

딥러닝 기반 위내시경 데이터 해부학적 위치 분류 모델 개발 연구

강성민^{*}, 김영재^{**}, 김윤재^{***}, 김광기^{****}

A Study on the Development of Anatomical Position Classification Model of Gastroscopy Data on Deep Learning

Seong Min Kang[†], Young Jae Kim^{**}, Yoon Jae Kim^{***}, Kwang Gi Kim^{****}

ABSTRACT

Gastric cancer is one of the main causes of cancer and death in Korea. Gastroscopy (EGD) is known as an effective gastric cancer screening technique. However, the quality of medical services is deteriorating as the doctor's workload increases due to non-detection of lesions caused by blind spots and dependence on treatment. Therefore, we conduct research on the development of a deep learning-based gastroscopy data anatomical position classification model for medical staff support. In this study, data were collected from about 604 patients who underwent gastroscopy through Gachon University Gil Hospital. Labeling of the data was classified based on anatomical location. This study is based on 6 categories consisting of a gastric cardia, gastric upper body, gastric middle body, gastric lower body, gastric angle, and gastric antrum and 4 categories that integrated the upper, middle and lower parts of the gastric body. We developed gastroscopy anatomical classification models using InceptionV3, and Inception-ResNetV2. In the case of 6 category classification, the InceptionV3 model was the highest F1-score with 62.07% F1-score. For 4 category classification, the Inception-ResNetV2 model was the highest F1-score of 91.58%.

Key words: Artificial Intelligence, Gastroscopy, Convolutional Neural Network

1. 서 론

위암은 1980년대 이후로 대한민국 암 발병률 및 사망률의 주된 요인 중 하나이다[1]. 위암 검진방식 중, 위내시경 검사(Esophagogastroduodenoscopy,

EGD)는 조기 위암의 검출률을 향상시키고 사망률을 감소시키는 효과적인 검사방법으로 알려져 있다[2]. 하지만 2014년부터 2016년까지 대한민국에서 집계된 통계를 살펴보면, 보고된 위암 오진 피해 사례 중 33.6%가 병변을 검출하지 못하고 놓치는 인적 과실

* Corresponding Author : Kwang Gi Kim , Address: Biomedical Engineering, School of medicine, Gil medical Center, Gachon Univ. , TEL : +82-32-458-2770, E-mail : kimkg@gachon.ac.kr

※ Corresponding Author : Yoon Jae Kim, Address: Department of Gastroenterology, Gachon University Gil Medical Center, Incheon, TEL : +82-32-460-3778, E-mail : yoonjaemed@gmail.com

Receipt date : Nov. 2, 2022, Revision date : Dec. 29, 2022
 Approval date : Jan. 16, 2023

[†] Medical Device R&D Center, Gachon University
 (E-mail : sm961121@gmail.com)

^{**} Dept of Biomedical Engineering, Gil Medical Center, Gachon University (E-mail : youngjae@gachon.ac.kr)

^{***} Department of gastroenterology, Gachon University Gil Hospital

^{****} Dept of Biomedical Engineering, Gil Medical Center, Gachon University

※ This work was supported by National IT Industry Promotion Agency(NIPA) grant funded by the Korea government(MSIT) (No.S0252-21-1001) and by the GRR program of Gyeonggi province. [GRR-Gachon2020(B01), AI-based Medical Image Analysis.

(Human error)에 의해 발생한 사례였다[3]. 인적 과실에 의한 간과율 증가의 원인은 위내시경 검사 시 발생하는 사각지대에 있으며, 이는 상부위장관 내 모든 구역을 세밀하게 관찰하지 못하여 발생하는 문제이다.

