

딥러닝 기반 장면인식 기법을 이용한 제조 작업공간 분류모델

김정수*, 이동명^o

Workspace Classification Model for Manufacturing Using Deep Learning-Based Scene Recognition

Jeong Su Kim*, Dong Myung Lee^o

요약

최근 머신러닝 기술의 발달로 산업현장에서 딥러닝(Deep Learning)을 통한 장면인식(Scene Recognition) 방법이 다양하게 연구되고 있다. 딥러닝을 이용한 장면인식의 성능은 알고리즘 구조와 학습방법에 따라 크게 영향을 받는다. 본 연구를 위한 사전 연구 결과, Places365 데이터셋으로 학습된 데이터 모델에 의한 제조 작업공간 분류 정확도는 54%로, 이 성능으로는 실제 환경에서 사용하기는 어렵다. 따라서 본 논문에서는 이러한 문제점을 해결하고자 CNN(Convolutional Neural Network) 기반에서 3가지의 전략으로 학습 데이터셋을 재구성하여 학습을 실시한 후 장면인식 기법을 이용하여 제조 작업공간 분류모델을 제시하였다. 제안한 알고리즘과 데이터셋 구성방법을 통해 학습할 경우, 제조 작업공간에 대한 장면인식 성능은 기존 방법에 비해 28%p 향상됨을 확인하였다.

Key Words : Scene Recognition, Deep Learning, Convolutional Neural Network, Places365, Manufacturing Workspace

ABSTRACT

With the recent development of machine learning technology, various methods of scene recognition through deep learning are being studied in industrial fields. The performance of scene recognition using deep learning is greatly affected by the algorithm structure and learning method. As a result of the preliminary study for this study, it was confirmed that the manufacturing workspace classification accuracy by the data model trained with the Places365 dataset was 54%, which was difficult to use in the real environment. Therefore, in this paper, in order to solve this problem, a classification model of the manufacturing workspace is presented using a scene recognition technique after learning by reconstructing a learning dataset with three strategies based on CNN (Convolutional Neural Network). When learning through the proposed algorithm and data set configuration method, it was confirmed that the scene recognition performance for the manufacturing workspace was improved by 28%p compared to the existing method.

* 본 성과물은 부산광역시의 대학혁신연구단지조성사업 중 “동명대학교 대학혁신연구단지조성사업” 지원으로 수행되었음.(IURP2201)

• First Author : Tongmyong University Department of Computer & Media Engineering, js.kim@ezgeo.com, 종신회원

o Corresponding Author : Tongmyong University Department of Computer Engineering, dmlee@tu.ac.kr, 종신회원

논문번호 : 202112-335-C-RN, Received December 16, 2021; Revised March 18, 2022; Accepted March 22, 2022

I. 서 론

기업의 작업공간(Workspace)은 작업공정에 따라 조립장, 검사장, 창고, 수작업장 등 작업유형에 따른 특징에 맞게 구성되어 있다. 작업자는 이러한 각 작업 공간을 이동하며 각 작업장에 맞는 작업을 작업지시에 맞춰 수행한다. 이 경우, 작업자의 안전하고 효율적인 작업을 위해 작업방법 안내, 안전관리요소 안내, 설비상태의 안내 등 작업장의 장소에 따른 다양한 정보 서비스 제공이 필요하다. 이러한 서비스를 위해 작업자와 작업공간의 정확한 위치측위가 필요하다.

