

내시경의 위암과 위궤양 영상을 이용한 합성곱 신경망 기반의 자동 분류 모델

박예랑¹ · 김영재² · 정준원^{3*} · 김광기^{1,2*}

¹가천대학교 융합의과학과, ²가천대학교 의용생체공학과, ³가천대 길병원 소화기내과

Convolution Neural Network Based Auto Classification Model Using Endoscopic Images of Gastric Cancer and Gastric Ulcer

Ye Rang Park¹, Young Jae Kim², Jun-Won Chung^{3*} and Kwang Gi Kim^{1,2*}

¹Department of Health Sciences and Technology, Gachon Advanced Institute for Health Sciences and Technology (GAIHST), Gachon University

²Department of Biomedical Engineering Gachon University

³Department of Gastroenterology, Gachon University Gil Hospital

(Manuscript received 18 December 2019 ; revised 16 March 2020 ; accepted 8 April 2020)

Abstract: Although benign gastric ulcers do not develop into gastric cancer, they are similar to early gastric cancer and difficult to distinguish. This may lead to misconsider early gastric cancer as gastric ulcer while diagnosing. Since gastric cancer does not have any special symptoms until discovered, it is important to detect gastric ulcers by early gastroscopy to prevent the gastric cancer. Therefore, we developed a Convolution Neural Network (CNN) model that can be helpful for endoscopy. 3,015 images of gastroscopy of patients undergoing endoscopy at Gachon University Gil Hospital were used in this study. Using ResNet-50, three models were developed to classify normal and gastric ulcers, normal and gastric cancer, and gastric ulcer and gastric cancer. We applied the data augmentation technique to increase the number of training data and examined the effect on accuracy by varying the multiples. The accuracy of each model with the highest performance are as follows. The accuracy of normal and gastric ulcer classification model was 95.11% when the data were increased 15 times, the accuracy of normal and gastric cancer classification model was 98.28% when 15 times increased likewise, and 5 times increased data in gastric ulcer and gastric cancer classification model yielded 87.89%. We will collect additional specific shape of gastric ulcer and cancer data and will apply various image processing techniques for visual enhancement. Models that classify normal and lesion, which showed relatively high accuracy, will be re-learned through optimal parameter search.

Key words: Gastroscopy, Classification, ResNet-50, Gastric ulcer, Gastric cancer

101

Corresponding Author : Kwang Gi Kim
Department of Biomedical Engineering, Gachon University
College of Medicine, 21, Namdong-daero 774 beon-gil, Namdong-gu, Incheon, 21565, Republic of Korea
Tel: +82-32-820-4036

E-mail: kimkg@gachon.ac.kr

Corresponding Author : Jun-Won Chung
Department of Biomedical Division of Gastroenterology, Department of Internal Medicine, Gil Medical Center, 21, Namdong-daero 774 beon-gil, Namdong-gu, Incheon, 21565, Republic of Korea
Tel: +82-460-8203

E-mail: drgreen@gilhospital.com

본 논문은 과학기술정보통신부와 정보통신산업진흥원의 2019년도 민간지능정보서비스확산사업(Grant number: A0602-19-1032)과 2018년도 가천대 길병원 연구비 지원에 의하여 이루어진 것임(Grant number: 2018-5283).

I. 서 론

위궤양은 위 내벽이 부분적으로 허는 질환을 말한다. 위궤양은 양성 위궤양과 악성 위궤양으로 나뉘는데, 악성 위궤양은 조기위암 또는 진행위암으로 분류되는 위암의 종류 중 하나이다[1].

양성 위궤양은 위암으로 발전하지는 않지만 조기 위암과 외관상 흡사하여 구분이 어렵기 때문에 판독 시 조기 위암을 양성 위궤양이라 판단할 가능성이 있다. 이러한 판독 오류는 적절한 치료 시기를 놓칠 수도 있다는 점에서 우려가 제기된다. 위궤양과 위암의 분류 뿐 아니라, 평탄하거나 미세한

부위의 조기위암은 정상 부위와도 구별하기 쉽지 않을 때가 많다. 마찬가지로 이는 육안으로 확인이 어려워 조기 발견 가능성이 현저히 떨어지기 때문에 진행 위암으로 발전될 가능성이 크다[2].