2013년 일본의 후쿠오카 지쿠시노시 대학병원의 발표에 따르면, 위내시경 검사 중 발생하는 사각지대의 문제점을 파악하고 사각지대의 발생 가능성을 낮추기 위한 위장 검사 프로토콜인 SSS(Systematic screening protocol for the stomach)를 제시한다. 이는 상부위장관 중 위장의 내시경 이미지의 22개의 위치 기준점을 정하여 모든 구역을 자세하게 촬영할 수 있도록 검수자를 돕는다[4]. 또한 2018년 대한민국의 국립암센터에서 발행된 위암 검진 지침에 따르면, 위내시경 검진 시 촬영되지 못하고 누락되는 구역을 사전에 방지하기 위해 상부 식도를 시작으로 위장 전 구역 및 십이지장 촬영을 유도하기 위한 내시경 표준 8부위 가이드라인을 제시한다[5]. 하지만 해당 가이드라인의 임상 적용에 대한 한계점은 올바르게 적용되었는지에 대한 판단이 작업자 개인에게 맡겨진다는 점이다. 따라서 인적 과실로 인해 상부위장관 내 촬영이 진행되지 않은 사각지대가 발생할 시, 작업자는 문제를 인지하지 못할 가능성이 높다. 또한 현대사회의 의학에 대한 의존도 상승에 따라, 의사에게 가중되는 업무량 역시 증가하였고, 이는 인적 과실의 발생 가능성을 증가시킨다[6]. 뿐만 아니라 기술과 경험이 미흡한 비 숙련자 집단에게 인적 과실은 더욱 취약하게 작용할 가능성이 높다[7]. 따라서 해당 문제점에 대한 해결 방법으로서, 위내시경 촬영 가이드라인 제공을 위한 컴퓨터 보조 진단(Computer aided diagnosis, CAD) 시스템이 요구된다.

딥러닝은 학습된 연산과정 내에서 일정한 결과값을 도출하며, 전문가의 판단이 요구되는 다양한 업무에 대해 신속하고 정확한 처리가 가능하다. 의료분야 역시 딥러닝의 도입을 통해 한정적인 의료자원의 효율적인 분배와 비용 절감 효과를 가져왔다[8-10]. 이중 합성곱 신경망(Convolution neural network, CNN)은 이미지 분석에 있어 높은 정확도를 보이고 있다. 하지만 기존의 연구들은 위내시경 이미지의 정상, 위암, 위궤양 등의 소견을 추론하기 위한 연구를 진행하거나 위암과 관련된 징후들의 신속하고 신뢰도 높은 검출이 주된 연구의 방향이었다[9-10]. 합성곱 신경

망은 이미지가 포함하고 있는 특징(Feature)과 패턴(Pattern)을 추출하여 학습시키기에 적합하며, 상부 위장관의 각 부위는 해부학적 위치를 기반으로 분류될 시, 합성곱 신경망을 기반으로 학습을 진행하기에 적합한 시각적 특징들을 가지고 있다. 그러나 현재까지 위내시경 촬영 가이드라인을 기반한 자동 위치 추론 연구는 미흡한 상태이다. 따라서 본 논문은 딥러닝 기반의 위내시경 해부학적 분류 모델을 제시한다. 위장의 구간별로 상이한 시각적인 특징을 분석한 모델은 입력된 위내시경 이미지의 해부학적 위치를 추론한다. 이를 통해 위 내시경 작업자가 위내시경 촬영 가이드라인 상 모든 구역을 빠짐없이 촬영했는지에 대한 평가를 진행할 수 있다. 본 연구의 모델은 InceptionV3, InceptionResNetV2 모델이 활용되었으며, 위장을 6개 해부학적 구간으로 분류한 데이터셋의 경우, InceptionV3 모델이 62.07%의 F1-score의 결과를 도출했다. 해부학적 구간을 4개로 구분한 데이터셋의 경우, Inception-ResNetV2 모델이 91.58%로 보다 우수한 결과를 도출했다.

2. 연구 방법

2.1 데이터

본 연구에서는 가천대학교 길병원에서 위내시경 검사를 실시한 604명 환자의 위내시경 데이터 이미지 4,039장을 수집하였다. 본 데이터는 2009년부터 2020년까지 수집되었으며, 20대에서 80대의 다양한 연령대의 남녀로 구성되어 Table 1을 통해 나타낸다. 수집된 데이터 중, 상부위장관의 상피 하 종양 혹은 용종의 식별을 위해 확대 촬영한 이미지와 해부학적

Table 1. Sex and age details of the collected gastric cancer patient data set.

