

A Study on the Outlet Blockage Determination Technology of Conveyor System using Deep Learning

Eui-Han Jeong*, Young-Joo Suh**, Dong-Ju Kim*

*Researcher, Postech Institute of Artificial Intelligence, POSTECH, Pohang, Korea

**Professor, Dept. of Computer Science and Engineering, POSTECH, Pohang, Korea

*Research Professor, Postech Institute of Artificial Intelligence, POSTECH, Pohang, Korea

[Abstract]

This study proposes a technique for the determination of outlet blockage using deep learning in a conveyor system. The proposed method aims to apply the best model to the actual process, where we train various CNN models for the determination of outlet blockage using images collected by CCTV in an industrial scene. We used the well-known CNN model such as VGGNet, ResNet, DenseNet and NASNet, and used 18,000 images collected by CCTV for model training and performance evaluation. As a experiment result with various models, VGGNet showed the best performance with 99.03% accuracy and 29.05ms processing time, and we confirmed that VGGNet is suitable for the determination of outlet blockage.

▶ **Key words:** Conveyor Systems, Blockage Determination, Deep Learning, Convolutional Neural Network, Visual Geometry Group Network, Residual Network, Dense Network, Neural Architecture Search Network

[요 약]

본 연구는 컨베이어 시스템에서 딥러닝을 이용한 배출구 막힘 판단 기술에 대하여 제안한다. 제안 방법은 산업 현장의 CCTV에서 수집한 영상을 이용하여 배출구 막힘 판단을 위한 다양한 CNN 모델들을 학습시키고, 성능이 가장 좋은 모델을 사용하여 실제 공정에 적용하는 것을 목적으로 한다. CNN 모델로는 잘 알려진 VGGNet, ResNet, DenseNet, 그리고 NASNet을 사용하였으며, 모델 학습과 성능 테스트를 위하여 CCTV에서 수집한 18,000장의 영상을 이용하였다. 다양한 모델에 대한 실험 결과, VGGNet은 99.89%의 정확도와 29.05ms의 처리 시간으로 가장 좋은 성능을 보였으며, 이로부터 배출구 막힘 판단 문제에 VGGNet이 가장 적합함을 확인하였다.

▶ **주제어:** 컨베이어 시스템, 막힘 판단, 딥러닝, CNN, VGGNet, ResNet, DenseNet, NASNet

-
- First Author: Eui-Han Jeong, Corresponding Author: Dong-ju Kim
 - *Eui-Han Jeong (defined314@postech.ac.kr), Postech Institute of Artificial Intelligence, POSTECH
 - **Young-Joo Suh (yjsuh@postech.ac.kr), Dept. of Computer Science and Engineering, POSTECH
 - *Dong-ju Kim (kkb0320@postech.ac.kr), Postech Institute of Artificial Intelligence, POSTECH
 - Received: 2020. 01. 06, Revised: 2020. 04. 24, Accepted: 2020. 04. 24.

I. Introduction

컨베이어 시스템은 자동으로 재료나 반제품, 또는 완제품 등을 운반하는 기계 장치이다. 현재 컨베이어 시스템 내에서 제품의 불량을 검출하는 기술은 상당히 자동화되어 있으나, 컨베이어 시스템의 끝 부분인 배출구의 막힘 상태를 판단하는 기술은 아직 자동화가 되어 있지 않은 경우가 대부분이며, 이에 작업자가 배출구의 상태를 수시로 확인하고 있는 실정이다. 제조 산업분야에 있어, 컨베이어 시스템의 배출구가 막혔을 때, 이에 대한 대처가 늦어지게 되면, 작업장 안전사고 및 제조 수율 하락 등의 요인으로 기업의 손실이 발생할 수 있기 때문에, 컨베이어 시스템의 배출구 막힘 상태를 자동으로 판단하는 기술 개발의 필요성이 대두되고 있다.

철강 제조분야 있어, 원료 혼합 슈트의 배출구 막힘 상태를 판단하는 기존 기술로는 물리적 장치를 이용한 막힘 방지 기술[1-3] 및 센서를 이용한 막힘 판단 기술[4-5] 등이 있다. 하지만, 금속 스크랩 슈트의 경우, 배출구 막힘 상태를 판단하는 기술은 없으며, 이에 금속 스크랩 슈트의 막힘 상태를 판단하는 기존 방식은 한 명 이상의 작업자가 수시로 배출구 상태를 직접 확인하는 방식으로 작업을 진행하고 있다.

