

MobileNetV2 기반의 개선된 Lightweight 모델을 이용한 열화 도로 영상에서의 블랙 아이스 인식

이옥걸¹ · 강선경^{2*}

A Black Ice Recognition in Infrared Road Images Using Improved Lightweight Model Based on MobileNetV2

Yu-Jie Li¹ · Sun-Kyoung Kang^{2*}

¹Lecturer, School of Intelligent Manufacturing, Weifang University of Science and Technology, Shouguang, 262700, China

^{2*}Professor, Department of Computer Software Engineering, Wonkwang University, Iksan, 54538 South Korea

요 약

본 논문에서는 블랙 아이스를 정확하게 인식하고 도로 노면 정보를 운전자에게 미리 알려줘서 속도를 제어하고 예방 조치를 취할 수 있도록 하기 위해 열화 도로 영상을 기반으로 블랙 아이스 검출하기 위해 lightweight 네트워크를 제안한다. 전이학습을 이용하여 블랙 아이스 인식 실험을 하였고, 블랙 아이스 인식의 정확도 향상을 위해 MobileNetV2 기반의 개선된 lightweight 네트워크를 개발하였다. 계산량을 줄이기 위해 Linear Bottleneck 및 Inverted Residuals를 활용하여 4개의 Bottleneck 그룹을 사용하고 모델의 인식률 향상을 위해 각 Bottleneck 그룹에 3 X 3 컨볼루션 레이어를 연결하여 지역적 특징 추출을 강화하고 특징 맵의 수를 늘렸다. 마지막으로 구축된 블랙 아이스 데이터 세트 대상으로 블랙 아이스 인식 실험을 진행하였으며, 제안된 모델은 블랙 아이스에 대해 99.07%의 정확한 인식률을 나타내었다.

ABSTRACT

To accurately identify black ice and warn the drivers of information in advance so they can control speed and take preventive measures. In this paper, we propose a lightweight black ice detection network based on infrared road images. A black ice recognition network model based on CNN transfer learning has been developed. Additionally, to further improve the accuracy of black ice recognition, an enhanced lightweight network based on MobileNetV2 has been developed. To reduce the amount of calculation, linear bottlenecks and inverse residuals was used, and four bottleneck groups were used. At the same time, to improve the recognition rate of the model, each bottleneck group was connected to a 3x3 convolutional layer to enhance regional feature extraction and increase the number of feature maps. Finally, a black ice recognition experiment was performed on the constructed infrared road black ice dataset. The network model proposed in this paper had an accurate recognition rate of 99.07% for black ice.

키워드 : 블랙아이스 인식, 전이학습, 열화 영상, MobileNetV2, Lightweight

Keywords : Black ice recognition, Transfer learning, Infrared images, MobileNetV2, Lightweight

Received 22 November 2021, Revised 24 November 2021, Accepted 30 November 2021

* Corresponding Author Sun-Kyoung Kang (E-mail:doctor10@wku.ac.kr, Tel:+82-63-850-6025)

Professor, Department of Computer Software Engineering, Wonkwang University, Iksan, 54538 South Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.12.1835>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

도로 위의 블랙 아이스는 도로에 나타나는 얇은 얼음 층으로, 거친 노면의 갈라진 틈에 블랙 아يس가 채워지는 경우가 많다. 블랙 아이스 자체는 색깔이 없고 투명하며, 얼음 층 사이로 노면의 색이 보이고 아스팔트 등 어두운 도로에서는 검게 보인다고 하여 블랙 아이스라는 이름이 붙었다[1]. 블랙 아이스 도로는 시각적으로 젖은 노면에 가깝고, 사람 눈으로 식별하기 쉽지 않다.

블랙 아이스는 기온이 0°C 이하로 떨어지면 노면의 수분에 의해 형성되는 얇은 얼음으로 산 그늘, 나무가 많은 도로, 터널 출입구 등 태양이 닿지 않는 곳에서, 그리고 다리 도로 노면에서 주로 발생한다[1]. 한국 국토의 70%가 산지이며, 많은 도로가 산으로 인해 그늘이 생겨서 겨울철에 도로 노면에 블랙 아이스가 쉽게 생성될 수 있다.

경찰청이 발표한 자료 중, 2015년~2019년, 5년간 겨울철 교통사고 통계에 따르면 교통사고 7,236건 중에서는 눈길 사고로 인한 사망자는 186명이며, 블랙 아이스로 인한 사망자는 706명으로 눈길로 인한 사고 사망자보다 3.8배 높았다[2]. 그리고 블랙 아이스에 대한 사고 발생 시 2차, 3차 등 추가 피해가 발생하여 대형 재난 사고로 이어지고 연쇄 충돌의 가능성이 높아진다.

최근 도로상황 감지 기반의 교통안전 조기 경보시스템 기술이 주목받고 있으나, 블랙 아이스 감지에 대한 구체적인 연구는 많지 않고, 그리고 블랙 아이스는 감지하기 어렵기 때문에 도로의 블랙 아이스 정보를 실시간으로 판단하여 운전자에게 실시간으로 경고하는 감지 장비가 필요하다. 블랙 아이스 인식 장비를 통해 운전자의 안전운행을 보장하고 교통사고 발생률을 낮출 수 있다.

II. 관련 연구

도로 노면 상태 감지 기술은 크게 접촉과 비 접촉(플러시 형 및 비플러시 형)의 두 가지 범주로 나뉜다. 일반적으로 사용되는 접촉 감지 방법에는 커패시턴스 방식, 컨덕턴스 방식, 압전 효과 측정 방식 및 광섬유 방식이 있다. 비 접촉 측정 방법은 편광 방법으로는, 광도 방법 및 이미지 방법이 있다.

