

골재의 형상 특성과 인공신경망에 기반한 콘크리트 압축강도 예측 연구

전준서¹, 김홍섭¹, 김창혁^{2*}

Study on Prediction of Compressive Strength of Concrete based on Aggregate Shape Features and Artificial Neural Network

Jun-Seo Jeon¹, Hong-Seop Kim¹, Chang-Hyuk Kim^{2*}

Abstract: In this study, the concrete aggregate shape features were extracted from the cross-section of a normal concrete strength cylinder, and the compressive strength of the cylinder was predicted using artificial neural networks and image processing technology. The distance-angle features of aggregates, along with general aggregate shape features such as area, perimeter, major/minor axis lengths, etc., were numerically expressed and utilized for the compressive strength prediction. The results showed that compressive strength can be predicted using only the aggregate shape features of the cross-section without using major variables. The artificial neural network algorithm was able to predict concrete compressive strength within a range of 4.43% relative error between the predicted strength and test results. This experimental study indicates that various material properties such as rheology, and tensile strength of concrete can be predicted by utilizing aggregate shape features.

Keywords: Concrete aggregate shape features, Compressive strength, Artificial neural network, Image processing technology

1. 서 론

최근 들어 노후 건축물의 증가로 인한 건축물 안전 성능 진단의 중요성이 커지고 있다. 전국 700만동 건축물 중 30년 이상 취약 건축물은 약 38% 정도로 지속적 증가 추세를 나타내고 있다(국회입법조사처, 2020). 이러한 노후 건축물의 재료 성능을 표기할 설계도면의 상당수는 존재하지 않지만, 건축물의 유지관리 시스템 구축을 위해서는 건축물의 성능을 정확히 판단해야 한다. 콘크리트의 압축강도와 같은 재료 성능은 건축물의 구조 성능을 평가하는 중요한 기준이므로 필수적으로 평가해야 한다.

기존 노후 건축물에 사용된 콘크리트의 압축강도를 평가하는 방법은 코어 공시체를 직접 채취해야 하므로 건축물에 손상이 발생하고 코어 공시체의 채취 과정에서 많은 진동과 소음이 발생하기 때문에 민원이 발생하기 쉽다. 따라서 기존의 방식과 차별성 있는 새로운 방법에 관한 연구가 많이 진행되고 있다.

콘크리트의 압축강도를 평가하기 위하여 인공신경망을 활용한 선행 연구는 다음과 같다. Park et al.(2020)은 경량혼합

토의 압축강도를 예측하기 위하여 심층신경망 모델을 사용하였다. 총 52개의 경량혼합토 공시체와 8개의 입력 변수를 사용하여 압축강도를 예측하였다. Eskandari-Naddaf and Kazemi(2017)는 인공신경망을 사용하여 시멘트 모르타르의 압축강도를 예측하였다. 인공신경망 모델과 실험 결과의 비교가 이루어졌다. 810개의 큐브형 공시체가 제작되었으며 총 5가지의 입력 변수를 고려하여 알고리즘을 구축하였다. Tenza-Abril et al.(2018)은 경량골재 콘크리트의 압축강도를 예측하기 위하여 인공신경망과 초음파속도를 활용한 연구를 수행하였다. 인공신경망 알고리즘을 구축하기 위해서 640개의 실험 결과를 수집하였으며 7가지의 입력 변수를 활용하였다. Onyari and Ikotun(2018)은 제올라이트가 포함된 모르타르의 압축 및 인장강도를 예측하기 위하여 인공신경망을 활용하였다. 이 연구에서는 총 30개의 실험 결과를 활용하였으며 6개의 변수가 고려되었다. Ashrafian et al.(2018)은 탄소섬유 콘크리트의 압축강도 예측을 위하여 다섯가지 다양한 인공지능 모델을 활용하였다. 압축강도 예측을 위한 실험체 군에서는 175개의 실험 데이터를 활용하였다. Cascardi et al.(2017)은 탄소섬유 구속된 원형 기둥의 압축강도를 예측하기 위하여 인공신경망을 적용하였다. 기존 문헌에서 수집된 208개의 데이터를 활용하여 연속 탄소섬유 보강된 원형 기둥의 강도를 예측하는 방법을 제안하였다. 앞서 언급된 선행 연구들은 콘크리트 압축강도를 예측하기 위하여 인공신경망

¹정희원, 한국건설기술연구원 수석연구원

²정희원, 인하대학교 건축학부 조교수

*Corresponding author: changhyuk@inha.ac.kr

Division of Architecture, Inha University, Incheon, 22212, Korea

•본 논문에 대한 토의를 2021년 11월 30일까지 학회에 보내주시면 2021년 12월호에 토론결과를 게재하겠습니다.