금속 스크랩은 금속 제품을 만들 때 발생하는 금속 부스러기로 철강재 생산에 재활용되며 제조원가의 50% 이상을 차지하는 주요 자원이다. 이에, 본 연구에서는 금속 스크랩의 재활용에 대한 중요성을 인지하고, 기존 작업자 감시 중심의 비효율성을 개선하고자, 산업현장에서 수집한 CCTV 영상과 딥러닝 알고리즘을 사용한 금속 스크랩 슈트의 배출구 막힘 상태 판단 방법에 대하여 제안한다.

II. Preliminaries

1. Overview of deep learning algorithm

딥러닝(Deep Learning)은 크게는 인공지능(Artificial Intelligence, AI), 작게는 머신러닝(Machine Learning, ML)의 한 갈래로 인공신경망(Artificial Neural Network, ANN)을 이용하면서 다중 레이어를 사용하여 깊은 학습을 하는 분야이다.

딥러닝의 대표적인 방법 중에 CNN(Convolutional Neural Network)[6]은 1989년 Y. LeCun이 발표한 논문[7]에서 소개되었고, 1998년 발표한 논문[8]에서 손글씨

숫자 인식을 위한 새로운 모델을 제안하면서 많은 사람에게 알려졌다.

일반적으로 CNN은 합성곱 계층(Convolution Layer)과 풀링 계층(Pooling Layer)의 반복된 구조로 이루어진 모델로, 주로 이미지 인식에 널리 사용되고 있으며, 잘 알려진 모델로는 VGGNet, ResNet, DenseNet, NASNet 등이 있다. 그림 1은 CNN 모델[9]의 알고리즘 예시를 나타낸다.




Fig. 1. Example Algorithm of CNN Model

1.1 VGGNet

VGGNet[10-11]은 2014년 대용량의 이미지 데이터셋으로 이미지 인식 알고리즘의 성능을 평가하는 대회인 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)에서 2위를 했지만, 간단한 구조로 인해 이해와 변형이 쉬워 많이 응용되고 있는 모델이다.

AlexNet, GoogLeNet과 비교하여 3x3 이라는 작은 사이즈로 합성곱 연산을 하지만, 연산을 여러 번 수행하여 큰 사이즈로 연산을 한 것보다 좋은 성능을 낸다.

하지만 연산을 여러 번 수행하다 보니 파라미터가 과도하게 많아지고 기울기 소실(Gradient Vanishing)[12]이나 과적합(Overfitting) 등의 문제가 발생할 가능성이 크다는 단점이 있다. 그림 2는 VGGNet 모델[13]의 대표적인 구조를 나타낸다.




Fig. 2. Architecture of VGG Model

1.2 ResNet

ResNet[14]은 신경망이 깊어질수록 학습이 어려워지는 문제를 해결할 수 있는 모델이다.

보통 신경망이 깊어질수록 성능이 좋아진다고 생각할 수 있지만, 단순한 네트워크(Plain Network)에서는 일정 수준 이상으로 신경망이 깊어지면 기울기 소실이나 기울기 폭주(Gradient Exploding) 또는 성능 저하 등의 문제가 생긴다. ResNet에서는 이 중 성능 저하 문제를 해결하기 위해서 잔차(Residual)를 학습하는 방법을 이용하며, 깊은 신경망에서도 학습하기 쉽다는 장점이 있다. 그림 3은 ResNet에서 사용되는 잔차 블록(Residual Block)과 지름길 연결(Skip Connection)을 나타낸다.




Fig. 3. Residual Block and Skip Connection

1.3 DenseNet

DenseNet[15]은 2016년 제안된 모델로, DenseNet에서는 ResNet의 지름길 연결 대신에 밀집 블록(Dense Block)을 이용한 완전 연결(Dense Connectivity)를 제안하였다. DenseNet을 사용하면 신경망이 깊어질수록 심해지는 기울기 소실 문제가 발생하지 않고, 깊이에 비해 파라미터 수가 적어서 연산량이 적고, 적은 데이터셋에서도 비교적 학습이 잘 되는 장점이 있다. 그림 4는 DenseNet 모델[16]에서 사용되는 밀집 블록과 완전 연결을 나타낸다.




