

<http://dx.doi.org/10.17703/JCCT.2023.9.2.561>

JCCT 2023-3-69

## 전이학습과 k-means clustering의 융합을 통한 콘크리트 결함 탐지 성능 향상에 대한 연구

### A study on the improvement of concrete defect detection performance through the convergence of transfer learning and k-means clustering

윤영근\*, 오태근\*\*

Younggeun Yoon\*, Taekun Oh\*\*

**요약** 콘크리트 구조물은 대내외적 환경에 의해 다양한 결함이 발생한다. 결함이 있는 경우 콘크리트의 구조적 안전성에 문제가 있어 이를 효율적으로 파악하여 유지관리하는 것이 중요하다. 하지만, 최근 딥러닝 연구는 콘크리트의 균열에 초점이 맞추어져 있어, 박락과 오염 등에 대한 연구는 부족하다. 본 연구에서는 라벨링이 어려운 박락과 오염에 초점을 맞추어 언라벨 방법, 필터링 방법, 전이학습과 k-means cluster의 융합을 통한 4개의 모델을 개발하고 성능을 평가하였다. 분석결과, 융합모델이 결함을 가장 세밀하게 구분하였으며, 직접 라벨링을 하는 것보다 효율성을 증가시킬 수 있었다. 본 연구 결과가 향후 라벨링이 어려운 다양한 결함 유형에 대한 딥러닝 모델 개발에 기여할 수 있기를 기대한다.

**주요어** : 콘크리트, 박락, 오염, 결함 탐지, 전이학습, k-평균 군집화

**Abstract** Various defects occur in concrete structures due to internal and external environments. If there is a defect, it is important to efficiently identify and maintain it because there is a problem with the structural safety of concrete. However, recent deep learning research has focused on cracks in concrete, and studies on exfoliation and contamination are lacking. In this study, focusing on exfoliation and contamination, which are difficult to label, four models were developed and their performance evaluated through unlabelling method, filtering method, the convergence of transfer learning based k-means clustering. As a result of the analysis, the convergence model classified the defects in the most detail and could increase the efficiency compared to direct labeling. It is hoped that the results of this study will contribute to the development of deep learning models for various types of defects that are difficult to label in the future.

**Key words** : Concrete, Spalling, Contamination, Defect detection, transfer learning, K-means clustering

#### 1. 서론

대부분의 사회기반시설물인 콘크리트 구조물들은 다양한 대내외적 요인으로 인해 노후화와 열화가 발생하

여 구조물의 안전성에 문제가 발생할 수 있어 적절한 안전점검을 통한 유지보수가 필요하다. 노후화 및 열화에 따라 콘크리트 구조물에 균열이 발생하여 구조적 안전성이 악화 될 우려가 있고, 누수에 의한 백태, 이끼와

\*정회원, 인천대학교 안전공학과 연구원 (제1저자)  
\*\*정회원, 인천대학교 안전공학과 교수 (교신저자)  
접수일: 2023년 2월 9일, 수정완료일: 2023년 3월 2일  
게재확정일: 2023년 3월 10일

Received: February 9, 2023 / Revised: March 2, 2023

Accepted: March 10, 2023

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

Dept. of safety engineering, Incheon National Univ, Korea

같은 오염 등에 의해 노후화가 가속되어, 콘크리트 박락 및 철근 부식과 같은 결함으로 이어질 수 있다 [1]. 대부분의 콘크리트 구조물은 규모가 크기 때문에 인력에 의한 수동적인 안전점검에는 한계가 있다. 따라서, 기술개발 방향에 따라 자동화 안전관리를 위한 기술 도입을 통해서 효율적이고 신뢰성 높은 방법으로 콘크리트 구조물의 결함을 판단하는 기술이 요구된다 [2].

주로 사용되는 안전점검 방법은 사람이 직접 구조물의 주변에 인접하여 진행되는 육안검사, 굴절차를 이용한 육안검사 등이 있으나, 효율성과 안전성의 문제점이 야기되고 있다. 최근에는 무인비행체 기술의 발달에 따라 드론의 사용을 통해 효율성과 안전성을 높이고, 사람이 검사할 수 없는 사각지대까지 검사를 진행하고 있다. 또한, 컴퓨팅 기술이 발달하여 영상에 대한 딥러닝 연구가 활발히 진행되고 있으며, 콘크리트 분야에서도 드론 등에서 촬영된 영상을 활용한 자동화 결함탐지 연구 등이 다양하게 수행되고 있다.