2011년, Patrik Jonsson[3] 등은 파장에 따른 흡수율

의 차이에 따라 할로젠 램프 광원과 960 nm, 1550 nm, 1950 nm 파장 3개를 가진 적외선 검출기를 사용하여 반복 실험을 수행하고 젖음, 블랙 아이스, 아이스, 적설 노면 상태의 실험 데이터에 대해 클러스터 분석을 수행하여, 다른 노면 상태를 구별하였다. 2017년 Tabatabai[4]은 콘크리트에 매설된 두 세트의 전신주 사이의 저항 변화를 감지하여 노면 상태를 구별할 것을 제안하였지만 이 방법은 정확도가 낮고 블랙 아이스의 상태를 정확하게 식별하지 못했다. 2017년, Youngis E. Abdalla 등[5]은 Kinect를 사용하여 블랙 아이스를 감지하는 시스템을 제안하였다. 제안하는 시스템은 Soft Ice, Wet Snow, Hard Ice, Black Ice 4가지 유형을 정확하게 분류할 수 있었다. 2020년, Ma Xinxu et al.[6]은 3파장 비 접촉 광학 기술을 사용한 블랙 아이스 검출 방법을 연구하였다. 3파장 후방산란파워의 차이를 이용하여 노면의 기상상태를 검출하는 방법을 제안하였다. 1310 nm, 1430 nm, 1550 nm를 검출파장으로 하여 노면의 젖음, 블랙 아이스, 결빙 및 적설 상태의 정확하게 판단할 수 있는 도로 블랙 아이스 검출 실험시스템을 구축하였다. 이미지 방법을 사용한 블랙 아이스 감지 연구에서 2017년, Li Xin et al.[7]은 OpenCV+Python을 기반으로 도로 결빙 감지 시스템을 설계했으며, 이 시스템은 이미지를 분할하기 위해 에지 감지와 이진 형태의 조합을 사용한 다음에 적응적 웨이블릿 알고리즘을 사용하여 잡음을 제거하고 최종적으로 도로 이미지의 특성 값을 추출하고 SVM 분류기를 통해 건조, 젖음, 눈, 얼음의 4가지 도로 이미지를 식별하였다. 2020년, Hojun Lee 등[8]은 구글 이미지 검색을 통해 블랙 아이스 감지 데이터 세트를 만들어서 CNN 딥 러닝 기법을 이용해 건조, 젖음, 눈, 블랙 아이스를 검출하여 인식률은 96%에 도달하였다.

카메라가 널리 보급됨에 따라 이미지는 도로 정보를 획득하기 위한 편리하고 빠르고 경제적인 방법이 되었으며 차량 교통 위반, 교통 흐름, 번호판 인식 등 분야에서 널리 사용되었지만 카메라 영상기반으로 도로 노면 블랙 아이스 모니터링에 대한 연구는 여전히 상대적으로 작다. 그리고 이미지 방식에 기반한 도로 블랙 아이스 감지 기술의 장점은 성능이 강력하고, 직관적이 있고, 소프트웨어로 제어하고, 업그레이드 용이성 있고, 저렴한 비용으로, 설치 및 유지보수 시 도로에 피해를 주지 않으며, 차선을 폐쇄하지 않으며, 다른 요구 사항에 따라 위치를 재설정할 수 있다. 따라서 본 논문에서는 도로의 블랙 아이스 탐지

를 연구하기 위해 이미지 기반 방법을 채택하였다.

또한, 딥 러닝 기술의 발전으로 최근 몇 년 동안 효과적인 이미지 분류 네트워크가 많이 등장하였다. 그러나 대부분의 도로 감시 카메라는 가시광선 RGB 영상을 획득하는 일반 카메라를 사용하며 가시광선의 스펙트럼 범위는 $0.43\mu\text{m}\sim 0.79\mu\text{m}$ 이며 조명이 부족한 환경에서는 영상의 품질이 저하되기 쉽다. 열화상 카메라는 온도가 절대 영도보다 높은 모든 물질에서 방출되는 열복사를 사용하여 열화 이미지를 생성하는 원리로[9], 24시간 작동하고 구름, 안개와 같은 악천후에 영향을 받지 않는 능력이 있을 뿐 아니라 감도가 높고 탐지 거리가 긴 특성을 가지고 있으며 목표 인식 및 탐지 분야에서 대체할 수 없는 역할을 하며 보안 모니터링, 원격 감지 영상, 국방 및 기타 분야에서 널리 사용되고 있다.

따라서 본 논문에서는 블랙 아이스가 생성되는 과정을 연구하여 블랙 아이스 생성 시뮬레이션 실험 환경을 만들어서 열화상 카메라를 이용하여 열화 도로 블랙 아이스 이미지를 수집하고 열화 도로 블랙 아이스 데이터 세트를 구축한 다음 CNN 전이학습 기반 네트워크와 MobileNetV2 기반으로 개선된 lightweight 네트워크를 제안해서 열화 도로 이미지에서 블랙 아이스를 정확하게 식별하는 방법을 제안한다.

III. 열화 도로 이미지 블랙 아이스 데이터 세트 구축

본 논문에서는 블랙 아이스 생성과정을 분석하기 위하여 두께 5cm, 면적 $1\text{m}\times 1\text{m}$ 의 아스팔트도로와 시멘트도로를 만든 다음에 $5\text{m}\times 5\text{m}$ 크기의 냉동실 안에 이들을 설치하고 깨끗한 물을 부은 다음에 냉동고의 온도를 조절하여 블랙 아이스 생성 과정을 시뮬레이션하였다. 열화 도로 블랙 아이스 촬영 실험 환경은 그림 1과 같다. 외부 제어 상자를 이용하여 냉동고의 온도를 조정해서 냉동고 안의 온도 값을 확인했다.

TPV-IAHDR 열화상 카메라를 이용하여 처음부터 블랙 아이스가 생성되는 전 과정을 캡처하였으며, 캡처된 동영상의 해상도는 1280×720 이다. 촬영 과정에서 뿌리는 물의 면적과 위치를 조정하여 노면에 무작위로 블랙 아이스가 발생하는 것을 시뮬레이션하고 조명이 있거나 없는 조건을 설정하여 주야간 조명 조건을 시뮬레



Fig. 1 The Environment of Taking Images of Infrared Road Black Ice Experiment

이션하였다. 캡처된 동영상에 대해 OpenCV를 사용하여 200ms마다 프레임을 샘플링함으로써 열화 도로 블랙 아이스 이미지를 생성하였다. 최종적으로 스크리닝 후 블랙 아이스 도로 이미지 328장, 젖은 도로 이미지 208장, 총 536장을 생성하였다. 생성된 이미지는 7:3의 비율에 따라 훈련 데이터 세트와 테스트 데이터 세트로 나뉘었다. 따라서 본 논문에서 구축된 열화 도로 블랙 아이스 데이터 세트는 표 1과 같다.

Table. 1 The Number of Infrared Black Ice Road Image Dataset

Type	Black Ice Road Images	Wet Road Images
Train	230	146
Test	98	62
Total	328	208

본 논문에서 구축한 열화 도로 블랙 아이스 이미지 데이터 세트의 샘플은 그림 2와 같다.

