

A Study on the Comparison of Learning Performance in Capsule Endoscopy by Generating of PSR-Weighted Image

Changnam Lim[†] · Ye-Seul Park^{**} · Jung-Won Lee^{***}

ABSTRACT

A capsule endoscopy is a medical device that can capture an entire digestive organ from the esophagus to the anus at one time. It produces a vast amount of images consisted of about 8~12 hours in length and more than 50,000 frames on a single examination. However, since the analysis of endoscopic images is performed manually by a medical imaging specialist, the automation requirements of the analysis are increasing to assist diagnosis of the disease in the image. Among them, this study focused on automatic detection of polyp images. A polyp is a protruding lesion that can be found in the gastrointestinal tract. In this paper, we propose a weighted-image generation method to enhance the polyp image learning by multi-scale analysis. It is a way to extract the suspicious region of the polyp through the multi-scale analysis and combine it with the original image to generate a weighted image, that can enhance the polyp image learning. We experimented with SVM and RF which is one of the machine learning methods for 452 pieces of collected data. The F1-score of detecting the polyp with only original images was 89.3%, but when combined with the weighted images generated by the proposed method, the F1-score was improved to about 93.1%.

Keywords : Machine Learning, Diagnostic Assistant, Medical Images, Capsule Endoscopy

폴립 가중치 영상 생성을 통한 캡슐내시경 영상의 학습 성능 비교 연구

임 창 남[†] · 박 예 슬^{**} · 이 정 원^{***}

요 약

캡슐 내시경은 식도부터 항문까지 소화기관 전체를 한 번에 촬영할 수 있는 의료기기로, 한 번의 검사에서 평균 8~12시간의 길이와 5만장 이상의 프레임으로 구성된 영상을 생성한다. 그러나 생성된 영상에 대한 분석은 전문가에 의해 수작업으로 진행되고 있어서, 질병 영상 진단을 돕기 위한 영상 분석 자동화에 대한 수요가 증가하고 있다. 그 중에서도 본 연구에서는 위장관 내에서 발견될 수 있는 용기성 병변인 폴립 영상 자동 검출에 초점을 맞추었다. 본 연구에서는 멀티 스케일 분석을 통해 폴립 의심 영역을 추출하고, 이것을 원본 영상과 합성하여 폴립 학습을 강화시킬 수 있는 가중치 영상을 생성하는 기법을 제안한다. 수집한 452장의 데이터에 대해 머신 러닝 기법중 하나인 SVM과 RF로 실험한 결과, 원본 영상을 이용한 폴립 검출의 F1점수는 89.3%였지만, 생성된 가중치 영상을 통해 학습한 결과 F1점수가 93.1%로 향상된 것을 확인하였다.

키워드 : 기계학습, 진단 보조, 의료 영상, 캡슐내시경

1. 서 론

캡슐내시경은 식도에서 항문까지 소화기관 전체를 관찰할 수 있는 의료기기이다. 캡슐은 장의 연동운동에 이동하며 장

내부 영상을 촬영한다. 이렇게 얻어진 영상은 복부에 부착된 터미널을 통해 전송되고, 한 번의 검사에서 보통 8~12시간의 길이, 5만장 이상의 프레임을 가진 영상을 생성한다. 현재는 이와 같이 생성된 영상의 판독을 의료진들이 수작업으로 진행해야 하는 불편함이 존재한다. 이로 인해, 캡슐내시경 영상 분석 자동화에 대한 기술적인 수요가 높아지고 있다.

의료 영상 분석에 대한 여러 가지 연구 중 대표적인 연구는 병변 검출에 대한 연구이다. 위장관 내에서 발견될 수 있는 용기성 병변 중 하나인 폴립에 대한 예를 들면, 폴립 검출을 위해 전통적인 방법을 통해 영상에서 특징을 추출하여 그 특징을 기계학습 기법에 적용시키거나[1-3], 기존의 방식과 딥러닝 기법을 적용하여 폴립을 검출하는 연구들이 진행되고 있다[4, 5]. 그러나 의료 영상의 특성상 위장관에 폴립이 관찰

※ 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터 지원사업의 연구결과로 수행되었음(IITP-2019-2016-0-00309).

