

논문 2021-16-24

간병 로봇을 위한 합성곱 신경망 (CNN) 기반 의약품 인식기 설계 (Design of Convolution Neural Network (CNN) Based Medicine Classifier for Nursing Robots)

김 현 돈*, 김 동 현, 서 필 원, 배 종 석
(Hyun-Don Kim, Dong Hyeon Kim, Pil Won Seo, Jongseok Bae)

Abstract : Our final goal is to implement nursing robots that can recognize patient's faces and their medicine on prescription. They can help patients to take medicine on time and prevent its abuse for recovering their health soon. As the first step, we proposed a medicine classifier with a low computational network that is able to run on embedded PCs without GPU in order to be applied to universal nursing robots. We confirm that our proposed model called MedicineNet achieves an 99.99% accuracy performance for classifying 15 kinds of medicines and background images. Moreover, we realize that the calculation time of our MedicineNet is about 8 times faster than EfficientNet-B0 which is well known as ImageNet classification with the high performance and the best computational efficiency.

Keywords : Convolutional Neural Network, Medicine classification, EfficientNet, Nursing robot, Autonomous mobile robot, Collaborative robot

I. 서 론

병원이나 요양원 등에는 정기적으로 정확한 시간에 약을 먹어야 하는 환자들이 많다. 하지만 정확한 복용 일정을 놓치거나, 복용 순서와 방법을 잊어버리는 경우가 많아 약물 오남용 문제가 자주 발생한다. 또한, 간호사들도 과중한 업무로 인하여 모든 환자를 챙기는 것은 현실적인 어려움이 많다. 이러한 문제점을 개선하기 위해서 다양한 간병 로봇이 제안되었다 [1]. 우리가 제안하는 간병 로봇의 역할은 로봇에 의사의 처방전과 환자의 얼굴 정보를 입력해 놓으면, 환자마다 복용 시간에 맞추어 손목에 차는 웨어러블 장치 또는 스마트폰 등을 이용하여 알람을 울려준다. 다음으로 알람을 받은 환자들이 로봇에게 가면 로봇은 환자의 얼굴을 인식하고 의사의 처방전에 따른 약을 제공함으로써 약을 제 시간에 먹도록 도와주고, 오남용을 막아주어 환자의 빠른 회복을 도와준다.

이러한 간병로봇을 구현하기 위하여 영상처리를 통한 얼굴 및 의약품 인식이 필요하다. 환자 본인인증을 위한 얼굴 인식 기능의 경우 OpenCV 라이브러리를 사용하여 구현하는 방법이 있다 [2]. 하지만 의약품 인식의 경우 적절한 공개 라이브러리가 없다. 특히 배터리를 사용하는 보급형 이동형 로봇에 적용을 고려하면, 일반적인 그래픽 카드가 내

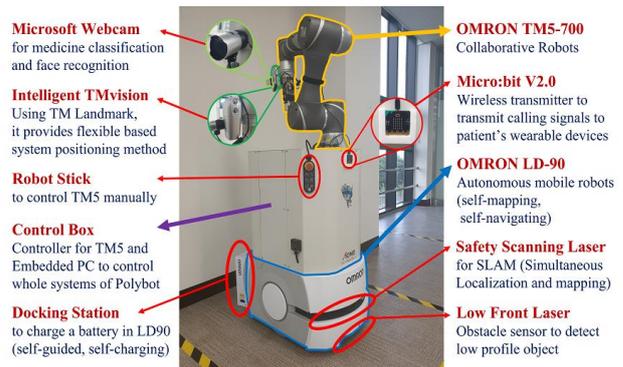


그림 1. 제안된 간병로봇 폴리봇
Fig. 1. The proposed nursing robot called Polybot

장된 고성능의 PC가 아닌 임베디드 PC에서도 처리가 가능한 계산량이 적으면서도 최대의 성능을 보장하는 인식기 설계가 필요하다. 이 논문에서는 합성곱 신경망 (CNN) [3] 기반의 의약품 인식기 MedicineNet 모델을 제안하였다. 제안한 모델은 15개 의약품과 비의약품 분류에 약 99.99%의 인식률 성능을 보였으며, 연산 효율성이 가장 좋다고 알려진 EfficientNet-B0 모델과 비교하여 약 8배의 빠른 실행속도를 보였다 [4].

