

영상 분할기법을 활용한 콘크리트의 공극률 평가

정현준¹, 정호성², 김재현³, 김강수^{4*}

Estimation of Concrete Porosity Using Image Segmentation Method

Hyun-Joon Jeong¹, Hoseong Jeong², Jae Hyun Kim³, Kang-Su Kim^{4*}

Abstract: In this study, an image segmentation model that can evaluate surface porosity based on concrete surface images was derived. Three types of concrete specimens with different water-cement ratios ($w/c = 54, 35, \text{ and } 30\%$) were prepared, and 2,729 surface images were obtained using an optical microscope. Benchmarking tests, parameter optimization, and final model derivation were performed using the surface images, and an image segmentation model with 97% verification accuracy was obtained. The model was verified by comparing the porosity obtained from the model and X-Ray Microscope (XRM). The model provided similar porosity to that of XRM for the specimens with a high water-cement ratio, but tended to give lower porosity for specimens with a low water-cement ratio.

Keywords: Concrete, Porosity, Image segmentation, Machine learning, Deep learning

1. 서론

사용연수 30년이 초과된 철근콘크리트 구조물(이하 RC 구조물)이 증가함에 따라 구조물의 내구성 평가 및 유지관리에 대한 사회적 관심이 높아지고 있다. 시설물 유지관리 지침(Ministry of Land, Infrastructure and Transport, 2022)에서 RC 구조물의 주된 내구성 평가항목은 탄산화 깊이 및 염화물 침투량이다. 탄산화 및 염화물 침투 속도는 콘크리트 공극률이 높아질수록 증가하기 때문에 RC 구조물의 내구성은 콘크리트 공극률에 큰 영향을 받는다(Chang & Chen, 2006). 공극률은 수분 흡수법, 가스흡착법 및 X-ray Microscope (XRM) 등을 통해 계측할 수 있다. 수분 흡수법(KS F 2385, 2018)은 콘크리트에 흡수된 수분량을 통해 공극률을 평가하는 방법이며, 가스흡착법은 내부 표면적에 흡착된 기체량에 기반하여 공극률을 추정하는 방법이다. X-ray Microscope (XRM)은 X-ray를 통해 내부 미세구조를 가시화하는 방법이며, 3차원으로 공극 네트워크(Pore network)를 확인할 수 있다는 장점이 있다(Lu et al., 2006). 한편, 이러한 측정법들은 파괴 시험

법이기에 때문에, 계측 비용이 높고 번거롭다는 한계를 지니고 있다(Torres-Luque et al., 2014).

영상 분할기법은 컴퓨터가 이미지 내의 객체를 픽셀 단위로 나누어주는 알고리즘으로, 의료, 자율주행 및 건설 등 다양한 산업 분야에서 활용되고 있다(Hofmarcher et al., 2019; Wang et al., 2018; Dogan et al., 2017; Jang et al., 2019; Yang et al., 2020). 영상 분할기법은 건설 분야에서 주로 균열 검출에 활용되어왔으며, 이는 균열 탐지에 소요되는 비용 및 시간을 크게 감축할 수 있었다(Dung, 2019). 이러한 영상 분할기법을 공극률 예측에 활용한다면, 선행 공극률 측정법의 한계를 극복할 수 있을 것으로 기대된다.

따라서, 본 연구에서는 영상 분할기법을 활용하여 콘크리트의 공극률을 예측하고자 하였다. 2장에서는 본 연구에서 활용된 영상 분할기법과 사용 장비를 소개하였고, 3장에서는 이미지 취득, 공극률 계측 및 모델학습에 사용된 방법들을 서술하였다. 4장에서는 실험 결과를 요약하였으며, 5장에서는 본 연구의 결론을 요약하였다.

2. 영상 분할기법 및 장비

영상 분할기법은 알고리즘이 객체를 인식하여 픽셀 단위로 객체를 분류하는 기법이다. 초기의 영상 분할기법은 임계값을 정하고 임계값을 기준으로 이미지 내의 객체를 분류하거나(Otsu, 1979), 비슷한 색깔을 군집화하여 객체를 분류(Dhanachandra et al., 2015)하였다. 이러한 방식들은 분류정

¹서울시립대학교, 건축공학과 스마트시티융합전공, 석사

²서울시립대학교, 건축공학과 스마트시티융합전공, 박사과정

³서울시립대학교, 건축공학과, 박사과정

⁴서울시립대학교, 건축공학과 스마트시티융합전공, 교수

*Corresponding author: kangkim@uos.ac.kr

3516 Construction Building 163 Seoulsiripdae-ro, Dongdaemun-gu, Seoul 02504, Korea

•본 논문에 대한 토의를 2023년 3월 31일까지 학회로 보내주시면 2023년 4월 호에 토론결과를 게재하겠습니다.