Fig. 4. Dense Block and Dense Connectivity

1.4 NASNet

AutoML(Automated Machine Learning, 자동화된 머신러닝) 중, NAS(Network Architecture Searching)[17]는 강화학습 등으로 최적의 신경망 구조를 찾는 방법론이며, 이를 발전시킨 것이 NASNet[18]이다. NAS를 이용하여 최적의 신경망 구조를 찾는다면 성능은 좋지만 최적의 신경망 구조를 찾는 데 많은 시간이 소요되는 단점이 있다. 그러나 NASNet은 최적의 신경망 구조를 찾을 때, 이

미지 분류를 위한 CNN 구조만으로 범위를 제한하기 때문에 최적의 신경망 구조를 찾는 데 시간이 많이 줄어든다.

III. The Proposed Scheme

1. Overview

그림 5는 다양한 CNN 모델을 학습하는 흐름도이다. 본 연구에서는 산업 현장의 CCTV에서 수집한 영상을 이용하여 다양한 CNN 모델들을 학습시키고, 학습한 모델들의 성능 평가를 통하여 가장 성능이 좋은 모델을 선정하였다.




Fig. 5. Flowchart of Training CNN Models

본 논문에서 CCTV에서 수집한 영상은 컨베이어 시스템의 배출구와 스크랩이 적재되는 스크랩 박스가 함께 모니터링되고 있기 때문에 배출구만 볼 수 있도록 관심이 있는 영역 (Region Of Interest, ROI)을 설정하였다. 더불어, 수집 영상을 막힌 상태와 정상 상태를 구분하고, 학습용과 검증용 그리고 실험용 데이터로 나누어 데이터셋을 구축하였다.

학습시에는 학습용 데이터를 이용하여 다양한 CNN 모델들을 학습하며, CNN 모델로는 TensorFlow Keras 어플리케이션[19]에서 지원하는 VGGNet과 ResNet, 그리고 DenseNet와 NASNet 모델들을 사용하였다. 이 때, 각 모델에 ImageNet 데이터셋으로 학습시킨 가중치를 전이 학습하였다.

그림 6은 본 논문에서 구현한 시스템이 산업 현장에 실제 적용되는 공정 흐름도를 나타낸다. 여기서 수집 데이터를 기반으로 다양한 CNN 모델들을 학습하고, 성능이 가장 좋은 모델을 실제 공정의 배출구 막힘 인식에 적용하였다.




Fig. 6. Flowchart of Actual Process

2. Data collection

본 논문에서는 산업 현장의 CCTV를 이용하여 99,000장의 영상을 수집하였고, 이 중에 배출구가 막힌 상태인 영상 9,000장, 정상 상태인 영상 9,000장을 선별하여 실험에 사용하였다. 그림 7은 산업 현장 CCTV를 이용하여 취득한 영상과 취득 영상 내에서 배출구가 막힌 부분에 대한 예시를 보이고 있다.



Fig. 7. CCTV Video Example of Real Work Site

더불어, 그림 8과 9는 각각 CCTV 영상을 이용하여 구축한 정상 상태와 막힘 상태의 영상 예시를 보여주고 있다.



Fig. 8. Normal Dataset Examples




Fig. 9. Blockage Dataset Examples

일반적으로 분류 문제에 있어 학습용(Train)과 실험용(Test) 데이터의 비율로 8:2 또는 7:3을 사용[20]한다. 이에, 본 논문에서는 데이터의 수집이 어려운 상황에서 학습에 더 많은 데이터를 사용하기 위하여[21], 선별 데이터의 80%를 학습용과 검증용(Valid) 데이터로 나누어 사용하였고, 나머지 20% 데이터만 실험용 데이터로 사용하였다. 그림 10과 같이 학습용, 검증용 그리고 실험용 데이터의 비율을 7:1:2로 구성하였고, 구축한 데이터셋을 이용하여 개발 시스템의 성능을 평가하였다.

또한 CCTV에서 수집한 원 영상의 경우 배출구와 스크랩 박스가 함께 나타나게 되어서, 그대로 사용한다면 학습 시간과 정확도에 영향을 미치기 때문에, 배출구 영역을 관심이 있는 영역(ROI)으로 설정하였다.