II. 제안하는 간병로봇

1. 시스템 구성

환자의 약 복용 시간에 맞추어 약을 선별하고 환자에게 전달하기 위하여 그림 1과 같이 간병로봇의 시스템을 구성하였

*Corresponding Author (reynolds@kopo.ac.kr)
Received: Aug. 26, 2021, Revised: Sep. 29, 2021, Accepted: Oct. 6, 2021.
H.-D. Kim: Korea Polytechnics (Assoc. Prof.)
G.H. Kim, P.W. Seo, J. Bae: Korea Polytechnics (Student)
※ 본 논문은 과학기술정보통신부 정보통신망의인재양성사업의 지원을 통해 수행한 ICT멘토링 프로젝트 결과물임.

다. 자율주행이 가능한 오픈 모바일 로봇 (LD-90)에 의약품을 집고 전달하기 위한 오픈 협동 로봇 (TM5)을 탑재한 형태이다. 협동 로봇 제어기는 하단의 몸통 내부에 장착되어 있으며, 통합 제어 및 의약품과 얼굴인식을 수행하는 임베디드 PC (ODYSSEY, J4105 CPU, 8GB RAM, 64GB eMMC)도 내장되어 있다. 임베디드 PC의 WiFi 모듈을 통하여 외부와 접속 할 수 있으며, 모바일 및 협동 로봇과는 텔넷 (telnet) 통신을 통하여 명령어를 주고받을 수 있다.

그림 1과 같이 6축 자유도를 가지는 협동 로봇 마지막 6 번째 조인트에는 로봇 좌표계를 보정하기 위한 빌트인 (built-in) TMvision 카메라가 있다. 이곳에 별도의 의약품 및 얼굴인식을 위한 웹 카메라를 장착하였으며 몸통 내부의 통합 제어용 임베디드 PC의 USB 단자에 연결되어 있다. 마지막으로 복용 시간에 맞추어 환자의 웨어러블 시계로 알람을 전송하기 위한 마이크로비트 무선송신 장치가 몸통 전면의 상단에 부착되어 있다.

2. 동작 시나리오

그림 2는 간병 로봇의 주요 동작 흐름도를 나타내며, 각 수행 순서에 따른 설명은 다음과 같다.

- ① 의사가 환자의 진단서를 작성하면 실시간으로 간병로봇에게 정보가 전달된다.
- ② 업데이트 진단서에 따라서 복용 시간에 맞추어 해당 환자들의 웨어러블 디바이스로 알람을 전송하여 곧 간병로봇이 의약품 전달 예정임을 알린다.
- ③ 환자들에게 복용 시간이 되었음을 무선 알람으로 전송한 후 의약품 보관소로 이동한다. 모든 이동은 모바일 로봇에 자체 탑재된 자율주행 기능을 사용하여 사람이나 장애물을 회피할 수 있다. 도착 후 웹 카메라 영상을 통하여 해당 환자의 진단서에 맞는 약품들을 인식하고 선별하여 탑재한다.
- ④ 환자가 있는 장소로 이동한 후, 로봇 팔에 장착된 웹 카메라로 환자의 얼굴을 인식하여 해당 환자가 맞는지 인증 후 약을 전달한다. 이때 2명 이상의 환자에게 동시에 약을 전달할 수 있다.
- ⑤ 약 전달을 완료하면, 대기 장소로 이동 후 자동으로 충전시스템에 도킹하여 충전하고, 다음 환자들의 약 복용 시간까지 대기한다.

3. 모바일 로봇 자율주행 및 도착 위치 보정

오픈 모바일 로봇은 자율주행 기능이 탑재되어 있으며 SLAM (Simultaneous Localization And Mapping)을 위한 지도 작성과 목적지 설정은 모바일 플래너 (MobilePlanner) 소프트웨어를 사용하여 작성이 가능하다. 그림 3의 (a)는 모바일 플래너 화면을 나타내고 5.4.2 버전을 사용하였다.

오픈 모바일 로봇은 목적지 근처에 도착하면 바닥의 마그네틱 테이프를 인식하여 정확한 위치에 도착할 수 있다. 마그네틱 테이프를 사용하면 거리 ±5mm, 각도 ±0.5도 이내의 정확도로 위치보정이 가능하다. 그림 3의 (b)는 로봇이 바닥의 마그네틱 테이프를 따라서 목적지에 접근하는 장면이다.