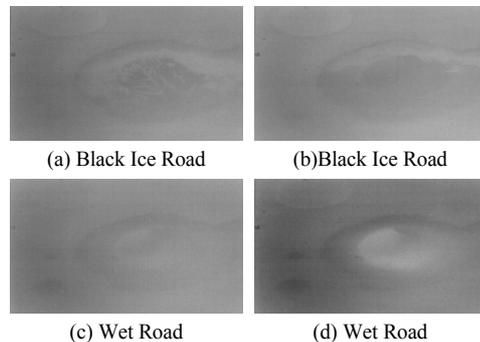


Fig. 2 The Samples of the Infrared Road Black Ice Dataset.

네트워크의 구조, 훈련 샘플의 품질 및 샘플 수는 네트워크 훈련의 정확도에 직접적인 영향을 미친다. 네트워크 훈련에서 샘플 수를 늘리면 overfitting을 효과적으로 방지할 수 있기 때문에 본 논문에서 학습 샘플 수가 적은 문제를 해결하기 위해서 수평 반전, 수직 반전 및 임의의 자르기와 같은 온라인 증강 기술을 사용하였다.

IV. CNN전이학습 기반 블랙 아이스 인식

4.1. 컨볼루션 신경망(CNN:Convolution Neural Network)

이미지 분류는 컴퓨터 비전 분야의 기본 작업이다. 빅데이터의 물결과 하드웨어 성능의 향상 덕분에 딥 러닝은 컴퓨터 비전 분야에서 획기적인 발전을 이루었다. CNN[10,11]은 강력한 특징 추출 기능을 가지고 있으며 이미지 인식, 탐지 및 분류 작업에서 우수한 성능을 발휘하고 있다. 계층별로 이미지 특징을 추출할 수 있을 뿐만 아니라 특징 및 구조적 특징도 병렬 학습을 통해 네트워크 효율성을 향상시킬 수 있다. CNN은 이미지 분류 분야에서 빠르고 효율적인 방법으로 이미지 분류 문제에 널리 사용되어 빠르게 연구 핫스팟이 되었다[11].

2012년 Krizhevsky et al.[12]은 LVSRC 경쟁에 CNN을 처음으로 사용하였으며, 제안된 AlexNet 네트워크 모델은 5개의 컨볼루션 레이어와 3개의 완전히 연결된 레이어, 약 650,000개의 뉴런과 6,000만 개의 훈련 가능한 매개변수 및 ReLU+dropout 기술을 가지고 있으며 당시 최고의 분류 결과를 달성하였다. 2015년 Simonyan et al. [13]은 CNN의 깊이를 연구하고 3×3 컨볼루션 커널을 사용하며 16~19층의 깊이를 갖는 VGG 모델을 제안하였다. 2015년 Szegedy et al. [14]은 1x1, 3x3, 5x5 컨볼루션 커널이 병렬로 구성된 Inception이라는 CNN의 기본 모듈을 제안했다. 2016년 He et al. [15]은 심층 네트워크의 열화 문제를 해결하기 위해 ResNet 네트워크 구조를 제안했다. 2016년 Landola et al. [16]은 SqueezeNet을 제안하였으며, 그 핵심은 Squeeze 레이어와 Expand 레이어인 Fire 모듈로 구성되었다. 2017년 Huang et al. [17]은 조밀하게 연결된 블록으로 구성된 CNN Densenet을 제안했다. CNN 모델을 소규모 이미지 처리 및 컴퓨팅 플랫폼에 더 잘 적용하기 위해 2017년 Howard et al. [18]은 MobileNet을 제안했다. 그 핵심은 표준 컨볼루션을 deepwise convolution과 pointwise

convolution의 두 단계로 변환하는 것이다. 표준 컨볼루션에 비해 계산량과 매개변수들이 많이 줄었다.

4.2. 전이학습(Transfer Learning)

데이터 수집은 복잡하고 비용이 많이 들기 때문에 대규모의 고품질 레이블이 지정된 데이터 세트를 구성하기가 매우 어렵다. 훈련 데이터가 불충분한 경우에 전이 학습을 사용하여 문제를 해결할 수 있다. 전이 학습은 기존의 대규모 데이터 세트에 대해 학습된 지식을 새로운 분야에 전이하여 사용함으로써 대상 필드에 레이블이 지정된 샘플 수가 적은 학습 문제를 해결하는 방법이다 [19,20]. 열화 이미지와 가시광선 이미지의 이미징 원리는 다르지만 이미지 특징은 유사하기 때문에 열화 이미지 대상 분류에 가시광선 전이 학습을 사용할 수 있다. 가시광선 분류 모델에 기반한 매개변수 미세 조정 모드는 overfitting을 어느 정도 줄일 수 있다.

Deng Ling et al. [21]은 InceptionV3 모델을 기반으로 하는 전이 학습 알고리즘을 구축하기 위해 전이 학습의 원리를 사용했으며 Ohio State 팀의 열화 이미지 데이터 세트에서 {자동차, 말, 쿼드로콥터, 코벨소, 축구하는 사람, 걷는 사람, 무기를 가진 사람} {car, horse, quadrocopter, rhino, soccer people, walking people, weapon people} 평균적으로 99.4%의 인식률을 달성하였다. Mao Yuanhong et al. [22]은 육교, 도로, 천연가트뱅크, 각종 건물 등 25개 카테고리를 포함한 2016개 데이터 세트에서 재구성 전이 학습을 기반으로 하는 열화 이미지 분류 방법을 제안했으며 가시 광선 이미지를 사전 훈련 및 미세 조정하는 방법에 비해 분류 정확도가 10.54% 향상되었다. Ziquan Liu et al. [23]은 Mask-RCNN 전이 학습을 기반으로 하는 열화 이미지 전력 장비에서 절연 스위치, 피뢰기, 파쇄기, 현재 변압기, 전압 변압기, 포장, GIS케이스, 유도 저항, 주체 등 12개 장비 탐지 방법을 제안했는데, 이는 적은 수의 픽셀 수준 레이블이 지정된 샘플의 조건에서 전력 장비의 윤곽을 더 잘 추출할 수 있으며, 장비 범주를 추가로 식별하였다.

4.3. CNN전이학습 기반의 열화 도로 영상에서 블랙 아이스 인식

위의 분석을 바탕으로 열화 도로 블랙 아이스 데이터가 부족한 점을 감안하여 본 논문에서는 먼저 전이 학습 기반 블랙 아이스 인식 방법을 제안한다. 본 논문은 매

개변수 기반의 전이학습 방법을 채택하였으며, 이 방법은 원본 도메인에서 학습된 매개변수를 대상 도메인에서 그대로 사용하여 학습을 사용함으로써 대상 도메인에서 처음부터 학습할 필요가 없고 대상 도메인 데이터 양의 요구가 줄어든다.