위치측위 기술은 RF(Radio Frequency) 기반 측위, 관성 측정 기반 측위, 의사위성(Pseudolite) 기반 측위, Floor Sensor 기반 측위, RFID(Radio Frequency Identification) 기반 측위, 자기(Magnetic System) 기반 측위 등 다양한 방법들로 나뉜다. 특히 측위정보를 의미 있는 장소 정보로 만들기 위해서는 실내 지도 및 실내공간 모델 구축이 필요하다¹⁾. RF기반의 방법에서는 측위를 위해 추가적인 설비 도입과 실내 지도 구축 및 실내공간 모델등의 과정이 필요하며, 이는 초기 시스템의 구축에 고비용이 요구되는 단점이 있다²⁾. 관성측정 장치(IMU: Inertial Measurement Unit) 기반 위치측위는 RF 기반 측위에 비해 초기 인프라 구축에 따른 비용과 불편함의 문제를 해결 할 수는 있으나 누적오차에 의한 측위 정확도가 감소하는 문제점이 있다³⁾. 마커(Marker)를 이용한 위치측위는 실시간으로 실내공간 인식에는 장점이 있으나 마커를 장소별로 설치를 해야 하며 마커가 훼손 될 경우 인식이 불가능하다는 단점이 있다⁴⁾.

이와 같은 위치측위 방법들은 고비용, 정확도가 떨어지는 문제로 산업현장에 적용하기 어려움이 있으며 최근 딥러닝(Deep Learning) 이미지 인식 기술이 발전함에 따라 이를 활용한 이미지의 장소를 분류하는 연구가 진행되고 있다. 이러한 배경에서 본 논문에서는 산업현장에서 앞서 기술들의 문제점을 해결하고자 딥러닝 모델의 일종인 CNN(Convolutional Neural Network) 기반에서 데이터셋을 구성하고 학습을 실시하고, 장면인식(Scene Recognition) 기법을 이용하여 제조 작업공간 분류 모델을 제안하였다.

II. 관련연구

딥러닝 기반 장면인식 기법을 이용한 제조 작업공간 분류모델의 제안을 위하여 이 논문에서는 딥러닝 데이터 모델, 데이터셋 그리고 실내 장면 분류 연구를

중점적으로 정리하였다.

2.1 CNN 모델

2.1.1 ResNet

ResNet은 신호 표현을 직접 학습하는 대신, 잔류(Residual) 표현 함수를 학습하며 최대 152개까지의 계층으로 구성된 모델이다. 이 모델은 이전 계층에서 다음 계층으로의 입력 매핑을 위한 스킵 연결(Skip Connection 또는 Shortcut Connection)을 도입하였으며, ILSVRC 2015(ImageNet Large Scale Visual Recognition Challenge 2015) 대회의 ‘이미지 분류’ 부문에서, 그리고 마이크로소프트의 MS COCO 2015 대회의 ‘탐지 및 세그먼테이션’ 부문에서 각각 우승을 차지한 바 있다⁵⁾.

2.1.2 DenseNet

기존의 연구인 ResNet, Highway Networks, FractalNets은 네트워크 출력이 가까운 계층에서 스킵 연결(Skip Connection)을 포함한 방법을 제안하였다. 이 방법의 특징은 초기 계층에서 다음 계층으로 단기 경로(Short Path)가 추가되었다는 점이다. 그러나 DenseNet은 네트워크에서 정보의 흐름을 극대화하기 위하여 모든 계층을 연결하기 때문에 기존의 방법에 비해 특성지도(Feature Map)에 대한 학습량이 적다는 장점이 있다⁶⁾.

2.1.3 SqueezeNet

지금까지 YOLOv3(You only look once version 3), Darknet, VGGNet등 인식 정확도의 성능이 우수한 모델들이 출시되고 있으나 이 모델들은 규모가 커서 처리에 과부하가 발생하는 점이 단점이다. 예를 들어 간단한 CNN 모델 중 하나인 AlexNet의 경우, 라즈베리와 모듈이나 스마트폰과 같은 모바일 디바이스에 탑재하기가 어렵다. 그러나 2016년 11월에 발표된 SqueezeNet은 이러한 문제점을 해결하였고 임베디드 분야에서 큰 호응을 얻고 있다⁷⁾.