활용하였지만, 학습과 검증에 사용된 데이터는 실험체가 제작되기 전 공시체 배합의 비율 등이 주된 입력데이터로 사용되었다.

재료 배합을 고려한 연구 외에는 콘크리트 단면 이미지를 사용하여 콘크리트의 압축강도를 예측한 연구가 있다. 먼저 Başyigit et al.(2012)은 이미지 프로세싱 기술을 활용하여 콘크리트 압축강도를 예측하였다. 28개 큐브 형태 공시체 중 7개의 공시체는 단면 촬영용으로 사용되었다. 촬영된 단면 이미지는 회색조 처리가 되었다. 그 후 이미지의 히스토그램을 분석하여 압축강도를 예측할 수 있는 식을 제안하였다. Dogan et al.(2017, 2015)은 인공신경망과 이미지 프로세싱 기술을 함께 활용하여 콘크리트의 압축강도를 측정하였다. 인공신경망 모델 구축을 위하여 96개의 원형 공시체가 사용되었다. 인공신경망의 입력데이터로 활용된 변수는 콘크리트 단면 회색조 이미지에서 추출된 평균, 표준편차, 중간값이다.

인공신경망과 이미지 프로세싱 기술을 활용한 대부분의 연구에서는 콘크리트 공시체 단면의 회색조 이미지를 분석하여 이루어졌다. 회색조 이미지 분석의 경우 골재의 형상을 반영하지 못하고 이미지 전처리과정에서 촬영된 이미지에 따라 일관성을 확보하지 못 할 수 있다. 따라서, 본 연구에서는 단면 이미지의 회색조 이미지 분석을 사용하지 않고 골재의 형상을 분석하였다. 일반 콘크리트 공시체에서 균열의 시작과 가장 관련이 있고 압축강도에 영향을 미칠 수 있는 골재의 7가지 다양한 형상에 대한 특성을 단면 이미지로부터 추출하여 연구를 수행하였다.

2. 실험 연구

2.1 콘크리트 공시체 제작

Table 1에 본 연구에서 사용한 콘크리트 공시체의 배합 및

Table 1 Mix proportion

Gmax [mm]	W/C [%]	Air [%]	S/a [%]	Unit weight[kg/m ³]			
				Water	Cement	Sand	Gravel
13	40	4	45	165	412.50	764.50	967.24
20	50	4	45	165	330.00	794.77	1005.54

Table 2 Mechanical properties of the used materials

Material	Properties
Cement	Portland cement, Density : 3.15g/cm ³ Fineness : 3,630cm ² /g
Sand	Density : 2.56g/cm ³ , Absorptance : 0.97%
Gravel	Crushed gravel, Maximum size : 13, 20mm Density : 2.65g/cm ³ , Absorptance : 0.90%

사용재료의 물리적 특성을 나타내었다. 본 연구에서는 콘크리트 공시체 단면의 굽은 골재 형상에 따른 압축강도를 예측하기 위하여 최대치수 13, 20mm의 굽은 골재 2종류를 사용하였다.

콘크리트 배합은 굽은 골재 최대치수 13, 20mm에 대하여 각각 W/C를 40, 50%로 설정하였으며, 잔골재율과 단위 수량은 각각 45%, 165kg/m³로 하였다. Table 2에 사용재료의 물리적 특성을 나타내었다.