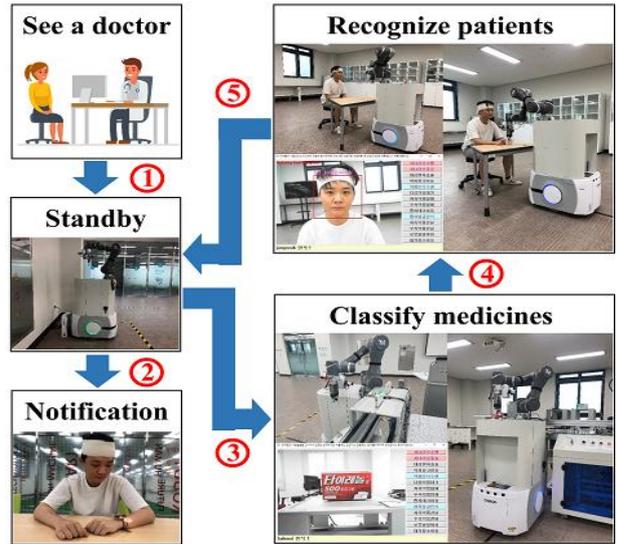
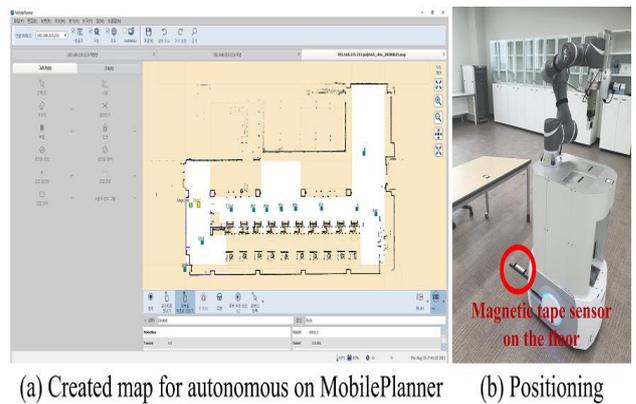


그림 2. 동작 순서도
Fig. 2. The scenario of demonstration



(a) Created map for autonomous on MobilePlanner (b) Positioning

그림 3. 모바일 로봇의 자율주행 목적지 지정과 지도 작성을 위한 모바일 플래너 화면 (a) 및 자석 테이프를 이용한 위치보정 시스템 (b)

Fig. 3. (a) is the mobile robot software suite for creating all major robot activities and mapping, and (b) is the high accuracy positioning system

4. 협동로봇 제어 및 이동좌표계 마커 보정

협동로봇의 작업생성 프로그래밍과 설정에는 그림 4의 (a)에 보이는 flow 기반 편집 소프트웨어인 TMflow를 사용하며 1.72.3800 버전을 사용하였다.

그리퍼가 달린 마지막 축에 장착된 비전 시스템 (TMvision)을 이용하여 그림 4의 (b)와 같이 TM 랜드마크를 영상으로 인식하고 모바일 로봇이 이동함에 따른 로봇 좌표계의 오차를 보정 할 수 있다.

5. 의약품 인식 및 환자 얼굴 인증

모바일 로봇이 약품 보관소에 도착하면 웹 카메라에서 의약품 영상정보가 임베디드 PC에 전송되고 합성곱 신경망 (CNN) 기반 의약품 인식기를 통해서 해당 의약품을 선별하

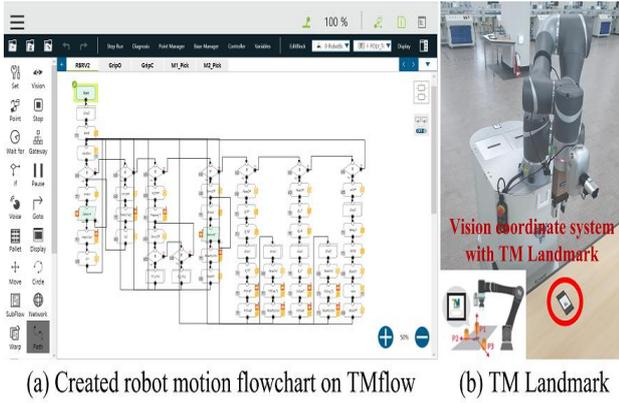


그림 4. 협동로봇의 설정과 모션작업 생성을 위한 개발 플랫폼 TMflow 화면 (a) 및 영상을 통한 좌표계 오차를 보정 할 수 있는 TM랜드마크 (b)

Fig. 4. (a) is a graphical HMI software for robot motion and logic programming, and (b) allows TM Robot to scan the landmark and update the coordinate of all objects in the workspace without re-adjustment

여 탑재하게 된다. 환자 대기소로 이동하고 나면 OpenCV를 사용한 환자의 얼굴 인증이 수행되어 전달 오류로 인한 의약품 오남용을 방지할 수 있다.

III. EfficientNet 배경이론

1. 전이학습 (Transfer learning)

일반적으로 CNN 기반의 딥러닝 모델을 제대로 학습하려면 대량의 데이터가 필요하다. 하지만 충분히 큰 데이터 세트를 얻는 것은 많은 시간과 돈이 필요하므로 간단한 일이 아니다. 이러한 현실적 어려움을 해결한 것이 바로 전이학습 (transfer learning)이다. 전이학습이란 이미지넷과 같이 아주 큰 데이터 세트에 훈련된 모델의 가중치를 가지고 와서 우리가 적용하려는 목적에 맞게 비교적 적은 수의 데이터를 가지고 딥러닝 모델을 훈련시키고 재보정해서 사용하는 것을 의미한다.

