동일한 움직임을 가진다는 가정과 물체의 운동을 평행이동으로 가정한다. 각각의 블록은 독립적이며 이 방법은 잡음에 강하고 계산량이 적어 실시간 처리에 유용하다. 블록은 8x8 사이즈로 하였으며, 나타내는 탐색위치를 정하고 그것의 SAD(Sum of Absolute Difference)값을 구하여 그중 가장 작은 값을 가지는 방향을 움직임벡터로 정한다. SAD값을 정하는 방법은 아래 (식 1)과 같다.

$$SAD(i,j) = \sum_{k=0}^{M-1} \sum_{l=0}^{N-1} |C(x+k, y+l) - R(x+i+k, y+j+l)| \quad (1)$$

(식 1)에서 $C(x+k, y+l)$ 은 현재프레임 MB 안의 화소들이고 $R(x+i+k, y+j+l)$ 은 참조프레임의 화소들을 가리킨다. i 와 j 의 범위는 $-p \leq i, j \leq p$ (탐색 영역)으로 하고 N, M 은 블록의 크기이다. 따라서 탐색영역 중 $SAD(i,j)$ 가 최소가 되는 점의 블록을 가장 정합이 잘된 블록으로 결정하고 이 때의 $M(i,j)$ 를 움직임벡터로 정한다[13]. 적용시 프레임별로 계산되는 모션 벡터값이 설정된 임계값을 초과하는 경우로, 계산되는 SAD값을 0~50으로 정규화하여 30이상인 경우에 알람을 주는 방식으로 제안하였다. 해당 SAD 임계값은 다양한 프레임별 영상들을 기준으로 임상의 가이드하에 테스트를 통해 설정하였다. 다음 [그림 2]는 제안한 SAD계산과 임계값을 적용한 결과 샘플을 나타낸다.



[그림 2] 모션 벡터 기반의 속도 가이드 결과

[Fig. 2] The Result of Velocity Guide based on Motion Vector

3.2 Fast R-CNN 기반의 대장 용종 인식 기술

Fast R-CNN [12]은 영역 기반 심화학습 중 하나로 입력 영상과 학습 영역(RoI)을 완전 연결층을 제외한 컨볼루션 네트워크(convolution Network)를 이용하여 특징 맵을 생성한다. 다양한 학습 영역이 완전 연결층으로 들어 갈수 있게 특징 맵으로부터 고정 길이 특징 벡터를 추출하는 RoI Pooling layer를 수행한다. RoI Pooling layer를 통해 특징을 추출 후 완전 연결층을 통해 학습한다. 학습 후 객체 검출(object detection)부분인 분류기(classifier)와 검출 영역(bounding box regression)에 대하여 소

소프트맥스(softmax)와 크로스 엔트로피(cross entropy)를 이용하여 분류하고 검출 영역을 예측한다. 객체 검출은 (식 2), (식 3)의 소프트맥스와 크로스엔트로피를 이용하여 K+1개의 카테고리들의 각 학습 영역에 대한 예측된 값을 이산확률 분포로 정의하여 학습 영역의 클래스(ground truth class)와 0과 1사이의 log 그래프의 무한대와 0과 1사이 결과값을 이용하여 에러(error)를 구하고 그 합을 최종 손실 값(loss)으로 정의하면 다음과 같다.

$$\text{Softmax}(\widehat{P}_{nk}) = \frac{\exp(x_{nk})}{\sum_{k'} \exp(x_{nk'})} \quad (2)$$

$$\text{Cross Entropy}(E) = \frac{-1}{N} \sum_{n=1}^N \log(\widehat{p}_n, l_n) \quad (3)$$

예측된 검출 영역은 객체 클래스들의 색인(index)인 k 개로 정의되며 각 학습 영역의 예측 클래스 u와 학습 영역의 좌표로 구성하여 객체 검출 부분인 분류(classification)와 검출 영역 좌표(bounding box regression)에 대한 multi task loss를 정의하면 (식 4)로 표현된다.

$$L(p, u, t^u, v) = L_{cls}(p, u) + \lambda[u \geq 1] L_{loc}(t^u, v) \quad (4)$$

예측된 클래스가 0인 경우는 배경 라벨(label)로 인식하고 1이상 인 경우 예측된 객체 영역의 좌표와 학습 영역의 좌표(ground truth bounding box regression)에 대한 거리 간 차이로 학습 영역과 예측된 영역의 거리를 최소화 하도록 정의하면 (식 5)와 (식 6)으로 표현된다.


$$L_{ioc}(t^u, v) = \sum_{i \in x, y, w, h} \text{smooth}_{L1}(t_i^u - v_i) \quad (5)$$

$$\text{Smooth}_{L1}(x) = \begin{cases} 0.5x^2, & \text{if } |x| < 1 \\ |x| - 0.5, & \text{otherwise} \end{cases} \quad (6)$$

R-CNN에서 CNN 특징들이 선형 독립적인 SVM과 객체 영역 좌표들에 대응하여 업데이트가 안 되는 문제, 복잡한 학습 구조를 가지는 문제에 대해 Fast R-CNN에서 multi task loss를 이용하여 객체 검출 부분 문제와 end-to-end 학습 구조를 이용하여 문제를 해결하였다[14]. 다음 [그림 3]은 Fast R-CNN을 통한 현재 화면에서의 대장 용종의 유무를 판단하여 알람을 표시한 결과를 나타낸다.