2.1.4 MobileNet

MobileNet은 모바일 및 임베디드용 디바이스의 딥러닝 처리를 위해 개발된 모델이다. 이 모델은 경량 심층 신경망(Light-weighted Deep Neural Network (DNN)) 구축을 위해 계층의 깊이별 분리가 가능한 간소화된 컨볼루션 구조를 채택하고 있다. 그리고 사용 하드웨어의 제약조건에 따른 적합한 모델을 선택할 수 있고, ImageNet 분류 성능에서 다른 모델에 비해

성능이 더 우수하다는 점이 장점으로 알려져 있다⁸⁾.

2.2 딥러닝 알고리즘 및 데이터셋

대용량 이미지셋을 이용한 이미지 인식 알고리즘의 성능을 평가하는 대회인 ILSVRC 2015에 출전한 딥러닝 알고리즘의 분석 결과는 그림 1과 같다. 그림에서 2010년과 2011년에는 AlexNet와 같은 얇은 구조(Shallow Architecture)의 딥러닝 알고리즘들이 주도로 우승을 차지하였으나 2012년 이후 부터는 CNN과 같은 깊은 구조(Deep Architecture) 기반의 딥러닝 알고리즘들이 우승을 차지하기 시작하였다⁹⁾.

Places365는 MIT에서 만든 장소에 관련된 데이터셋으로 365개의 클래스에 대해 각 5천장의 훈련(Training) 이미지와 100장의 시험(Test) 이미지를 가지고 있다¹⁰⁾. 그리고 MIT의 CSAIL(Computer Science & Artificial Intelligence Laboratory) 컴퓨터 비전 프로젝트에 의하면 데이터셋 중 ResNet이 가장 정확도가 가장 높고, 상위 5개 검증(Validation)셋에서 85.08%, 상위 5개 시험셋에서 85.07%의 성능을 가짐을 발표하였다¹¹⁾.

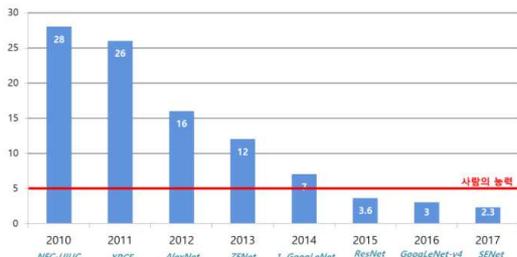


그림 1. 딥러닝 알고리즘의 인식 에러율 비교
Fig. 1. Comparison of recognition error rate of deep learning algorithm.

2.3 컬러 및 깊이 정보 기반 실내 장면 분류 기법

딥러닝 기반의 컬러 및 깊이 정보(Color and Depth Images) 추출 기술을 활용한 장면인식 기법이 자동 잔향 편집(Reverberation Sound Editing)시 공간의 깊이 정보를 사용하기 위해서 제안되었다¹²⁾. 이 기법은 SCR + DNew (Scene Classification for Reverb + Depth Net)를 적용하여 92.4%의 인식 정확도를 달성하였으며, 이는 기존의 CNN기반 분류기 보다 더 높은 성능을 가진다. 그러나 이 기법은 Home 클래스에서는 인식 성능이 우수하지만 콘서트 홀(Concert Hall)과 터널(Tunnel) 클래스에서는 인식 성능이 하락되는 점이 단점으로 평가된다.

III. CNN기반 제조 작업공간 모델 설계

3.1 문제점 정의

선행연구를 통해 본 바와 같이 CNN 기반의 장면 인식 모델은 Places365를 통해 학습을 수행한 모델로 일반 환경에서 정확성이 높다. 그러나 제조현장에서 적용되려면 산업 환경에서 RF 기반 측위, 관성 측정 기반 측위, 마커를 통한 장면인식 및 음성신호를 이용한 측위와 대비하여 유사 및 이상 수준의 정확도가 보장되어야 한다.

3.2 제조 작업공간 모델의 시스템 구성

제안하는 시스템은 CNN 기반의 장면인식 알고리즘을 호출하고 학습을 하고 모델의 성능을 평가 할 수 있어야 한다. 제안 모델은 그림 2에서 보는 바와 같이 데이터셋을 이용하여 학습과 검증을 실시하는 ‘작업공간 분류 딥러닝 학습 모듈’과 가중치를 호출하여 장면을 분류하는 ‘장면인식 모듈’으로 구성된다¹³⁾.