이 논문에서는 최근 ImageNet 대회에서 가벼운 모델로 우수한 성능을 보인 EfficientNet을 선택하였고 [4], 제한한 의약품 인식기의 성능 비교평가에 사용하였다.

2. EfficientNet 모델

EfficientNet 논문은 2019년 5월에 발표되었으며 [4], 모델의 정확도를 향상하기 위한 scaling 과정에 있어 compound scaling이라는 scaling factor 적용 기법을 제시함으로써 영상분류 성능을 크게 개선하였다. Compound scaling이라는 것은 모델의 성능을 높이기 위해서 필터 (filter) 또는 채널 (channel)을 늘리는 width, 가장 일반적으로 사용되는 층 (layer)을 늘리는 depth, 그리고 입력 데이터의 해상도를 높이는 resolution, 세 가지 요소 (factor)에 대해서 동시에 고려하는 것으로 연산량과 정확도 측면에서 효율적임을 증명

하였다. 참고로 2021년 7월에 EfficientNet 두 번째 버전 모델이 발표되었다 [5].

EfficientNet의 특징으로 depthwise separable convolution [6] 과 squeeze and excitation (SE) [7] 개념이 혼합된 mobile inverted bottleneck convolution (MBCConv) 블록을 사용한다.

Depthwise separable convolution은 이미지 혹은 피쳐맵을 각 채널 별로 쪼개서 컨볼루션 연산을 적용하는 depthwise convolution과 필터의 크기가 1로 고정되어 있는 1차원 convolution으로 여러 개의 채널을 하나의 새로운 채널로 합치는 과정을 통해서 차원과 연산량을 감소시킬 수 있는 pointwise convolution이 합쳐진 개념이다 [6]. 원래 모바일 기기에서 동작하는 것을 목표로 탄생한 CNN 아키텍처로 최근 효율적으로 연산량을 감소시키려는 방법들이 추가로 제안되었다 [8, 9].

Squeeze and excitation은 각 채널들의 중요한 정보만 추출하는 squeeze 과정과, 이를 통해 각 정보의 중요도에 따라서 스케일을 재조정 해주는 excitation 과정으로 이루어져 있다 [7]. 이 방법은 모델 복잡도와 계산 복잡도가 많이 증가하지 않으면서도 성능 향상도가 큰 장점이 있다.

3. EfficientNet 성능

EfficientNet은 표 1과 같이 모델 크기에 따라서 B0~B7 버전이 있으며 B0가 가장 가벼운 모델이다. 이 논문에서는 저 사양 임베디드 PC에서도 실행되는 계산량이 적은 모델의 설계가 중요하므로 B0를 기준으로 성능 비교평가를 하였다. 특히, 기존 DenseNet-169 [10], ResNet-50 [11] 모델과 비교하여 파라미터 개수는 각각 약 0.27배, 약 0.2배 적으며, 연산량 횟수를 나타내는 FLOPs (FLoating point Operations) 도 약 10%에 불과하면서도 동급 우세 성능을 보인다. 표 1에서 Input은 입력 이미지의 크기를 나타내며, 가로와 세로 244개 화소를 의미한다. Output은 마지막 fully connected layer 층을 만들기 전에 나오는 크기를 나타낸다.

4. 의약품 인식기 적용

표 2는 성능 비교평가에 사용할 EfficientNet B0 모델의 네트워크 구조를 나타낸다. 참고로 EfficientNet은 ImageNet

표 1. EfficientNet 성능 및 입출력 사양

Table 1. EfficientNet performance and the input/output size according to kinds of models

Efficient Net	#Params	#FLOPs	Input	Output
B0	5.3M	0.39B	224	1280
B1	7.8M	0.70B	240	1280
B2	9.2M	1.0B	260	1408
B3	12M	1.8B	300	1536
B4	19M	4.2B	380	1792
B5	30M	9.9B	456	2048
B6	43M	19B	528	2304
B7	66M	37B	600	2560

표 2. EfficientNet-B0 네트워크 구조
Table 2. EfficientNet-B0 baseline network

Stage	Operator	Resolution	Channel	Layers
1	Conv3x3	224x224	32	1
2	MBCConv1, k3x3	112x112	16	1
3	MBCConv6, k3x3	112x112	24	2
4	MBCConv6, k5x5	56x56	40	2
5	MBCConv6, k3x3	28x28	80	3
6	MBCConv6, k5x5	14x14	112	3
7	MBCConv6, k5x5	14x14	192	4
8	MBCConv6, k3x3	7x7	320	1
9	Conv1x1& Pooling&FC	7x7	1280	1