확도가 낮았었지만, 최근에는 딥러닝 기술이 급속한 발전을 이루면서 높은 정확도를 보이는 영상 분할기법 모델들이 다수 개발되었다.

2.1 딥러닝 기반 영상 분할모델

2.1.1 Fully Convolutional Network (FCN)

Fig. 1와 같이 FCN은 이미지에서 대상의 특징을 추출하는 다운샘플링(Down-sampling) 과정과 대상의 위치를 찾는 업

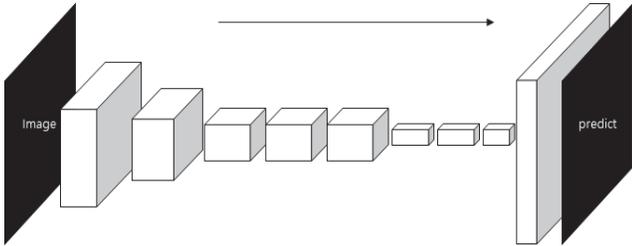


Fig. 1 Structure of FCN

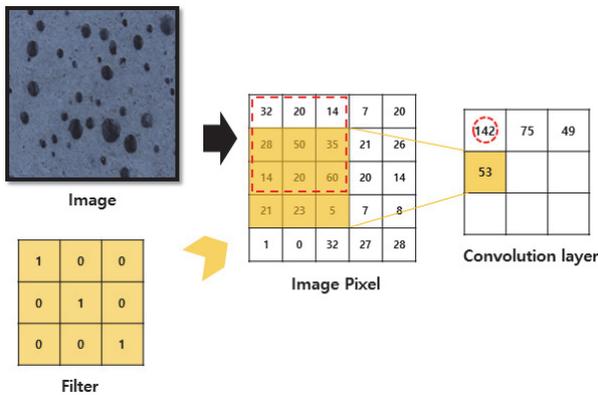


Fig. 2 Convolution layer

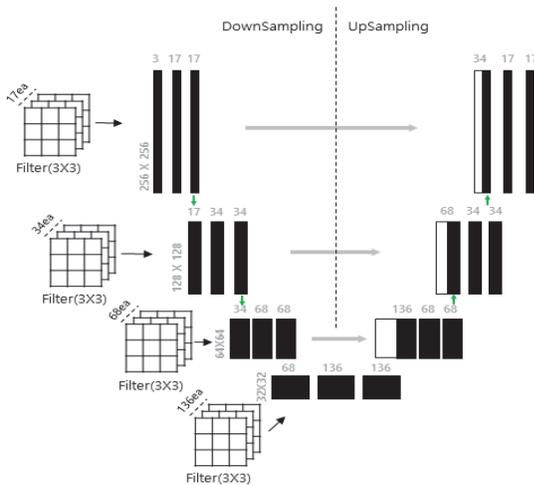


Fig. 3 Structure of U-net

샘플링(Up-sampling) 과정으로 구성된다(Long et al., 2015). 다운샘플링 과정에서는 Fig. 2에 나타난 바와 같이 컨볼루션 레이어(Convolution layer)가 이미지의 특징 정보를 추출하고, 주요 정보만을 풀링(Pooling) 과정으로 저장하게 된다. 이 과정을 여러 번 반복하여 얻은 정보를 통해 대상의 특징을 파악하고, 이를 업샘플링 과정으로 이전시킨다. 업샘플링 과정에서는 해당 특징의 위치를 언풀링(Unpooling)하여 특정함으로써 대상의 위치정보를 파악한다. FCN은 업샘플링에서 발생하는 위치정보의 손실 최소화하기 위하여 다운샘플링에서 컨볼루션 레이어의 일부를 참조한다.

2.1.2 U-net

Fig. 3과 같이 U-net 또한 다운샘플링 과정과 업샘플링 과정으로 구성된다(Ronneberger et al., 2015). 이 방법은 모든 업샘플링 레이어에서 다운샘플링 단계의 컨볼루션 레이어를 참조하기 때문에 일반적으로 FCN대비 높은 분류정확도를 갖는다. 또한 컨볼루션 레이어에서의 중복 검증문제를 해결하여 학습 속도가 빠르다는 특징을 갖는다.