열화 도로에서 블랙 아이스를 인식하는 작업을 목표로 제안하는 전이학습 방법의 구체적인 단계는 다음과 같다.

- (1) 모델을 선택한다. 딥 네트워크 전이학습 방법은 고전적인 신경망 AlexNet, VGG16, InceptionV3, DenseNet121, ResNet34 및 경량의 딥 러닝 네트워크 SqueezeNet1_0 및 MobileNetV2 중 하나를 선택하고, ImageNet 데이터 세트에 대해 학습된 매개변수를 이용한다.
- (2) 네트워크 출력 레이어 구조를 설계한다. 선정된 네트워크 모델의 특성에 따라 실험에서 요구하는 젓음, 블랙 아이스 카테고리 최종 예측 카테고리를 조정하여 네트워크 출력 레이어 구조를 만든다.
- (3) 매개변수 최적화. 네트워크 모델에 따라 Dropout 기술과 freeze 레이어 등 기술을 이용하여 전이학습 모델을 미세조정한다.

4.4. 전이학습 실험 및 분석

4.4.1. 실험 환경

본 논문에서 사용한 실험플랫폼은 Ubuntu16.08LTS 이고, 딥 러닝 소프트웨어 프레임워크는 Pytorch, 프로그래밍 언어는 Python을 선택하였으며, GPU는 NVIDIA GeForce 1080Ti*1 GPU 11GB이다. 소프트웨어 환경은 CUDA 10.2, Python3.8, Pytorch1.8.1이다. Tensorboard를 이용하여 실험 결과 정확도 그래프를 시각화 하였다.

4.4.2. 실험 초기 설정

실험에서 초기 학습률은 0.003, batch_size은 16개 샘플로 설정하였다. 실험에서 모델은 학습 시간이 길수록 최적의 값에 가까워지므로 학습 과정에서 반복이 계속 될수록 학습률을 점차 줄여야 한다. 따라서 본 실험에서는 학습률을 갱신하기 위해 지수 감쇠 방법을 사용하였다. 사용된 감쇠 공식은 다음 식 (1)과 같다.

$$lr = lr_0 \cdot dr^{\left(\frac{gs}{ds}\right)} \quad (1)$$

식 (1)에서 lr 은 쇠퇴 후 학습률, lr_0 은 초기 학습률 0.001, dr 은 쇠퇴율 0.8, gs 는 현재 반복 단계, ds 는 쇠퇴 단계 길이로 10의 값을 갖는다.

학습 과정에서 CrossEntropyLoss를 사용하여 분류 손실을 계산하는데, 학습 과정에서 매개변수 조정의 효율성을 높이고 모델의 학습 능력을 최대화하기 위해 SGD 알고리즘을 통해 손실 함수를 최적화하고 가중치와 바이어스를 갱신한다.

실험에서 반복 횟수는 500 epoch이고 입력 이미지 크기는 (224,224,3)이며 식 (2)의 Softmax 분류기를 사용하여 최종 분류 결과를 계산한다.

$$Softmax(x) = \begin{cases} 1, & Black\ Ice\ Road \\ 0, & Wet\ Road \end{cases} \quad (2)$$

4.4.3. 실험 결과 및 분석

AlexNet, VGG11, DenseNet121, ResNet34, SqueezeNet, InceptionV3, MobileNetV2 전이학습모델에서 열화 도로 블랙 아이스 데이터 세트에서 학습 Epoch와 Train Accuracy의 변화는 다음 그림 3과 같다.

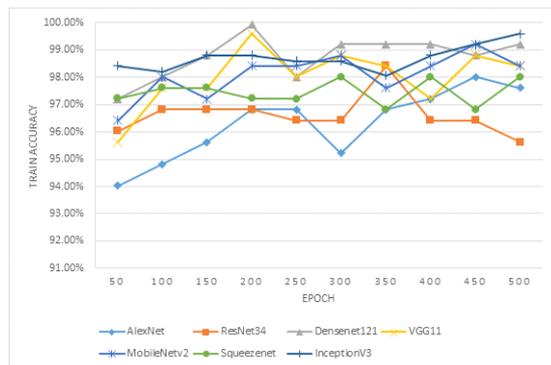


Fig. 3 The Trends of Train Accuracy on Infrared Road Ice Dataset Using Transfer Learning

그림 3은 열화 도로 블랙 아이스 데이터 세트에서 7가지 유형의 전이학습 이미지 분류 네트워크의 훈련 과정을 보여주며, 전체적으로 7가지 유형의 네트워크는 150 epoch이후에 수렴에 도달할 수 있으며 모든 7가지 유형의 네트워크는 훈련 과정에서 정확도 비율은 96% 이상이었다. 여기서 DenseNet121은 훈련 세트에서 가장 높은 정확도를 갖고 VGG11은 훈련 세트에서 가장 높은 안정성을 가지며 정확도 표준편차는 0.0043 이었다.

표 2는 열화 도로 블랙 아이스 테스트 세트에서

AlexNet, VGG11, DenseNet121, ResNet34, SqueezeNet, InceptionV3, MobileNetV2의 7개 유형 전이학습 이미지 분류 네트워크 모델의 평가 지표를 비교한 것이다.

Table. 2 The Comparison of Different Transfer Learning Network Performance

Transfer Learning Networks	Train Accuracy	Train Time	Test Accuracy
AlexNet	96.26%	23'37"	89.72%
ResNet34	96.61%	23'33"	92.52%
DenseNet121	98.76%	23'17"	97.20%
VGG11	98.01%	23'50"	97.20%
MobileNetV2	98.09%	22'21"	96.26%
Squeezenet	97.45%	22'48"	89.72%
InceptionV3	98.71%	25'59"	96.62%

표 2의 Test Accuracy는 7가지의 전이학습 네트워크 모델을 적용하여 테스트 데이터 세트에 테스트를 실행한 후에 얻은 정확도이다. 테스트 세트에서 AlexNet과 SqueezeNet의 정확도가 89.72%로 가장 낮고, ResNet34이 92.52%의 정확도로 뒤를 이었다. InceptionV3의 정확도는 96.62%이고, MobileNetV2의 정확도는 96.26%이었으며, DenseNet121과 VGG11의 정확도는 97.20%로 가장 높았다. 훈련 시간 측면에서 InceptionNetV3이 소요한 시간이 가장 긴 25'59"이고 MobileNetV2가 가장 짧은 22'21"이었다.