에 맞추어 학습되어 있으므로 마지막 출력 차원은 1000차원이며, 전이학습 적용 시 출력 차원 조정이 필요하다. 예를들면, B0 모델의 입력 크기 형태는 [1, 3, 224, 224]이며, 출력은 [1, 1280, 7, 7] 크기 형태이다. 따라서 원 Softmax 출력 크기를 [1, 1000]에서 16개 (의약품 15종 + 비의약품 1종)의 분류 개수로 수정하여 학습하고 평가하였다.

IV. 의약품 인식기 설계

1. 네트워크 구조

제안한 의약품 인식기 네트워크 구조는 그림 5와 같다. 640x480 이미지를 입력으로 사용하지만, 비교 평가 모델인 EfficientNet과 입력 크기를 맞추기 위해서 축소 (resize) 및 중앙을 잘라내어 (center crop) 224x224 크기로 변환되어 실제 네트워크에 입력된다. 컨볼루션층은 총 4개로 구성되어 있으며, 컨볼루션 1번과 2번층 거치면 배치 정규화와 맥스 풀링층을 거친다 [12]. 그리고 다시 컨볼루션층 3번과 4번을 거쳐 배치 정규화 층을 지나면 3개의 풀리 커넥티드 (FC) 층을 통과하여 최종 15개 의약품과 1개의 비의약품 총 16개 클래스를 분류할 수 있다. 이 논문에서는 저사양 임베디드 PC에서 실행을 염두에 두고 연산시간을 줄이기 위해서 네트워크층과 입력 이미지의 크기를 최대한 줄이면서도 성능감소는 최소화되도록 최적화하여 구성하였다.

제안한 네트워크에 대한 최적화 여부를 판단하기 위해서 입력 이미지를 512x512 크기로 확대하고 이에 따른 네트워크 가로세로 크기도 재조정된 네트워크를 별도로 구성하여 비교평가를 수행하였다. 그림 5의 네트워크와 비교하여 최종 분류개수 16개는 같지만, 마지막 풀리 커넥티드 층을 만들기 전 크기 형태는 [1, 128, 5, 5]에서 [1, 128, 14, 14]로 차이가 있다.

2. 학습용 데이터 세트 및 데이터 증강

학습용 데이터 세트는 그림 6와 같이 15개의 의약품의 이름이 표시되는 정면을 기준으로 다양한 배경에서 의약품 당

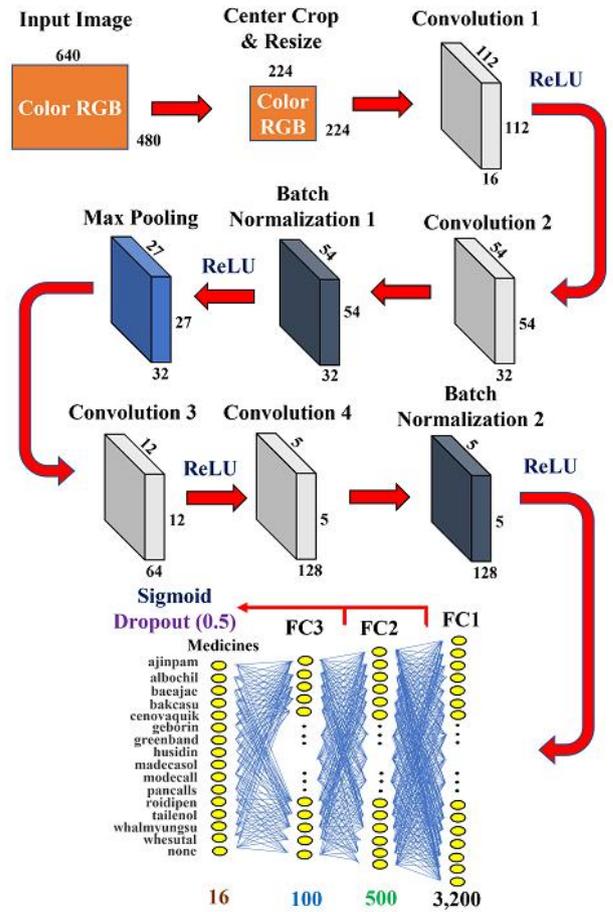


그림 5. 제안한 의약품 인식기 네트워크 구조
Fig. 5. The structure of a proposed medicine classifier (MedicineNet-224)