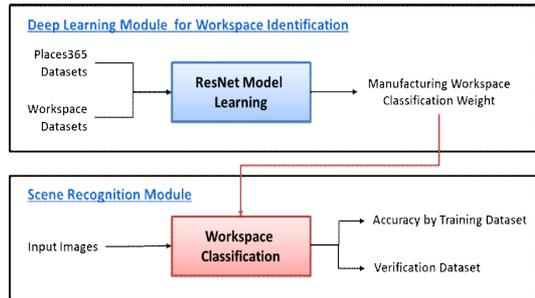


그림 2. 시스템 구성도
Fig. 2. System configuration.

3.3 작업공간 분류 딥러닝 학습 모듈 흐름도

제안하는 딥러닝 기반 장면인식 기법을 이용한 작업공간 분류 딥러닝 모듈은 다음의 단계로 구성되며, 흐름도는 그림 3과 같다.

3.3.1 학습 환경 정의

먼저 학습, 출력 및 연산을 위한 장비의 처리환경을 정의한다. 여기에서는 학습을 위한 파이토치(PyTorch) 라이브러리, 출력을 위한 matplotlib 라이브러리, 그리고 연산을 위한 numpy 라이브러리, 그리고 처리를 위한 CUDA(Compute Unified Device Architecture) 라이브러리를 정의한다.

3.3.2 데이터셋 검색 및 데이터 모델 정의

Train 데이터셋과 Validation 데이터셋을 검색한

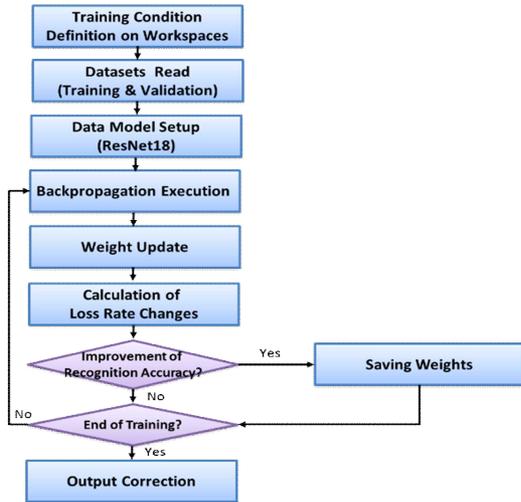


그림 3. 제조 작업장 분류의 딥러닝 모듈 흐름도
Fig. 3. Flows of Deep learning module of Manufacturing workspace classification.

후, 이들이 이미지를 학습에 적합하도록 변이(Crop, Flip)시키고, 전이된 numpy 배열의 이미지를 학습이 가능한 형태로 변환한다. 데이터 모델링의 단계에서는 ResNet 모델을 호출하고 학습에 사용할 장치, 손실함수, optimizer, 입출력 계층(Layer)을 정의한다¹⁴⁾.

3.3.3 역전파(Back Propagation) 단계 실행 및 가중치 변경

역전파 단계를 수행하기 위하여 변화도 값을 초기화하고, 경사 하강법(gradient descent)을 사용하여 optimizer 가중치를 갱신한다. 그 다음, 데이터 모델을 수행하여 매개변수에 대한 손실의 변화도를 계산한 후 이를 평가하여 가중치가 업데이트 되었으면 이를 저장한다¹⁵⁾.

3.4 데이터셋 정의

앞서 조사된 ResNet, DenseNet, SqueezeNet, MobileNet의 작업장 평가 정확도에 따라 최적의 알고리즘이 선정되면 해당 알고리즘을 활용하여 다음의 3가지 전략으로 데이터셋에 따른 정확성을 평가하며 세부적인 내용은 표 1과 같다.