2.1.3 DeepLab v3+

DeepLab v3+는 기본적으로 FCN모델과 유사한 구조로 되어 있지만, Fig. 4에 나타난 바와 같이 공간 피라미드 풀링

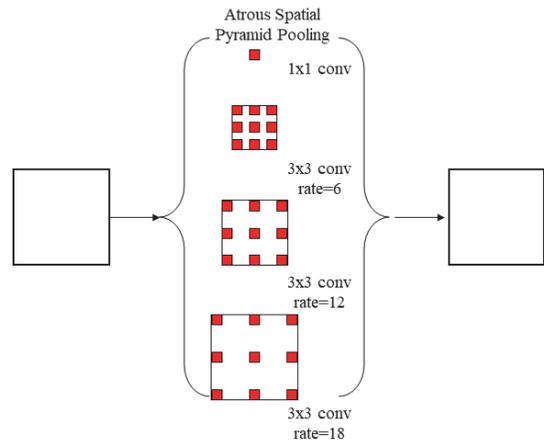


Fig. 4 Spatial pyramid pooling

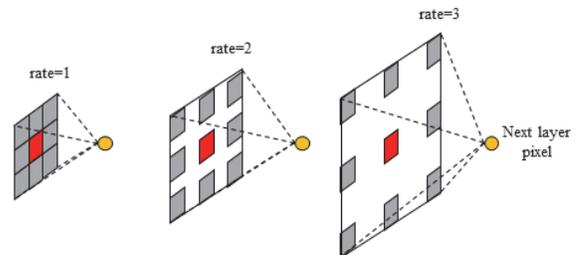


Fig. 5 Atrous convolution

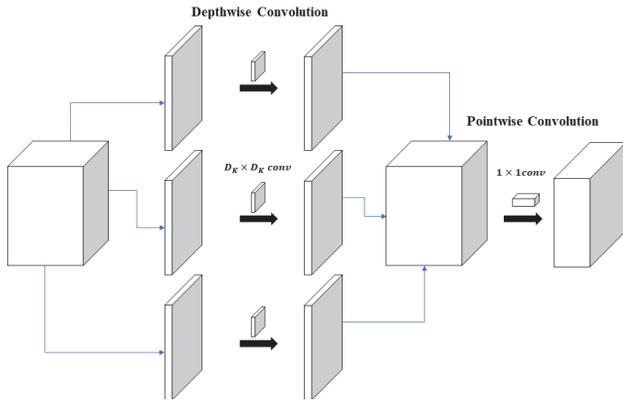


Fig. 6 MobileNet

(Spatial Pyramid pooling) 기법이 활용된다(Chen et al., 2017). 이 기법은 빈 공간을 갖는 필터를 활용하며, 비율 (rate)의 값에 따라 빈 공간의 크기가 결정된다. 예를 들어, rate=1일 경우 필터에 빈 공간이 없으며, 비율이 커질수록 빈 공간이 넓어지게 된다. 이를 통해 Fig. 5와 같이 필터를 이용한 계산량을 적게 유지하면서도 한 픽셀로 볼 수 있는 영역을 넓게 가져갈 수 있다.

2.1.4 MobileNet

Howard et al.(2017)는 기존의 컨볼루션(convolution)에서 한 축의 연산을 감소시킨 Depth-wise separable convolution (DWSC) 을 활용하여, 저사양 컴퓨팅 기기에 적용할 수 있는 영상 분할 알고리즘(MobileNet)을 개발하였다(Fig. 6). 이 알고리즘은 다른 영상 분할기법 대비 낮은 분류성능을 갖지만, 우수한 연산효율로 인해 스마트폰 등에 주로 활용되고 있다.

2.2 실험장비

콘크리트의 표면 이미지를 취득하기 위하여 광학현미경 (HT004, Gasworld)을 활용하였다. 콘크리트의 실제 공극률을



Fig. 7 Specimen

Table 1 Summary of concrete mix-proportion

Type	water	cement	fine aggregate	coarse aggregate
Type1	175	325	910	921
Type2	162	460	785	970
Type3	177	600	681	902

단위 : kg/m³

측정하기 위하여 X-ray Microscope (XRM, Xradia 620 Versa, Carl Zeiss)을 활용하였으며, Dragonfly Pro를 사용하여 XRM 데이터를 3차원으로 가시화하였다. 비파괴 시험법에 기반하여 콘크리트의 압축강도를 추정하기 위하여 Concrete Test & Surveyor (CTS, HJ-CTS-02v04, Heungjin)를 활용하였다.