※ 이 논문은 2018년도 한국정보처리학회 추계학술발표대회에서 '폴립 검출 권 불투선 신경망 설계를 위한 캡슐내시경 영상의 멀티 스케일 분석 기반 특징 추출 기법'의 제목으로 발표된 논문을 확장한 것이다.

† 준 회 원 : 아주대학교 전자공학과 석사과정

** 준 회 원 : 아주대학교 전자공학과 박사과정

*** 중 심 회 원 : 아주대학교 전자공학과 교수

Manuscript Received : January 14, 2019

First Revision : March 28, 2019

Accepted : April 8, 2019

* Corresponding Author : Jung-Won Lee(jungwony@ajou.ac.kr)

되지 않는 환자의 경우가 대부분이고, 폴립이 있더라도 폴립 영상은 전체 영상에 비해 일부분에 불과하다. 이와 같은 언더 샘플링(Undersampling)-학습데이터의 불균형 문제는 약 12 시간을 지속적으로 촬영하는 캡슐내시경에서 더욱 심각하다. 따라서 수집된 데이터를 기계학습 기법에 바로 적용시키기는 어려우므로 특별한 전처리 과정이 필요하다.

이를 위해, 본 논문에서는 멀티 스케일 분석을 통한 폴립 학습 강화용 영상 생성 기법을 제안한다. 이 기법은 멀티 스케일 분석을 통해 폴립 의심 영역을 설정하고 의심 영역 정보를 통해 원래의 영상에 가중치를 설정한 영상을 생성하는 기법이다. Fig. 1은 생성한 학습 강화용 영상을 이용하여 영상을 학습하는 과정을 나타낸다. 특히, Fig. 1의 과란색 박스는 제안하는 폴립 학습 강화용 영상 생성 기법을 나타낸다. 먼저, 내시경 영상으로부터 폴립이 의심되는 영역을 추출하는 과정을 수행한다. 이는 크게 잡음을 제거한 윤곽선 검출, 멀티 스케일 원형 검출, 단일 의심 영역 추출(PSR, Polyp Suspicious Weight), 단일 의심 영역의 결정 과정으로 이루어진다. 추출된 PSR의 정확도를 평가하기 위해, 폴립이 있는 영역에 masking한 영상과 대조하여 평가를 수행하였다. 평가 결과, 평균적으로 67%, 63%, 58%의 정밀도, 재현율, F1점수를 기록하였다. 다음은 이와 같이 추출된 단일 의심 영역 행렬을 영상화하는 과정과, PSR 가중치 영상을 생성하는 과정을 거친다.

생성된 PSR 가중치 영상의 정확도를 평가하기 위해, 본 논문에서는 두 가지 기계학습 알고리즘(SVM: Support Vector Machine, RF: Random Forest)을 적용해보았다. 기계학습 알고리즘 적용을 위해, 각각의 영상에 대한 HOG(Histogram Oriented Gradient) 특징을 추출하여 SVM 혹은 RF 학습을 진행하였다. 실험 결과, 원본 영상을 사용하였을 때의 평균 F1점수가 89.3%에 비해, 생성된 영상을 이용해 학습을 진행한 결과 평균 F1 점수가 93.1%로 약 3.8% 정도가 개선되었음을 확인할 수 있었다. 이와 같은 결과는 폴립이 의심되는 영역에 대해 후보 지역을 축소시켜줌에 따라 학습의 정확도를 향상시킨 것으로 판단된다.

2. 관련 연구

현재 폴립 검출을 위한 연구는 Fig. 2와 같이 크게 두 가지 방향으로 진행되고 있다. 첫 번째는 전통적인 방법을 통해 영상에서 특징을 추출하고, 그 특징을 기계학습 기법에 적용시켜 폴립의 여부를 판단하는 방향이다(Fig. 2(a)). [1]에서는 BoF(Bag of Features)기법을 사용한 후 SVM과 FLDA(Fisher's Linear Discriminant Analysis)를 사용하여 폴립을 판별하였다. [2]의 경우에는 질감 특징, 형태적 특징을 결합하여 SVM, MLP (Multilayer Perceptron) 등을 사용하여 폴립을 판별하였다. 비슷한 방법의 [3]의 경우는 웨이블릿(Wavelet)과 앰퍼시스(Emphasis) 특징을 추출하여 사용하였다. 두 번째는 기존의 전통적인 기법과 딥러닝 기법을 결합하는 방향이다(Fig. 2(b)). [4]의 경우 딥러닝 기법을 활용하여 캡슐내시경 영상을 6가지 카테고리로 분류한다. 이 때 영상의 기울기 분석과 같은 고전적인 방법을 적용하여 획득한 라플라시안(Laplacian) 영상, 헤시안(Hessian) 행렬을 함께 학습시킨다. [5]의 경우, [4]의 경우와는 다르게 영상 처리 방법론이 네트워크의 학습 과정에