[전략 1] Places365에서 5종의 연관 데이터셋 학습

- Places365의 데이터셋 중 본 논문에서 정의된 ‘모텔 공장’의 5종 장면인 조립라인(Assembly Line), 자동화 공장(Auto Factory), 화학 실험실(Chemistry Lab), 정비공장(Repair Shop), 저장고

표 1. 데이터셋 구성
Table 1. Datasets configuration

Datasets	Characteristics	Remarks
Places365 dataset	<ul style="list-style-type: none"> • 5 Scenes on Places365 • 23,115 images - Training datasets: - 22,615 images; - Validation datasets: - 500 images 	<ul style="list-style-type: none"> • Training datasets: - assembly line (4,168); - auto_factory(5,000); - chemistry_lab(3,447); - repair_shop(5,000); - storage_room(5,000) • Validation datasets: - 100 jpeg images per scene
Workspace dataset	<ul style="list-style-type: none"> • Scenes on Google searching • 40,000 images - Training datasets: - 3,500 images; - Validation datasets: - 500 images 	<ul style="list-style-type: none"> • Training datasets: - 700 images per scene • Validation datasets: - 100 images per scene
Test dataset	Google searching 50 images	10 jpg images per scene

(Storage Room)에 대한 이미지를 사용함

[전략 2] 제조공간 데이터셋 5종만 학습

- 전략 1의 5종에 관련된 데이터 분류를 Google을 통해 검색된 이미지만을 활용하여 ‘산업현장 데이터셋’을 구축함

[전략 3] 전략 1과 전략 2를 혼합하여 학습

- 전략 1을 통해 선별된 5종의 Places365 이미지와 전략 2의 ‘산업현장 데이터셋’을 혼합하여 이미지를 구축함

‘Places365’ 데이터셋은 기존의 Places365 데이터셋에서 CNN 알고리즘의 평가 방법과 동일한 5개의 부분을 발췌되었고, ‘제조공간 데이터셋’은 해당 장면을 키워드로 사용하여 구글을 통해 7일간 검색한 결과에서 수집되었다. 테스트 데이터셋은 기존의 Places365 데이터셋에서 구글을 통해 수집한 제조공간 이미지 중 100개를 무작위로 추출하여 구성되었다.

IV. 실험 및 결과 분석

4.1 딥러닝 학습 모듈의 장면 분류 성능

학습된 모델이 산업현장 장면인식에 적정인지 확인하기 위해 Places365로 학습된 모델을 이용하여 산업현장 이미지에 대한 작업공간 분류 딥러닝 학습모듈의 성능을 평가한다. 50인 이하의 중소기업 중 원재료

표 2. 주요 공정별 Places365 장면 분류
Table 2. Classification of Places365 scenes by major process

주요공정	Places365 장면 분류	Sample	
Manual assembly	Assembly_line		
Car assembly	Auto_factory		
Chemical management	Chemistry_lab		
Welding, Grinding, Painting	Repair_shop		
Loading materials, Product loading	Storage_room		

를 입고하여 인력, 기계를 통해 가공, 조립 또는 화학적 처리하여 제품을 생산하는 형태의 공장에 적합하도록 Places365 이미지를 표 2와 같이 5개의 장면으로 분류하였다. 각 장면에 대한 적절한 이미지는 Google을 통해 검색하여 무작위로 10개가 선정되었다.

산업현장 이미지 분류에 대한 정확도는 표 3에서 보는 바와 같이 DenseNet, ResNet이 54%로 가장 높게 나타났다. 그리고 대부분의 가중치 모델에서 Chemistry lab, Repair shop, Storage room의 경우, 분류의 정확성이 타 작업 공간에 비해 낮음을 알 수 있다. Chemistry lab의 분류 오류는 Clean_room, Mezzanine, Embassy에서 발생하였고, 그리고 Repair shop의 분류 오류는 Hangar/indoor, Physics_laboratory에서 발생하였다. 학습된 가중치를 적용한 산업현장 장면인식 정확도는 표 3에서 보는 바와 같이 60% 미만으로 나타났는데, 이 결과는 ‘마커 이미지 기반 위치 인식’에 비해 편리성이 확보된다고 하더라도 현장 적용에는 미흡한 것으로 평가된다.

