

<http://dx.doi.org/10.17703/JCCT.2023.9.2.569>

JCCT 2023-3-70

전이학습 기반 콘크리트의 다양한 결함 분류에 관한 연구

A study on the classification of various defects in concrete based on transfer learning

윤영근*, 오태근**

Younggeun Yoon*, Taekeun Oh**

요약 콘크리트 구조물의 적절한 유지관리를 위해서 다양한 결함에 대해 사전에 파악하고 유지관리하는 것이 필요하다. 현재 방법으로는 규모가 큰 사회기반시설물의 점검 시 효율성, 안전성, 신뢰성에 문제가 있어 새로운 점검 방식의 도입이 필요하다. 최근에는 영상에 대한 딥러닝 기술이 발달함에 따라 콘크리트 결함 분류 연구가 활발히 진행되고 있다. 하지만, 균열 외에 오염과 박락 등에 대한 연구는 제한적이다. 본 연구에서는 사전에 학습된 딥러닝 모델에 대한 전이학습을 통한 다양한 콘크리트 결함 유형 분류 모델을 개발하고, 정확도를 저하시키는 요인을 도출 및 향후 발전 방향을 제시하였다. 이는 향후 콘크리트 유지관리 분야에서 활용도가 높을 것으로 예상된다.

주요어 : 콘크리트, 오염, 박락, 결함 분류, 딥러닝, 전이학습

Abstract For maintenance of concrete structures, it is necessary to identify and maintain various defects. With the current method, there are problems with efficiency, safety, and reliability when inspecting large-scale social infrastructure, so it is necessary to introduce a new inspection method. Recently, with the development of deep learning technology for images, concrete defect classification research is being actively conducted. However, studies on contamination and spalling other than cracks are limited. In this study, a variety of concrete defect type classification models were developed through transfer learning on a pre-learned deep learning model, factors that reduce accuracy were derived, and future development directions were presented. This is expected to be highly utilized in the field of concrete maintenance in the future.

Key words : Concrete, Contamination, Spalling, Defect classification, Deep learning, Transfer learning

1. 서론

사회기반시설의 대부분을 차지하고 있는 토목 및 건축 구조물의 노후화와 열화에 따른 유지관리에 대한 중요성과 필요성이 고조됨에 따라 구조물의 안전점검은 필수적이다. 노후화된 사회기반시설물에서는 균열이

발생하여 구조적 문제가 발생할 우려가 있고, 누수, 오염 등에 의해 노후화가 가속될 수 있다 [1]. 토목 및 건축 구조물은 대부분 규모가 크고 전국적으로 많이 건축되어 있으므로 정밀안전진단을 통한 보수·보강 여부를 판단하기 전에 빠르고 신뢰성 높은 방법으로 이를 사전에 검토 및 진단할 수 있는 기술이 요구된다 [2]. 현재 교량 하부의 통로에서 교량 주축의 옆면을 육안으

*정회원, 인천대학교 안전공학과 연구원 (제1저자)

**정회원, 인천대학교 안전공학과 교수 (교신저자)

접수일: 2023년 2월 13일, 수정완료일: 2023년 3월 2일

게재확정일: 2023년 3월 10일

Received: February 13, 2023 / Revised: March 2, 2023

Accepted: March 10, 2023

**Corresponding Author: thoh@inu.ac.kr

Dept. of safety engineering, Incheon National Univ, Korea

로 점검하는 방법은 시각적으로 사각이 발생하여 검사가 정확하게 이루어질 수 없다. 또한, 육안검사를 위해 교량의 가설통로를 이동할 때 추락에 의한 사고가 발생할 수 있어 점검 시 안전성도 확보되어야 한다. 다양한 사회기반시설물은 대부분 규모가 크므로 사람에 의한 전체 점검 시 효율성이 다소 낮으며, 점검을 위한 공간도 협소한 편이므로 구조물의 유지관리를 위해 점검자가 이동하며 점검하는 것은 효율성, 신뢰성 및 안전성의 문제가 있으며, 이를 해결하기 위해 새로운 기술의 적용이 필요한 상황이다. 이러한 문제의 해결을 위해 굴절차를 이용한 안전검사, 스카이 장비를 활용한 육안 검사로 점검방식이 변화되고 있으며, 최근에는 딥러닝 등 영상 분석 기술이 발전됨에 따라 무인동력비행장치 등에서 수집된 영상을 활용한 점검 자동화 연구가 활발히 진행되고 있다. 하지만, 최근의 딥러닝 연구들은 대부분 콘크리트의 균열을 더 정확하게 탐지하는 것에 초점을 두고 있어, 콘크리트에서 발생할 수 있는 다양한 결함인 오염, 박락 등의 탐지 연구는 미비한 실정이다 [3].