최근에는 유사한 영상 세트를 활용하여 폴리곤 라벨 [3], 픽셀 라벨 [4], 필터 라벨 [5] 등을 이용하여 콘크리트 균열에 대한 탐지 정확도 향상에 초점을 두고 연구가 진행되었다. 하지만, 콘크리트에서 발생하는 누수로 인한 백태, 이끼, 균열의 진전으로 인한 박리 및 박락과 같은 결함에 대한 연구는 미비하다 [6]. 균열의 경우 다양한 연구가 진행되어 원본 영상과 라벨링 데이터의 공유가 활발하여 공공데이터를 활용한 정확도 향상 연구가 많지만, 오염과 박락 같은 결함은 라벨링 된 공유 데이터가 부재하며, 직접 라벨링하는 경우 균열의 라벨링에 비해 상당히 많은 노력이 요구된다. 따라서, 미비한 연구 분야의 문제점을 고찰하고 이에 대한 개선을 통해 콘크리트에서 발생 가능한 다양한 결함탐지 연구가 필요한 시점이다.

본 연구에서는 콘크리트의 결함 유형을 오염 및 박락까지 확장하고 k-means clustering을 활용하여 결함 영역 탐지의 성능을 향상시킨다. 먼저, 다양한 정상 및 균열, 박락, 오염과 같은 결함 영상이 mendelej 와 AI 허브에서 수집되었다. 다음으로 4가지의 필터링 및 딥러닝 방법으로 결함 유형 및 영역을 예측하고, 모델별 성능을 비교한다. 마지막으로 모델별 정확도를 저하시키는 요인을 도출 및 콘크리트의 다양한 결함 분류를 위한 향후 연구방향을 제시하고자 한다. 본 연구는 콘크리트에서 발생 가능한 결함 유형을 확장하였다는 것

에 의미가 있으며, 박락 및 오염과 같은 결함의 라벨링 한계를 개선하는 연구로 향후 더욱 다양한 결함유형 탐지에 기여할 수 있을 것으로 기대한다.

## II. 연구방법

### 1. 연구 동향

2022년 콘크리트 분야의 결함 탐지 연구 동향은 그림 1과 같이 폴리곤 라벨에 의한 균열의 mask 예측, 픽셀 라벨에 의한 균열 영역 예측 및 의미론적 분할, 필터 라벨 이미지를 활용한 의미론적 분할 연구가 활발히 진행되고 있다 [3-5]. 과거 정상과 균열의 분류를 통해 균열 영역을 박스형으로 예측하는 수준에서 세부 영역을 예측하는 방향으로 발전하고 있다. 하지만, 균열의 진전에 따른 박락과 노후화를 가속시키는 오염에 대한 연구는 미비한 것으로 분석되어, 콘크리트 구조물의 다양한 결함 탐지를 통한 적절한 유지관리를 위해서는 결함 유형을 확장하여 탐지하는 연구가 필요하다.

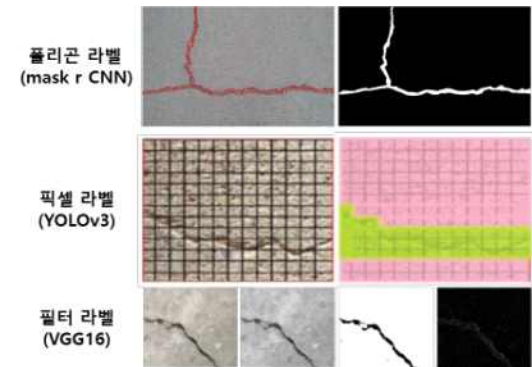


그림 1. 콘크리트 분야 최근 결함탐지 연구 동향  
Figure 1. Recent defect detection research trends in the concrete field

### 2. 데이터 구축

본 연구에서는 기존에 다양한 연구에서 활용된 Mendeley의 정상 및 균열 영상이 수집되었으며, 오염과 박락 영상은 AI허브를 통해 수집되었다 [7]. 수집된 영상 데이터는 그림 2와 같으며, 정상 500장, 균열 50장, 박락 50장, 오염 50장으로 하여 총 650장으로 구성되며, 사용된 영상 데이터는 유사한 영상이 아닌 최대한 다양한 유형을 포함하도록 사전 검토를 통해 선별되었다.