전체적인 결과로부터 ImageNet 데이터 세트에 있는 7가지 모델을 전이학습 하여 데이터가 적은 열화 도로 블랙 아이스 데이터 세트에 fine-tuning 배치하면 비교적 높은 분류 정확도를 얻을 수 있어 7가지 전이학습 모델은 블랙 아이스 이미지를 효과적으로 인식할 수 있다는 결론을 내릴 수 있다.

V. MobileNetV2 기반의 개선된 Lightweight Network 모델

5.1. 네트워크 구조 디자인

MobileNetV2은 Lightweight CNN모델 중 하나이다. Depthwise Separable Convolution을 도입함으로써 공간 컨볼루션을 실현하여 네트워크의 정확도를 확보하면서 네트워크 계산량을 줄일 수 있고 학습 시간 또한 단축할 수 있다. 그래서 도로 블랙 아이스를 정확하게 인식하는

것은 안전과 관련된 중요한 문제이므로, 본 논문에서는 블랙 아이스 인식의 정확도를 높이기 위해 MobileNetV2 기반의 개선된 경량의 네트워크 모델을 제안한다.

5.1.1. Depthwise Separable Convolution

현재 많은 고효율 신경망 구조에서 깊이 분리 가능한 컨볼루션[18](Depthwise Separable Convolution)은 매우 중요한 설계이다. 본 논문에서 제안한 개선된 네트워크는 Depthwise Separable Convolution을 사용하였다. Depthwise Separable convolution는 표준 convolution을 두 부분으로 통합하는 것이다. 첫 번째 부분은 depthwise convolution이고, depthwise convolution은 각 입력 채널에 컨볼루션 커널을 적용하여 입력 채널의 수와 같은 출력 채널이며, 두 번째 부분 pointwise convolution은 depthwise convolution의 출력을 선형적으로 결합하는 데 사용되는 일반적인 1x1 컨볼루션이다.

5.1.2. Bottleneck Design

Bottleneck 설계할 때 먼저 차원 확장한 다음 차원 축소 전략을 채택하고 차원 축소 후에 채널 수가 적은 tensor에서 더 큰 정보 손실을 유발하기 방지를 위해서 비선형 활성화 함수 ReLU를 사용하지 않고 선형 활성화 함수 ReLU6을 사용하였다[18].

ReLU6 활성화 함수는 다음 식 (3)과 같다.

$$ReLU6(x) = \min(\max(x, 0), 6) \in [0, 6] \quad (3)$$

본 논문에서 사용한 Bottleneck은 그림 4과 같다. Inverted Residual 모듈은 두 부분으로 나뉜다. Stride=1 일 때 그림 4(b)와 같은 Shortcut 구조를 통해서 특징을 융합한다.

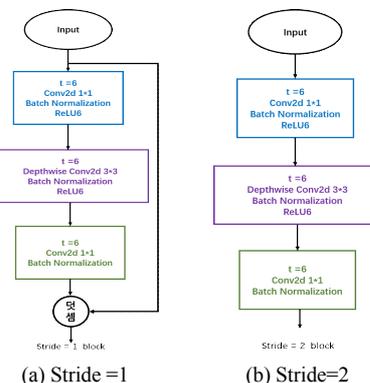


Fig. 4 Inverted Residual Linear Block

MobileNetV2는 deepwise convolution 자체가 채널 수를 변경할 수 있는 기능이 없고, 저차원에서 상대적으로 성능이 좋지 않기 때문에 정확도를 높이기 위해 먼저 차원 확장을 실행한다. 채널 확장을 위해 1x1 pointwise convolution을 사용할 때 계수는 모두 6으로 설정된다. 네트워크 매개변수의 양을 줄이기 위해 17개의 선형 bottleneck 구조를 7로 줄인다. 다음 표 3은 본 논문에서 제안하는 개선된 네트워크 모델에서 사용하는 bottleneck 계수를 보여 주고 있다.

Table. 3 Improved Network Structure Parameters

Backbone	Bottleneck Group	Expand Ratio(t)	Repeats(n)	Total Bottleneck
MobileNetV2	7	(1,6,6,6,6,6,6)	(1,2,3,4,3,3,1)	17
Proposed Network	4	(6,6,6,6)	(1,2,2,2)	7

5.1.3. 개선된 네트워크 모델 아키텍처

열화 이미지는 저해상도, 약한 텍스처, 약한 콘트라스트 등의 특성을 가지고 있다. 본 논문은 열화 이미지를 분류하기 위한 것이므로 정보의 양이 상대적으로 단일하고 온도가 높을수록 밝기 특성이 더 분명하며 열화 이미지는 가시광선만큼 텍스처가 없고 색상 정보도 비교적 단순하기 때문에 특징이 충분히 풍부하지 않을 때 MobilenetV2 모델의 일부 필터의 컨볼루션 커널은 실제로 쓸데 없고 일부 뉴런은 활성화하지 않고 비활성 상태이므로 개선된 네트워크 모델은 원본 MobilenetV2 모델의 뉴런을 적절하게 삭제하고 수정한다.

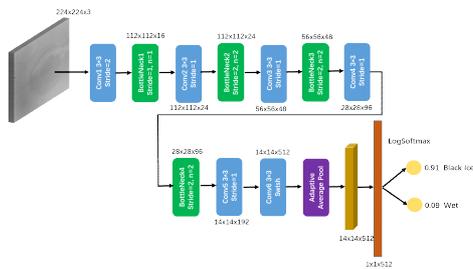


Fig. 5 Improved Network Model Architecture

MobileNetV2에서 Bottleneck 그룹과 Bottleneck 그룹을 직접 연결하여 사용하며, Bottleneck의 top과 tail은 모두 1x1 컨볼루션 커널이고 1x1 컨볼루션 커널은 특징 맵을 압축하여 계산량을 줄이는 기능을 가지고 있지만,

1x1의 컨볼루션 커널은 주변 이웃의 정보를 사용할 수 없어 특징 맵 정보가 부족하고 손실되며 분류 정확도가 떨어진다. 열화 이미지는 경계가 흐릿한 특성을 가지며 인접 영역 간의 정보가 밀접하게 연관되어 있으므로 분류 정확도를 고려하면서 본 논문에서 제안하는 네트워크 구조는 3x3 컨볼루션 커널을 사용하여 Bottleneck 그룹을 연결한다. 이 방법으로 픽셀의 8개 이웃 정보를 캡처하고 로컬 컨텍스트 정보를 늘리고 특징 맵 정보를 향상시킨다. 제안된 개선된 네트워크 모델의 아키텍처 다이어그램은 그림 5에서 볼 수 있다.