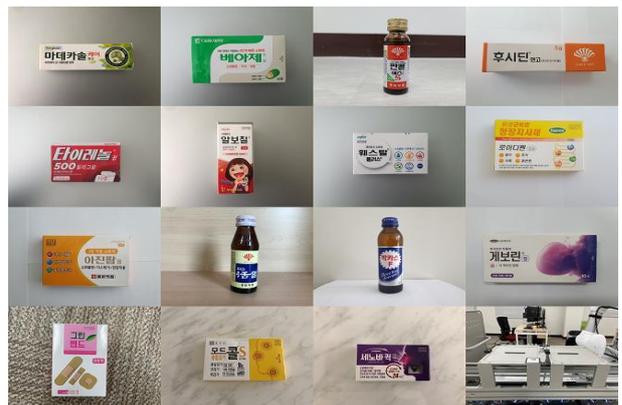


그림 6. 16종 의약품 및 비의약품 샘플 이미지
Fig. 6. 16 kinds of sample medicine and background images

400장씩 총 6,000장을 카메라로 촬영하여 구축하였다. 또한 의약품이 없거나 비의약품과 관련된 영상이 입력되었을 경우 오인식을 방지하기 위해서 그림 6의 오른쪽 아래의 마지막 이미지와 같이 의약품이 없는 배경화면 이미지도 400장 추가하여 총 16개 클래스와 6,400장을 생성하였다. 다음으로

의약품 당 400장의 이미지는 학습에 충분하지 않으므로 30도 간격으로 회전시켜서 12배 데이터 증강을 하였다. 즉, 의약품 이미지 당 4,800장 총 76,800개의 이미지가 있는 의약품 데이터 세트를 최종 구축하였다.

여기에서 클래스당 3,200장은 학습 (training)에 사용하고, 800장은 학습 시 데이터 성능검증 (validation)으로, 마지막으로 800장은 최종 성능평가 (evaluation) 용도로 무작위로 나누었다. 따라서 총 51,200장의 학습데이터 세트, 검증 및 평가 데이터 세트 각 12,800장을 구성하여 사용하였다.

3. 학습조건

학습 (Training)에 사용되는 최적화 (Optimizer) 함수는 ADAM을, 손실 함수 (Loss function)는 교차 엔트로피 (Cross Entropy)를 사용하였다 [13]. 정확한 학습의 척도를 검증 (Validation)하기 위한 검증 데이터 세트 비율은 전체 데이터에서 학습데이터 세트의 20% 크기를 할당하였다. 학습을 위한 배치 크기 (batch size)는 64로, 학습 반복 횟수 (Epoch)는 100번 수행되었다. 여기서 오버피팅을 방지하기 위해서 학습 반복 횟수 내에서 최대의 검증 인식률 (accuracy)과 최저의 손실률 (loss)을 가지는 모델을 최종 선택하여 평가에 사용하였다. 또한, 비교평가를 위해 선택한 EfficientNet-B0 모델도 동일한 학습 및 검증 데이터 세트를 이용하고, 미리 학습된 EfficientNet 가중치 (weight)는 고정하고 뒷부분 fully connected layer 2단계만 학습하였다 [4].

V. 성능평가

1. 성능평가 조건

성능평가를 위해서 각 클래스당 800장, 총 16개 클래스 12,800장의 이미지를 개별로 인식된 결과를 기록하였다. 우리가 제안한 의약품 인식기 모델은 ImageNet 입력 이미지 크기와 동일한 224x224 크기에 최적화된 모델 (MedicineNet-224)과 해상도를 높은 512x512 이미지 입력으로 사용하는 모델 (MedicineNet-512), 그리고 EfficientNet-B0 모델 3가지를 성능비교 평가하였다.

성능평가에 사용된 PC는 Intel i7-7700K 4.2GHz, 32GB RAM, 1GB SSD 사양에서 수행되었다. 또한, 우리가 제안한 간병 로봇과 같은 보급형 서비스 로봇에서 사용되는 임베디드 PC 사양을 고려하여 학습과 평가에는 GPU를 사용하지 않고 CPU 단독 동작 조건에서 수행되었다.

2. 최적의 학습횟수 결정

학습은 총 100번을 반복하였다. 학습횟수에 따른 과적합 (overfitting)을 방지하기 위해서 에포크 (epoch)가 완료될 때마다 검증 인식률 (validation accuracy)과 검증 손실 값 (validation loss)을 구하고, 인식률은 최대이면서 손실 값이 최소인 모델을 선택하였다. 그림 7과 같이 에포크 반복수행 50번 이내에 최대 인식률 및 최소 손실 값으로 수렴됨을 알 수 있다.