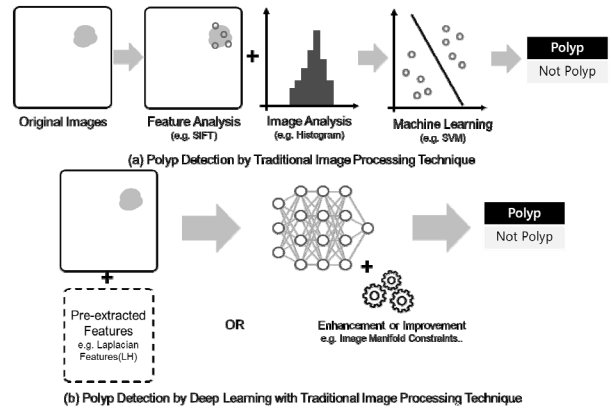


Fig. 2. Conventional Polyp Detection Method

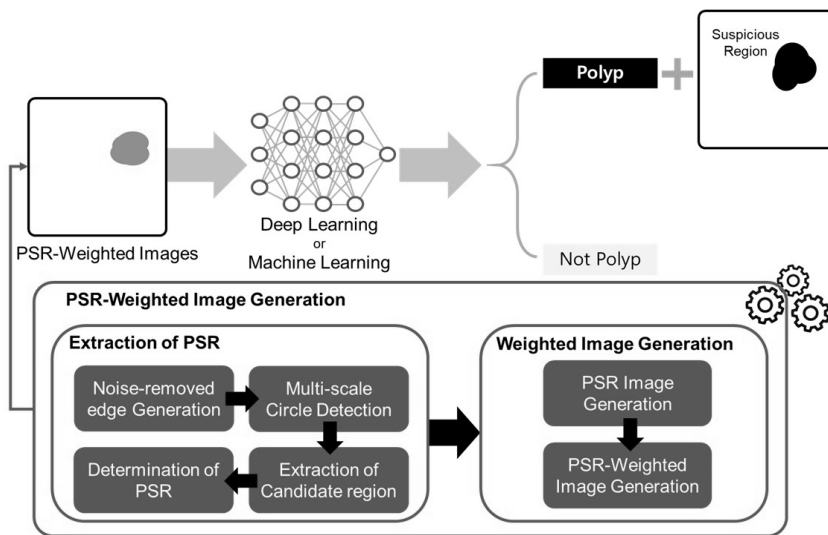


Fig. 1. Design of Convolutional Neural Network for Polyp Detection

개입한다. 스파스 오토인코더(Sparse Auto Encoder)로 설계된 네트워크를 중첩하고, 각 층의 결과에 개입하는 방식이다. 그러나 이와 같은 방법들은 언더샘플링의 특징을 가진 폴립을 검출하기에 한계를 갖고 있다. 또한 현재의 방법들은 폴립 영상을 구분하였다 할지라도 어느 위치에 의해서 폴립이라 결정되었는지 확인하기 어려운 구조이다. 이를 개선하기 위해 본 논문에서는 폴립 의심 영역을 추출하고, 추출된 영역을 이용해 학습 강화용 영상을 생성하는 기법을 제안한다.

3. 멀티 스케일 기반 폴립 의심 영역 추출

3.1 잡음 제거한 윤곽선 검출

폴립 의심 영역을 검출하기 위해 가장 먼저 진행하는 것은 윤곽선 검출 작업이다. 윤곽선은 가장자리 부근을 나타낸 선으로 영상 내에서 밝기가 급변하는 부분이다. 윤곽선을 검출하는 다양한 기법이 존재하는데, 본 연구에서는 캐니(Canny) 윤곽선 검출 기법을 사용하여 윤곽선을 검출하였다. Fig. 3(b)는 Fig. 3(a)에서 윤곽선을 추출한 Fig이다. 이렇게 얻은 윤곽선은 길이를 측정해 일정 이하의 길이를 가진 윤곽선은 노이즈로 판단하여 제거하는 작업을 진행하였다(Fig. 3(c)).