2.2 공시체 골재 특성 추출

선행 연구에서는 고려되지 않은 골재의 형상 특성을 공시체 단면으로부터 추출하여 인공신경망의 입력 변수로 사용하였다. 본 연구에서 일반강도 범위 콘크리트 골재의 형상 특성을 고려한 이유는 다음과 같다. 첫 번째로는 유지관리가 필요한 노후 건축물의 경우 30년 이상 오래된 경우가 많으며, 노후 건축물에 사용된 콘크리트는 일반 강도 범위이다. 두 번째로는 일반강도 콘크리트의 경우 고강도 콘크리트와는 다르게 균열의 진전이 골재와 모르타르의 경계면에서부터 시작하기 때문이다. 그 후 균열은 골재 면을 따라 진전하기 때문에 골재의 형상이 균열의 진전에 영향을 미치리라 판단하였다. 이와 같은 이유로 본 연구에서는 Fig. 1과 같은 7개의 골재 형상 특성을 공시체 단면 이미지로부터 추출하였다.

골재의 형상 특성을 나타낼 수 있는 거리-각도 특징에 대해서는 Fig. 2에 나타내었다. 거리-각도 특징은 도형의 도심으

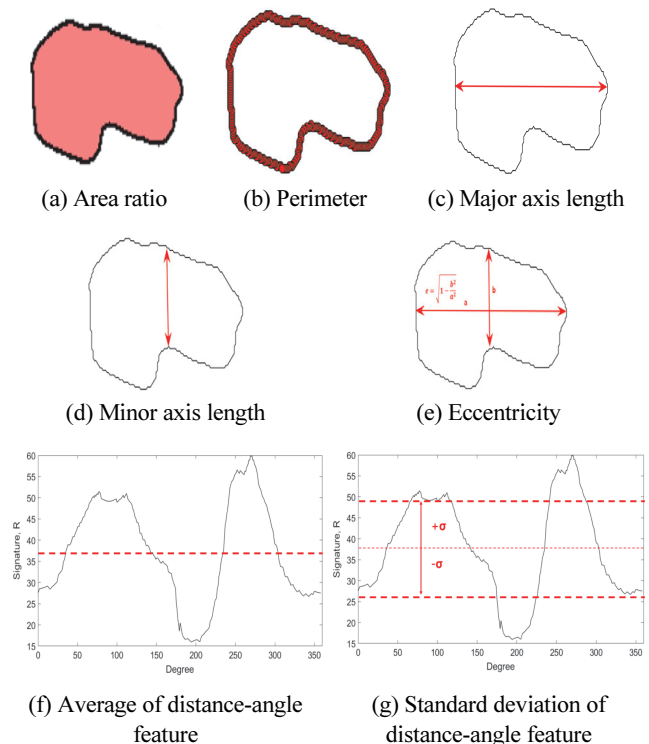


Fig. 1 Shape features of concrete aggregate

로부터 각도에 따른 경계선까지의 거리를 나타내는 것이다. Fig. 2(a)의 경우에는 도형이 원형이기 때문에 각도와 상관없이 거리는 동일하다. 하지만 Fig. 2(b)의 경우에는 각도에 따라 거리가 변화하는 것을 알 수 있다. Fig. 2(d)는 Fig. 2(c)에서 음영 처리된 하나의 골재에 대한 거리-각도 특징을 나타내고 있다.

공시체 단면 이미지에 분포하는 7가지 다양한 골재의 특징을 한 번에 추출하여 골재 크기별로 정리할 수 있는 알고리즘을 구성하여 연구에 활용하였다. 콘크리트 공시체의 골재 분포 이미지 사진은 공시체의 상하부를 일정하게 연마하여 확보하였다. 하지만 공시체를 제작할 때 Fig. 3(a)와 같이 골재 분리 현상이 발생할 수 있다. 이러한 입력데이터의 불균질성은 콘크리트 공시체 제작 당시 다짐의 정도에 따른 현상이라고 판단된다. 골재 분리 현상은 동일한 압축강도를 발휘하는 콘크리트 공시체에서 확연히 다른 두 골재 분포를 나타내므로 보완되어야 하며, 본 연구에서는 골재 분리 현상을 보완하기 위하여 상하부 두 이미지를 함께 고려하여 골재의 분포를 균등하게 반영할 수 있도록 하였다.