[그림 3]에서 확인할 수 있듯이 Fast R-CNN을 적용하여 대장 용종 자체의 유무를 판단한 결과로, 화면을 4분할 형태로 분류하여 용종이 있는 영역에 붉은 색으로 표시하는 결과를 나타낸다. 용종 자체의 정확한 경계선 정보 추출까지는 아니지만 실제로 용종이 영상 4분할된 영역 중에 어떤 영역에 위치해있는지 대략적인 정보 확인은 가능한 결과이다. 이후 붉은 색으로 표시되는 영역이


발생하게 되면, 임상에게 속도 조절을 가이드하는 알람을 제공하는 형식으로 진행된다.



[그림 3] Fast R-CNN 기반의 대장 용종 유무 인식 결과
[Fig. 3] The Result of Polyp Detection based on Fast R-CNN

4. 성능 평가

제안 방법의 성능 평가를 위해 총 500건의 대장암 환자 내시경 동영상 데이터와 동일한 건수의 대조군 동영상 데이터를 통하여 학습을 수행하였다. 학습시 환자데이터의 용종 영역을 Fast R-CNN 적용을 위해 ROI 레이블링 작업을 수행하였으며 성능 평가를 위해 모션 벡터 속도의 임상 가이드와 비교하고, 용종이 있는 구간엔 한해선 적절한 속도로 가이드 되어야 하기 때문에 용종 유무 인식 정확도를 평가하고자 하였으며 이는 기존 방법과 비교하여 평가하였다.



(A) 용종이 포함된 비정상 데이터 샘플 그룹

(B) 정상 데이터 샘플 그룹

[그림 4] 대장 용종 유무 판단을 위해 사용한 실험데이터 샘플
[Fig. 4] The Samples of Experiment Date for Polyp Detection Method

실험 데이터의 확인은 다음 [그림 4]에서 나타내었으며, 학습데이터 관점에서 대장용종 유무 인식을 위해 Normal과 Abnormal로 구분하여 샘플데이터로 표시하였다. 그리고 내시경 가이드의 적절성을 평가하기 위해 [표 1], [표 2]와 같이 비교 결과들을 확인하였고 제안 알고리즘의 적합성에 대해 확인할 수 있었다.

[표 1] 제안 방법과 임상의 기준과의 비교 결과

[Table 1] Comparison Result of the Proposed Method with the Doctor's Criteria

환자 구분	속도 가이드 알람 횟수 비교		대장용종 유무 결과 비교	
	Proposed method	Criteria	Proposed method	Criteria
1	12	10	4	4
2	11	12	3	3
3	10	9	8	7
4	8	5	4	3
5	12	11	3	3
6	15	15	5	5
7	10	8	6	6
8	9	9	3	2
9	7	5	3	3
10	11	11	5	5
Average	95.2%		96.8%	

먼저 [표 1]의 경우 제안방법과 임상의의 확인결과(Criteria)를 비교하여 제안방법의 적절성을 검증하고자 하였다. 총 500건의 대장암 환자의 동영상 데이터를 실험데이터로 하였고 [표 1]의 경우 이중 10개의 환자 데이터를 샘플 결과로 나타내었으며, 평균의 경우 500건에 대한 평균값으로 표기하였다. 속도 가이드 알람 횟수의 경우 동영상에서의 특정 구간에서 알람이 몇 번 표시되었는지에 대한 표시로 임상의 기준과 비교하였고, 대장용종 유무의 경우도 동일하게 특정 구간에서의 용종 유무에 대한 표시를 비교하여 제안 방법의 정확성과 적절성을 검증하고자 하였다. 해당 비교 결과 평균 96%의 정확도를 확인할 수 있었다. [표 2]의 경우 대장용종 검출에 대한 정확도를 평가하기 위하여 기존의 다양한 객체 검출방법[15][16]을 통하여 정확도를 비교하였다. 제안 방법의 경우 정확한 경계 검출은 아니지만 4분 분할 영역에 어느 영역에 존재한다라는 결과값으로 비교하였고, 비교 방법의 경우 검출 영역 결과와 임상의 검출결과(Criteria)인 영역 정보와 80% 이상만 매칭될 경우 정확한 결과로 판단하여 500건에 대한 오차행렬(Confusion Matrix)을 계산하였다. 영역 검출에 대한 제안방법과 비교 방법에 대한 직접적인 비교보단, 용종 유무에 대한 비교 검증 차원으로 진행한 실험으로 픽셀 기반의 검출 방법보단 영역 기반의 용종 유무에 대한 검출 결과가 진단 보조 개념으로 보다 효과적임을 확인할 수 있었다. 일부 부정확한 결과에 대해선 학습 데이터의

그룹핑 과정에서 모호한 결과들의 적용이 원인으로 생각되며, 보다 정제된 학습 데이터 구축의 필요성을 확인할 수 있었다.