본 논문에서 제안하는 개선된 네트워크 구조에서는 두 개의 Bottleneck 그룹을 연결하는 컨볼루션 레이어는 3x3 컨볼루션 커널을 사용하고, 배치 정규화 방법을 사용하여 데이터를 정규화하며, 데이터의 평균값은 0이고 분산이 1인 정규 분포로 정규화되고 데이터 분포를 일관되게 만들어서 기울기 값이 사라지는 것을 방지한다. 동시에 ReLU 활성화 함수는 3x3 컨볼루션 연산에 사용되어 전체 네트워크를 보다 비선형으로 만들어 제안된 네트워크 모델의 결정 함수가 잘 판별할 수 있도록 한다.

네트워크의 마지막 컨볼루션 계층에서 ReLU 활성화 함수를 대체하기 위해 Swish 활성화 함수를 사용한다.

Swish 활성화 함수는 상한이 없고 하한만 있고, 부드럽고, 단조롭지 않은 특성을 가지고 있기 때문에 딥 모델에서 ReLU보다 더욱 효과적이다[24]. Swish 활성화 함수의 정의는 다음 식(4)와 같다.

$$f(x) = x \cdot \text{sigmoid}(\beta x) \tag{4}$$

위에 식(3)에서, β 는 상수 또는 훈련 가능한 매개변수이다. $\beta = 0$ 일 때, Swish 함수는 선형 함수 $f(x) = \frac{x}{2}$ 로 된다. $\beta \rightarrow \infty$ 일 때, $\sigma(x) = (1 + \exp(-x))^{-1}$ 는 0 또는 1이다. Swish 함수는 ReLU : $f(x) = 2\max(0, x)$ 로 된다. 그래서 Swish 활성화 함수는 선형 함수와 ReLU 함수 사이의 부드러운 함수로 간주할 수 있다.

5.2. 매개변수량 및 계산량 분석

컨볼루션 레이어의 매개변수량 계산 식은 식 (5)에 나와 있다.

$$P_c = K \times K \times c_{in} \times N \tag{5}$$

컨볼루션 레이어의 계산량은 다음 식 (6)과 같이 계산

할 수 있다.

$$M_c = c_{out} \times h_{out} \times w_{out} \times (c_{in} \times K \times K) \quad (6)$$

위의 식 (5), 식 (6)에서, P_c 는 컨볼루션 레이어의 매개변수량을 나타내고, M_c 는 컨볼루션 레이어의 계산을 나타내고, c 는 입력 채널 수이고, c_{out} 는 출력 채널 수이고, h_{out} 는 출력 이미지의 높이이고, w_{out} 는 출력 너비이고, h_{in} 과 w_{in} 는 각각 입력 이미지의 높이와 너비이고, h_{out} 과 w_{out} 는 각각 출력 이미지의 높이와 너비이고; t 는 확장 인자이고, c_{in} 와 c_{out} 는 각각 입력 채널 수와 출력 채널 수이다.

Bottleneck의 매개변수량 계산 방법은 식 (7)에 나와 있다.

$$P_B = t \times c_{in} \times c_{in} + 9 \times t \times c_{in} + t \times c_{in} \times c_{out} \quad (7)$$

Bottleneck의 계산량은 다음 식 (8)과 같이 계산할 수 있다.

$$M_B = h_{in} \times w_{in} \times c_{in} \times t + (9 + c_{out}) \times h_{out} \times w_{out} \times t \quad (8)$$

미지의 넓이이고, K 는 컨볼루션 커널 크기 이고, N 는 컨볼루션 커널의 갯수 이다.

위의 식(7), 식(8)에서, P_B 는 Bottleneck의 매개변수량을 나타내고, M_B 는 Bottleneck의 계산 량을 나타낸다.

식 (5), (6), (7), (8)에 따라 본 논문에서 설계한 네트워크 구조에 해당하는 매개변수량과 계산 량은 표 4와 같다.

본 논문에서 제안된 네트워크 모델의 매개변수량은 256,399개로 0.25M에 불과하며, 기존 MobileNetV2와 비교하여 매개변수는 약 90% 감소하고 계산 량은 약 6% 감소한 280M이다. 매개변수량과 계산량이 감소하는 주된 이유는 Bottleneck 계층을 적절하게 삭제하고

Table. 4 The Parameters and Computation of the proposed Network

Layer Name	Input	Output	Parameters	Computation
Conv2d	224 X 224 X 3	112 X 112 X 16	432	5,419,008
Bottleneck1	112 X 112 X 16	112 X 112 X 24	4,704	2,601,984
Conv2d	112 X 112 X 24	112 X 112 X 24	648	65,028,096
Bottleneck2	112 X 112 X 24	56 X 56 X 48	11,664	1,249,920
Bottleneck2	112 X 112 X 24	56 X 56 X 48	11,664	1,249,920
Conv2d	56 X 56 X 48	56 X 56 X 48	1,152	65,028,096
Bottleneck3	56 X 56 X 48	28 X 28 X 96	44,082	1,397,088

Layer Name	Input	Output	Parameters	Computation
Bottleneck3	56 X 56 X 48	28 X 28 X 96	44,082	1,397,088
Conv2d	28 X 28 X 96	28 X 28 X 96	2,592	65,028,096
Bottleneck4	28 X 28 X 96	14 X 14 X 192	171,072	687,960
Bottleneck4	28 X 28 X 96	14 X 14 X 192	171,072	687,960
Conv2d	14 X 14 X 192	14 X 14 X 192	5,184	65,028,096
Conv2d	14 X 14 X 192	14 X 14 X 512	13,824	19,267,584
AdaptiveAvg Pool	14 X 14 X 512	14 X 14 X 512	0	100,352
Conv2d	1 X 1 X 512	1 X 1 X 2	1,024	1024
Total			0.25M	280M
MobileNetV2			3.4M	300M

Bottleneck 그룹 간의 연결을 위해 3x3 컨볼루션 계층을 사용하기 때문이다. 3x3 컨볼루션 커널 자체는 수용 영역을 넓게 하고 이웃의 특성 정보를 추출하는 동시에 대형 필터보다 적은 매개변수 계산량을 달성할 수 있다. 따라서 본 논문에서 제안하는 네트워크 구조는 경량의 특성을 가지며 휴대폰과 같은 임베디드 기기에 잘 적용될 수 있다.