그림 2. 분석에 사용된 4가지 유형의 영상  
 Figure 2. Four types of images used in the analysis

### 3. 연구 방법 및 분석 절차

#### 3.1 딥러닝 방법

최근 영상 딥러닝 연구는 convolution neural network (CNN)에 기반한 모델들이 주류를 이룬다. AlexNet부터 NASnet-Large 모델까지 다양한 CNN 모델이 개발 및 활용되고 있다. 여러 딥러닝 모델 중 ResNet 시리즈는 단순한 구조를 가지지만, 일정 수준 이상의 정확도를 구현한다는 점에서 현재까지도 많이 활용되고 있는 모델이다. 이 모델들은 자동차, 비행기, 과일, 동물, 사람 등 일상생활에서 접할 수 있는 객체에 대해 사전에 학습된 상태이며, 다양한 영상에서 여러

객체를 구분하기 위해 다양한 파라미터를 산출한다. 딥러닝 학습을 통해 파라미터 산출을 위해서는 원본 영상과 라벨링 좌표 또는 라벨링 된 영상이 필요하다. 하지만, 콘크리트 박락 및 오염의 경우에는 공유된 라벨링 데이터가 부재하며, 직접 라벨링 한다고 하여도 분포 범위가 넓어 많은 시간과 노력이 필요하다.

본 연구에서는 라벨링 노력을 줄이기 위해 3가지 종류의 딥러닝 방법이 사용되었다. 첫 번째 방법으로 Variational autoencoder (VAE)를 사용하여 이상치를 감지하는 Alibi-detect 모델이 사용되었으며, 두 번째 방법으로 ResNet 18 모델을 사용하여 추출된 특징 임베딩의 단일 클래스 학습을 통한 유사성 기반 검출 방법인 patch distribution modeling (PaDiM) 방법 [8]이 사용되었다. 세 번째는 전이학습 [9]으로 사전 학습된 ResNet 18 모델의 출력 레이어를 변경하여 학습의 효율성을 증가시키는 방법이다. 앞선 2가지 방법은 콘크리트 정상 영상을 기반으로 학습하여, 별도의 라벨링 과정 없이 결함을 시각화하는 방법이며, 세 번째 전이 학습 방법은 영상 내 세부 라벨링이 아닌 폴더 자체 라벨을 통해 학습되었으며 본 연구에서 제안한 k-means clustering 방법과 융합되는 사전 분류모델이다.

### 3.2 이미지 처리 방법

#### 3.2.1 k-means clustering

k 평균 군집화(k-means clustering)은 분포된 데이터 사이의 거리를 계산하여 가장 유사한 데이터를 k개의 군집으로 분류하는 비지도학습 방법이다. 본 연구에서 영상의 경우 각각의 픽셀 색상 벡터에 대해 k-means clustering을 적용하여 영상의 표면 환경에 부합하는 색의 일치도에 따라 픽셀을 k개의 군집으로 나누어 분류하는 방법이 적용되었다.

#### 3.2.2 영상 색 변환

영상 분석은 일반적으로 RGB 색을 사용하여 색 변화에 기반한 분석이 진행된다. 균열의 탐지 분야에서는 연산의 효율성 문제로 휘도를 유지하면서 채도 및 정보를 제거한 Gray 색이 많이 사용된다. 본 연구에서는 k-means clustering 이전에 Gray 색 변환을 이용하여 연산의 효율성을 높이는 방법이 적용되었다.

#### 3.2.3 필터링 방법

본 연구에서 적용된 필터링 방법은 다음과 같다. 먼저, 정상과 비정상 부분의 차이를 구분할 수 있도록

RGB 색 환경에서 채널별 임계값을 설정하였다. 다음으로 형태학적(Morphological) 닫기(Closing) 연산이 수행된다. 형태학적 닫기 연산은 구조 요소에 팽창을 통해 주요 mask의 빈 부분에 대해 틈을 채우는 데 사용된다. 이외에 Median filtering, subtraction processing, Otsu's 이진화 등 다양한 필터링 방법이 존재하지만, 특정 영상에 부합하도록 만들어진 영상처리 프로세스는 다른 영상에 적합하지 않을 수 있으므로 본 연구에서는 일반화 성능을 높이고 효율성을 고려하여 최소한의 필터링을 적용하였다.