본 연구에서는 콘크리트의 결함 유형을 오염 및 박락으로 확장하여 전이학습을 통해 분류 모델의 성능을 평가한다. 먼저, 다양한 결함의 수집을 위해 mendeley와 AI 허브의 데이터를 수집하고, 다음으로 사진에 학습된 5개의 딥러닝 모델에 대한 전이학습을 통해 정상, 균열, 오염, 박락 분류 모델을 개발 및 파라미터에 따른 성능을 비교하고자 한다. 마지막으로 개발된 전이학습 모델별 분류가 어려운 콘크리트 영상에 대한 고찰을 통해 향후 연구 방향을 제시하고자 한다. 이를 통해 대규모 사회기반시설물에 대한 안전점검 시 다양한 유형의 결함 판단에 대한 효율성을 증가시키고, 향후 의미론적 분할 딥러닝 모델과 연계될 수 있을 것으로 기대된다.

II. 연구방법

1. 선행연구 분석

콘크리트 분야의 영상 딥러닝 연구는 그림 1과 같이 초기에는 정상과 균열의 분류를 통해 균열 영역을 박스 형태로 예측하는 수준에서 세부 영역을 예측하는 방향으로 발전하였으며, 최근에는 mask-R-CNN 모델로 픽셀 단위의 예측을 통해 길이 및 폭을 정확하게 계산하는 연구가 활발히 진행되고 있다. 하지만, 대부분의 연

구가 균열 탐지의 정확도 향상에 초점을 두고 있음에 따라 콘크리트에서 발생할 수 있는 다양한 결함인 박락, 누수, 이끼에 따른 오염과 균열의 진전에 따른 박락·박락에 대한 연구는 미비한 것으로 분석되어 노후된 사회기반시설물의 관리를 위해 오염과 박락을 분류할 수 있는 딥러닝 모델 연구가 필요하다.




그림 1. 콘크리트 분야 딥러닝 연구의 동향

Figure 1. Trends in deep learning research in the concrete field

2. 전이학습

2.1 딥러닝 모델 선정

현재 영상 분야 딥러닝 연구에서는 convolution neural network (CNN)에 기반한 모델들이 주류를 이룬다. AlexNet을 시작으로 하여 지속적으로 개발되고 있는 CNN 모델은 그림 2와 같다 [4]. 여기서, 대중적으로 많이 사용되는 모델들은 GoogLeNet, ResNet 시리즈 및 최근 가장 높은 정확도를 보였던 Nasnet의 소프트 버전인 Nasnet-Mobile이 있으며, 계층 및 파라미터 수가 다른 모델보다 작음에도 높은 정확도를 가진다는 장점이 있다. 이 모델들은 비행기, 자동차, 동물, 과일, 사람 등 일상의 데이터에 대해 사전에 학습된 상태이며, 다양한 파라미터를 포함한다. 본 연구에서는 사전 학습된 모델의 일부 레이어를 변경하여 학습의 효율성을 증가시키는 전이학습을 진행하고자 하며, 전이학습을 위해 5가지(Nasnet-Mobile, GoogLeNet, ResNet 18, ResNet 50, ResNet 101) 딥러닝 모델이 사용되었다.