Fig. 10. Dataset for Blockage Determination

3. Evaluation indicator

배출구 막힘 판단 성능을 평가하기 위해 고려해야 한 것은 크게 2가지이다.

첫 번째는 정확도이다. 우선 배출구가 정상 상태일 때를 Negative, 막힌 상태일 때를 Positive라고 정의한다. 이 때, 배출구가 막힌 상태라고 예측했는데 정상 상태일 경우 (False Positive)에는 배출구 상태 점검을 위해 인력 낭비 등이 발생하지만 이는 큰 문제가 아니다. 하지만 정상 상태라고 예측했는데 배출구가 막힌 상태일 경우(False Negative)에는 사고 또는 상품이 망가지는 문제 등으로 이어질 수 있어 상대적으로 더 중요하게 봐야 한다. 그렇기 때문에 본 연구에서는 표 1의 혼동행렬(Confusion Matrix)와 수식 3의 F1 스코어를 평가 지표를 사용하여 정확도를 확인하였다.

Table 1. Confusion Matrix of Binary Classification

		Predicted	
		Positive	Negative
Actual	Positive	True Positive	False Positive
	Negative	False Negative	True Negative

Math Exp 1. Evaluation Indicator for Accuracy

$$Precision = \frac{TP}{TP+FP} = \frac{TP}{all\ detections} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} = \frac{TP}{all\ ground\ truths} \quad (2)$$

$$F_1 = 2 \times \frac{1}{1/recall + 1/precision} = 2 \times \frac{precision \times recall}{precision + recall} \quad (3)$$

수식 1과 2에서 TP(True Positive)는 배출구가 막힌 상태라고 예측했는데 막힌 상태인 수, all detections는 배출구가 막힌 상태라고 예측한 수, 그리고 all ground truths는 실제 배출구가 막힌 상태인 수이다. 최종적으로, 정밀도(Precision)와 재현율(Recall) 그리고 수식 3을 이용하여 F1 스코어를 계산하고, 모델의 정확도를 측정하였다.

두 번째는 처리 시간이다. CCTV에서 받은 영상으로 3,000장의 이미지를 만들고, 처음 1장을 제외한 2,999장의 처리 시간을 확인하였다. 산업의 특성상 배출구 막힘 판단이 늦어지면 이는 손해로 이어지기 때문에 일정 기준 보다는 처리 시간이 짧아야 한다.

IV. Experiment

1. Performance evaluation

에폭(Epoch)이 크다는 것은 학습을 많이 시켰다는 의미를 갖는다. 일반적으로, 에폭이 커질수록 모델의 성능은 좋아지지만, 학습용 데이터에 과적합되어 성능이 떨어질 수도 있다. 최적의 성능을 갖는 에폭을 찾기 위하여, 본 논문에서는 다양한 에폭에서 모델을 평가하였다.

1.1 Accuracy of each model

VGGNet, ResNet, DenseNet, NASNet 모델의 에폭별 실험 결과를 표 2부터 표 5에 각각 혼동행렬 형태로 나타내었다. 본 논문에서는 혼동행렬을 통하여 각 모델에 따른 성능을 확인할 수 있었고, 같은 모델이어도 에폭에 따라 정확도가 바뀌는 것을 확인할 수 있었다.

Table 2. Confusion Matrix of VGGNet Model by Epochs

		VGGNet(25epoch)		VGGNet(50epoch)	
		blocked	unblocked	blocked	unblocked
True label	blocked	1788	4	1787	5
	unblocked	1	1791	1	1791
		VGGNet(75epoch)		VGGNet(100epoch)	
		blocked	unblocked	blocked	unblocked
True label	blocked	1790	2	1789	3
	unblocked	2	1790	2	1790

Table 3. Confusion Matrix of ResNet Model by Epochs

		ResNet(25epoch)		ResNet(50epoch)	
		blocked	unblocked	blocked	unblocked
True label	blocked	1617	175	1655	137
	unblocked	1	1791	1	1791
		ResNet(75epoch)		ResNet(100epoch)	
		blocked	unblocked	blocked	unblocked
True label	blocked	1689	103	1700	92
	unblocked	1	1791	1	1791