ResNet 모델별 특징 및 성능은 표 4에서 보는 바와 같이 ResNet50는 ResNet18에 비해 메모리 사용량이 10.9GB 더 소요되지만, Top 5의 평균 정확도는 3.4% 더 우수한 것으로 나타났다. 따라서 가성비를 볼 때 ResNet18가 ResNet50에 비해 훨씬 더 우수하기 때문에 본 논문에서는 ResNet18으로 실험하였다.

표 3. 장면인식 모델별 작업공간의 장면 분류 일치 평가표
Table 3. Match evaluation table of workspace classification by scene recognition model

Model	Accuracy (%)	A	B	C	D	E
DenseNet161	54	9	9	1	2	6
MobileNet_v2	50	9	9	2	2	3
ResNet18	54	10	9	0	3	5
Resnet50	54	10	10	1	2	4
Squeezenet1.0	28	8	4	1	0	1
Total	-	46	41	5	9	19

주: A: Assembly line; B:Auto factory; C: Chemistry lab
D: Repair shop; E: Storage room

표 4. ResNet 모델별 특징 및 성능
Table 4. Features and performance by ResNet model

Model Name	Layer Count (Trials)	Memory Used (GB)	Average Accuracy(%)	
			Top 5	All
ResNet18	18	6.2	80.24	74.90
ResNet50	50	17.1	83.64	78.94

4.2 데이터셋 전략에 따른 장면인식 성능 분석

각 전략에 대한 학습의 검증셋의 정확도 결과를 확인한 결과, 전략 1의 경우 검증셋의 최초 학습은 그림 4와 같이 45.4%로 나타났다. 그리고 9회 학습에서 정확도가 61.4%로 증가하고 이후 정확도가 10%p 이상 상승하지 않았다.

전략 2의 경우, 최초 정확도는 그림 5에서 보는 바와 같이 1.2%로 낮게 나타났다. 그리고 108회 학습에서 80%로 정확도가 증가되었으나 이후 정확도가 10% 이상 상승하지 않았다. 전략 3의 경우, 그림 6에

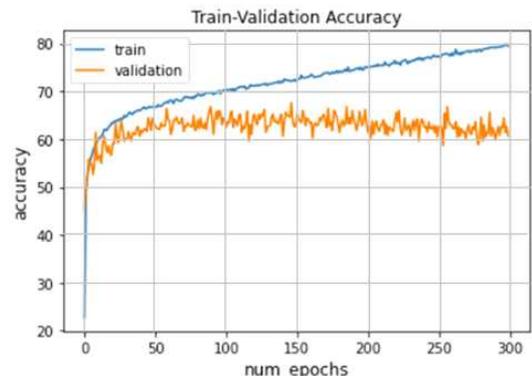


그림 4. 전략 1: 데이터셋 정확도(300회 학습)
Fig. 4. Strategy 1: Dataset Accuracy (300 learnings)

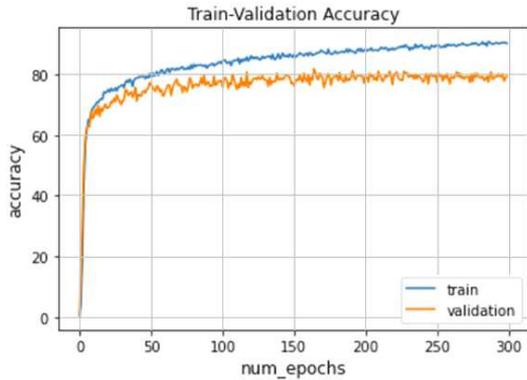


그림 5. 전략 2: 데이터셋 정확도(300회 학습)
Fig. 5. Strategy 2: Dataset Accuracy (300 learnings)