2.2 전이학습 방법

전이학습(Transfer Learning)은 그림 3과 같이 사전에 학습된 모델의 구조와 가중치 등을 다른 작업에 이용하는 것을 의미한다 [5]. 많은 데이터를 활용한 학습을 사전에 수행하여 확보된 신뢰성있는 모델을 활용하는 경우 전이학습 시 다음과 같은 장점들이 있다. 먼저, 기존에 많은 데이터를 통해 검증된 특징과 가중치를 활용하여 학습하므로 학습 시간이 감소된다. 이는 이미




그림 2. CNN 모델별 성능
 Figure 2. Performance of CNN models

입력된 데이터의 구조에 따라 특징을 효율적으로 추출하기 때문에, 전이학습을 통해 이후 학습되는 데이터의 특징을 추출하기 위한 학습을 별도로 하지 않아도 되기 때문이다. 또한, 과적합 예방, 미세한 특징까지 추출이 가능하다는 장점이 있다. 본 연구에서는 Matlab 2022a 환경에서 모델별 네트워크 중 fullyConnectedLayer와 ClassificationLayer를 4개의 최종 라벨이 출력되도록 수정하여 학습을 진행하였다.

3. 데이터 구축 및 분석 절차

3.1 영상 데이터 세트

다양한 콘크리트 결함 유형 분류를 위해 그림 4와 같이 Mendeley에서 정상, AI 허브에서 균열, 박락, 오염 영상을 수집하였다. 훈련 및 1차 검증을 위한 데이터는 유형별로 100장이 사용되었으며, 총 400장이 훈련 70%, 1차 검증 30%의 비율로 학습되었다. 이후 개발된 모델별 성능 분석을 위해 새로운 영상 40장을 활용하여

2차 검증을 진행하였다.



그림 4. 학습에 사용된 영상 데이터의 정보
 Figure 4. Information of images used for learning

3.2 분석 절차

본 연구는 그림 5와 같이 크게 3단계의 절차에 따라 진행되었다. 1단계는 다양한 유형의 영상 데이터를 수집하는 단계이며, AI 허브에서 공개된 콘크리트 균열, 박락, 오염, 철근노출 영상을 수집하였다. AI 허브 자료에는 정상 콘크리트에 대한 자료가 없으므로 다양한 연구에서 많이 활용된 Mendeley에서 제공한 콘크리트 정상 영상을 활용하였다. 2단계는 수집된 영상을 유형별로 구분하는 단계이다. 수집된 데이터 중 AI 허브에서 수집된 결함 영상은 수집자 및 기관에 의해 2차까지 검증된 데이터지만 라벨이 일부 틀린 경우가 있어 폴더내 오분류 데이터를 정제 하여 활용하였다. 영상 데이터는

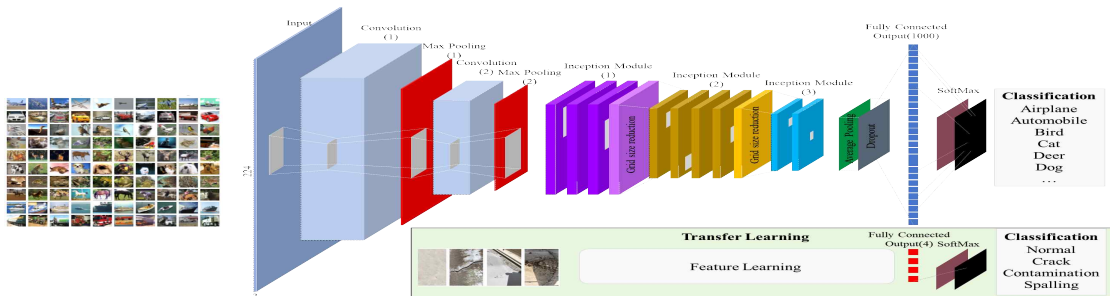


그림 3. 기존 딥러닝 모델을 활용한 전이학습 방법
 Figure 3. Transfer learning method using an existing deep learning model

학습 및 1 ~ 2차 검증까지 총 440장이 사용되었다. 3단계는 선정된 5가지 딥러닝 모델을 활용하여 전이학습을 수행 및 성능을 분석하는 단계이다. Matlab 2022a 환경에서 전이학습이 진행되었으며, 440장의 영상 중 280장은 학습, 120장은 1차 검증, 40장은 2차 검증에 사용되었다. 1차 및 2차 검증을 통해 5가지 모델의 성능을 검토하고, 전이학습의 활용 방안을 제시한다.