### 3.3 분석 절차

본 연구는 그림 3과 같은 절차로 수행된다. 먼저, 콘크리트 정상 및 결함(균열, 박락, 오염)에 대한 공공 데이터를 수집한다. 이후 다양한 유형이 포함되도록 사진 검토를 통해 정상 500장, 결함 150장 영상을 선정 및 구축하였다. 이후 구축된 영상을 활용하여 4가지 방법에 대한 학습 및 예측을 진행한다. Alibi-detect 및 Feature Embedding(FE) ResNet 18는 딥러닝 방법으로 정상 영상에 대해 학습되고, 결함 영상을 예측하는 방식으로 정확도가 산출되었다. 필터링 방법의 경우 다양한 설정값 변경을 통해 일반화 성능이 높은 조합을 도출하였으며, 최종적으로는 픽셀 라벨의 특성에 따른 결함을 박스형으로 예측 및 성능을 평가하였다. 마지막으로 본 연구에서 제안한 융합방법은 사전 학습된 ResNet 18에 대한 전이학습을 통해 정상, 균열, 박락, 오염을 분류하고, 결함으로 판정된 경우 k-means clustering을 통한 결함 영역을 시각화하는 방식으로 분석이 진행되었다.

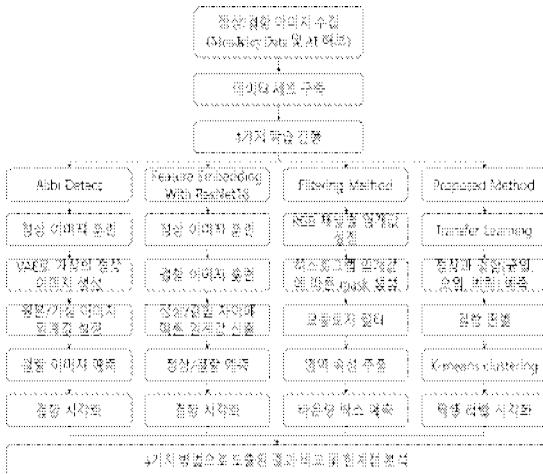


그림 3. 연구 방법 및 분석 절차

Figure 3. Research methods and analysis procedures

## III. 연구결과

### 1. 결함 영상의 라벨링 한계

먼저, 기존 연구의 한계점을 확인하기 위해 Matlab 2022a를 이용하여 샘플 영상 데이터에 대한 라벨링을 진행하고 그림 4에 제시하였다. 가장 일반적으로 사용되어온 박스형 라벨링의 경우 균열 및 박리 부분에 대해서는 쉽게 활용될 수 있지만, 오염의 경우 영상 전반에 분포되어 거의 영상 전체를 라벨링하는 경우가 생길 수 있다. 픽셀형 라벨링의 경우에도 균열 및 박락은 다소 용이하였으나, 오염의 경우 정확한 픽셀 라벨을 지정하는 것에 한계가 있으며, 노력과 시간이 많이 필요하다는 단점을 가진다. 따라서, 기존의 방법 보다 본 연구에서 활용된 언라벨 또는 영상 전체 라벨 등의 방법이 효율성이 높다고 사료된다.




그림 4. 라벨링 방법의 검토

Figure 4. Review of labeling methods

### 2. 모델별 학습 및 예측 결과 분석

#### 2.1 Alibi-detect 훈련 및 결과

결함 탐지를 위해 Alibi-detect의 OutlierVAE가 사용되었으며, 훈련은 정상 영상 450장, 검증은 50장의 정상 영상이 사용되었다. 최적화 방법으로는 mse, epochs는 30로 설정하였으며, 영상은 리사이즈 되어 64×64 사이즈의 영상이 훈련에 사용되었다. Alibi-detect를 이용하여 재구성된 영상은 그림 5의 우측과 같다. 그림 6은 검증 영상 50장에 대한 모델의 임계값에 따른 정상과 결함의 예측 결과이며, 2개의 영상이 결함으로 분류되어 정확도는 약 96%이다. 그림 7은 임계값 초과에 따라 정상 및 결함으로 분류된 샘플이며, 정상-정상의 경우 원본 영상과 재구성된 영상의 차이가 적지만, 정상-결함의 경우 넓은 범위에서 차이가 있음을 알 수 있다.