위암은 발견 전까지는 특별한 증상이 없기에 주기적인 위 내시경 검사를 받는 것이 권고된다. 이를 통해 병변을 조기 발견해 위암으로 진행되는 것을 막는 것이 매우 중요하다[3]. 위내시경은 위암을 조기에 발견할 수 있는 현재까지 알려진 가장 좋은 방법이다. 하지만 내시경의사에 따라 숙련도가 다르고 검사 당시의 피로도에 따라 같은 의사라도 결과에 차이가 발생할 위험성이 존재한다. 실제로 의료과오에서 법적인 문제로 소화기 의사가 제소된 경우를 분석한 미국의 보고에 의하면 44%는 내시경 관련 문제인 것으로 드러났다[4]. 내시경검사의 이러한 의료과오 및 오진을 줄이기 위해서는 사소한 병변이어도 조직생검을 시행하여 조직학적 진단을 해두는 게 좋다. 하지만 한 명의 의사가 하루에 내원하는 모든 환자의 내시경 검사부터 판독 및 조직 생검을 실시하기란 쉬운 일이 아니다.

만약 조직 검사 전까지의 과정인 내시경 검사와 판독을 자동화하여 시간을 줄일 수 있다면 의사의 피로도를 감소시켜 오진을 줄이고 환자의 검진 만족도는 증가시킬 수 있을 것이다. 이러한 과정을 효율적으로 할 수 있게 해주는 컴퓨터 보조 진단(Computer Aided Diagnosis, CAD) 시스템 중의 하나로, 딥러닝(Deep Learning)이 해당 분야에서 활발히 연구되는 중이다.

내시경 분야의 딥러닝 활용 기법의 예시로, 일본의 암 연구재단에서는 위암 검출을 위해 Single Shot MultiBox Detector(SSD) 아키텍처를 기반으로 한 합성곱 신경망 모델을 이용하였고 13,584개의 이미지를 학습시켜 47초만에 2,296개의 이미지를 92.2% 민감도(sensitivity)로 검출한 바 있다[5]. 중국의 Zhejiang 대학교에서는 GPDNet을 이용하여 용종과 미란 및 위궤양을 분류하는 연구를 진행했고, 반복적 강화 학습(iterative reinforced learning)이라는 방식을 채택하여 88.90%의 분류 정확도를 보였다[6]. 한편 독일 베를린의 대학 연구팀에서는 위내시경 병리 이미지를 딥러닝 분류에 사용하였다. 염색된 세포 이미지에서 AlexNet으로 위암을 분류하여 정확도 69.9%를 얻었다[7].

현재까지 내시경의 위암 영상을 분류한 연구는 진행되지 않았으며 임상에서의 보다 높은 활용도를 위해서는 해당 이미지의 분류 연구의 필요성이 있었다.

상부 위장관 암 환자 3,787명을 대상으로 한 내시경에서의 암을 놓치는 비율에 관한 연구에서 전체 암의 11.3%가 진단에서 누락되었다고 발표했고 이에 진단 정확도는 88.7%로 추정되는데[8], Zhejiang 대학교 연구의 88.9%라는 정확도는 내시경의사의 진단능과 비등한 수치라는 것을 알 수 있다. 이에

본 연구에서는 사람의 판단보다 정확도가 높은 진단 보조 도구를 구현하여 내시경 전문의의 판독 실수를 줄이고자 하였다. 또한 앞선 병리 이미지의 위암 분류 연구에서 조직 검사 과정의 세포 이미지를 직접 분류한 것과 달리, 본 연구에서의 위내시경 이미지 분류에서는 조직검사 대상이 되는 부위를 빠르게 선별하는 데 도움이 되고자 하였다.

이에 따라 본 논문에서는 합성곱 신경망 기반의 위 내시경 영상에서의 정상과 위궤양, 정상과 위암, 위궤양과 위암을 각각 따로 분류하여 보다 높은 분류 성능을 내고자 한다. 위암 검진에서 위암 또는 위암 의심 병변 발견율이 0.44%라는 것을 고려하면[9], 병변들끼리만 분류하는 것보다 정상 이미지를 포함하여 함께 분류하여 임상에서 보다 유용하게 사용될 수 있을 것이라 판단하였다. 또한 의료 데이터 특성상 많은 데이터를 수집하기 어려워 제한된 데이터로 학습해야 하기 때문에 데이터 증강(augmentation) 기법을 적용하여 데이터 개수가 증가했을 때의 정확도가 기존 데이터 개수일 때보다 높은지 비교하였다. 그 증강 배수로는 각각 5배, 15배를 지정해주었다.