5.3. MobileNetV2기반의 개선된 네트워크 모델 실험 및 분석

개선된 네트워크의 효율성을 검증하기 위해 본 논문에서 제안한 새로운 네트워크 모델과 MobileNetV2를 사용하여 구축된 열화 도로 블랙 아이스 데이터 세트에 대해 10회 반복 학습하고, 테스트 데이터 세트에 대해 정확도 테스트를 수행하고, 10번의 평균값을 분류 정확도로 사용한다. 사용된 실험 플랫폼은 4장의 전이학습 플랫폼과 동일하다.

입력 이미지 해상도는 224x224이며, 실험에서 Adam 알고리즘을 사용하여 손실 함수를 최적화하였다. 학습률과 학습 감퇴율은 전이학습과 동일하며 각각 0.001과 0.8이며 배치 크기는 16개 샘플이다.

그림 6은 MobileNetV2의 네트워크 훈련 반복 횟수와 정확도의 변화를 보여준다.

그림 7은 본 논문에서 제안하는 네트워크 훈련 반복 횟수와 정확도의 변화를 보여준다.

그림 6에서 보는 것과 같이 MobileNetV2는 epoch=250에서 수렴을 달성하고 정확도는 96.54%에 도달하지만 정확도가 충분히 안정적이지 않고 진동 범위가 커서 93.57%와 96.54% 사이에서 앞뒤로 진동함을 알 수 있

다. 이로 인해 인식률이 불안정하며 가장 높은 인식률은 97.21%로 Epoch가 증가할수록 정확도가 지속적으로 향상되지는 않았다.

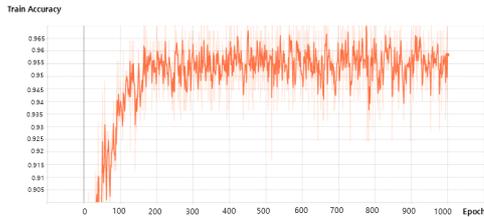


Fig. 6 MobileNetV2 Training Accuracy

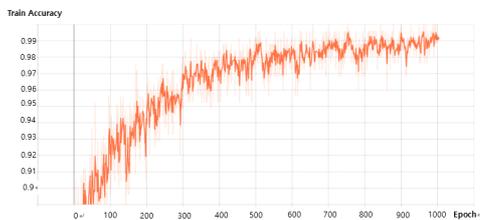


Fig. 7 Proposed Model Training Accuracy

그림 7에서 보는 것과 같이 제안하는 네트워크는 epoch=650 정도에서 수렴에 도달하고 정확도는 99.63%에 달함을 알 수 있으며 수렴은 느리지만 수렴 후 정확도가 97.51%에서 99.35% 사이에서 안정되어 모델이 상대적으로 안정적인 것을 알 수 있다. MobileNetV2와 비교하여 훈련 세트에서 제안된 네트워크의 정확도가 2% 정도 향상되어 제안된 네트워크가 블랙 아이스 도로와 젖은 도로를 효과적으로 식별할 수 있음을 나타낸다.

표 5는 열화 도로 블랙 아이스 데이터 세트에서 MobileNetV2와 제안된 네트워크 모델 간의 성능 비교를 보여준다.

Table. 5 The Comparison of MobileNetV2 and Proposed Model Network Performance

Network	Train Accuracy	Train Time	Test Accuracy
MobileNetV2	97.12%	53'10"	93.46%
Proposed Model	99.63%	48'52"	99.07%

표 5에서 보는 것과 같이 본 논문에서 제안한 열화 도로 블랙 아이스 테스트 세트에 대한 네트워크의 평균 정확도는 99.07%임을 알 수 있다. MobileNetV2의 인식률이 충분히 안정적이지 않기 때문에 테스트 세트에 대한

평균 정확도는 93.46%밖에 안된다. MobileNetV2와 비교하여 테스트 세트의 평균 정확도가 5%정도 향상되어 블랙 아이스 도로와 젖은 도로의 정확한 분류에서 본 논문에서 제안한 네트워크 모델이 기존 MobileNetV2 보다 월등히 우수함을 나타낸다. 훈련 시간 측면에서 보면 epoch는 1000 일 때, MobileNetV2의 훈련 시간은 53'10"이며, 본 논문에서 제안한 네트워크 모델의 훈련 시간은 48'52"이며, MobileNetV2비해서 3'28"보다 줄었다. 그래서 본 논문에서 제안하는 네트워크 모델은 훈련 시간의 단축을 보장할 뿐만 아니라 인식 정확도를 향상시킨다.

그리고, 4절의 그림7에서 전이학습 모델 적용 열화 도로 블랙 아이스 테스트 데이터의 가장 높은 정확도는 97.20%이며, 본 논문에서 제안한 네트워크 모델의 정확도는 99.07%로 전이학습 모델보다 2%정도 높아 제안된 네트워크 모델이 열화 도로 블랙 아이스 데이터 세트에 대해 더 효율적인 인식 효과가 있음을 확인할 수 있었다.

VI. 결론

본 논문에서는 겨울철 운전의 안전성을 향상시키기 위해 CNN 기반의 열화 도로 블랙 아이스 인식 알고리즘을 제안하였다. 블랙 아이스가 생성되는 과정에 대해 시뮬레이션된 블랙 아이스 생성 실험 환경을 만들고 열화 도로 블랙 아이스 데이터 세트를 구축하였다. 그리고 CNN 기반의 전이학습 열화 도로 블랙 아이스 인식 네트워크를 제안하였으며, 실험을 통해 설계된 7가지 전이학습 모델의 가장 높은 정확도는 97.20% 이었다. 인식의 정확도를 향상시키기 위해 열화 이미지 정보가 단순하고 경계선이 흐린 특성을 기반으로 MobileNetV2를 개선하였다. 17개의 Bottleneck을 7개의 Bottleneck으로 축소하고, 픽셀 이웃의 정보를 포착하고 로컬 컨텍스트 정보를 증가시키기 위해 3x3 컨볼루션을 사용하여 Bottleneck 그룹 사이를 연결하고 특징 맵 정보의 양을 증가시켜 네트워크 성능을 향상시켰다. 실험을 통해 본 논문에서 제안한 네트워크 모델은 블랙 아이스 테스트 세트에서 99.07%의 정확도를 가지며, 전이학습 네트워크 및 기존 MobileNetV2 네트워크와 비교하여 학습 시간을 보장하면서 인식 정확도를 향상시켰다. 또한, 본 논문에서 제안하는 네트워크 모델은 0.25M의 파라미터

만 가지고 있어 네트워크 구조가 가벼운 모델로 휴대폰과 같은 임베디드 기기에 잘 적용될 수 있다. 따라서 본 논문에서 제안한 열화 도로 이미지 블랙 아이스 인식 모델 적용을 통해 향후 안전운전의 효율성을 높이고 사람들의 생명과 재산을 보호할 수 있는 방안으로 적용 가능할 것으로 보인다. 또한 제안한 lightweight 모델의 정확도와 처리속도 등 성능을 검증하기 위해서 향후 휴대폰과 같은 임베디드 기기에서 실시간으로 블랙 아이스를 검출할 수 있도록 구현하고자 한다. 이를 통해 향후 교통관제 시스템 등 실시간을 요구하는 스마트 교통에 활용될 수 있을 것이다.