Table 4. Confusion Matrix of DenseNet Model by Epochs

		DenseNet(25epoch)		DenseNet(50epoch)	
		blocked	unblocked	blocked	unblocked
True label	blocked	1787	5	1790	2
	unblocked	2	1790	2	1790
		DenseNet(75epoch)		DenseNet(100epoch)	
		blocked	unblocked	blocked	unblocked
True label	blocked	1790	2	1790	2
	unblocked	2	1790	2	1790

Table 5. Confusion Matrix of NASNet Model by Epochs

		NASNet(25epoch) Confusion Matrix		NASNet(50epoch) Confusion Matrix	
		blocked	unblocked	blocked	unblocked
True label	blocked	1676	116	1784	8
	unblocked	1	1791	2	1790
		blocked	unblocked	blocked	unblocked
		Predicted label		Predicted label	

		NASNet(75epoch) Confusion Matrix		NASNet(100epoch) Confusion Matrix	
		blocked	unblocked	blocked	unblocked
True label	blocked	1788	4	1787	5
	unblocked	2	1790	2	1790
		blocked	unblocked	blocked	unblocked
		Predicted label		Predicted label	

실험 결과로부터 VGGNet과 NASNet 모델의 경우, 100epoch이 되면 과적합 등의 문제로 정확도가 오히려 떨어지는 현상을 확인할 수 있었다. 이에 모델별의 성능 비교를 위하여, 본 논문에서는 75epoch을 기준으로 하여 모델별 성능 평가를 수행하였다. 표 6은 75epoch일 때의 모델별 혼동행렬을 나타내며, 이로부터 모델별 정확도를 확인할 수 있었다.

Table 6. Confusion Matrix of Each Model at same Epoch

		VGGNet(75epoch) Confusion Matrix		ResNet(75epoch) Confusion Matrix	
		blocked	unblocked	blocked	unblocked
True label	blocked	1790	2	1689	103
	unblocked	2	1790	1	1791
		blocked	unblocked	blocked	unblocked
		Predicted label		Predicted label	

		DenseNet(75epoch) Confusion Matrix		NASNet(75epoch) Confusion Matrix	
		blocked	unblocked	blocked	unblocked
True label	blocked	1790	2	1788	4
	unblocked	2	1790	2	1790
		blocked	unblocked	blocked	unblocked
		Predicted label		Predicted label	

1.2 Processing time of each model

표 7은 75epoch일 때, 각 모델별 처리 시간을 비교한 결과이다. 실험은 총 3,000장의 테스트 영상으로 처리시간을 측정하였으며, 모델별 처리 시간의 비교는 첫 번째 영상을 제외한 나머지 2,999장에 대한 평균 처리 시간을 기준으로 하였다. 이는 표 7에서 “average process time

without 1’s”으로 표현되어 있으며, 첫 번째 영상에 대한 시간은 모델 로딩 시간을 포함하기 때문에 평균 시간 계산에서 제외하였다. 실험 결과로부터 평균 처리 시간은 VGGNet 모델이 29.05ms로 가장 좋은 반면 NASNet 모델은 42.98ms로 가장 길었다.

Table 7. Average Process Time of Each Model at Same Epoch

VGGNet(75epoch)	
1 's process time:	2.31518722
3000 's process time:	0.02847767
total data's process time:	89.45301342
average process time:	0.02981048
average process time without 1's:	0.02904843
ResNet(75epoch)	
1 's process time:	3.09930587
3000 's process time:	0.03230858
total data's process time:	97.89394140
average process time:	0.03262345
average process time without 1's:	0.03160088
DenseNet(75epoch)	
1 's process time:	4.48144746
3000 's process time:	0.03757048
total data's process time:	113.02252245
average process time:	0.03766639
average process time without 1's:	0.03618464
NASNet(75epoch)	
1 's process time:	7.41918182
3000 's process time:	0.04364610
total data's process time:	136.33688521
average process time:	0.04543749
average process time without 1's:	0.04297875

2. Summary

본 논문에서는 표 8에 CNN 모델들에 대한 성능평가 결과를 정확도와 처리 시간으로 요약하여 나타내었다. CNN 모델들의 성능평가 결과, 정확도는 VGGNet과 DenseNet이 99.89%로 가장 높았고, 처리 시간은 VGGNet이 29.05ms로 가장 짧은 것을 확인할 수 있었다. 이때, 정확도는 F1 스코어를 기준으로 비교하였고, 처리 시간은 테스트 영상 2,999장을 처리하는데 소모되는 평균시간을 기준으로 하였다. 이로부터, 본 논문에서 제안하는 배출구 막힘 판단 시스템에 VGGNet이 다른 모델들 보다 정확도와 처리 시간 측면에서 가장 좋은 성능을 보임을 확인할 수 있었다.