	Number of patients (%)
Sex	
Male	423(70.0)
Female	181(30.0)
Age	
Teenager (13~18 years old)	0(0.0)
Youth (19~29 years old)	3(0.4)
Middle-age (30~49 years old)	41(6.8)
Prime-age (50~64 years old)	210(34.8)
Old-age (Over 65 years old)	350(58.0)




Fig. 1. Endoscopic anatomy classification images of 6 categorical(A~F) and 4 categorical(a~j). (a) Gastric cardia, (b) Gastric upper body, (c) Gastric middle body, (d) Gastric lower body, (e) Gastric angle, (f) Gastric antrum, (g) Gastric cardia, (h) Gastric body, (i) Gastric angle, and (j) Gastric antrum.

으로 위치 판단이 모호한 구역의 이미지 2,360장은 학습에서 제외되었다. 데이터의 레이블링 작업은 학습 이미지가 해부학적으로 위치하는 구역을 기반 하여 진행되었다. 데이터 셋은 들문(Gastric cardia), 위 체부 상부(Gastric upper body), 위 체부 중부(Gastric middle body), 위 체부 하부(Gastric lower body), 위 각부(Gastric angle), 전 정부(Gastric antrum)의 6개 구역으로 범주화한 데이터 셋 A와 위 체부의 상부, 중부, 하부를 통합해 4개 구역으로 이뤄진 데이터 셋 B로 구성되어 Fig. 1을 통해 나타낸다. 데이터 셋 A는 훈련 데이터(Training data set) 1,347장 시험 데이터(Test data) 166장 확인 데이터(Validation data) 166장으로 구성되었고, 데이터 셋 B는 훈련 데이터 810장 시험 데이터 99장 확인 데이터 99장으로 구성되었다.

2.2 데이터 전처리

학습에 사용된 이미지는 224×224 픽셀의 크기로 조정되었다. 데이터 간의 불균형이 존재하여 상대적으로 수가 적은 데이터에 대해 Imgaug 라이브러리를 활용하여 데이터 증강(Augmentation)을 진행하여 Fig. 2를 통해 나타낸다. 데이터 증강 기법으로 이미지 좌우, 상하 반전, 360° 내 무작위 회전, Blur처리, 색 반전, 이미지 내 임의의 구역을 채우거나 삭제시키는 기법 등이 모두 무작위로 적용되었다. 데이터 셋 A의 들문과 위 체부 상부 데이터에 대해 2배의 배율을 적용하였고, 데이터 셋 B의 들문에 2배, 위 체부에 1배의 배율을 적용하였다. 데이터 셋 A의 경우 1,347장에서 1,731장으로 증강되었으며, 데이터 셋 B의 경우 810장에서 1,119장으로 증강되었으며, 증강




Fig. 2. (a) Original images and (b) Augmented images.

Table 2. Number of training data in A, B dataset before and after data augmentation.

	Before augmentation(%)	After augmentation(%)
Dataset A		
Cardia	70(5.2)	210(12.1)
Upper body	122(9.1)	366(21.1)
Middle body	205(15.2)	205(11.9)
Lower body	379(28.1)	379(21.9)
Angle	219(16.3)	219(12.7)
Antrum	352(26.1)	352(20.3)
Total	1,347(100.0)	1,731(100.0)
Dataset B		
Cardia	70(8.6)	210(18.8)
Body	169(20.9)	338(30.2)
Angle	219(27.0)	219(19.6)
Antrum	352(43.5)	352(31.5)
Total	810(100.0)	1,119(100.0)

전후 데이터 차이를 Table 2를 통해 나타낸다.