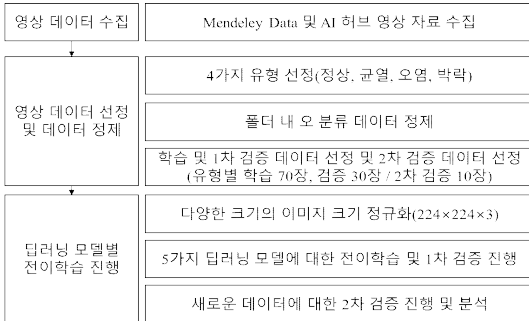


그림 5. 전이학습 모델 개발 및 성능 분석 절차
Figure 5. Transfer learning model development and analysis procedure

III. 연구결과

1. 모델 구성 및 학습

본 연구에서 사용된 5가지 모델은 기존 일상 영상에 대해 1,000개의 라벨을 출력하도록 구성되어 있으므로 본 연구의 타겟인 4가지 라벨을 가지도록 수정되었다. 이에 따라 기존 모델의 계층, 파라미터 수, 출력 레이블 변화에 따른 변경된 파라미터 수 및 비율에 대한 정보를 표 1에 제시하였다. 분석결과 NASnet-Mobile은 계층 수가 많지만 파라미터 수가 가장 적었으며, ResNet101의 경우 파라미터가 가장 많았다.

fullyConnectedLayer와 ClassificationLayer를 본 연구에 맞도록 수정하여 변경된 파라미터를 활용하여 전이학습이 진행되었다.

표 1. 전이학습으로 활용된 모델의 세부 정보
Table 1. Details of the model used as transfer learning

모델	계층	파라미터 (수)	변경된 파라미터 (수)	변경된 파라미터 (비율, %)
NASnet-Mobile	913	5.3M	4.2M	9.88
GoogLeNet	144	6.9M	5.9M	13.88
ResNet18	71	11.6M	11.1M	26.12
ResNet50	177	25.5M	23.5M	55.29
ResNet101	347	44.6M	42.5M	100.00

5가지 모델의 입력 영상의 크기는 224×224로 동일하지만, 본 연구에서 사용된 2가지 데이터 세트는 영상의 크기가 다르므로 영상 데이터 스토어를 구축하는 과정에서 정규화를 통해 224×224로 변환하였다. 학습에 사용되는 영상은 과적합 방지를 위해 X축을 기준으로 하여, -90도 ~ 90도 무작위 회전, 무작위 가로 평행이동(1 ~ 2 픽셀)이 적용되었다. 이후 표 2와 같이 동일한 훈련 옵션을 설정하고 모델별 학습을 진행하였다.

표 2. 딥러닝 학습의 훈련 옵션
Table 2. Training Options for Deep Learning Learning

훈련옵션	비고
Solver	sgdm
InitialLearnRate	0.01
ValidationFrquency	50
MaxEpochs	30
MinBatchSize	128

2. 모델별 전이학습 및 1차 검증 결과

5가지 모델이 각각 280장의 영상에 대해 훈련된 결과는 그림 6과 같다. ResNet 50 및 ResNet 101의 경우 훈련 초기 정확도가 80%까지 상승하여, 훈련이 종료될 때 까지 가장 높은 정확도로 훈련되었으며, GoogLeNet의 경우 훈련이 진행됨에 따른 정확도 상승률이 다소 낮은 것으로 분석되었다. 최종적으로 5가지 모델의 훈련 정확도는 98% 이상인 모델이 개발되었다. 하지만, 전이학습으로 적은 영상 데이터가 활용되어, 훈련 정확도가 검증 정확도를 의미하지는 않는다. 따라서, 모델의 훈련 시간 및 1차 검증 정확도를 그림 7에 제시하였다.