정상과 위암 및 위궤양을 자동으로 분류하고, 분류된 이미지가 실제로 정답에 얼마나 가까운지 검증하였으며, 해당 분류기가 어디에 가중치를 두고 분류하였는지 직접 확인하기 위해 분류 활성화 지도(Class Activation Map, CAM) 이미지로 나타내었다.

II. 연구 방법

1. 데이터 수집

가천대 길병원에서 내시경 검사를 받은 환자들의 위내시경 이미지 3,015장을 수집하였다. 본 논문에서 사용되는 데이터는 가천대 길병원의 임상시험심사위원회(IRB)의 허가를 획득하였다(2018-052). 수집한 이미지 데이터는 정상 1,076장, 위궤양 970장, 위암 969장으로 구성되었다. 훈련과 테스트에는 8:2 비율로 데이터가 사용되어 정상의 훈련셋과 테스트셋이 860장과 216장, 위궤양의 훈련셋과 테스트셋이 776장과 194장, 위암의 훈련셋과 테스트셋을 776장과 193장으로 구성하였다. 수집된 정상과 위궤양 및 위암의 내시경 이미지는 다음 그림 1과 같다.

2. 이미지 전처리

딥러닝 학습에는 일반적으로 높이와 너비가 동일한 영상이 입력으로 사용된다. 이에 반해 내시경 이미지는 일반적으로 직사각형 형태로 얻어지기 때문에 크기를 조정 해주는 작업이 요구된다. 이미지의 높이나 너비를 줄일 경우 원본 형태의 변형이 일어나기에 위와 아래의 여백에 검은색으로 채워 정사각형으로 만들어주는 영상처리 작업을 수행하였다.




그림 1. 정상과 위궤양, 위암 병변 이미지의 예, (A) 정상, (B) 위궤양, (C) 위암

Fig. 1. The Examples of normal, gastric ulcer and gastric cancer (A) normal (B) gastric ulcer (C) gastric cancer

데이터 증강(Augmentation)은 제한된 데이터로 충분히 학습시켜야 할 경우에 데이터를 늘리기 위한 방법의 하나이다[10]. 데이터 증강 기법을 사용하여 시계 및 반시계 방향으로 1~5° 이내 범위로 회전시키고, 너비와 높이 및 이미지 전체를 각각 1~5% 확대 및 축소시켰으며, 각 이미지의 상하좌우 가장자리 부위 1~5%를 자르는 과정을 모두 랜덤하게 적용시켜 이미지 수를 증가시켰다.

위와 같은 방법으로 테스트셋을 제외하고 훈련 셋만 증강을 적용했다. 정상과 위궤양 및 위암에서 5배 증강시킨 훈련셋의 개수는 각각 4,300장, 3,880장, 3,880장이며 15배 증강시킨 훈련셋 개수는 각각 12,900장, 11,640장, 11,640장이다(표 1).

3. 이미지 분류 모델

위내시경 이미지에서 정상과 위궤양, 정상과 위암, 위암과 위궤양 총 세 가지 경우로 나누어 분류 결과를 확인하고 각각의 경우에서 데이터 증강이 정확도에 영향을 미치는 지 5배와 15배 증강 시킨 데이터에서 결과를 살펴보았다.

이미지 분류 대회에서 최저의 에러율로 수상하고 이후로도 간결한 구조와 편리한 사용성으로 많이 사용되는 Keras 모듈의 ResNet-50을 적용하였다[11,12](그림 2). 그림 3의 (B)와 같이 기존의 CNN이 학습 레이어를 거쳐 입력 x 를




그림 3. 기존의 CNN 학습 방식 (A)과 ResNet 학습 방식 (B)

Fig. 3. The learning method of existing CNN (A) and of ResNet (B)

표 1. 원본 데이터 개수 및 5배와 15배 증강시킨 데이터 개수

Table 1. Initial dataset and 5 times and 15 times augmented dataset

	data			5 times augmentation			15 times augmentation		
	Normal	Gastric ulcer	Gastric cancer	Normal	Gastric ulcer	Gastric cancer	Normal	Gastric ulcer	Gastric cancer
Training set (validation set)	860 (172)	776 (154)	776 (154)	4,300 (860)	3,880 (776)	3,880 (776)	12,900 (25800)	11,640 (2328)	11,640 (2328)
Test set	216	194	193	216	194	193	216	194	193
Total	1,076	970	969	4,516	4,074	4,073	13,116	11,834	11,833



그림 2. CNN 모델 아키텍처의 하나인 ResNet-50

Fig. 2. ResNet-50 one of the Convolution Neural Network architecture

최적의 타겟값 y 를 찾는 방법이라면, ResNet의 핵심이 되는 잔차 블록(Residual block)은 학습 레이어 이후에 입력 x 를 더함으로써 최적의 $F(x)+x$ 를 찾아 다음 레이어의 입력으로 사용하는 방법이다. ResNet-50은 컨볼루션층(Convolution layer)과 전결합층(Fully connected layer)의 개수의 합이 50개가 되는 모델을 말한다.