2.3 Fine tuning

본 연구에서는 InceptionV3, Inception-ResNetV2 모델을 활용하여 Fine tuning을 진행하였다. Incep-

tionV3는 신경망의 정확도와 연산 효율을 끌어올리기 위해 모델의 사이즈와 연산 비용(Computation cost)에 집중하는 것이 아닌, 효율적으로 연산량을 최소화하기 위한 기법이 차용된 모델이다. Inception-ResNetV2 모델의 아키텍처는 Inception, ResNet 계열의 장점을 결합하기 위한 연구로 제시되었다. Ensemble의 활용으로 리소스를 줄이고, Residual block, Bottleneck, 비대칭 합성곱 등의 활용을 통해 학습 속도의 향상을 제시하는 모델이다[11-12]. Inception 및 ResNet 계열에서 제시된 메커니즘은 연산량 증가에 따라 발생하는 학습 문제들을 일부 해소하였고, InceptionV3, Inception-ResNetV3 모델들은 모두 접근성과 성능을 모두 갖춘 우수한 모델로 본 연구에 차용되었다.

사용된 모델들은 Imagenet의 데이터로 사전 학습이 진행되었다. 따라서 사전학습이 진행된 모델의 경우 학습이 전혀 이뤄지지 않은 모델에 비해 연산을 위한 매개변수를 도출하기 용이하다. 해당 아키텍처는 Fig. 3을 통해 도식화한다.

2.4 학습 환경

본 연구는 Python 기반의 Tensorflow 2.2.0 라이




Fig. 3. Model architecture of (a) InceptionV3 and (b) Inception-ResNetV2.

브러리를 사용하여 구현되었으며, Ubuntu 18.04.6 LTS, Intel(R) Xeon(R) CPU E5-1650 v4 @ 3.60 GHz, Titan xp GPU를 사용한 환경에서 연구를 진행하였다.

학습 파라미터의 경우, Tensorflow 모델을 Sklearn 모델 형태로 담아준 뒤 Randomsearch를 이용해 하이퍼 파라미터 튜닝 작업을 실시했다. 따라서 배치 사이즈(Batch size) 32, 학습 횟수(Epoch) 300, Optimizer Adam을 지정했다. 초기 학습률(Learning rate)은 0.001로 지정하였고 손실 함수의 최적화를 위해 손실 함수의 감소가 없을 시 Factor(=0.5)의 학습률 감소를 설정하여 더욱 빠르게 최소로 수렴하도록 유도하는 방식을 사용했다.

2.5 평가 지표

학습에 활용된 평가지표로는 정확도(Accuracy), F1-score, 정밀도(Precision), 재현율(Recall)이 사용되었다. 평가 지표들은 식 (1)~(4)을 통해 계산되었다. 수식에 활용되는 요소들인 TP(True positive), TN(True negative), FP(False positive), FN(False negative)은 혼동 행렬을 통해 표현 가능하다. TP는 실제 True 값에 대한 분류 모델의 예측 결과가 True인 경우, TN는 실제 False 값에 대한 분류 모델의 예측 결과가 False인 경우, FP는 실제 False 값에 대한 분류 모델의 예측 결과가 True인 경우, FN는 실제 True 값에 대한 분류 모델의 예측 결과가 False인 경우를 의미한다.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1\ Score = \frac{2 * Precision + Recall}{Precision + Recall} \quad (4)$$

분류 모델 성능의 도식화 및 수치화를 위해 활성화 지도(Class activation map, CAM), AUROC(Area under receiver operating characteristic)가 활용되었다. 활성화 지도는 Fully connected layer 이전 Feature 값을 도식화 한다. Feature 값은 모델의 정답 추론 시, 이미지에서 가장 많은 영향을 끼치는 위치 정보를 의미한다. ROC(Receiver operating characteristic) 커브는 임계 값(Threshold) 변경에 따른 TPR(True positive rate)와 FPR(False positive rate)의 변화를 그래프 형태로 도식화 한다. 그래프가 좌 상단에 치우쳐져 있을수록 모델이 견고하게 학습된 것으로 판단한다. AUROC의 경우 ROC 커브의 하단 넓이를 스코어 형태로 표현하며, 모델의 분류 성능을 평가하는 지표로서 사용된다.