Fig. 3. Edge Detection Process

3.2 멀티 스케일 원형 검출

다음은 폴립이 대개 원형 혹은 타원형이라는 특징에서 착안하여 영상에서 원 형태를 검출하는 작업을 진행한다. 이 때, 타원형, 일그러진 원형 등의 폴립은 원래의 영상에서 검출하기 힘들기 때문에 서로 다른 중횡비를 가진 영상들을 생성한다. 구체적으로는 1:1의 중횡비를 가진 원본 영상에서 1:2, 1:3, 1:5, 2:1, 3:1, 5:1의 비율로 변경한 6개의 영상을 생성하였다(Fig. 4). 이렇게 생성된 각각의 영상에서 허프(Hough) 원 검출 기법을 사




Fig. 4. Image Generation of Changed Aspect Ratio and Circle Detection Result

용하여 원 형태를 검출한다. 허프 원 검출 기법을 사용할 때 필요한 매개변수 중 누산기의 임계값을 결정하는 매개변수가 존재한다. 이 매개변수의 값은 높을수록 더 정확한 원 형태를 검출하고 낮아질수록 더 많은 원 형태를 검출하는데, 그로 인해 잘못 검출되는 경우 또한 많아지게 된다. 본 논문에서는 이러한 특성을 고려하여 이 매개변수를 변경하면서 여러 번 원 형태를 검출하였고, 높은 매개변수에서 검출된 원일수록 3.4절에서 진행하는 영역 병합 과정에서 높은 가중치를 두어 병합하였다.

3.3 단일 의심 영역 추출

검출된 각각의 원에 대해 두 가지 검사를 실행하는데, 각각의 검사는 폴립이 용기성 병변이기 때문에 내부가 밝고 외부로 갈수록 어둡다는 특징을 이용한다. 두 검사는 원을 13등분한 대략 27.69°의 방향 별로 각 원에 대해 총 13번 실행된다(Fig. 5). 이 13이라는 값은 여러 번의 실험 결과 refined된 값이다. 첫 번째 검사는 검출된 원의 내부와 외부의 밝기 차를 비교하여 내부가 외부보다 일정 수준 이상 밝을 경우 검사를 통과한 것으로 한다(Fig. 6(a)). 두 번째 검사는 검출된 원의 내부를 관찰하여 내부에서 외부로 갈수록 밝기가 어두워질 경우 검사를 통과한 것으로 한다(Fig. 6(b)). 첫 번째 검사와 두 번째 검사를 통과한 방향의 수가 각각 전체 검사한 방향수와 대비해 일정 비율 이상일 경우 해당 검사를 통과한 것으로 한다. 두 가지 검사를 모두 통과할 경우 해당 원을 폴립이 있는 영역이라고 판단하고 단일 의심 영역이라고 정의한다(Fig. 6(c)).




Fig. 5. Circle Analysis Direction

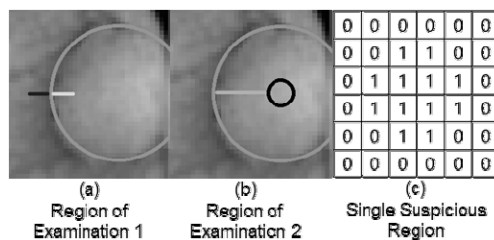


Fig. 6. Circle Analysis Process for a Direction

3.4 PSR 영역 병합

추출된 각각의 단일 의심 영역들을 원래의 중횡비로 되돌리는 작업을 수행하고, 3.2절에서 허프 원 검출 기법을 사용할 때의 매개변수 값에 따라서 가중치를 부여한다. 원본 영상과 똑같은 크기의 행렬을 생성한 후 검출된 각각의 단일 의심 영역과 같은 위치에 해당하는 행렬의 영역에 단일 의심 영역에 부여된 가중치만큼 값을 더한다. Fig. 7(b)는 Fig. 7(a)의 단일 의심 영역들을 이용해 생성된 폴립 의심 영역이다. 이렇게 생성된 행렬은 값이 클수록 해당 부분에 폴립이 의심

됨을 의미하고, 이 행렬에 1이상의 값을 가지는 부분을 폴립 의심 영역이라고 정의한다.