CNN을 구축하는 대부분의 경우에는 처음부터 학습하지 않는 대신에 기존에 학습된 가중치를 초기값으로 전이하여 사용한다. 본 연구에서는 실생활 이미지 125만장과 1,000개의 클래스로 구성되어 영상 인식 분야에서 가장 유용하게 사용되는 이미지넷(ImageNet)을 데이터 베이스로 사용하였고, 이 가중치를 전이 학습(transfer learning)에 적용하였다[13].

학습을 진행하는 데 사용된 파라미터는 컴퓨팅 파워에 맞추어 배치 사이즈(batch size) 40, 에폭(epoch) 300으로 설정해주었고, 전이학습 가중치의 큰 변화를 막기 위해 학습율(learning rate)을 0.0001로 설정하였다. 학습에 사용되는 이미지는 256×256으로 크기를 조정해주었다.

III. 연구 결과

본 논문에서는 딥러닝의 한 종류인 합성곱 신경망(Convolution Neural Network)을 기반으로 위 내시경 영상에서 정상과 위궤양, 정상과 위암, 위궤양과 위암을 각각 분류하는 모델을 만들었다. 더불어 데이터 증강 여부와 증강된 배수에 따라 정확도에 미치는 영향을 확인하였다.

검증 방법으로는 5차 교차검증(5-fold Cross Validation)을 실시하였다. 5차 교차검증은 데이터 전체를 5등분하여 각 등분이 한 번씩 테스트 셋(test set)이 되고 나머지 네 개 등분은 훈련 셋(train set)이 되어 한 번씩 테스트 하고 이를 총 5번 순차적으로 진행하는 검증 방식이다. 이 방식은 단순히 훈련셋과 테스트셋을 나눌 때와 비교하여 각기 다른 테스트 데이터로 5번 테스트하기 때문에, 특정 테스트 셋에 훈련 모델이 과도하게 잘 맞거나 현저히 맞지 않는 문제를 방지하여 결과값에 신뢰도를 향상시킨다.

데이터 증강을 하지 않은 데이터로 학습 시켜 정상과 위궤양, 정상과 위암, 위궤양과 위암 각 세 가지 경우에서의 정확도와 ROC curve를 그림 4에 나타내었다. 각 모델에서




그림 4. 각 딥러닝 모델에서의 각 검증 결과 중 최고 점수를 나타낸 ROC (Receiver Operating Characteristic) 커브 및 AUC (Area Under Curve) 값

Fig. 4. The ROC curves and AUC values of highest performed cases among each deep learning model's result

가장 높은 AUC 값은 정상과 위궤양을 분류하는 모델에서 0.99, 정상과 위암 분류 모델에서 0.99, 위궤양과 위암 분류에서 0.95였다.

정상과 위궤양 분류의 경우 데이터 증강 미적용, 5배 증강, 15배 증강 각 세 가지 조건에서 93.52%, 94.87%, 95.11%의 정확도를 보였다. 정상과 위암 분류 시 데이터 증강 미적용, 5배 증강, 15배 증강에서 각각 96.65%, 97.79%, 98.28%의 정확도를 나타냈으며, 위궤양과 위암 분류 시 데이터 증강 미적용, 5배 증강, 15배 증강에서 각각 86.45%, 89.3%, 87.89%의 정확도를 보여주었다(표 2).

딥러닝 모델이 이미지의 어느 부위에 가중치를 두고 분류하는지 알기 위해 분류 활성화 지도(Class Activation Map, CAM) 이미지를 사용하여 확인하였다(그림 5).