[표 2] 제안 방법과 기존 방법들과의 용종 검출 비교 결과

[Table 2] Polyp Detection Comparison Result of the Proposed Method with the Other Exist Method

Confusion matrix (500 Case)	Proposed method	Canny edge (Contour based)	Region growing (Region based)
True Positive	481	430	448
False Positive	19	70	52
True Negative	472	410	455
False Negative	28	90	45

5. 결론

본 논문은 대장암 환자의 대장 내시경 시행시 진단의에게 실시간으로 보조적인 가이드를 제공해주고자 제안되었다. 제안 방법은 두 가지의 정보를 활용하여 대장 내시경 가이드를 진행한다. 첫 번째 대장 내시경의 모션 벡터 기반 속도 가이드 방법과 두 번째로 특정 구간에서의 대장 용종 유무를 판단하여 적절한 속도 가이드를 위해 알람을 제공하는 과정으로 진행된다. 해당 제안 방법은 임상이가 실제 대장 내시경을 진행할 때, 빠른 움직임이나 놓칠 수 있는 용종에 한해서 인공지능 기술을 활용하여 진단보조 도구의 역할을 제공해주기 위해 개발되었다. 개발 알고리즘의 정확도 및 적절성을 평가하기 위해 임상의 기준과 비교 평가하였으며, 추가로 대장용종 유무 인식에 대한 정확도 판단을 위해 기존 영상 처리 방법을 활용하였다. 비교 평가 결과 평균 96%의 정확도를 도출하여 제안 방법이 보다 효과적이고 정확도가 높음을 확인할 수 있었다. 그러나 몇 가지 케이스로 임상이의 내시경 속도에 차이와 대장 용종의 환자 상태에 따라 인식 정확도가 차이가 나는 점을 확인할 수 있었다. 이러한 부분의 해결은 환자 맞춤형의 프로그램 제안으로 갈수 있는 연구 방향으로, 향후 추가적인 딥러닝 방법을 활용하여 환자 맞춤형 요소를 높이고자 한다.

References

- [1] Jeon, Gyeong-Suk, Eun-Suk Choi, and Hyo-Young Lee. "Gender-related difference in the utilization of health care services by Korean adults." *Journal of Korean public health nursing*, (2010), Vol.24, No.2, pp.182-196, (<https://doi.org/10.5932/JKPHN.2010.24.2.182>)
- [2] Ministry of Health & Welfare. 2008 National cancer registration statistics. Seoul, (2010).
- [3] <http://www.nso.go.kr/kosis>, Retrieved: May 21 (2019)
- [4] Esteva, Andre, et al. "Dermatologist-level classification of skin cancer with deep neural networks." *Nature* 542.7639, (2017), pp.115.
- [5] Lecun, Y., et al. "Gradient-based learning applied to document recognition, (1998), vol.86, pp.2278-2324.
- [6] <http://image-net.org/>, Retrieved: May 14 (2019)
- [7] <https://www.flickr.com/>, Retrieved: May 14 (2019)
- [8] <http://pascal.inrialpes.fr/data/human/>, Retrieved: May 21 (2019)
- [9] Zeiler, Matthew D., and Rob Fergus. "Visualizing and understanding convolutional networks." *European conference on computer vision*. Springer, Cham, 2014, pp.818-833, (https://doi.org/10.1007/978-3-319-10590-1_53)
- [10] Uijlings, Jasper RR, et al. "Selective search for object recognition." *International journal of computer vision*, (2013), Vol.104, No.2, pp.154-171, (<https://doi.org/10.1007/s11263-013-0620-5>)
- [11] Girshick, Ross, et al. "Rich feature hierarchies for accurate object detection and semantic segmentation." *Proceedings of the IEEE conference on computer vision and pattern recognition*. (2014), Jun 24-27, Columbus, Ohio
- [12] Girshick, Ross. "Fast r-cnn." *Proceedings of the IEEE international conference on computer vision*. (2015), Dec 13-16, Santiago, Chile.
- [13] Jung-muk Kim, Ji-in Kim, Goo-rak Kwon, Optokinetic anticipation in frames by using motion-vector among frames, *Proceedings of KIIT Summer Conference*. (2012), May, Jeju, Korea.
- [14] Byeong-jun Kim, Dong-Hoon Kim and Joonwhoan Lee, An Improved License Plate Recognition Technique in Outdoor Image, *Journal of Korean institute of intelligent systems*, (2016), Vol.26, No.5, pp.423-431, (<https://doi.org/10.5391/JKIIS.2016.26.5.423>)
- [15] Rajinikanth, V., et al. "Evaluation of ischemic stroke region from CT/MR images using hybrid image processing techniques." *Intelligent Multidimensional Data and Image Processing*. IGI Global, (2018), pp.194-219, (DOI: 10.4018/978-1-5225-5246-8.ch007)
- [16] Williams, Donna J., and Mubarak Shah. "A fast algorithm for active contours and curvature estimation." *CVGIP: Image understanding*, (1992), Vol.55, No.1, pp.14-26, ([https://doi.org/10.1016/1049-9660\(92\)90003-L](https://doi.org/10.1016/1049-9660(92)90003-L))