ACKNOWLEDGEMENTS

This work was supported by National IT Industry Promotion Agency(nipa) grant funded by the Korea government (National Balanced Development Special Accounting)

REFERENCES

- [1] G. Y. Park, S. H. Lee, E. J. Kim, and B. Y. Yun, "A Case Study on Meteorological Analysis of Freezing Rain and Black Ice Formation on the Load at Winter," *Journal of Environmental Science International*, vol. 26, no. 7, pp. 827-836, 2017.
- [2] Korea Traffic Accident Analysis System [Internet]. Available: <http://taas.koroad.or.kr/>.
- [3] P. Jonsson, "Remote Sensor for Winter Road Surface Status Detection," *SENSORS*, Limerick: Ireland, pp. 1285-1288, Oct. 2011.
- [4] A. Troiano, E. Pasero, and L. Mesin, "New System for Detecting Road Ice Formation," *IEEE Transactions on Instrumentation and Measurement*, vol. 60, no. 3, pp. 1091-1101, Mar. 2011.
- [5] Y. E. Abdalla, M. T. Iqbal, and M. Shehata, "Black Ice detection system using Kinect," *IEEE 30th Canadian Conference on Electrical and Computer Engineering (CCECE)*, pp. 1-4, Apr. 2017.
- [6] X. Ma and C. Ruan, "Method for black ice detection on roads using tri-wavelength backscattering measurements," *Appl. Opt.*, vol. 59, no. 24, pp. 7242-7246, 2020.
- [7] Q. Li, Y. W. Ji, and Z. P. Wang, "Design of Road Icing Detection System Based on Opencv+Python," *Journal of Shaanxi University of Science & Technology(Natural Science Edition)*, vol. 35, no. 2, pp. 158-164, 2017.
- [8] H. Lee, K. Hwang, M. Kang, and J. Song, "Black ice detection using CNN for the Prevention of Accidents in Automated Vehicle," *International Conference on Computational Science and Computational Intelligence (CSCI)*, Las Vegas: USA, pp. 1189-1192, June. 2020.
- [9] N. Henbest and M. Marten, *The New Astronomy*, 2nd ed. Cambridge, NewYork: Cambridge University Press, 1996.
- [10] P. Li, J. Li, and G. C. Wang, "Application of convolutional neural network in natural language processing," *15th International Computer Conference on Wavelet Active Media Technology and Information Processing(ICCWAMTIP)*, Chengdu: China, pp. 120-122, 2018.
- [11] A. Krizhevsky, I. Sutskever, and G. E. Hinton., "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84-90, 2017.
- [12] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet Classification with Deep Convolutional Neural Networks," *Advances in Neural Information Processing Systems(NIPS)*, Lake Tahoe, pp. 1097-1105, Dec. 2012.
- [13] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *International Conference on Learning Representations(ICLR)*, arXiv preprint: arXiv:1409.1556, 2015.
- [14] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, "Going Deeper with Convolutions," *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, Boston: USA, pp. 1-9, Jun. 2015.
- [15] K. M. He, X. Y. Zhang, and J. Sun, "Deep residual learning for image recognition," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, Boston: USA, pp. 770-778, Jun. 2016.
- [16] F. N. Landola, S. Han, M. W. Moskewicz, K. A. shraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size," *arXiv:1602.07360*, 2016.
- [17] G. Huang, Z. Liu, L. V. D. Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, pp. 1-3, Jun. 2017.
- [18] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, "MobileNets: Efficient convolutional neural networks for

- mobile vision applications,” *arXiv:1704.04861*, 2017.
- [19] M. Oquab, L. Bottou, I. Laptev, and J. Sivic, “Learning and transferring mid-level image representations using convolutional neural networks,” *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, Columbus, pp. 1717-1724, 2014.
- [20] S. J. Pan and Q. A. Yang, “A Survey on transfer learning,” *IEEE Transactions on knowledge and data engineering*, vol. 22, no. 10, pp. 1345-1359, 2010.
- [21] L. Deng and K. Zhou, “Infrared image classification based on transferring learning,” *Journal of Tianjin University of Technology and Education*, vol. 30, no. 3, pp. 23-29, 2020.
- [22] Y. H. Mao, Z. Z. He, and Z. Ma, “Infrared Target Classification with Reconstruction Transfer Learning,” *Journal of University of Electronic Science and Technology of China*, vol. 49, no. 4, pp. 609-614, 2020.
- [23] Z. Q. Liu, H. Fu, and Y. J. Li, “Electrical Equipment Detection in Infrared Images Based on Transfer Learning of Mask-RCNN,” *Journal of Data Acquisition and Processing*, vol. 36, no. 1, pp. 176-183, 2021.
- [24] P. Ramachandran, B. Zoph, and Q. V. Le, “Searching for activation functions,” *arXiv:1710.05941*, 2017.



강선경(Sun-Kyoung Kang)

2010년 원광대학교 컴퓨터공학과 박사
2016년 (주)좋은정보기술 연구소장
2015년~현재 IITP 기술사업화 전문위원
2021년~현재 익산시 정보화위원
2021년~현재 전라북도 정보화위원
2017년~현재 원광대학교 컴퓨터소프트웨어공학과 조교수
※관심분야: 멀티미디어 시스템 및 응용, 빅데이터, 영상처리, 가상현실



이옥걸(Yu-Jie Li)

2008년 중국 노도대학교 정보공학 학사, 원광대학교 컴퓨터공학과 학사
2010년 원광대학교 컴퓨터공학과 석사
2011년~현재 중국 웨이팡 과학 및 기술 대학교 강사
2020년~현재 원광대학교 컴퓨터공학과 박사과정
※관심분야: 영상처리, 딥러닝, 패턴인식