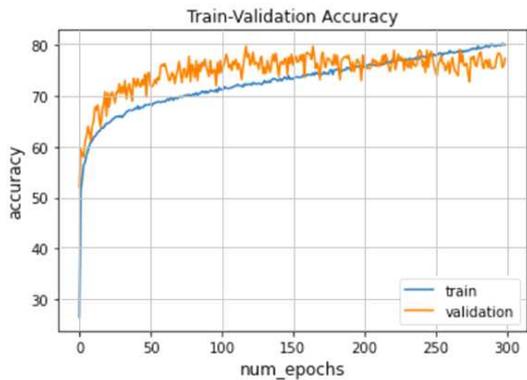


그림 6. 전략 3: 데이터셋 정확도(300회 학습)
Fig. 6. Strategy 3: Dataset Accuracy (300 learnings)

서 보는 바와 같이 최초 정확도가 52.0%로 나타났고, 19회 학습에서 70.8%로 증가한 후 그 이후 정확도가 10% 이상 증가하지 않았음을 알 수 있다.

각 전략별 높은 정확도의 검증셋 5개의 측정값은 표 5와 같다. 표 5의 전략별 평가셋 학습결과를 기초로 TOP 5의 평균을 측정한 결과, 전략 2인 산업현장 데이터셋을 통한 학습결과가 81.2%로 가장 높은 정확도를 가지며, 전략 3과 전략 1이 각각 79.4%와 66.8%로 그 다음으로 나타났다.

최종적으로 표 5의 Top 5 Average의 결과 중 가장 학습결과가 우수한 전략 2의 평가셋을 사용하여 작업장별 예측 정확도 시험을 실시하였다. 작업장별 예측 정확도는 표 6에서 보는 바와 같이 82.0%로 측정되었는데(100회 학습 경우), 이 값은 표 3의 54% 보다 28%p 성능이 우수하다.

표 5. 전략별 평가셋 학습결과

Table 5. Learning results of validation dataset on each strategy

	Strategy 1		Strategy 2		Strategy 3	
	Training Trials	Accuracy (%)	Training Trials	Accuracy (%)	Training Trials	Accuracy (%)
Top 5	147	67.6	165	81.8	118	79.8
	90	66.8	192	81.2	165	79.8
	186	66.8	210	81.0	268	79.2
	257	66.8	218	81.0	222	79.0
	59	66.4	228	81.0	240	79.0
Top 5 Average	66.8%		81.2%		79.4%	

표 6. 작업장별 예측 일치 결과(100회 학습 경우)

Table 6. Results of prediction matching by workspace(100 trials case)

Training Trials	Accuracy (%)	Assembly line	Auto factory	Chemistry Lab	Repair Shop	Storage Room	Total
100	82.0	10	10	4	8	9	41
200	80.0	10	10	4	7	9	40
300	80.0	10	9	4	9	9	40

V. 결론

본 논문에서는 제조 산업현장에서 작업장의 분류에 있어서 전통적인 기존 방법의 문제점을 해결하기 위하여 딥러닝 기반 장면인식 기법을 이용한 제조 작업 공간 분류모델을 제안하고 학습회수에 따른 모델의 성능을 분석하였다.

산업현장의 이미지 인식의 경우, 투입되는 컴퓨팅 자원과 시간에 대비하여 ResNet18이 가장 우수한 성능을 가짐을 확인하였다. 데이터셋의 구축전략별 검증셋 정확도는 Top 5의 평균값을 기준으로 Places365의 데이터셋을 부분적으로 사용한 경우 66.8%, 별도로 수집한 제조업 작업장 이미지로 데이터셋을 구성하여 사용한 경우 81.2%, 그리고 두 가지 데이터셋을 혼합한 경우 79.4%으로 각각 측정되었다.

실험 결과, 3가지 전략 중 별도로 구성된 제조업 작업장 이미지로 학습할 경우 검증성능이 가장 우수하다는 것을 확인 할 수 있었다. 그러나 동일 모델에서 학습횟수에 따른 정확도를 비교하면 100회, 200회 및 300회의 정확도는 각각 82%, 80%, 80%로 나타났다. 이 경우, 학습회수와 정확도가 서로 비례하지 않기 때문에 학습횟수를 100회로 조정하였다.