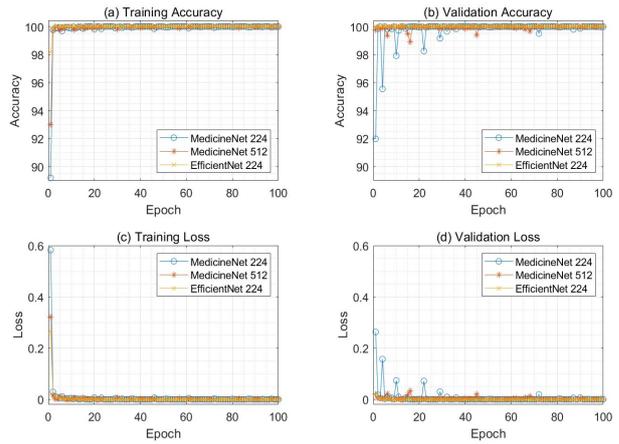


그림 7. 학습에 따른 인식률과 손실 값 변화

Fig. 7. Accuracy and loss on train and validation along training epochs

표 3. 의약품 인식기 비교평가 결과

Table 3. The results of performance

Measurement	MedicineNet -224	MedicineNet -512	EfficientNet -B0
Accuracy	99.99% (12799 /12800)	99.98% (12798 /12800)	100.00% (12800 /12800)
Loss (Average)	0.0005	0.0007	0.0001
Time (Average)	8.5ms	23.9ms	72ms

3. 평가결과

표 3은 제안한 MedicineNet과 EfficientNet-B0모델의 성능 비교평가 결과이다. MedicineNet은 입력 이미지 크기에 따라서 224와 512 두 가지 모델로 평가를 진행하였다. 간병 로봇에 적용된 MedicineNet-224 모델의 인식률은 99.99%로 총 12800개의 평가 이미지에서 1개만 오인식 되었다. 나머지 두 개의 비교평가 모델에서도 동일하게 우수한 인식률을 보였으며, 평균 손실 값은 EfficientNet-B0 모델이 가장 낮았다. 하지만, 무엇보다도 1장을 실행하는데 소요된 평균 시간은 8.5ms로 다른 두 개의 모델에 비해서 압도적으로 빨랐다. 특히 기존에 연산량 대비 인식률이 가장 효율적인 모델로 알려진 EfficientNet-B0의 경우와 비교하여 약 8배 빠른 성능을 보여주었다.

4. 성능분석

표 3과 같이 제안한 MedicineNet-224 모델은 실행시간이 압도적으로 빠르면서도 100%에 가까운 인식률을 보여 임베디드 PC에 적용 시 가장 효율적임을 알 수 있다. 또한 입력 이미지의 해상도를 높더라도 인식률 변동이 없어 입력 이미지의 크기는 224x224가 성능 면에서 최적임을 확인할 수

있다. 반면에 EfficientNet-B0 모델의 경우 ImageNet에 맞추어 학습되어 있으므로 최종 분류개수가 1,000개이다. 따라서 향후 분류해야 하는 의약품 개수가 급격히 늘어난다면 인식률 측면에서는 더 우수할 것으로 기대할 수 있다. 하지만 연산량이 높아 GPU가 없는 저사양 PC에서는 실시간 수행이 어려운 단점이 있다.

VI. 결론

이 논문에서는 의사의 처방전에 맞추어서 환자의 얼굴과 의약품을 인식하여 약을 제시간에 먹도록 도와주고, 오남용을 막아주어 환자의 빠른 회복을 도와주는 간병 로봇 구현을 최종 목표로 한다. 간병 로봇을 실현하기 위해서 이 논문에서는 합성곱 신경망(CNN) 기반 의약품 인식기를 제안하였다. 특히 모바일 로봇에도 적용할 수 있도록 그래픽 카드가 내장된 고성능의 PC가 아닌 저전력의 임베디드 PC에서도 처리가 가능한 연산량이 적으면서도 고성능을 보이는 네트워크를 제안했다. 제안한 MedicineNet-224 모델은 16개 종류의 의약품과 비의약품을 약 99.99%의 인식률로 분류하고, 연산 효율성이 가장 좋다고 알려진 EfficientNet-B0 모델과 비교하여 약 8배의 빠른 실행속도를 보였다.