그림 6. 모델별 딥러닝 훈련 정확도
Figure 6. Deep learning training accuracy for each model

280장의 영상 훈련 시 소요시간과 120장의 영상을 1차 검증한 결과는 그림 7과 같다. NASnet-Mobile 모델의 경우 변경된 파라미터 수는 가장 적지만, 계층 수가

많아 훈련에 소요된 시간이 가장 많았으며, GoogLeNet 모델과 ResNet 18 모델은 훈련에 가장 적은 시간이 소요되었다. 많은 파라미터를 산출하는 것보다 몇 개의 계층을 통과하느냐가 훈련시간에 영향을 미치는 것으로 파악된다. 1차 검증 정확도는 ResNet 50, ResNet 18, ResNet 101, GoogLeNet, NASnet-Mobile 순으로 약 최대 88%에서 최소 80%의 정확도로 검증되었다. 훈련 시간 및 1차 검증 결과에 따라 전이학습을 통해 콘크리트 영상을 분류하는 경우 단순히 계층 수가 많고 많은 파라미터를 산출하는 모델이 좋은 모델이 아닐 수 있다는 결론이 도출되었다. 따라서, 향후 전이학습을 타 분야에 적용하는 경우 영상 데이터의 수 및 정확도를 고려하여 최적의 모델을 선정하는 것이 필요하다.




그림 7. 모델별 훈련 시간 및 1차 검증 정확도
 Figure 7. Training time and first verification accuracy for each model

기존에 수만 ~ 수백만 장 이상의 영상을 활용하여 사전 학습된 모델들은 다양한 라벨을 예측하기 위해 영상 내에서 수많은 특징을 도출하도록 설계되어 있다. 일상적인 영상의 경우 영상 내 객체의 특징들에 차이가 크지만 콘크리트의 경우 결합별 유사한 특징이 존재할 수 있다. 균열과 박리·박락, 박리·박락과 오염, 균열과 오염 등 영상 내 유사한 특징을 보일 것으로 예상되므로 향후 발전 방향을 모색하기 위해 구체적인 분석을 진행하였다.

3. 2차 검증 및 성능 분석

표 3은 모델별로 40장의 영상을 활용한 2차 검증 결과를 보여준다. NASnet-Mobile은 가장 낮은 정확도로 나타났으며, GoogLeNet, ResNet 18, ResNet 50은 85%의 정확도를 보였고, ResNet 101은 훈련 및 1차 검증보다 낮은 정확도로 분석되었다.

표 3. 새로운 데이터에 대한 2차 검증 전체 결과
 Table 3. Second verification overall result for new data

원본 라벨	모델	예측된 라벨				정확도 (%)
		오염	균열	정상	박락	
NASnet-Mobile	오염	7	0	0	3	72.50
	균열	0	6	0	4	
	정상	1	0	9	0	
	박락	3	0	0	7	
GoogLeNet	오염	8	0	0	2	85.00
	균열	1	8	0	1	
	정상	0	0	10	0	
	박락	2	0	0	8	
ResNet 18	오염	7	1	0	2	85.00
	균열	1	8	0	1	
	정상	0	0	10	0	
	박락	1	0	0	9	
ResNet 50	오염	10	0	0	0	85.00
	균열	1	6	0	3	
	정상	0	0	10	0	
	박락	2	0	0	8	
ResNet 101	오염	6	3	0	1	77.50
	균열	1	8	0	1	
	정상	1	0	9	0	
	박락	2	0	0	8	

표 3의 결과는 앞서 예상한 것과 같이 균열과 박리·박락, 박리·박락과 오염, 균열과 오염 사이에 유사한 특징이 있어 잘못 예측되는 경우가 발생한다. 또한, 콘크리트 결합의 경우 하나의 영상 내에 여러 개의 결합을 포함할 수 있어 단순히 1개의 영상이 1개의 라벨을 가지도록 훈련하는 경우 예측 정확도가 낮을 수 있다.