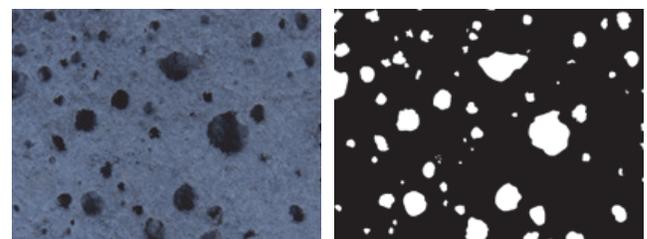
3. 실험방법

3.1 시편 제작

본 연구에서는 콘크리트의 표면 이미지를 수집하기 위해 물시멘트비를 변수로 하는 3종류의 콘크리트 실험체들을 제작하였다. Table 1에는 각 실험체의 콘크리트 배합비를 나타내었으며, 한 변의 길이가 50mm인 정육면체 실험체를 배합당 30개씩, 총 90개를 제작하였다(Fig. 7). 모든 실험체는 28일간 수중양생 되었다.

3.2 이미지 취득 및 예측 공극률 산정

86배율 및 500만 화소의 광학현미경을 활용하여 표면처리를 거치지 않은 실험체들의 표면 이미지를 취득하였다. 표면 공극률의 변동성을 고려하기 위하여 모든 실험체(90개)를 이미지 취득에 활용하였다. 다만, 각 시편의 6개 면 중, 거푸집과 맞닿은 5개의 면에 대해서만 촬영이 이루어졌으며, 각 면당 6개의 구역을 나누어 표면 이미지를 촬영하였다. 그 결과, 총 2,729장(90개×5면×6구역 + 29장의 추가 이미지)의 이미지를 취득하였다. 이 중 총 139개 이미지의 공극을 마스크하여 모델학습, 검증 및 시험(model training, validation and testing)에



(a) Image

(b) Mask

Fig. 8 Surface images extracted by microscope

활용하였으며, 나머지 2,590장의 이미지는 배합 별 공극률을 평가하는 데 사용되었다. 여기서 예측 공극률은 전체 이미지 면적 중 공극이 차지하는 면적의 비율로 산정되었다. Fig. 8 (a) 및 (b)는 각각 광학현미경으로 촬영된 실험체의 표면 이미지와 마스크 된 이미지를 나타낸다.

3.3 측정 공극률 산정

영상 분할기법을 통해 도출한 예측 공극률의 정확도를 평가하고자, XRM 및 수분 흡수법을 활용하여 공극률을 계측하였다. 각 배합 별 실험체를 $10 \times 10 \times 10 \text{ mm}^3$ 크기로 절단하여 XRM 시편을 준비하였으며, Fig. 9는 XRM (X-Ray Microscopy) 을 통해 촬영된 시편의 3차원 공극 구조를 나타낸다. 이때, 공극 구조는 Dragonfly Pro의 Threshold를 조절하며 공극을 구분하고 촬영한 것이다. 제안 방법은 굵은골재가 보이지 않는 표면 이미지를 바탕으로 예측 공극률을 산정하기 때문에, 굵은골재가 없는 3차원 영역의 XRM 결과를 활용하여 측정 공극률을 산정하였다.

수분 흡수법(Ahn et al., 2013)으로 공극률을 측정하기 위하여 실험체를 100°C 환경에서 24시간 건조한 뒤, 1주일간 수중에 두어 실험체에 수분이 충분히 흡수될 수 있게 하였다. 이후 실험체의 변화된 중량을 통해 공극률(P)을

$$P(\%) = 1 - \frac{V_{sol}}{V_T} = \frac{(W_S - W_D) / \gamma_W}{V_T} \quad (1)$$

으로 산정하였으며, 여기서, P 는 백분율로 나타낸 시료의 공극률, V_{sol} 는 공극을 제외한 시료의 부피, V_T 는 시료의 부피, W_S 는 시료의 수중중량, W_D 는 시료의 건조중량, γ_W 는 물의 단위중량을 나타낸다.