Table 3은 공시체 단면 이미지로부터 추출된 골재 형상 특성의 예시를 나타내고 있다. 예시에서는 골재의 크기가 상위 20번째까지 나타나 있지만, 실제 인공지능망 알고리즘에 적용된 골재는 실제 크기가 대략 5mm 이상인 골재가 모두 고려

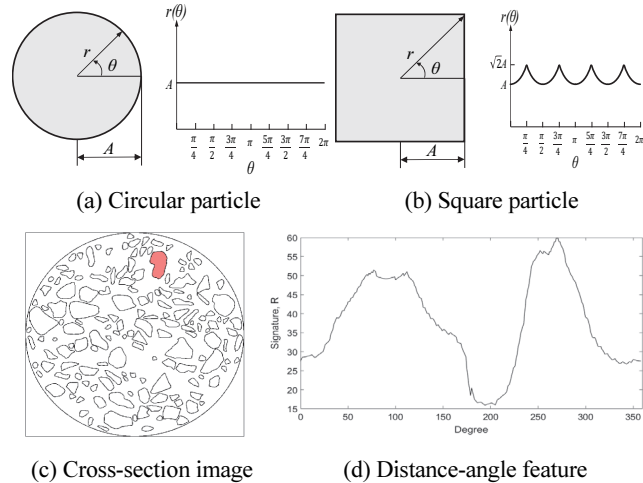


Fig. 2 Distance-angle feature




Fig. 3 Aggregate segregation of concrete cylinder

되었다. 이렇게 추출된 골재의 형상 특성 데이터는 기계학습을 통한 회귀 분석에 사용되었다.

2.3 압축강도 측정

제작된 콘크리트 공시체의 상하부 단면 이미지를 확보한 후 모든 공시체는 압축강도 측정에 사용되었다. 압축강도 측정은 Photo 1의 UTM(Universal Testing Machine)을 사용하여 KS F 2405 「Standard test method for compressive strength of concrete」에 준하여 실시하였다.

Table 3 Extracted shape features of concrete aggregate

No.	Area ratio	Major axis length	Minor axis length	Eccentricity	Perimeter	Distance-Angle featur	
						Mean	Standard deviation
						1	0.0095
2	0.0070	130.07	85.58	0.75	368.89	47.36	11.69
3	0.0052	97.19	80.49	0.56	294.38	41.63	6.37
4	0.0045	99.32	71.62	0.69	296.18	38.46	8.12
5	0.0045	130.00	50.28	0.92	304.85	36.36	14.33
6	0.0043	112.84	53.91	0.88	280.34	36.87	10.01
7	0.0041	97.48	60.05	0.79	260.39	36.34	7.51
8	0.0040	140.19	41.77	0.95	306.96	32.98	16.16
9	0.0039	90.96	60.91	0.74	254.76	35.83	5.93
10	0.0037	79.10	67.44	0.52	237.17	35.39	3.45
11	0.0036	90.22	59.41	0.75	246.22	34.45	6.79
12	0.0036	78.05	71.11	0.41	255.34	34.41	5.90
13	0.0036	75.77	67.87	0.44	232.14	34.72	3.24
14	0.0036	90.54	59.74	0.75	261.22	33.80	7.35
15	0.0032	73.14	62.76	0.51	220.52	32.62	3.65
16	0.0031	77.64	60.45	0.63	233.63	31.96	5.52
17	0.0030	80.71	58.65	0.69	235.01	31.44	6.22
18	0.0025	87.18	42.22	0.87	214.47	27.91	8.26
19	0.0024	94.22	37.55	0.92	229.89	26.54	9.56
20	0.0023	97.42	35.78	0.93	229.19	25.79	10.72



Photo 1 Compressive strength test set up

2.4 압축강도 실험 결과

Table 4에 압축강도 시험 결과를 나타내었다. 본 연구에서는 각 배합 수준에서 Ø100×200mm 원주형 공시체 30개를 제작하여 압축강도를 측정하였다. G_{max} 13mm, W/C 40%의 평균 압축강도는 39.8MPa, G_{max} 20mm, W/C 50%의 평균 압축강도는 28.5MPa로 측정되었으며, 시험체별 측정결과는 Table 4에 나타내었다.