제한한 제조 작업공간 분류모델은 기존 방법이 가지고 있는 비용과 유지보수의 문제를 해결 가능할 것으로 예상된다. 아울러 본 논문 결과는 별도의 인프라 구축 없이 스마트폰 환경에서도 실시간으로 이미지를 수집하고 처리하며 정확성을 높일 수 있을 것으로 기대된다.

References

[1] J. Lu, "Trends in indoor location-based service technology and service development," *Weekly Technol. Trend*, pp. 18-21, Aug. 2013.

[2] J. Y. Ham, et al., "A study on working space safety management services using bluetooth low energy beacon," in *Proc. Symp. KICS*, pp. 366-367, Jan. 2017.

[3] S. H. Park, J. M. Chae, and J. M. Lee, "Pedestrian dead reckoning based position estimation scheme considering pedestrian's various movement type under combat environments," *J. Korea Academia-Ind. Cooperation Soc.*, vol. 17, no. 10 pp. 609-617, 2016.

[4] B. D. Song, B. J. Shin, and H. K. Yang, "A real-time indoor place recognition system using image features detection," *J. KIEEME*, vol. 25, no. 1, pp. 76-83, Jan. 2012.

[5] T. K. Lee, "ResNet," Nov. 10, 2020, <https://medium.com/@codecompose/resnet-e3097d2cf e42>

[6] H. Gao, "DensetNet paper review," Nov. 10, 2021, <https://ysbsb.github.io/cnn/2020/02/12/DenseNet.html>

[7] Engineering student's garage, "[Keras] SqueezeNet Model (CNN)," Nov. 10, 2021, <https://underflow101.tistory.com/27>

[8] A. G. Howard, et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," Nov. 21, 2021, <https://arxiv.org/abs/1704.04861>

[9] Bskyvision, "ILSVRC Competition (Image Net Image Recognition Competition) Winning Algorithms," Nov. 21, 2021, <https://bskyvision.com /425>

[10] R. Sakong, B. Lim, H. Y. Seok, and J. H.

Nang, "More accurate method of places scene classification using cumulative results," in *Proc. Korea Computer Congress 2018*, pp. 891-893, Jeju Island, Korea, Jun. 2018.

[11] Zhoubolei, "Release of Places365-CNNs," Nov. 21, 2021, <https://github.com/CSAIL Vision/places365/blob/master/README.md>

[12] M. H. Jung, et al., "Indoor scene classification based on color and depth images for automated reverberation sound editing," *J. KIICE*, vol. 24, no. 3, pp. 384-390, Mar. 2020.

[13] J. S. Kim, "A study on the deep learning based scene recognition system for the classification of workspace in manufacturing industry," M.S. Thesis, Dept. Engineering, The Graduate School of Tongmyong Univ., pp. 1-53, Feb. 2021.

[14] Laonpeople, "CNN Structure - VGGNet, ResNet," Nov. 21, 2021, <https://m.blog.naver.com/laonple/221259295035>

[15] J. S. Kim and D. M. Lee, "A deep learning module design for workspace identification in manufacturing industry," in *Proc. 3rd ICAIIC 2021*, pp. 390-393, Jeju Island, Korea, Apr. 2021.

김 정 수 (Jeong Su Kim)



2005년 2월 : 동명대학교 컴퓨터미디어 공학과 (학사)
 2021년 2월 : 동명대학교 컴퓨터미디어 공학과 (석사)
 2021년 3월~현재 : 동명대학교 컴퓨터미디어공학과 (박사과정 재학)

2004년 7월~현재 : 이지지도 대표

<관심분야> 영상처리, 위치추정 시스템, 센서 네트워크, 임베디드

이 동 명 (Dong Myung Lee)

한국통신학회 논문지 제45권 제7호 참조 (2020년 7월)