3. 결 과

본 논문은 합성곱 신경망(Convolution neural network)을 기반으로 위내시경 이미지의 해부학적 위치 추론을 위해 InceptionV3, Inception-ResNetV2 활용했다. 더불어 분류 기준이 상이한 A, B 데이터 셋을 이용, 각 모델간의 학습 결과 차이를 비교했다.

InceptionV3 모델의 학습 결과, A 데이터 셋의 경우 정확도 64.45%, F1-score 62.07%, 정밀도 62.81%, 재현율 64.45%, B 데이터 셋의 경우, 정확도 88.89%, F1-score 88.76%, 정밀도 90.64%, 재현율 88.89%를 도출했다. Inception-ResNetV2 모델의 학습 결과, 데이터 셋 A의 경우 정확도 65.06%, F1-score 60.68%, 정밀도 64.89%, 재현율 65.06%, 데이터 셋 B의 경우, 정확도 91.92%, F1-score 91.58%, 정밀도 91.92%, 재현율 92.68%를 도출되었으며, 이는 Table 3를 통해 표현되었다.

Table 3. Learning results of dataset A, B.

	Accuracy (95% CI)	F1 Score (95% CI)	Precision (95% CI)	Recall (95% CI)
Dataset A				
InceptionV3	0.6445 (0.60-0.65)	0.6207 (0.59-0.63)	0.6281 (0.61-0.68)	0.6445 (0.60-0.65)
Inception-ResNetV2	0.6506 (0.61-0.66)	0.6068 (0.58-0.65)	0.6489 (0.64-0.68)	0.6506 (0.61-0.66)
Dataset B				
InceptionV3	0.8889 (0.88-0.90)	0.8876 (0.89-0.90)	0.9064 (0.90-0.91)	0.8889 (0.89-0.90)
Inception-ResNetV2	0.9192 (0.88-0.92)	0.9158 (0.88-0.91)	0.9268 (0.89-0.92)	0.9192 (0.88-0.92)

데이터 셋 A의 학습 결과, F1-score를 제외한 다른 평가지표에서 Inception-ResNetV2 모델이 InceptionV3 모델에 비해 높은 결과를 도출했다. 데이터 셋 B의 학습 결과, 모든 평가지표에서 Inception-ResNetV2 모델이 보다 우수한 학습 결과를 도출했다.

시험 데이터에 대한 활성화 지도 결과를 통해, 붉게 표시된 지점이 모델의 이미지 추론에 영향을 끼친 위치정보임을 알 수 있으며 Fig. 4를 통해 나타낸다.

InceptionV3, Inception-ResNetV2 모델의 AUROC 결과, 두 모델 공통적으로 데이터 셋 A의 위 상부, 중부, 하부 ROC 스코어가 상대적으로 낮은 것을 확인할 수 있고, 데이터 셋 B의 경우, ROC 스코어가

크게 향상된 것을 Fig. 5를 통해 볼 수 있다.

4. 고찰 및 결론

본 연구는 위내시경 검사 시 인적 과실로 인해 발생하는 병변 미 검출로 인한 간과율 증가 문제를 방지하고자, 합성곱 신경망 기반의 딥러닝 모델을 활용한 위내시경 자동 위치 추론 모델을 제시한다. 적합한 모델 선정에 위해 InceptionV3, Inception-ResNetV2 두 모델간의 학습 결과 비교를 진행하였다.

데이터 셋 A의 경우 InceptionV3 모델이 62.07%의 F1-score를 보였으며, 데이터 셋 B의 경우 Incep-




Fig. 4. CAM images of Test set images, (a) CAM image of gastric cardia, (b) CAM image of gastric body, (c) CAM image of gastric angle, and (d) CAM image of gastric antrum.