Table 4 Compressive strength (MPa)

Gmax [mm]	13	20
W/C [%]	40	50
NO. 1	40.9	29.1
NO. 2	39.8	-
NO. 3	39.3	28.7
NO. 4	40.8	29.0
NO. 5	42.9	30.3
NO. 6	41.3	27.3
NO. 7	41.2	28.5
NO. 8	41.9	30.2
NO. 9	35.1	29.9
NO. 10	39.3	27.2
NO. 11	40.0	28.3
NO. 12	39.2	31.0
NO. 13	40.6	28.7
NO. 14	40.5	29.9
NO. 15	39.7	27.9
NO. 16	40.6	28.2
NO. 17	41.4	26.6
NO. 18	41.1	27.8
NO. 19	41.2	29.3
NO. 20	40.2	27.0
NO. 21	38.9	28.0
NO. 22	40.0	27.6
NO. 23	32.4	28.6
NO. 24	39.3	27.7
NO. 25	38.8	29.9
NO. 26	37.6	26.6
NO. 27	37.6	25.8
NO. 28	41.2	27.6
NO. 29	41.0	29.4
NO. 30	38.7	29.3
AVE.	39.8	28.5
MAX.	42.9	31.0
MIN.	32.4	25.8
StDev	2.02	1.24

3. 기계학습 연구


3.1 인공신경망 알고리즘

뉴런으로 복잡하게 연결된 사람의 뇌 구조에 영감을 얻은 인공신경망은 공학, 경제학, 수학, 의학 등 다양한 영역에서 사용되어왔다. 각각의 뉴런은 서로 연결되어 신경망을 구성하는데, 훈련과정을 통해 연결 관계가 강해지거나 약해지는 가중화된 연결(Weighted connection)을 통해 특정한 값을 도출하게 된다. 이런 가중화된 연결은 초기 가중치(Weight)와 편향(Bias)을 가지는 각 층의 뉴런에 훈련 샘플을 대입하여 예측값을 계산하고, 결과값(Target)과 비교하여 오차를 측정 한 후 역방향으로 각 층을 지나면서 연결이 오차에 기여한 정도를 측정하여 오차가 감소하도록 가중치를 조정하게 되는 역전파(Backpropagation)를 통해 이루어진다 (Géron, 2017).


3.2 다층신경망 알고리즘 구축

인공신경망 구축을 위해 MATLAB Deep Learning Toolbox를 이용하였다. 학습에 사용된 입력 변수는 2.2절에서 설명된 7가지의 골재 형상 특성이며, 출력값은 이미지가 추출된 공시체의 압축강도이다. 압축강도 예측 알고리즘 학습을 위해 데이터를 훈련 세트(Training set) 70%, 검증 세트(Validation set) 15%, 테스트 세트(Test set) 15% 비율로 무작위로 분할하였다. 일반적으로 훈련 세트는 신경망 가중치(Weight)와 편향(Bias)를 수정하고, 검증 세트는 훈련 과정 중 과대적합 유무를 판단하고, 테스트 세트는 훈련에는 이용되지 않으나 훈련된 신경망의 성능을 확인하기 위해 사용된다. 훈련 중 신경망의 성능은 평균 제곱 오차(Mean squared error)를 이용하여 판단하였으며, 가장 낮은 평균 제곱 오차를 반환할 때 훈련을 종료하였다. 또한 과대적합 방지를 위해 검증 세트의 성능이 떨어지기 시작할 때, 즉 검증 세트의 평균 제곱 오차가 감소하다 다시 증가할 때 훈련을 중지시키는 조기 종료(Early stopping)를 적용하였다.

학습규칙은 Levenberg-Marquardt 역전파 알고리즘을 이용하였으며, 활성화 함수로 은닉층은 로그-시그모이드 함수(Log-sigmoid function), 출력층은 선형 함수(Linear function)를 이용하였다. 은닉층의 수, 은닉층의 뉴런 수에 따라 신경망의 정확도는 달라지나, 완벽한 수를 찾아내기는 쉽지 않다. 따라서 일반적으로 사용되는 하나 혹은 두 개의 은닉층에 뉴런 수를 변화시켜 상관계수가 가장 큰 값을 주는 조합을 이용하였다. Fig. 4는 은닉층의 수, 은닉층의 뉴런 수 변화에 따른 상관계수를 나타낸다. 하나의 은닉층을 이용할 경우 뉴런의 수가 8개일 때, 두 개의 은닉층을 이용할 때는 은닉층마다 6개의 뉴런을 이용할 때 가장 큰 상관계수를 보였다. 최종적으로 Fig. 5와 같이 8개의 뉴런을 가지는 단일 은닉층 구조를 선택하였다.