Table 8. Model Evaluation in terms of Accuracy and Process Time

Model name	Evaluation indicator	Value	Rank
VGGNet	Accuracy	99.89%	1
	Processing Time	29.05ms	1
ResNet	Accuracy	97.10%	3
	Processing Time	31.60ms	2
DenseNet	Accuracy	99.89%	1
	Processing Time	36.18ms	3
NASNet	Accuracy	99.83%	2
	Processing Time	42.98ms	4

V. Conclusions

본 논문에서는 컨베이어 시스템의 완전 자동화를 위한 연구를 포함하고 있으며, 컨베이어 시스템의 배출구 막힘 판단 부분을 자동화하기 위한 CNN 기반의 상태인식 시스템을 제안하였다. 다양한 CNN 모델을 이용하여 시스템을 구현하고 성능평가를 수행한 결과, 정확도와 처리 시간 측면에 있어 VGGNet이 가장 좋은 성능을 보임을 확인하였다.

일반적으로 분류 대상이 다수인 복잡한 문제에 있어서는 ResNet이나 NASNet 등과 같은 깊은 네트워크가 좋은 성능을 보인다. 하지만, 본 논문에서의 배출구 막힘 판단 문제와 같이 상대적으로 간단한 문제에서는 VGGNet만으로도 충분한 정확도를 도출할 수 있음을 실험으로부터 확인할 수 있었다. 또한, VGGNet의 처리 시간이 다른 모델들에 비해 더 빠르기 때문에 VGGNet이 본 문제에 있어 최적의 모델임을 확인 할 수 있었다.

ACKNOWLEDGEMENT

This work(research) was supported by 2019 R&D support project based on science and technology according to the regional demand funded by the Ministry of Science and ICT(CN19100GB001).

REFERENCES

- [1] Hyundai Steel Co., Ltd., "DEVICE FOR PREVENTING CHUTE CLOGGING," 10-1968857, Apr 08, 2019.
- [2] POSCO Co., Ltd., "Device for preventing chute clogging," 10-1635986, Jun 28, 2016.
- [3] POSCO Co., Ltd., "Apparatus and method for preventing a bin chute from being clogging," 10-1543590, Aug 05, 2015.
- [4] POSCO Co., Ltd., "ANTI-CLOG CHUTE," 10-1289150, Jul 17, 2013.
- [5] POSCO Co., Ltd., "APPARATUS FOR DETECTING CLOGGING OF COKE BIN CHUTE," 10-1289420, Jul 18, 2013.
- [6] CS231n Convolutional Neural Networks for Visual Recognition, "CS231n Convolutional Neural Networks for Visual Recognition", <http://cs231n.github.io/convolutional-networks/>
- [7] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, L. D. Jackel, "Backpropagation Applied to Handwritten Zip Code Recognition," NEURAL COMPUTATION, Vol. 1, No. 4, pp. 541-551, Dec 1989. DOI: 10.1162/neco.1989.1.4.541
- [8] Y. Lecun, L. Bottou, Y. Bengio, P. Haffner, "Gradient-based learning applied to document recognition," PROCEEDINGS OF THE IEEE, Vol. 86, No. 11, pp. 2278-2324, Nov 1998. DOI: 10.1109/5.726791
- [9] Mathworks Korea, "Convolutional Neural Network," <http://blog.naver.com/PostView.nhn?blogId=matlablove&logNo=221611175120&parentCategoryNo=29&categoryNo=&viewDate=&isShowPopularPosts=false&from=postView>
- [10] K. Simonyan, A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," International Conference on Learning Representations (ICLR) 2015, Sep 2014. CoRR, abs / 1409.1556
- [11] B. B. Shi, R. Hou, M. A. Mazurowski, L. J. Grimm, Y. H. Ren, J. R. Marks, L. M. King, C. C. Maley, E. S. Hwang, J. Y. Lo, "Learning better deep features for the prediction of occult invasive disease in ductal carcinoma in situ through transfer learning," MEDICAL IMAGING 2018: COMPUTER-AIDED DIAGNOSIS, Vol. 10575, Houston, USA, Feb 2018. DOI: 10.1117/12.2293594
- [12] WikiDocs, "Gradinet Vanishing and Exploding," <https://wikidocs.net/61375>
- [13] K. M. He, X. Y. Zhang, S. Q. Ren, J. Sun, "Deep Residual Learning for Image Recognition," 2016 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), pp. 770-778, Seattle, USA, Jun 2016. DOI: 10.1109/CVPR.2016.90
- [14] B. Kazimi, F. Thiemann, K. Malek, M. Sester, K. Khoshelham, "Deep Learning for Archaeological Object Detection in Airborne