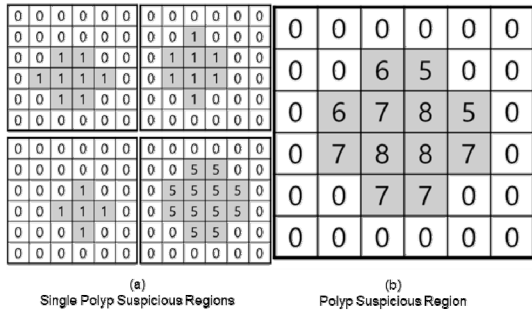


Fig. 7. Merge Single Suspicious Regions

3.5 PSR 평가

다음은 추출된 폴립 의심 영역(PSR)에 대한 평가이다. 이 실험에서는 각각의 폴립 영상에서 폴립인 부분을 직접 마스크킹하여 정답으로 활용할 수 있는 영상을 만든 후, 추출한 의심영역과 대조하는 방식으로 진행하였다. 평가는 정밀도, 재현율, F1점수로 진행하였다. Fig. 8은 실험 평가 방법을 표현한 것으로, 그림에서 하얀색 영역은 마스크된 병변 부분, 검정색 영역은 병변이 없는 부분, 붉은색 영역은 맞게 검출한 부분, 초록색 부분은 잘못 검출한 부분을 나타낸다. 실험한 데이터들 중에서 높은 F1점수를 보인 경우의 예시는 Fig. 9, 낮은 F1점수를 보인 경우의 예시는 Fig. 10과 같다. 전체 데이터에 대한 평균을 낸 결과 정밀도, 재현율, F1점수의 평균은 각각 67%, 63%, 58%로 나타났다. F1점수가 떨어지는 데이터에 대한 분석을 수행하였을 때, 작은 폴립이 많이 존재하거나 이미지에서 폴립이 차지하는 영역이 큰 이미지에서 결과가 좋지 않게 나왔음을 확인할 수 있었다.




Fig. 8. PSR Evaluation




Fig. 9. Examples of Images Showing High F1-Score




Fig. 10. Examples of Images Showing Low F1-Score

4. 폴립 학습 강화를 위한 가중치 영상 생성

4.1 PSR 영상 생성

4.1절에서는 생성한 PSR행렬을 영상으로 바꾸는 작업을 진행한다. PSR행렬은 음이 아닌 정수들로 이루어져 있으며 영상에 따라 수백 혹은 수천까지의 값도 존재하지만 영상으로는 0~255까지의 값만 표현할 수 있다. 이로 인해, 행렬의 값을 영상에서 표현할 수 있는 범위로 바꾸는 작업이 필요하다. 각 값의 비율을 유지하기 위해 행렬의 각 값을 행렬의 최대값으로 나눠준 후 영상에서 표현할 수 있는 최대값인 255를 곱해주는 방식으로 이 작업을 수행하였다. 이렇게 생성된 영상은 Fig. 11과 같다.




Fig. 11. PSR Image

4.2 PSR 가중치 영상 생성

다음은 4.1절에서 생성된 PSR영상을 이용해 폴립 학습 강화용 영상(PSR-weighted Image)을 생성하는 과정이다. 영상의 생성은 흑백으로 표현한 원본영상과 PSR영상을 가중치를 주어 중첩시키는 방식으로 진행하였다. 가중치가 1:3, 1:1, 3:1일 때 생성된 영상은 Fig. 12와 같다. 생성된 영상은 가중치가 작을수록 원본 영상에 가깝고, 클수록 PSR영상에 가깝게 생성된다.




Fig. 12. PSR-Weighted Images

5. PSR 가중치 영상의 학습 성능 비교

5장에서 PSR 가중치 영상의 적용을 통한 학습 성능 분석 결과를 제시한다. 실험에 사용한 데이터는 118x118 크기의 폴립 영상 150장, 폴립이 아닌 영상은 302장 중 임의로 뽑은 150장으로 구성되며, SVM, RF 기법을 적용하였다. 가중치 영

상을 학습하는 경우에는 테스트 데이터와 트레이닝 데이터 모두 가중치 영상을 생성한 후 가중치 영상으로 진행하였다.