(a) One hidden layer



(b) Two hidden layers

Fig. 4 Correlation coefficients with various numbers of neuron




Fig. 5 Architecture of artificial neural networks

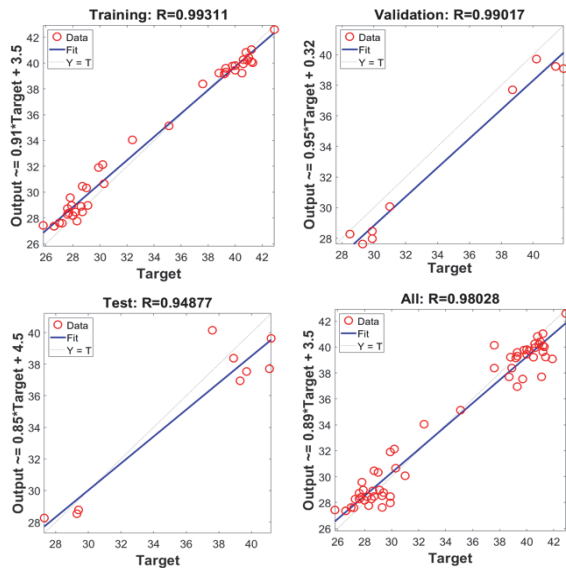


Fig. 6 Regression plots of the proposed ANN model

Table 5 Comparison in compressive strength between experimental data and predicted data

No.	Compressive strength [MPa]		Relative error [%]
	Experimental data	Predicted data	
NO. 1	27.30	28.26	3.52
NO. 2	29.40	28.77	2.15
NO. 3	29.30	28.53	2.63
NO. 4	41.20	39.63	3.81
NO. 5	39.30	36.95	5.99
NO. 6	39.70	37.53	5.46
NO. 7	41.10	37.70	8.26
NO. 8	38.90	38.37	1.35
NO. 9	37.60	40.14	6.76

Fig. 6은 훈련 후 신경망의 성능을 확인하기 위해 신경망으로 예측된 강도와 실험값(목표값) 사이의 회귀 분석 결과를 나타낸다. 상관계수는 훈련 세트, 검증 세트, 테스트 세트, 모든 데이터에 대해 1에 거의 근접한 값을 보여주며, 이는 훈련된 신경망의 성능이 양호함을 나타낸다.

3.3 실험 결과와의 비교

Table 5는 개발된 신경망을 이용하여 훈련에 사용되지 않았던 일부 공시체의 예측 강도를 예측하여 비교하였다. 상대 오차는 최소 1.35%, 최대 8.26%, 평균 4.43%로 나타났다.

4. 결론

본 연구에서는 선행 연구에서 고려되지 않은 콘크리트 골재의 형상 특성을 공시체 단면 이미지로부터 추출하였다. 추출된 7가지 골재 특성 데이터와 인공신경망을 사용하여 콘크리트 공시체의 압축강도 예측 가능성을 검증하였다. 일반적인 인공신경망 연구와 비교해 상대적으로 적은 데이터가 사용되었지만, 선행 연구를 참고하여 의미 있는 결과를 도출할 수 있는 데이터의 양을 결정하고 실험을 진행하였다. 이를 통해 이미지를 활용하여 일반강도 콘크리트의 압축강도를 예측할 수 있었고 다음의 결론을 도출하였다.

- (1) 콘크리트 강도에 영향을 미치는 물시멘트비, 단위수량, 결합재량, 공기량 등을 인공신경망의 입력 변수로 사용하지 않고, 콘크리트 단면에 분포하는 골재 이미지만을 사용하여 입력 변수를 추출하고 인공신경망에 적용하여도 콘크리트 압축강도를 예측할 수 있는 것을 확인하였다.
- (2) 콘크리트 균열이 골재를 관통하지 않는 일반강도 콘크리트의 경우 골재 형상 특성을 추출하여 압축강도를 예측

할 수 있었다. 인공신경망 알고리즘 구축에 사용되지 않은 9개의 별도 공시체를 사용하여 예측 강도와 실제 강도를 비교한 결과 평균 상대오차는 약 4.43%로 나타났다.