그림 5. Alibi-detect를 이용한 영상 재구성  
 Figure 5. Image reconstruction using Alibi-detect

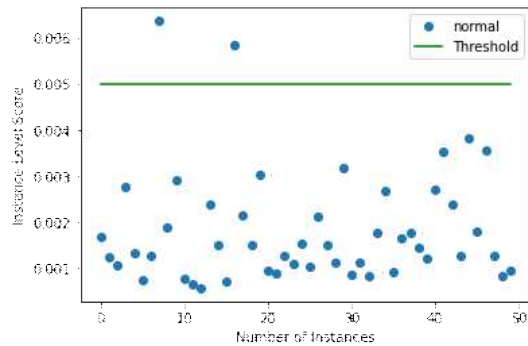


그림 6. Alibi-detect의 정상 영상 훈련 결과  
 Figure 6. Normal image training result of Alibi-detect




그림 7. Alibi-detect의 정상 영상 예측 결과  
 Figure 7. Normal image prediction result of Alibi-detect

그림 8 및 그림 9는 개발된 Alibi-detect 모델로 예측한 결함 영상의 결과이다. 정상 영상을 통해 설정된 임계값을 전부 초과하는 것으로 분석되어 정상과 결함의 분류정확도가 높은 모델이 개발된 것을 알 수 있다. 하지만, 결함의 세부 시각화 과정에서 일반적인 박락의 경우 픽셀단위를 정확하게 예측하였지만, 박락 범위가 넓어 경계면에 강한 음영이 생기는 경우 해당 부분이 강조되어 정확도가 낮으며, 이는 철근이 노출된 경우에도 정확도가 저하될 것으로 분석된다.




그림 8. Alibi-detect의 결함 영상 훈련 결과  
 Figure 8. Defect image training result of Alibi-detect



그림 9. Alibi-detect의 결함 영상 예측 결과  
 Figure 9. Defect image prediction result of Alibi-detect



## 2.2 FE ResNet 18 훈련 및 결과

FE ResNet 18의 경우 훈련 중에 정상 영상 특징의 평균과 공분산을 모델링하는 가우시안 분포를 맞춘다. 테스트 중 모델은 특징이 특정 임계값 이상으로 가우시안 분포에서 벗어난 영상을 결함으로 표출한다. 그림 10은 FE ResNet 18로 정상 영상을 훈련하고, 추출된 특징에 따라 결함 영상을 테스트한 평균 이상 점수 히스토그램을 보여준다. 정상 영상과 결함 영상의 분포에는 차이가 큰 차이가 있으며, 이에 따라 정상과 결함을 구분하는 모델의 정확도는 99.76%를 보였다.





그림 10. FE ResNet 18에 의한 이상 점수 히스토그램  
Figure 10. Histogram of outlier scores by FE ResNet 18



(a) 원본 영상



(b) 결함 예측 영상

그림 11. FE ResNet 18의 결함 영상 예측 결과

Figure 11. Defect image prediction result of FE ResNet 18

그림 11은 정상 영상 학습을 통해 개발된 FE ResNet 18로 결함 영상을 예측한 결과를 보여준다. 균열 및 박락의 경우 대략적인 위치의 파악이 가능하지만 전체적인 면적의 예측이 아닌 테두리의 예측에 그치므로 균열 예측에 적합할 것으로 사료되며, 오염의 경우에는 픽셀단위 예측의 정확도가 낮은 것으로 분석된다.

## 2.3 필터링 방법 및 예측 결과

다양한 딥러닝 방법이 존재하지만 과거부터 현재까지 여러 필터 방법을 조합하는 다양한 연구가 진행되었으며, 높은 정확도를 가짐에 따라 본 연구에서도 필터링만을 이용한 결함의 mask 추출 및 예측을 진행하였다. 먼저, RGB 차원에서 R(0 ~ 100), G(4 ~ 107), B(0 ~ 107)로 설정하고 기본적인 mask를 추출하였으며, 추출된 mask에 모폴로지 필터를 적용하여 최종적으로 mask 결정하고 픽셀의 형상에 따라 가장 큰 영역을 가지는 픽셀영역을 결함으로 예측하였다. 필터링 조합에 따른 예측결과는 그림 12와 같다. 본 연구에서는 하나의 영상에서 세밀한 예측을 하는 필터 조합이 아닌 다양한 조건의 영상에서 일반적인 성능 이상을 발휘하는 조합을 개발하였으며, 사용된 150장의 결함 중 135장에서 높은 정확도로 결함을 예측하는 결과를 보였다.