• SVM(Support Vector Machine)의 적용

먼저, SVM에 대한 적용이다. SVM을 통한 학습의 경우, 118x118의 높은 차원을 축소시키기 위해 각각의 영상에서 HOG 특징을 추출한 후 진행하였다. 테스트 데이터와 트레이닝 데이터의 비율은 2:8로 수행되었으며, 5-Fold 교차 검증(CV, Cross Validation)을 진행하였다. 원본 영상으로 학습했을 때 정확도, 정밀도, 재현율, F1점수는 각각 평균 91.0%, 91.3%, 91.3%, 91.1%로 나타났다. PSR 가중치 영상은 합성 비율이 22%일 때가 가장 높은 F1점수를 보였으며 이때의 정확도, 정밀도, 재현율, F1점수는 각각 평균 94.3%, 94.0%, 94.7%, 94.3%로 원본 영상으로 학습했을 때에 비해 성능이 개선됨을 확인하였다. 5-Fold 교차 검증에 대한 세부적인 성능 분석 결과는 Table 1과 같다.

Table 1. Analysis of Learning Performance for PSR-weighted Image by SVM

data set	Original Images			PSR-weighted Images		
	Acc	Precision	Recall	Acc	Precision	Recall
set1	0.933	0.964	0.900	1.000	1.000	1.000
set2	0.883	0.829	0.967	0.933	0.933	0.933
set3	0.917	0.963	0.867	0.900	0.900	0.900
set4	0.917	0.879	0.967	0.950	0.935	0.967
set5	0.900	0.929	0.867	0.933	0.933	0.933
avg (F1 score)-Original : 0.911/PSR-weighted : 0.943						

* Acc=Accuracy

• Random Forest(RF)의 적용

다음은 RF에 대한 적용이다. RF의 경우, SVM과 다르게 RF를 생성할 때의 생성되는 포레스트의 최대 깊이에 대한 제한을 둘 수 있는 파라미터가 존재한다. 본 논문에서는 최대 깊이 파라미터에 대한 값을 변경하면서 4개의 학습 모델을 획득하였다. 5.1절과 마찬가지로 각 모델에 대해 5-Fold 교차 검증을 수행하였으며, 4가지 모델 모두 원본 영상을 적용하였을 때에 비해 PSR 가중치 영상을 적용하였을 때 평균 F1점수가 개선됨을 확인할 수 있었다. 4가지 모델 별 학습 성능을 분석한 결과는 Table 2와 같이 정리된다. 대부분 PSR 가중치 영상에 대해 성능이 향상된 것을 확인할 수 있다. 그러나 모델 1의 set 5, 모델2의 set 4, 모델 3의 set 3, 모델4의 set 3, 5와 같이 몇 set들의 실험 결과에서 성능이 떨어지는 것을 확인할 수 있다. 이는 실험에 수행된 set가 무작위로 생성된 데이터 중에서 폴립의 크기가 작고 많은 경우의 데이터가 많이 포함된 데이터 셋이어서 평가 결과가 비교적 좋지 못했던 것으로 판단된다.

• PSR의 성능에 따른 PSR 가중치 영상 학습 성능 분석

다음은 PSR의 성능에 따른 PSR 가중치 영상 학습 성능의 변화를 분석해보았다. PSR을 추출할 때 사용되는 매개변수의 값을 조절하여 정밀도와 재현율을 변화시키며 PSR 가중치 영상의 학습 성능을 측정했다. Table 3은 매개변수의 변화에 따른 PSR의 성능과 이렇게 추출한 PSR을 이용한 PSR 가중치