Fig. 5. The AUROC of classification model using test set (a) InceptionV3 model for 6category, (b) InceptionV3 model for 4category, (c) Inception-ResNetV2 model for 6category, and (d) Inception-ResNetV2 model for 4category

tion-ResNetV2 모델이 91.58%의 F1-score로 데이터 셋 A의 경우 InceptionV3 모델이 데이터 셋 B의 경우 Inception-ResNetV2 모델이 보다 나은 결과를 보였다. 평가 지표 중, Accuracy를 기준으로 둔다면 두 데이터 셋 모두 Inception-ResNetV2 모델이 더 향상된 결과를 도출한 것을 볼 수 있다. 이는 두 모델의 연산량 비교를 통해 유추 가능하다. InceptionV3 모델은 7,400만개, Inception-ResNetV2 모델은 약 9,300만개의 파라미터로 이루어져 더 많은 연산량을 다룬다. 또한 Inception-ResNetV2 모델은 연산량 증가에 따른 기울기(gradient) 소실(vanishing) 및 폭발(exploding) 문제를 일정 해소한 Inception, ResNet 계열의 결합으로 제안되어 더 향상된 결과를 도출한 것으로 유추된다.

두 모델 모두 데이터 셋 B의 경우 상대적으로 데이터 셋 A에 비해 높은 정확도를 도출하였는데, 통상적으로 다중 분류 문제에서 클래스 수의 증가는 학습 복잡도를 상승시켜 전반적인 학습 난이도를 증가시킨다[13]. 해당 실험의 경우, 시각적으로 특징이 유사한 클래스의 병합과 함께 클래스의 감소가 정확도 상승에 도움을 준 것이라고 판단된다. 이에 대한 근거로, AUROC의 경우 Body 클래스의 ROC 스코어가 다른 클래스에 비해 상대적으로 낮게 측정되는 것을 Fig. 5를 통해 확인할 수 있었다. 또한 활성화지도 결과 값을 통해 위 체부를 나누는 3개 클래스의 데이터에서 시각적으로 유사한 부분의 Feature값에 집중하는 것을 확인하였다.

해당 연구는 데이터 분류 과정에서 해부학적 특징에 적합하지 못한 데이터는 학습에서 제외되었는데, 이는 상피 하 중양 혹은 용종의 식별을 위한 확대 영상, 위치 판단이 모호한 클래스 간 중간 지점의 영상 등이 포함된다. 이러한 데이터는 실제 위내시경 영상에 상당수 존재하지만 실제 학습에 활용되지 않았기 때문에 임상에서 적용하기 위해선 추가적인 연구가 요구된다.

향후 연구로 해부학적 분류기준에 속하지 못하여 제외된 데이터를 하나의 클래스로 지정해 학습함으로써 모델의 견고함을 증가시키고자 한다. 혹은 학습이 이뤄지지 않은 데이터에 대해 Unknown class를 반환하도록 고안된 방식인 Open set recognition을 이용하여 위내시경 영상에 대한 분류 성능을 만족시키기 위한 연구를 진행할 계획이다. 또한 임상에 적

용되기 위한 최소 프레임수를 충족하기 위해 추론 결과의 신뢰도를 유지하는 상태에서 리소스 부담이 적은 모델의 활용하거나 시스템의 최적화를 통한 처리 속도 향상이 요구된다.

앞서 언급된 방식들의 적용으로 학습 데이터와 모델을 최적화하고 성능을 향상시킴으로써 임상에서 위내시경 검사 시, 시각지대로 인해 발생하는 인적 과실을 방지하고자 한다. 이를 통해, 현 위내시경 검사에 소모되는 인적, 물적 자원을 감소시키고, 양질의 의료서비스 제공을 위한 환경 구축에 이바지하고자 한다.