IV. 고찰 및 결론

본 논문에서는 위와 같은 보조 진단 시스템에서 최근 가장 많이 활용되고 있는 합성곱 신경망 기반의 딥러닝 모델을 사용해 위 내시경 검사 및 진단에 도움을 주고자 하였다. 이를 위해 정상과 위궤양, 정상과 위암, 위궤양과 위암을 분류하는

표 2. 데이터 증강 배수에 따른 정확도(%) 및 AUC

Table 2. Accuracy and AUC values according to augmented multiples

	Data	5 times augmentation	15 times augmentation	AUC
Normal vs Ulcer	93.52%	94.87%	95.11%	0.99
Normal vs Cancer	96.65%	97.79%	98.28%	0.99
Ulcer vs Cancer	86.45%	89.30%	87.89%	0.95

모델을 본 연구에서 제시하였다.

그 결과 정상과 위궤양 분류의 경우 최고 95.11%, 정상과 위암 분류의 경우 최고 98.28%로 높은 정확도를 보였다. 반면 위궤양과 위암 분류 모델의 경우 89.30%의 상대적으로 낮은 정확도를 나타냈다.

데이터 증강 배수에 따라서는 정상과 병변 부위를 분류하는 경우 배수가 높아질수록 정확도가 증가하는 추이를 보이지만, 위궤양과 위암을 분류하는 경우 5배만 증가시킨 조건이 15배를 증가시킨 조건보다 더 높은 정확도를 보여주고 있다. 이는, 정상과 병변은 그 차이가 뚜렷하지만 위궤양과 위암은 외관상 그 형태가 비슷한 이미지들이 많기 때문에 증강 배수가 어느 정도 이상이면 오히려 분류 성능이 떨어지는 것으로 추측된다.

앞서 중국의 연구팀이 총 1,331장의 데이터로 용종과 미란, 위궤양을 88.9% 정확도로 분류한 사례가 있다. 데이터 측면에서 본 연구는 중국 연구팀의 약 3배인 3,015장을 사용하여 상대적으로 충분히 학습되었다고 판단되고, 방법론적 측면에서는 3개의 클래스를 한 번에 분류한 것이 아닌 2개씩 분류하여 결과를 도출했기 때문에 위 연구보다 최대 10% 더 높은 결과를 얻을 수 있었던 것으로 생각된다.

그림 5를 통해 정분류된 이미지에서 학습된 딥러닝 모델이 병변 부위에 가중치를 주어 활성화됨을 알 수 있었다. 가중치가 클수록 빨간색으로 나타나게 되는데, 위궤양과 위암의 이미지에서 실제 병변이 있는 부위가 빨간색으로 표시됨을 확인하였고, 정상 이미지의 경우 가중치를 크게 주는 부분

이 없어 빨간색이 적게 나타났기 때문에 역치(threshold) 이하의 값으로 분류되어 정상이라고 옳게 판단하였다.

위궤양과 위암을 분류하는 모델은 상대적으로 정확도가 낮았는데 잘못 분류한 이미지들을 분류 활성화 지도(Class Activation Map, CAM)로 확인해본 결과 대부분의 영상들이 육안으로도 위궤양과 위암을 구분하기가 어려웠다(그림 6). 실제로 조기 위암 형태 중 용기형을 제외한 표면형과 함몰형 위암은 위내시경 이미지 상에서 위궤양과 거의 흡사한 모습을 보인다[2]. 이를 보완하기 위해 위궤양과 외관상 유사한 표면형 및 함몰형 위암 데이터를 증점적으로 수집한다면 추가 학습에 사용하여 위궤양과 위암의 분류 성능을 더 높일 수 있을 것이라 예상된다.

뿐만 아니라 노이즈 제거 기법으로 이미지 학습에 불필요한 잡음을 제거하고, 선명화(Sharpening) 기법으로 병변의 엣지(Edge) 부위를 선명하게 하거나, 히스토그램 평활화(Histogram Equalization) 기법으로 색 대비를 뚜렷하게 하여 학습한다면 더 높은 정확도를 얻을 수 있을 것이라 예상된다.

정상과 병변을 분류하는 모델은 정확도를 향상하기 위한 최적화 단계를 진행할 예정이다. 최적화 방법 중 하나로 하 이퍼 파라미터 탐색 방법이 있다. 모델의 성능을 최대로 끌어올리기 위한 방법으로, 최적의 파라미터 값을 찾는 것인데 그 리드 서치(Grid Search) 또는 랜덤 서치(Random Search) 등이 이에 해당된다.