Laser Scanning Data," 2nd Workshop On Computing Techniques For Spatio-Temporal Data in Archaeology And Cultural Heritage (COARCH 2018), Vol. 2230, pp. 21-35, Melbourne, AU, Aug 2018. DOI: 10.4230 / LIPIcs.COARCH.2018


- [15] G. Huang, Z. Liu, L. van der Maaten, K. Q. Weinberger, "Densely Connected Convolutional Networks," 30TH IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR 2017), pp. 2261-2269, Honolulu, USA, Nov 2016. DOI: 10.1109 / CVPR.2017.243
- [16] G. Huang, S. Liu, L. van der Maaten, K. Q. Weinberger, "CondenseNet: An Efficient DenseNet Using Learned Group Convolutions," 31st IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2018), pp. 2752-2761, Salt Lake City, USA, Jun 2018. DOI: 10.1109 / CVPR.2018.00291
- [17] B. Zoph, Q. V. Le, "Neural Architecture Search with Reinforcement Learning," International Conference on Learning Representations (ICLR) 2017, Jul 2017. CoRR, abs / 1611.01578
- [18] B. Zoph, V. Vasudevan, J. Shlens, Q. V. Le, "Learning Transferable Architectures for Scalable Image Recognition," 2018 IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), pp. 8697-8710, Salt Lake City, USA, Jun 2018. DOI: 10.1109 / CVPR.2018.00907
- [19] Keras Documentation, "Models for image classification with weights trained on ImageNet," <https://keras.io/applications/>
- [20] S. Raschka, "Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning," Nov 2018. arXiv: 1811.12808
- [21] K. K. Dobbin, R. M. Simon, "Optimally splitting cases for training and testing high dimensional classifiers," BMC Medical Genomics, vol. 4, no. 31, Apr 2011. DOI: 10.1186 / 1755-8794-4-31

Authors



Eui-Han Jeong received the B.S. degree in Electronic Engineering from Jeonbuk National University, Korea, in 2015 and M.S. degree in Electronic and Information Engineering (Electronics) from Jeonbuk National

University, Korea, in 2017. Mr. Jeong joined the Researcher of the Research Department of Postech Information Research Laboratories, POSTECH, Pohang, Korea, in 2019. He is currently a Researcher of the Research Department of POSTECH Institute of Artificial Intelligence. He is interested in Computer Vision, Image Processing, Smart Factory.



Young-Joo Suh received the B.S., M.S. degrees in Electronics Engineering from Hanyang University, Korea, in 1985, 1987, respectively and Ph.D. degree in Electrical and Computer Engineering from Georgia

Institute of Technology, Georgia in 1996. Dr. Suh joined the faculty of the Department of Computer Science and Engineering at POSTECH, Pohang, Korea, in 1998. He is currently a Professor in the Department of Computer Science and Engineering, POSTECH. He is interested in wireless LAN MAC protocol, mobility management, 5G mobile networks, and indoor positioning systems.



Dong-Ju Kim received the B.S., M.S. degrees in Radio Wave Engineering from Chungbuk National University, Korea, in 1998, 2000, respectively and Ph.D. degree in Electric, Electronic and Computer Engineering from

Seongkyungwan National University, Korea, in 2010. Dr. Kim joined the Senior Researcher of the Research Department of Postech Information Research Laboratories, POSTECH, Pohang, Korea, in 2016. He is currently a Research Professor of the Research Department of Postech Institute of Artificial Intelligence. He is interested in Face Recognition, HCI, Computer Vision, Artificial Intelligence.