3.4 압축강도 평가

압축강도는 공극률과 강한 상관관계를 갖는 대체인자 이므

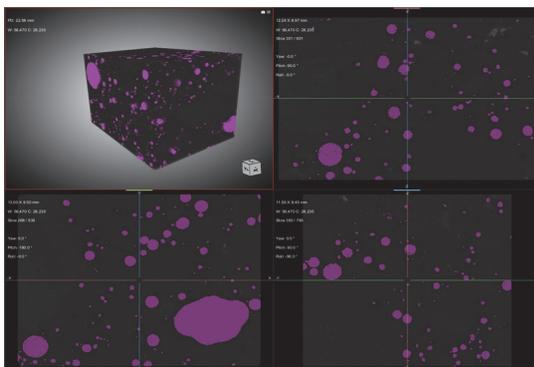


Fig. 9 3-Dimensionalized X-ray images (Type 1)

로(Kumar et al., 2003), CTS(비파괴 시험, Nitto, 2009)와 Universal Testing Machine(UTM, 파괴 시험, KS F 2405, 2022)을 활용하여 콘크리트의 압축강도를 측정하였다. 압축 강도 측정은 Type 별로 각각 지름이 100 mm이고, 높이가 200 mm인 원주형 공시체 3개에 대해 실시되었다. CTS를 활용할 경우, 원주형 공시체를 20회 타격하여 도출된 반발 정도 값에 기반하여 압축강도를 산정하였다.

3.5 모델학습

3.5.1 증강(Augmentation)

컴퓨터 비전은 이미지를 수치화하여 사용하므로, 회전, 반전 및 확대된 객체를 다른 객체로 인식할 수 있다. 이에 따라 이미지의 회전과 반전, 확대 등의 데이터 증강과정을 통해 추가 이미지를 확보하고, 학습에 활용하였다. 또한 모델이 다양한 크기 및 해상도의 이미지를 활용할 수 있도록 생성자(generator)를 거쳐 이미지의 크기를 256×256 으로 변형하였다. 이후 전반적인 모델도출과정은 Fig. 10에 도식화하였다.

3.5.2 모델 선택

학습에 사용될 최적의 딥러닝 모델(Deep Learning Model)을 도출하기 위하여 FCN, MobileNet, DeepLab v3+ 및 U-net을 활용하여 벤치마크 테스트를 수행하였다. 벤치마크 테스트에서 각 모델의 학습에는 default parameter가 사용되었으며, 30장의 이미지를 활용하여 학습이 수행되었다. Table 2는 벤치마크 테스트 결과를 나타낸 것이다.

테스트 결과, 학습 시간은 MobileNet이 가장 낮았으며, 공

Table 2 Result of benchmark test

Models	FCN	MobileNet	DeepLab v3+	U-net
Time	1.1h	0.3h	0.7h	0.5h
Accuracy	93.0%	89.2%	96.1%	95.8%

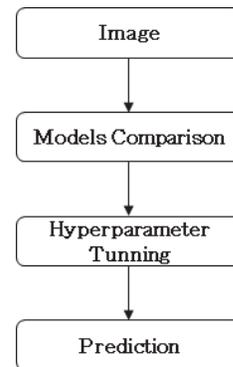


Fig. 10 Flowchart for model derivation

Table 3 Grid search

Parameter	Value	Parameter	Value
Input shape	(256,256,3)	*Number of layers	3
Batch norm	True	Number of classes	1
Up-sampling mode	Deconvolut-ion	Dropout type	Spatial
Attention	True	Dropout rate	0.5
*Filters	17	Activation of output	Sigmoid
Optimizer	Adam	Epochs	1000
*Batch size	2	Shuffle	True

* Parameters for grid search

극를 평가 정확도는 DeepLab v3+가 가장 높았다. U-net은 DeepLab v3+와 유사한 수준의 정확도를 나타내었지만, 학습 시간은 DeepLab v3+보다 30%가량 낮았다. 이처럼 미미한 평가 정확도의 차이는 매개변수 최적화(Hyper parameter tuning)를 통하여 극복할 수 있으므로, 학습 및 tuning에 소요되는 시간이 짧은 U-net을 활용하여 이후 연구단계를 진행하였다.

3.5.3 매개변수 최적화

모델의 최적화된 매개변수 조합을 찾기 위하여 Grid search를 수행하였다(Liashchynskyi, 2019). Grid search는 batch size=[2, 4, 8, 16], filter=[5, 6, 7, 9, 11, 13, 15, 17, 19, 21, 23, 25, 27, 29, 30], layer=[2, 3, 4, 5, 6, 7, 8, 9, 10]에 대해 수행되었으며, 에포크(epoch)는 1,000으로 설정되었다. Table 3에는 개발 모델의 최적화된 매개변수를 나타내었으며, 가장 좋은 성능을 나타낸 매개변수의 조합은 각각 batch size=2, filter=17, layer=3이었다.