그림 12. FE ResNet 18의 결함 영상 예측 결과  
 Figure 12. Defect image prediction result of FE ResNet 18

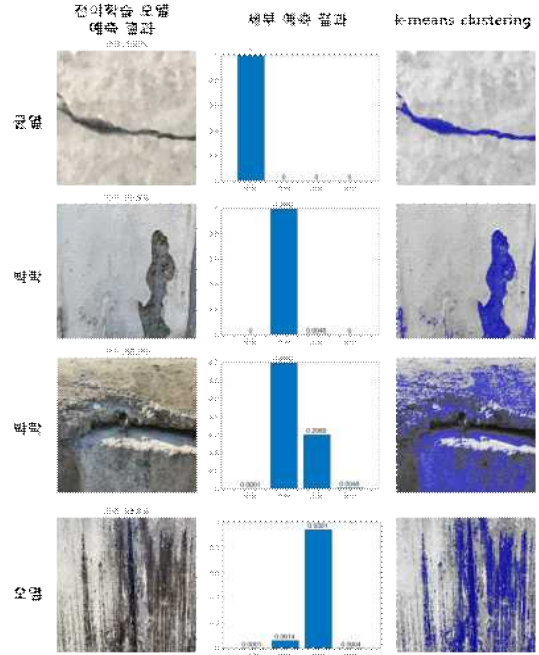


그림 14. k-means cluster를 활용한 시각화  
 Figure 14. Visualization with k-means clustering

#### 2.4 제안된 방법에 따른 훈련 및 예측 결과

ResNet 18 모델에 대해서 fullyConnectedLayer 및 ClassificationLayer를 최종 출력이 4가지가 되도록 수정하여 전이학습이 진행되었다. 학습 시 영상의 과적합을 방지하기 위해 X축 기준 0도 ~ 180도 무작위 회전, 1 ~ 2 픽셀 무작위 가로 평행이동이 적용되었으며, Solver는 sgd, MaxEpochs는 30으로 하여 학습이 진행되었다. 전이학습의 훈련 및 검증 결과는 그림 13과 같다. 훈련 정확도는 98%, 검증 정확도 95.9%를 가지는 결함 분류 모델이 전이학습을 통해 개발되었다. 그림 14는 전이학습을 통해 결함으로 예측된 경우 k-means clustering을 통해 해당 결함을 시각화 한 결과이다.




그림 13. 전이학습의 훈련 및 검증 결과  
 Figure 13. Training and verification results of transfer learning

k-means clustering으로 결함을 시각화한 균열, 박락, 오염 영상은 원본 영상과 95% 이상 동일한 픽셀 예측 결과를 보였다. 하지만, 특정한 영상에서는 정확도가 다소 낮게 나타난 측면이 있다. 이는 영상이 동일한 각도와 거리에서 측정되지 않았으며, 영상 축소과정에서 일부 특징이 소실된 것일 수 있다. 하지만, 제안한 방법의 경우 결함 유형을 정확하게 분류 가능하며, 결함으로 분류된 경우 군집화를 통해 결함을 시각화 하므로 연산 과정과 양이 적어 효율적이다. 딥러닝 분야의 연구는 특정 분야에서 고도로 발달되고 있지만, 실질적으로 현장 등에서 활용하는데 제한이 많다. 본 연구를 통해서 기존에 다소 연구가 부족했던 결함 유형인 박락과 오염에 대한 연구 가능성을 제시하였으며, 다양한 향후 연구를 통해 라벨링 작업을 최소화하고 성능을 극대화하는 모델이 개발될 수 있다고 사료된다.