Table 2. Analysis of Learning Performance for PSR-weighted Image by RF

data set	RF model 1 (depth=INF)					
	Original Images			PSR-weighted Images		
	Acc	Precision	Recall	Acc	Precision	Recall
set1	0.917	0.931	0.900	0.983	1.000	0.967
set2	0.967	0.938	1.000	0.983	1.000	0.967
set3	0.800	0.737	0.933	0.950	0.966	0.933
set4	0.850	0.889	0.800	0.950	0.935	0.967
set5	0.817	0.744	0.967	0.800	0.750	0.900
avg (F1 score)-Original : 0.878/PSR-weighted : 0.937						
data set	RF model 2 (depth=2)					
	Original Images			PSR-weighted Images		
	Acc	Precision	Recall	Acc	Precision	Recall
set1	0.783	0.730	0.900	1.000	1.000	1.000
set2	0.900	0.833	1.000	0.933	0.882	1.000
set3	0.850	0.784	0.967	0.867	0.806	0.967
set4	0.883	0.871	0.900	0.867	0.867	0.867
set5	0.750	0.692	0.900	0.800	0.765	0.867
avg (F1 score)-Original : 0.850/PSR-weighted : 0.899						
data set	RF model 3 (depth=5)					
	Original Images			PSR-weighted Images		
	Acc	Precision	Recall	Acc	Precision	Recall
set1	0.983	1.000	0.967	1.000	1.000	1.000
set2	0.933	0.933	0.933	0.967	1.000	0.933
set3	0.950	0.935	0.967	0.933	0.906	0.967
set4	0.967	0.967	0.967	0.967	1.000	0.933
set5	0.783	0.743	0.867	0.867	0.867	0.867
avg (F1 score)-Original : 0.927/PSR-weighted : 0.947						
data set	RF model 4 (depth=10)					
	Original Images			PSR-weighted Images		
	Acc	Precision	Recall	Acc	Precision	Recall
set1	0.967	0.938	1.000	0.967	0.967	0.967
set2	0.867	0.867	0.867	0.983	0.968	1.000
set3	0.967	0.967	0.967	0.950	0.935	0.967
set4	0.883	0.848	0.933	0.933	0.933	0.933
set5	0.817	0.852	0.767	0.800	0.765	0.867
avg (F1 score)-Original : 0.899/PSR-weighted : 0.929						

* Acc=Accuracy

영상의 학습 성능을 표시한 것이다. PSR Precision, PSR Recall은 추출한 PSR의 성능을 평가한 것이다. PSR Weighted F1은 추출된 PSR을 이용해 생성한 가중치 영상으로 학습했을 때의 F1 점수이며, Original F1은 원본 영상으로 학습했을 때의 F1점수이다. 전반적으로 원본 영상만을 이용하여 학습했을 때에 비해 F1점수가 향상된 것을 확인할 수 있으며, 평균 3% 성능이 향상된 것을 확인할 수 있다. PSR의 정밀도, 재현율 그리고 F1의 변화와 해당 PSR을 이용하여 PSR 가중치 영상으로 학습했을 때의 F1 점수와의 뚜렷한 상관관계가 보이지 않는데, 이는 PSR 평가 방법의 한계점으로 인한 것이다. 생성된 PSR을 보면 Fig. 8이나 Fig. 11과 같이 폴립의 중앙부분에 가까울수록 밝은 것을 볼 수 있다. PSR을 추출하는 매개변수에 따라 추출된 PSR이 바뀌는데, 매개변수를 엄격하게 할 경우 폴립의 가운데 부분만을 PSR로 추출하여 정밀도가 높아지고

Table 3. Analysis of Learning Performance for PSR-weighted Images as Performance of PSR

Test Case	PSR Precision	PSR Recall	PSR Weighted F1	Original F1
1	0.85	0.12	0.95	0.90
2	0.84	0.15	0.94	0.92
3	0.83	0.19	0.94	0.93
4	0.82	0.22	0.94	0.91
5	0.81	0.26	0.94	0.92
6	0.80	0.30	0.94	0.90
7	0.79	0.34	0.94	0.90
8	0.77	0.38	0.94	0.91
9	0.76	0.42	0.93	0.89
10	0.74	0.47	0.94	0.92
11	0.72	0.52	0.94	0.90
12	0.70	0.58	0.93	0.91
13	0.67	0.63	0.94	0.92
14	0.64	0.69	0.95	0.91
15	0.60	0.75	0.94	0.91
16	0.53	0.83	0.93	0.91
17	0.52	0.84	0.94	0.93

재현율이 낮아지게 된다. 반대의 경우에는 폴립 주변의 영역까지 PSR로 추출하게 되어 정밀도가 낮아지고 재현율이 높아지게 된다. 따라서 PSR의 정밀도, 재현율과 PSR 가중치 영상을 이용한 학습 결과의 연관성이 관찰되지 않는 것으로 보이며, PSR 행렬의 값과 폴립의 중심부분의 위치 등을 고려하여 평가하는 방법이 필요할 것으로 보인다. 또한 PSR의 재현율이 낮아져도 폴립의 중앙부분이 PSR로 추출되었기 때문에 PSR 가중치 영상을 이용하여 학습한 경우가 원본 영상만을 이용하여 학습했을 때보다 성능이 향상된 것으로 판단된다.