3.5.4 모델학습

앞서 도출된 매개변수를 활용하여 모델을 학습시켰다. 전체 데이터 중 60%는 학습, 20%는 검증, 20%는 시험에 활용되었다. 데이터의 순서(sequence)가 모델의 학습에 영향을 미치는 것을 방지하기 위해 에포크마다 학습데이터의 순서를 무작위 변경하였다. 또한 모델의 일반화 성능을 확보하고자 early-stopping을 통해 과적합을 방지하였으며, 최대 학습 횟수(epoch)는 1,000 및 검증정확도의 개선 실패 한계(patience)는 10으로 설정하였다. 학습된 모델의 검증정확도는 97%였으며, 시험정확도는 92%로 나타났다.

4. 결과 및 고찰

4.1 공극률

Table 4에는 XRM, 수분 흡수법, U-net을 통해 도출된 공극

Table 4 Measured porosity

Methods	Type 1	Type 2	Type 3
XRM	9.26 %	3.96 %	2.20 %
Water absorption	20.90 %	16.67 %	16.15 %
U-net	9.28 %	3.10 %	1.75 %

Table 5 Predicted porosity using image data

	Type 1	Type 2	Type 3
Average	9.28 %	3.10 %	1.75 %
Median	9.22 %	2.65 %	1.53 %
P-value	1.79e-12	3.99e-26	3.23e-22

률을 비교하였다. 세 가지 측정법 모두 물시멘트비(w/c)가 높을수록, 높은 공극률을 나타내었다. Type 1에 대해서는 XRM과 U-net이 유사한 공극률을 나타내었으나, Type 2 및 3에 대해서는 U-net이 공극률을 조금 더 낮게 평가하는 경향을 나타내었다. 이는 XRM에 비해 이미지 기반 U-net을 활용하여 계측할 수 있는 최소공극의 크기(XRM: 0.5 μ m, U-net: 20~30 μ m)가 크므로, w/c가 감소할수록 U-net이 관측할 수 없는 공극들이 많아지기 때문으로 판단된다. 수분 흡수법은 XRM 및 U-net보다 비교적 높은 공극률을 나타내었는데, 이는 XRM 및 U-net이 관측할 수 있는 공극보다 작은 공극(0.5 μ m 이하의 capillary void 등)에서도 수분흡수가 발생하기 때문으로 판단된다.

4.2 필요 표본크기

현장에서 취득한 콘크리트의 표면 이미지를 활용하여 신뢰성 있는 공극률을 추정하기 위해, 통계적 기법을 활용하여 필요한 표본의 수를 조사하였다. U-net과 2,729개의 이미지를 활용하여, 이미지마다 공극률을 도출하였으며, 도출 값이 정규분포를 따르는지 판단하기 위하여 Shapiro-Wilk test를 수행하였다. 귀무가설은 '정규분포를 따른다.'로 설정되었으며, 유의수준은 0.05로 설정하였다. Table 5에 나타낸 바와 같이, 모든 종류의 시험체에서 유의확률이 0.05보다 낮았으며, 이는 예측 공극률이 정규분포를 따르지 않는 것을 의미한다. 따라서, 다양한 확률분포를 모사할 수 있는 감마분포를 활용하여 모평균 추정에 필요한 최소 표본크기를 산정하였다.

표본크기(n)는 아래와 같이 산정되었으며,

$$n = \frac{(Z \times \sigma)^2}{d^2} \quad (2)$$

Z 는 Z-score, σ 는 표준편차, d 는 허용오차 크기를 나타낸다. Table 6에는 신뢰수준 (90%, 95%, 99%) 및 허용 오차(2%,

Table 6 Sample size

Confidence level	Margin of error	Type 1	Type 2	Type 3
90%	2%	9	3	1
	1%	34	9	4
	0.5%	136	36	15
95%	2%	12	4	2
	1%	49	13	5
	0.5%	193	51	21
99%	2%	21	6	3
	1%	84	22	9
	0.5%	333	87	35

Table 7 Compressive strength of specimens

	Type 1	Type 2	Type 3
CTS	35.1 MPa	66.9 MPa	82.2 MPa
UTM	38.9 MPa	77.2 MPa	86.4 MPa

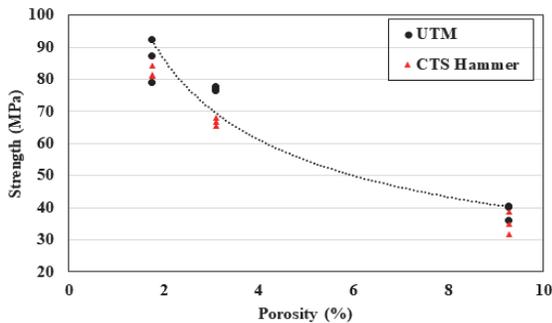


Fig. 11 Relationship between porosity and strength

1%, 0.5%)에 따른 필요 표본 개수를 나타내었다. 신뢰수준을 90%로 하고 허용오차를 1% 내외로 한다면 Type 1, 2, 3 실험체 별로 필요한 이미지 수는 각각 34, 9, 4장이었다.