그림 8 및 표 4에서 어떤 특징을 가진 영상이 오류가 높은지 분석하기 위해 2차 검증 영상을 기반으로 2개 이상의 모델에서 잘못 예측된 영상이 분석되었다. 먼저, 그림 8에서 여러 모델에서 오류가 발생한 경우는 동시에 2가지 이상의 결합이 존재하거나, 결합의 특징이 미미한 것으로 파악되며, 이는 표 4의 세부 예측 결과에서 타 결합의 비중이 높게 예측될 수 있음을 의미한다. 또한, 이러한 문제는 폴더 구성 시 라벨의 문제일 수 있으며, 영상 내 추출된 특징이 유사한 비율로 결합에 매칭되는 것일 수 있다. 예를 들어, 균열로 라벨링되었지만 폭과 너비가 큰 경우 영상 내 특징에 따라 박리·박락으로 구분될 수 있으며, 결합 주변(콘크리트의 색)이 환경 조건에 따라 전부 다르므로 오염으로 판별될 수 있다. 향후에 전이학습을 진행 시 영상 원본을 그대로 활용하는 것이 아니고 결합의 특징이 도출되는 영상을 별도로 정제하여 활용하는 경우 정확도 개선에 도움이 될 것이라고 판단된다.



그림 8. 2차 검증에 사용된 영상 및 결과
Figure 8. Images and results used for secondary verification

표 4. 새로운 데이터에 대한 2차 검증 샘플 분석
Table 4. Second validation sample analysis on new data

모델	예측 정확도 분포(%)				예측 결과
	오염	균열	정상	박락	
NASnet-Mobile	15%	17%	0%	68%	박락
Googlenet	14%	3%	0%	83%	박락
Resnet18	0%	76%	0%	24%	균열
Resnet50	76%	2%	0%	22%	오염
Resnet101	0%	0%	0%	100%	박락

IV. 결 론

사회기반시설의 대부분을 차지하는 콘크리트 구조물의 노후화와 열화에 따른 유지관리를 위해 다양한 유형의 결함을 사전에 탐지하여 관리하는 것은 구조물의 안전성에 있어 중요하다. 본 연구에서는 기존에 일상 영상에 대해 사전 학습된 5가지 딥러닝 모델에 대한 전이 학습을 통해 4가지 유형의 콘크리트 표면 상태를 85% 정도로 예측하는 모델을 개발 및 성능을 평가하였으며, 본 연구에 따라 도출된 결과는 다음과 같다.

- 전이학습 시 단순히 계층 수 및 파라미터 수가 많은 모델이 좋은 모델이 아닐 수 있으므로 다양한 모델을 분석하여 적절한 모델을 선정하는 것이 필요하다.
- 일상적인 영상의 경우 영상 내 객체의 특징들에 차이가 크지만 콘크리트의 경우 균열과 박리·박락, 박리·박락과 오염, 균열과 오염 등 영상 내 유사한 특징을 보유하고 있어, 더욱 정교한 라벨링이 요구된다.
- 공공데이터 중 균열에 대한 영상은 많지만, 다양한 콘크리트의 결함인 오염(백태, 누수, 이끼 등), 박리·박락·철근노출 등에 대한 영상이 부족하므로 이에 대한

구축이 필요하다.

본 연구에서는 콘크리트에서 발생할 수 있는 다양한 결함 유형의 분류에 초점을 맞추고 전이학습을 통해 분류모델을 개발하였으며, 모델의 한계점과 콘크리트 영상 분류를 제한하는 특징을 도출 및 제시하였다. 전이 학습은 향후 발전 가능성이 높은 분야이며, 해당 결과에 기반하여 다양한 후속 연구가 진행되기를 기대한다.

References

- [1] K.F. Dunker, B.G. Rabbat, Performance of highway bridges. *Concr. Int.* 1990, 12, 40 - 42.
- [2] J. Zhang, C. Lu, J. Wang, L. Wang, and X.-G. Yue, Concrete cracks detection based on fcn with dilated convolution, *Applied Sciences*, Vol.9, No.13, pp.2686, 2019.
- [3] J.Y. Jung, S.K. Lee, C.I. Pa가, S.Y. Cho, J.H. Y, A Method for Detecting Concrete Cracks using Deep-Learning and Image Processing, *JAİK*, Vol, 35, No.11, pp.163-170, 2019.
- [4] S. Bianco, R. Cadene, L. Celona and P. Napoletano, "Benchmark Analysis of Representative Deep Neural Network Architectures," in *IEEE Access*, vol. 6, pp. 64270-64277, 2018, doi: 10.1109/ACCESS.2018.2877890.
- [5] Pan, S.J. and Yang, Q., 2010. A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10), pp.1345 - 1359.