REFERENCE

- [1] K. Jung, Y. Won, S. Hong, H. Kong, and E.S. Lee, "Prediction of Cancer Incidence and Mortality in Korea, 2020," *Cancer Research and Treatment*, Vol. 52, No. 2, pp. 351-358, 2020.
- [2] Y.S. Cho, S.H. Lee, H.J. So, D.W. Kim, Y.J. Choi, and H.H. Jeon, "Effect of Gastric Cancer Screening on Patients with Gastric Cancer: A Nationwide Population-based Study," *Journal of Digestive Cancer Reports*, Vol. 8, No. 2, pp. 102-108, 2020.
- [3] Hospital misdiagnosis, cancer misdiagnosis, 6 out of 10 cases(2017), <https://www.kca.go.kr/kca/sub.do?menukey=5084&mode=view&no=1002072633> (accessed March 30, 2022).
- [4] K. Yao, "The Endoscopic Diagnosis of Early Gastric Cancer," *Annals of Gastroenterology*, Vol. 26, No. 1, pp. 11-22, 2013.
- [5] E.S. Lee, *Guidelines of Gastric Cancer Screening*, National Cancer Center Korea, South Korea, Gyeonggi Province, Goyang City, 2018.
- [6] J. Wen, Y. Cheng, X. Hu, P. Yeam, T. Hao, and Y. Shi, "Workload, Burnout, and Medical Mistakes among Physicians in China: A Cross-Sectional Study," *Bioscience Trend*, Vol. 10, No. 1, pp. 27-33, 2016.
- [7] Y.D. Kim, W.K. Bae, Y.H. Choi, Y.J. Jwa, S.K. Jung, B.H. Lee, et al., "Difference in Adenoma Detection Rates according to Colonoscopic

- Withdrawal Times and the Level of Expertise,” *The Korean Journal of Gastroenterology*, Vol. 64, No. 5, pp. 278-283, 2014.
- [8] G.Y. Yi, Y.J. Kim, S.T. Kim, H.Y. Kim, and K.G. Kim, “Comparison and Verification of Deep Learning Models for Automatic Recognition of Pills,” *Journal of Korea Multimedia Society*, Vol. 22, No. 3, pp. 349-356, 2019.
- [9] T. Itoh, H. Kawahira, H. Nakashima, and N. Yata, “Deep Learning Analyzes Helicobacter Pylori Infection by Upper Gastrointestinal Endoscopy Images,” *Endoscopy International Open*, Vol. 6, No. 2, pp. 139-144, 2018.
- [10] J.H. Lee, Y.J. Kim, Y.W. Kim, S. Park, Y. Choi, Y.J. Kim, et. al., “Spotting Malignancies from Gastric Endoscopic Images Using Deep Learning,” *Surgical Endoscopy*, Vol. 33, No. 11, pp. 3790-3797, 2019.
- [11] C. Szegedy, V. Vanhoucke, S. Ioffe, and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision,” *arXiv Preprint*, arXiv:1512.00567, 2015.
- [12] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning,” *arXiv Preprint*, arXiv:1602.07261, 2016.
- [13] N. Sharma, V. Jain, and A. Mishra, “An Analysis of Convolutional Neural Networks for Image Classification,” *International Conference on Computational Intelligence and Data Science*, pp. 377-384, 2018.



강 성 민


2017년 2월 아세아항공직업전문
학교 항공정비학과
(공학사)
2021년 12~현재 가천대 길병원 의
료기기 R&D센터 연구원
관심분야: 의료영상, 인공지능, 머
신러닝



김 영 재

2007년 2월 남서울대학교 컴퓨터
학과(학사)
2013년 2월 광운대학교 플라즈마
바이오토폴레이학과
(공학석사)
2018년 2월 광운대학교 플라즈마
바이오토폴레이학과
(공학박사)

2009년 2월~2017년 4월 국립암센터 의공학연구과
2018년 5월~현재 가천대학교 의과대학 의예과 연구교수
관심분야: 의료영상, 인공지능, 3D, 디스플레이



김 윤 재

1999년 2월 연세대학교 의과대학
졸업(학사)
2003년 2월 연세대학교 의학대학
원 졸업(석사)
2014년 2월 연세대학교 의학대학
원 졸업(박사)

2019년~현재 가천대 길병원 소화기내과 교수



김 광 기

1996년 2월 안동대학교 물리학과
(학사)
1998년 2월 포항공과대학교 물리
학과(이학석사)
2005년 2월 의용공학과(공학박사)
2007년 7월~2017년 1월 국립암
센터 의공학연구과

2017년 2월~현재 가천대학교 의용생체공학과 교수
관심분야: 의료영상, 의료정보, 인공지능, 로봇