(3) 면적, 둘레, 길이 등과 같은 일반적인 골재의 형상 특성이 아닌 거리-각도 특징은 콘크리트 골재의 형상을 수치적으로 표현하고 물성치 예측에 활용될 수 있었다. 이와 같은 특성은 추후에 콘크리트의 유동성(슬럼프, 레올로지), 휨·인장강도 등 다양한 물성치를 예측할 때 활용될 수 있을 것으로 판단된다.

감사의 글

본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었음(과제번호 21CTAP-C163910-01)

References

1. NARS (2020), The Status and future tasks of old buildings, National Assembly Research Service.
2. Park, B., Kim, D., and Park, D.-W. (2020), Predictive System for Unconfined Compressive Strength of Lightweight Treated Soil(LTS) Using Deep Learning, *Journal of the Korea Institute for Structural Maintenance and Inspection*, 24(3), 18-25.
3. Eskandari-Naddaf, H., and Kazemi, R. (2017), ANN Prediction of Cement Mortar Compressive Strength, Influence of Cement Strength Class, *Construction and Building Materials*, 138, 1-11.
4. Tenza-Abril, A. J., Villacampa, Y., and Solak, A. M. (2018), Prediction and Sensitivity Analysis of Compressive Strength in Segregated Lightweight Concrete Based on Artificial Neural Network Using Ultrasonic Pulse Velocity, *Construction and*

Building Materials, 189, 1173-1183.

5. Onyari, E. K., and Ikotun, B. D. (2018), Prediction of Compressive and Flexural Strengths of a Modified Zeolite Additive Mortar Using Artificial Neural Network, *Construction and Building Materials*, 187, 1232-1241.
6. Ashrafiyan, A., Taheri Amiri, M. J., and Rezaie-Balf, M. (2018), Prediction of Compressive Strength and Ultrasonic Pulse Velocity of Fiber Reinforced Concrete Incorporating Nano Silica Using Heuristic Regression Methods, *Construction and Building Materials*, 190, 479-494.
7. Cascardi, A., Micelli, F., and Aiello, M. A. (2017), An Artificial Neural Networks Model for the Prediction of the Compressive Strength of FRP-Confined Concrete Circular Columns, *Engineering Structures*, 140, 199-208.
8. Başığit, C., Comak, B., and Kilincarslan, Ş. (2012), Assessment of Concrete Compressive Strength by Image Processing Technique, *Construction and Building Materials*, 37, 526-532.
9. Dogan, G., Arslan, M. H., and Ceylan, M. (2017), Concrete Compressive Strength Detection Using Image Processing Based New Test Method, *Measurement: Journal of the International Measurement Confederation*, 109, 137-148.
10. Doğan, G., Arslan, M. H., and Ceylan, M. (2015), Statistical Feature Extraction Based on an Ann Approach for Estimating the Compressive Strength of Concrete, *Neural Network World*, 25(3), 301-318.
11. Géron, A. (2017), Hands-On Machine Learning with Scikit-Learn & TensorFlow, O'Reilly Media, Inc, California, 336-339.
12. KS F 2405 Standard test method for compressive strength of concrete.

Received : 08/30/2021

Revised : 09/08/2021

Accepted : 09/10/2021

요 지 : 본 연구에서는 일반강도 범위 콘크리트의 단면에서 골재 형상의 특성을 추출하고 이를 인공신경망과 이미지 프로세싱 기술에 적용하여 콘크리트의 압축강도를 예측하였다. 이를 위하여 면적, 둘레, 길이 등과 같은 일반적인 골재 형상 특성과 함께 골재의 거리-각도 특징을 수치적으로 표현하고 물성치 예측에 활용하였다. 그 결과, 콘크리트 압축강도에 영향을 미치는 주요변수를 사용하지 않고 단면의 골재 형상 특성만을 사용하여 압축강도 예측이 가능하였으며, 인공신경망 알고리즘 구축을 통해 예측 강도와 실제 강도의 상대오차 4.43% 이내의 범위에서 콘크리트 압축강도를 예측할 수 있었다. 본 연구에서 도출된 결과를 기반으로 골재의 거리-각도 특징을 활용하여 콘크리트의 유동성, 휨·인장강도 등 다양한 특성을 예측도 가능할 것으로 판단된다.

핵심용어 : 골재 형상 특성, 압축강도, 인공신경망, 이미지 프로세싱