4.3 압축강도

Table 7에는 CTS 해머와 UTM을 이용하여 측정한 압축강도를 나타내었다. CTS 해머의 시험 결과는 UTM을 통한 압축 파괴시험과 비교할 때, Type 1과 3은 5MPa 내외로, Type 2는 10MPa 내외로 유사한 압축강도를 나타내었다.

4.4 공극률과 압축강도의 상관관계

Fig. 11에는 제안모델을 활용하여 얻어진 공극률과 UTM 및 CTS 해머로 측정된 압축강도를 비교한 것이다. 모델로 측정된 공극률은 압축강도와 모두 반비례하는 것으로 나타났다.

5. 결론

본 연구에서는 콘크리트의 표면 이미지와 영상 분할기법을 활용하여 공극률을 측정하는 딥러닝 모델을 개발하였으며, 본 연구로부터 다음과 같은 결론을 도출할 수 있었다.

1. 콘크리트 표면 이미지와 영상 분할 알고리즘(Fully Convolution Network, MobileNet, DeepLab v3+ 및 U-net)을 활용하여 벤치마킹 테스트를 수행하였다. 테스트결과 Deep Lab v3+와 U-net이 가장 높은 정확도를 나타내었으며, U-net은 DeepLab v3+에 비해 30% 낮은 학습 시간을 소요하였다. 따라서 U-net을 활용하여 매개 변수 최적화를 수행하였으며, 97% 수준의 검증정확도를 확보할 수 있었다.
2. 콘크리트의 w/c가 증가함에 따라 U-net을 활용하여 예측한 공극률이 증가하는 경향을 나타내었다. 또한, 일반 강도 콘크리트에 대해서 X-Ray Microscope (XRM)의 측정 공극률과 U-net의 예측 공극률이 유사한 것으로 나타났다. 이에 비해, 고강도 콘크리트에서는 측정 공극률(XRM)보다 예측 공극률(U-net)이 작게 나타났는데, 이는 w/c가 감소함에 따라 광학현미경으로 관측이 어려운 작은 공극들이 많아지기 때문으로 판단된다.
3. 수분 흡수법으로 관측한 공극률은 XRM 또는 U-net으로 측정된 공극률보다 높게 나타났는데, 이는 XRM 또는 U-net으로 관측할 수 있는 최소공극 크기보다 작은 공극에서도 수분이 흡수되기 때문으로 판단된다.
4. U-net으로 측정된 공극률과 압축강도의 상관관계를 확인하였으며, 공극률이 증가할수록 압축강도는 지수적으로 감소하였다.
5. 제안 방법은 점검 및 진단이 실시되는 현장에서 콘크리트의 공극률을 간편하고 신속하게 측정하는데 활용될 수 있다. 한편, 이미지 촬영에 활용된 현미경의 배율에 따라 관측할 수 있는 공극 크기의 범위가 한정되므로, 배율이 낮은 현미경을 활용할 경우 공극률을 실제보다 낮게 평가할 수 있다.

5.1 추후 연구

추후 연구에서는 다양한 배율의 공극 이미지(멀티스케일 공극 이미지)를 활용하여 U-net 기반 영상 분할모델을 학습할 필요가 있다. 또한, 제안 방법은 공극률의 추정뿐만 아니라, 골재량 및 콘크리트 배합비를 추정하는 데에도 활용될 수 있으므로, 모델의 응용범위를 확장하여 콘크리트 품질평가에 이를 활용할 수 있도록 해야 할 것이다.

감사의 글

이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2019R1A2C2086388).