현재 국내에서 의사 처방 없이 편의점에서 구매 가능한 일반 상비 의약품은 감기·해열·진통제 7개, 소화제 4개, 소염제 2개 등 총 13개 종류임을 고려하면 15개 의약품 분류개수는 합리적인 수 있다. 하지만 일본의 경우 2,000여 개, 미국의 경우 약 3만여 개의 상비 의약품 품목이 있음을 고려하고, 향후 병원이나 요양원 등의 확대 적용을 위해서는 의약품 종류 분류개수 증대는 필수적이다. 물론 분류개수가 증가함에도 우수한 성능을 유지하면서 연산량 최적화를 실현하는 것이 앞으로의 과제이다. 덧붙여서 제안한 간병 로봇은 환자의 얼굴 인종에 OpenCV 라이브러리를 사용하고 있으나 낮은 인식성능과 이에 따른 환자의 얼굴 수를 늘리는 데 한계가 있다. 따라서 차후 개선된 간병 로봇은 새롭게 설계한 딥러닝 기반 얼굴인식기를 탑재 예정이다.

References

[1] Jiang, Z. Huang, B. Huo, Y. Zhang, S. Song, "Research Progress and Prospect of Nursing Robot", Recent Patents on Mechanical Engineering, Vol. 11, No. 1, pp. 41-57, 2018.

[2] S. EMAMI, V.P. SUCIU, "Facial Recognition using OpenCV", Journal of Mobile, Embedded and Distributed systems, Vol. 4, No. 1, pp. 38-43, 2012.

[3] R. Yamashita, M. Nishio, R.K.G. Do, K. Togashi, "Convolutional Neural Networks: An Overview and Application in Radiology", Insights Imaging, pp. 611-629, Aug. 2018.

[4] M. Tan, Q.V. Le, "EfficientNet: Rethinking Model

Scaling for Convolutional Neural Networks", Proc. of 36th Int. Conference on Machine Learning (PMLR), pp. 6105-6114, Long Beach, USA, June, 2019.

[5] M. Tan, Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training", Proc. of 38th Int. Conference on Machine Learning (PMLR), pp. 10096-10106, July, 2021.

[6] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, H. Adam, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications", Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 2261 - 2269, 2017.

[7] J. Hu, L. Shen, S. Albanie, G. Sun, E. Wu, "Squeeze-and-Excitation Networks", Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 7132-7141, 2018.

[8] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks", Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 4510-4520, 2018.

[9] A. Howard, M. Sandler, G. Chu, L.-C. Chen, B. Chen, M. Tan, W. Wang, Y. Zhu, R. Pang, V. Vasudevan, Q. V. Le, H. Adam, "Searching for MobileNetV3", Proc. of the IEEE/CVF Int. Conference on Computer Vision, pp. 1314-1324, 2019

[10] G. Huang, Z. Liu, L. Maaten, K. Q. Weinberger, "Densely Connected Convolutional Networks", Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 4700-4708, 2017.

[11] K. He, X. Zhang, S. Ren, J. Sun, "Deep Residual Learning for Image Recognition", Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778, 2016.

[12] A. Krizhevsky, I. Sutskever, G.E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks", Advances in Neural Information Processing Systems, pp. 1097-1105, 2012.

[13] D.P. Kingma, J.L. Ba, "Adam: A Method for Stochastic Optimization", Int. Conference on ICLR (Poster), pp. 1-15, San Diego, CA, USA, May 7-9, 2015.

Hyun-Don Kim (김 현 돈)



1997 Control and Instrumentation Engineering from Korea University (B.S.)
2004 Electrical Engineering in Graduate School from Korea University (M.S.)
2008 Intelligence Science and Technology in Graduate School of Informatics from Kyoto University, Japan (Ph.D.)

2017~Assistant Professor, Department of Robot Automation in Robot Campus of Korea Polytechnics

Career:

2002 Engineer, Semiconductor R&D Center, Memory Division, Samsung Electronics Corporation

2008 Japanese Government (MEXT) Scholarship

2012 Senior Research Engineer, Future IT R&D Lab., LG Advanced Research Institute, LG Electronics Inc.

2017 Managing Researcher, Convergence Security Research Center, Samsung S1 Corporation

Field of Interests: Deep Learning, Human Robot Interaction, Biometrics, Sound Signal Processing, Speech Recognition, Collaborative Robot, Artificial Intelligence

Email: reynolds@kopo.ac.kr

Dong Hyeon Kim (김 동 현)



2021~Robot Automation in Robot Campus of Korea Polytechnics, Student

Field of Interests: Artificial Intelligence & Robot Control

Email: dhkhan99@naver.com

Pil Won Seo (서 필 원)



2021~Robot Automation in Robot Campus of Korea Polytechnics, Student

Field of Interests: Embedded System & Artificial Intelligence

Email: dpdd0914@naver.com

Jongseok Bae (배 종 석)



2021~Robot Automation in Robot Campus of Korea Polytechnics, Student

Field of Interests: Human Robot Interaction & PID Control

Email: qkqhrudtjrl@naver.com