이와 같이 데이터의 추가적인 수집, 다양한 영상 처리 기




그림 5. 테스트 셋(test set) 이미지와 분류 활성화 지도(Class Activation Map, CAM), (A)(B)(C) 테스트셋 이미지 (D)(E)(F) 각 테스트 셋에 대응하는 CAM이미지

Fig. 5. Test set images and CAM, (A)(B)(C) Test set images (D)(E)(F)CAM images corresponding to each test set




그림 6. 위궤양과 위암의 오분류된 이미지와 CAM 예시, (A)(B) 위궤양을 위암으로 인식한 이미지와 CAM, (C)(D) 위암을 위궤양으로 인식한 이미지와 CAM

Fig. 6. CAM image examples of misclassified gastric ulcer and gastric cancer (A)(B) Image and CAM recognized gastric ulcer as gastric cancer (C)(D) Image and CAM recognized gastric cancer as gastric ulcer

법 적용, 최적 파라미터 탐색 과정 단계를 거쳐 향상된 정확도의 모델을 본 연구에 반영한다면 내시경 의사들이 더욱 정확하고 빠르게 검진하는 데 도움을 줄 것이다.

나아가 실제 임상에서 이를 적용한 실시간 분류 시스템을 구축하기 위해서는, 초당 약 60프레임(Frame)의 대량 데이터인 내시경 영상을 받아와 처리할 수 있도록 빠른 연산을 위한 모델 경량화 연구가 필요하다. 합성곱 신경망의 가장 큰 계산량을 요구하는 합성곱 필터를 변경하여 연산을 효율적으로 줄이거나, 파라미터의 불필요한 표현력을 줄이는 가중치 가지치기와 같은 방법을 이용하여 알고리즘을 경량화한다면 내시경 검진 시에도 실시간으로 영상 분류가 가능할 것이다.

앞서 언급된 다양한 기법을 적용하여 모델 성능을 향상시킨 후 위와 같은 방법으로 경량화하여 실시간 검진에 적용한다면 현 내시경 검진 시스템의 인적, 물적 자원을 줄이고 의료의 질을 크게 향상시킬 것이라 기대되는 바이다.

References

- [1] Yoon SJ. Screening between benign and malignant gastric ulcers. *Korean Journal of Gastrointestinal Endoscopy*. 2007; 35:29-33.
- [2] Sim KN. Endoscopic findings of early gastric cancer. *Korean Journal of Gastrointestinal Endoscopy*. 2007;34:254-7.
- [3] Park HA, Nam SY, Lee SK, Kim SK, Sim KN, Park SM, Lee SY, Han HS, Sin YM, Kim KM, Lee KJ, Lee TY, Choi IJ, Hong SS, Kim JW, Lee YJ, Kim SY, Kim Y, Lee WC, Jeong IK. The Korean guideline for gastric cancer screening. *J Korean Med Assoc*. 2015;58(5):373-84.
- [4] Ryu JS. Cases of misdiagnosis and countermeasures. *Korean Journal of Gastrointestinal Endoscopy*. 2008;37:24-6.
- [5] Hirasawa T, Aoyama K, Tanimoto T, Ishihara S, Shichijo S. Application of artificial intelligence using a convolutional neural network for detecting gastric cancer in endoscopic images. *Gastric Cancer*. 2018;21(4):653-60.
- [6] Zhang X, Hu W, Chen F, Liu J, Yang Y, Wang L, Duan H, Si J. Gastric precancerous diseases classification using CNN with a concise model. *PLoS One*. 2017;12(9):1-10.
- [7] Sharma H, Zerbe N, Klempert I, Hellwich O, Hufnagl P. Computerized Medical Imaging and Graphics Deep convolutional neural networks for automatic classification of gastric carcinoma using whole slide images in digital histopathology. *Comput. Med. Imaging Graph*. 2017;61:2-13.
- [8] Menon S, Trudgill N. How commonly is upper gastrointestinal cancer missed at endoscopy? A meta-analysis. *Endoscopy*. 2014;2(2):46-50.
- [9] Kim N. Screening and Diagnosis of Early Gastric Cancer. *J Korean Med Assoc*. 2010;53(4):290-8.
- [10] Wang J, Perez L. The Effectiveness of Data Augmentation in Image Classification using Deep Learning. *arXiv preprint arXiv 2017;1712.04621*.
- [11] Wen L. A transfer convolutional neural network for fault diagnosis based on ResNet-50. *Neural Comput. Appl*. 2019; 0123456789.
- [12] <https://bskyvision.com/644>. Accessed on 12 Dec 2019.
- [13] Huh M, Agrawal P, Efros AA. What makes ImageNet good for transfer learning?. *arXiv preprint arXiv*. 2016;1712.04621.