6. 결 론

본 연구에서는 멀티 스케일에서의 분석을 통한 폴립 의심 영역을 추출하고 추출된 영역을 통해 폴립 학습 강화용 영상을 생성하는 기법을 제안하였다. 또한, 이를 기반으로 생성된 PSR 가중치 영상은 수집한 데이터 452장 전체에 대해 실험을 진행하였다. 실험 결과, 원본 영상을 이용하였을 때 비해 F1점수가 평균 3% 향상되는 것을 확인하였다. 상승폭이 크지 않은 것은 Fig. 10의 예와 같이 폴립의 크기가 작고 광범위하게 분포한 경우 PSR이 정확하게 추출되지 못하였기 때문으로 판단된다. 추후 연구에서는 이러한 경우에서 PSR을 정확히 추출할 수 있도록 알고리즘의 개선이 필요하다. 또한, 추가적인 데이터 수집을 통해 더욱 강화될 수 있을 것으로 전망하고 있으며, 빅데이터 확보를 통해 향후에는 컨볼루션 신경망(딥러닝)에 적용할 계획이다.

References

[1] Yixuan Yuan, Baopu Li, and Max Q-H. Meng, "Improved Bag of Feature for Automatic Polyp Detection in Wireless Capsule Endoscopy Images," *IEEE Transactions on Automation*

Science and Engineering, Vol.13. No.2, pp.529-535, 2016.
 [2] Mohamed El Ansari and Said Charfi, "Computer-aided System for Polyp Detection in Wireless Capsule Endoscopy Images," *Wireless Networks and Mobile Communications (WINCOM), 2017 International Conference on. IEEE*, 2017.
 [3] Meryem Souaidi, Said Charfi, et al., "New Features for Wireless Capsule Endoscopy Polyp Detection," *Intelligent Systems and Computer Vision (ISCV), 2018 International Conference on. IEEE*, 2018.
 [4] Santi Seguí, Michal Drozdal, et al., "Generic Feature Learning for Wireless Capsule Endoscopy Analysis," *Computers in Biology and Medicine*, Vol.79, pp.163-172, 2016.
 [5] Yixuan Yuan and Max Q H. Meng, "Deep Learning for Polyp Recognition in Wireless Capsule Endoscopy Images," *Medical Physics.*, Vol.44. No.4, pp.1379-1389, 2017.



임 창 남

<http://orcid.org/0000-0002-4525-5176>

e-mail : chn0714@naver.com

2015년 아주대학교 전자공학과(학사)

2019년~현 재 아주대학교 전자공학과

석사과정

관심분야 : Medical Images, Machine Learning, Deep Learning, Big-Data Analysis, Embedded Software



박 예 슬

<https://orcid.org/0000-0003-2584-7489>

e-mail : yeseuly777@gmail.com

2015년 아주대학교 전자공학과(학사)

2017년 아주대학교 전자공학과(석사)

2017년~현 재 아주대학교 전자공학과

박사과정

관심분야 : Bio-medical Data Modeling, Data Analysis, Medical Images, Ontology, Machine Learning, Deep Learning, Industrial Robot, Embedded Software



이 정 원

<https://orcid.org/0000-0001-8922-063X>

e-mail : jungwony@ajou.ac.kr

1993년 이화여자대학교 전자계산학과(학사)

1995년 이화여자대학교 전자계산학과(석사)

1995년~1997년 LG종합기술원 주임연구원

2003년 이화여자대학교 컴퓨터학과(박사)

2003년~2006년 이화여자대학교 컴퓨터학과 BK교수,

전임강사(대우)

2006년~현 재 아주대학교 전자공학과 교수

관심분야 : Embedded Software, Automotive Software,

Bio-Medical Data Modeling