References

1. Ministry of Land, Infrastructure and Transport. (2022), Guidelines for safety and maintenance of infrastructures, Korea Ministry of Government Legislation. <https://www.law.go.kr/>
2. Chang, C. F., and Chen, J. W. (2006). The experimental investigation of concrete carbonation depth, *Cement and Concrete Research*, 36(9), 1760-1767.
3. KS F 2385. (2018). Permeable asphalt mixtures, Korea Standards Association. <https://e-ks.kr/streamdocs/view/sd;streamdocsId=72059199200454467>
4. Lu, S., Landis, E. N., and Keane, D. T. (2006). X-ray microtomographic studies of pore structure and permeability in Portland cement concrete, *Materials and Structures*, 39(6), 611-620.
5. Torres-Luque, M., Bastidas-Arteaga, E., Schoefs, F., Sánchez-Silva, M., and Osmá, J. F. (2014). Non-destructive methods for measuring chloride ingress into concrete: State-of-the-art and future challenges, *Construction and Building Materials*, 68, 68-81.
6. Hofmarcher, M., Unterthiner, T., Arjona-Medina, J., Klambauer, G., Hochreiter, S., & Nessler, B. (2019). Visual scene understanding for autonomous driving using semantic segmentation, *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning*, 285-296.
7. Wang, G., Li, W., Zuluaga, M. A., Pratt, R., Patel, P. A., Aertsen, M., ... & Vercauteren, T. (2018). Interactive medical image segmentation using deep learning with image-specific fine tuning, *IEEE Transactions on Medical Imaging*, 37(7), 1562-1573.
8. Dogan, G., Arslan, M. H., and Ceylan, M. (2017), Concrete compressive strength detection using image processing based new test method, *Measurement*, 109, 137-148.
9. Jang, Y., Ahn, Y., and Kim, H. Y. (2019). Estimating compressive strength of concrete using deep convolutional neural networks with digital microscope images, *Journal of Computing in Civil Engineering*, 33(3), 04019018.
10. Yang, H., Jiao, S. J., and Yin, F. D. (2020). Multilabel Image Classification Based Fresh Concrete Mix Proportion Monitoring Using Improved Convolutional Neural Network, *Sensors*, 20(16), 4638.
11. Dung, C. V. (2019). Autonomous concrete crack detection using deep fully convolutional neural network, *Automation in Construction*, 99, 52-58.
12. Otsu, N. (1979). A threshold selection method from gray-level histograms, *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66.
13. Dhanachandra, N., Manglem, K., and Chanu, Y. J. (2015). Image segmentation using K-means clustering algorithm and subtractive clustering algorithm, *Procedia Computer Science*, 54, 764-771.
14. Long, J., Shelhamer, E., and Darrell, T. (2015). Fully convolutional networks for semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 3431-3440.
15. Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation, *International Conference on Medical image computing and computer-assisted intervention*, Springer, Berlin, 234-241.
16. Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., and Yuille, A. L. (2017). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs, *IEEE transactions on pattern analysis and machine intelligence*, 40(4), 834-848.
17. Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications, *arXiv preprint arXiv*, 1704.04861.
18. Ahn, J., Lee, Y., Vaidya, S., Kim, J. H., & Lee, S. W. (2013). Estimation the porosity of pervious concretes based on X-Ray CT and submerged weight, *Journal of the Korean Society of Hazard Mitigation*, 13(4), 77-82.
19. Kumar, R., and Bhattacharjee, B. (2003). Porosity, pore size distribution and in situ strength of concrete, *Cement and Concrete Research*, 33(1), 155-164.
20. Nitto. Concrete tester and surveyor(User manual). (2009). Nitto, Osaka, Japan.
21. KS F 2405. (2022). Test method for compressive strength of concrete, Korea Standards Association. https://e-ks.kr/streamdocs/view/sd;streamdocsId=7205926579_6199707
22. Liashchynskyi, P., and Liashchynskyi, P. (2019). Grid search, random search, genetic algorithm: A big comparison for NAS, *arXiv preprint arXiv*, 1912.06059.

Received : 11/03/2022

Revised : 01/04/2023

Accepted : 01/09/2023

요 지 : 이 연구에서는 콘크리트 표면 이미지를 활용하여 표면공극률을 평가할 수 있는 영상 분할모델을 도출하였다. 물-시멘트비가 다른 3종류의 콘크리트 실험체 (w/c = 54, 35, 및 30%) 가 제작되었으며, 광학현미경을 활용하여 2,729장의 표면 이미지를 취득하였다. 공극이 마스크 된 표면 이미지를 활용하여 벤치마킹 테스트, 매개변수 최적화, 최종모델 도출이 실시되었으며, 97%의 검증정확도를 나타내는 영상 분할 모델을 도출할 수 있었다. 영상 분할모델 및 X-Ray Microscope (XRM)을 통해 얻은 공극률을 비교하여 모델을 검증하였으며, 물시멘트비가 높은 시편에 대해선 모델과 XRM이 평가한 공극률이 유사하였고, 물시멘트비가 낮은 시편에 대해서는 모델이 XRM보다 공극률을 낮게 평가하는 경향을 나타내었다.

핵심용어 : 콘크리트, 공극률, 영상분할, 머신러닝, 딥러닝