#### IV. 결론

콘크리트 구조물은 대내외적 환경에 의해 다양한 결함이 발생하며, 결함의 존재는 콘크리트의 구조적 안전성에 영향을 미치므로 유지관리를 위해 다양한 결함을

사전에 탐지하는 것이 필요하다. 본 연구에서는 라벨링 작업의 최소화 및 탐지 모델의 효율성 극대화에 초점을 맞추어 4가지 결합 탐지 모델을 개발 및 비교하였으며, 딥러닝 모델의 경우 정상과 결함의 유형을 95% 이상 예측 가능한 모델이 개발되었으며, 결합의 의미론적 분할에 있어 k-means clustering의 활용 가능성을 확인하였다. 연구를 통해 도출된 결과는 다음과 같이 요약될 수 있다.

- Alibi-detect의 경우 정상 영상에 대해 96%, 결합 영상에 대해 99%로 분류하는 모델이 개발되었으며, 세부적으로 균열의 경우 95%이상의 픽셀 예측이 가능하였고 특정한 박락의 경우에도 활용이 가능하였다. 하지만, 음영이 강한 부분, 철근 노출 등이 있는 경우 성능이 저하되므로 활용 가능 분야를 적절히 선정할 필요가 있다.

- FE ResNet 18의 경우 정상과 결함의 분류에서 99.76%로 높은 분류율을 보였으나, 실제 결함의 시각화 예측에서는 다소 낮은 정확도를 가지는 것으로 분석되었다.

- 별도의 딥러닝 학습 없이 결합의 특징을 파악하고 필터링 조합을 통해 예측한 결과 90% 정도로 결합의 mask를 정확하게 예측하였다. 필터링 조합을 통해서 하나의 결합을 세밀하게 예측하는 방법보다는 일반화 성능이 향상된 필터조합을 개발하고 이를 고도화하는 연구가 필요할 것으로 사료된다.

- 본 연구에서 제안한 전이학습을 통한 콘크리트의 결함을 사전에 분류하고 결합인 경우 k-means clustering으로 시각화한 결과 90% 이상으로 결합 영역의 픽셀 예측이 가능하였으며, 이는 박락과 오염 등 라벨링을 위한 노력이 많이 수반되는 영상에서 활용도가 높을 것으로 예상된다.

본 연구에서는 콘크리트의 균열 외에 박락과 오염의 예측까지 확장하고 영상 데이터 학습을 위한 라벨링 최소화 및 효율성 극대화에 초점을 맞추어 4가지 모델을 개발 및 비교하였으며, 모델별 한계점과 향후 활용 방안을 제시하였다. 콘크리트의 결함은 더욱 다양하므로 더욱 세분화하여 성능이 높은 모델을 개발한다면 콘크리트 구조물의 유지관리에 상당한 기여를 할 것으로 기대된다.

- [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] H. Yu, L. Zhu, D. Li, Q. Wang, X. Liu, C. Shen, Comparative Study on Concrete Crack Detection of Tunnel Based on Different Deep Learning Algorithms, *Front. Earth Sci*, Vol 9, pp.1452, 2022.
- [4] A. Villanueva, J. K. B. Balba, C. D. Beceril, J. L. G. Belza, R. I. P. Tagle, M. C. A. Venal, M. M. Rosales, (2022, June). Crack Detection and Classification for Reinforced Concrete Structures using Deep Learning. In 2022 2nd International Conference on Intelligent Technologies (CONIT) (pp. 1-6). IEEE.
- [5] V. P. Golding, Z. Gharineiat, H. S. Munawar, F. Ullah, Crack Detection in Concrete Structures Using Deep Learning. *Sustainability*, Vol 14, No 13, 8117. 2022.
- [6] 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.
- [7] C.F. Ozgenel, A.G. Sorguc, Performance comparison of pretrained convolutional neural networks on crack detection in buildings. In: *ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction*, vol 35. IAARC Publications, pp 1 - 8, 2018.
- [8] T. Defard, S. Aleksandr, L. Angelique, A. Romaric, "PaDiM: A Patch Distribution Modeling Framework for Anomaly Detection and Localization." In *Pattern Recognition. ICPR International Workshops and Challenges*, 475 - 89. Lecture Notes in Computer Science. Cham, Switzerland: Springer International Publishing, 2021.
- [9] Pan, S.J. and Yang, Q., 2010. A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10), pp.1345 - 1359.

## References