

대공간 구조물의 UHPC 적용을 위한 기계학습 기반 강도예측기법

Machine Learning Based Strength Prediction of UHPC for Spatial Structures

이 승 혜*
Lee, Seunghye

이 재 홍**
Lee, Jaehong

Abstract

There has been increasing interest in UHPC (Ultra-High Performance Concrete) materials in recent years. Owing to the superior mechanical properties and durability, the UHPC has been widely used for the design of various types of structures. In this paper, machine learning based compressive strength prediction methods of the UHPC are proposed. Various regression-based machine learning models were built to train dataset. For train and validation, 110 data samples collected from the literatures were used. Because the proportion between the compressive strength and its composition is a highly nonlinear, more advanced regression models are demanded to obtain better results. The complex relationship between mixture proportion and concrete compressive strength can be predicted by using the selected regression method.

Keywords : UHPC, Spatial structure, Machine learning, Strength prediction, Deep learning

1. 서론

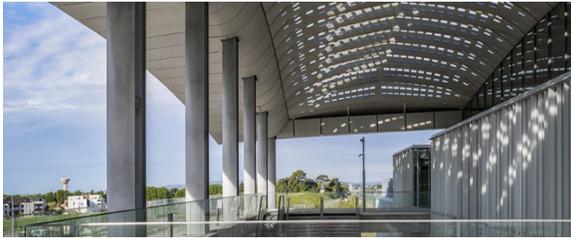
UHPC(Ultra-High Performance Concrete)는 초고 강도의 압축 성능과 높은 내구성을 발휘하는 고성능 콘크리트 재료를 의미한다. 프랑스의 de Larrard & Sedran(1994)이 UHPC의 개념을 처음으로 발표¹⁾한 이후 여러 연구자들에 의해 조성과 배합 비율 등에 관한 연구가 계속되어 왔다. 미국 연방고속도로관리국(FHWA: The Federal Highway Administration)에 따른 UHPC의 정의는 물-결합재비(Water-to-Binder ratio, W/B)가 0.25 미만이고, 섬유보강(Fiber reinforcement) 재료가 혼입되어 있으며, 압축강도가 150MPa 이상인 재료를 말한다. UHPC는 콘크리트 내 공극을 줄이기 위해 지름 5mm 이상의 굵은 골재를 사용하지 않는다. 분말도와 강도를 높이기 위해 일반 포틀랜드 시멘트(Ordinary Portland Cement, OPC)의 일부

를 타 시멘트성 물질로 대체하고, 물, 잔골재, 고성능 감수제(Superplasticizer)와 실리카퓌름(Silica fume) 또는 마이크로 실리카(Microsilica) 등을 혼합하여 구성한다²⁾. 여기에 섬유보강 재료를 사용하여 8~20MPa의 인장강도를 얻을 수 있는 고인성 재료를 완성할 수 있다³⁾.

위와 같은 우수한 기계적 성능으로 인해 UHPC를 교량, 건축 요소, 해양구조물, 수리구조물 등에 적용하려는 노력이 지속되어 왔다⁴⁾. 특히 UHPC는 물, 염소이온, 열화인자 등의 침투를 거의 허용하지 않으며 탁월한 내구성, 균열저항성능 등의 우수한 장점이 많아 보수, 보강 등에 많이 사용하고 있다. 또한 얇으면서 단단한 외장재를 만드는데 탁월하다⁵⁾.

전 세계 다양한 제조사에서 고유한 상표 혹은 제조사명을 띤 UHPC를 출시하였는데, Ceracem[®], BCV[®], Cemtec[®], Ductal[®], DURA[®] 등이 대표적이라 할 수 있다. 현재까지 가장 대중적인 Ductal[®] 브랜드는 프랑스의 LAFARGE, BOUYGUES, RHODIA의 세 업체가 공동으로 특허를 소유하고 있으며, 랜드마크 역할을 하는 대공간 구조물에 UHPC를 적용하여 그 활용 가능성을 널리 알리기도 하였다.

* 정회원, 세종대학교 건축공학과 조교수, 공학박사
Dept. of Architectural Engineering, Sejong Univ.
** 교신저자, 정회원, 세종대학교 건축공학과 교수, 공학박사
Dept. of Architectural Engineering, Sejong Univ.
Tel: 02-3408-3287 Fax: 02-3408-4331
E-mail: jhlee@sejong.ac.kr



〈Fig. 1〉 Montpellier - South of France station, Double-curved roofing, Ductal®



〈Fig. 2〉 Jean Bouin Stadium in France Paris, Roof and facade, Ductal®

〈Fig. 1〉은 프랑스 남부 Montpellier 역 지붕재에 Ductal®의 UHPC 재료를 사용한 사진이다. 또한 Ductal®사는 〈Fig. 2〉와 같이 프랑스 파리 내 Jean Bouin 경기장 지붕재 및 파사드(Facade)에 UHPC를 적용하여 대공간을 창출하였다. 이 외에도 캐나다의 Shawnessy LRT 역 지붕재, 프랑스 마르세유에 위치한 MuCEM 박물관의 기둥 및 파사드, 프랑스 파리에 위치한 Foundation Louis Vuitton 박물관의 외피 패널, 아부다비 Saadiyat 섬에 위치한 Louvre Abu Dhabi 박물관 지붕 등 대공간 구조물에 UHPC를 활용하는 사례가 점점 증가하는 추세이다.

UHPC는 구성 재료와 배합 비율에 따라 경화 후의 기계적 성능에 큰 영향을 받는다. 구성 재료 및 비율의 조합은 셀 수 없이 다양하게 존재하여 각각의 조합을 실험실에서 확인하는 DOE(Design of Experiments) 방법은 많은 시간과 노력이 필요하다⁶⁾. 따라서 UHPC 구성에 따른 압축강도의 도출은 기존의 실험 데이터를 사용하여 통계학적으로 예측하는 SMD(Statistical Mixture Design) 기법이 효율적이라고 할 수 있다. 하지만 재료의 구성과 압축강도의 관계가 비선형적으로 연결되어 고도의 예측기법의 개발이 필요한 실정이다.

기계학습(Machine learning) 기법은 데이터 세트를 통하여 훈련된 학습모델을 사용하여 새로운 데이터를

예측하는 형태로 UHPC 압축강도 예측을 위한 최적의 선택이라 할 수 있다. 이 때 재료의 구성과 압축강도의 관계가 완전 연결되어 연속적인 값을 출력하는 UHPC 데이터 세트는 회귀(Regression) 기법을 적용해야 한다.

Ghafari et al.(2015)은 15개의 은닉층(Hidden layer)을 사용한 인공신경망(Artificial Neural Network: ANN) 기법을 적용하여 UHPC 데이터의 회귀 문제를 해결하였다⁷⁾. Abellán-García(2020) 또한 2개의 은닉층(Hidden layer)을 사용한 인공신경망 기법을 적용하여 UHPC의 강도를 예측하였다⁸⁾. 그러나 컴퓨터 공학 분야에서는 다양한 회귀문제 해결 기법이 존재하고 최근 예측의 정확성을 높이기 위한 혁신적인 기법이 개발되어 왔으나 이를 UHPC에 적용한 사례는 거의 전무하다 할 수 있다⁹⁾.

본 연구에서는 앙상블 학습 기법(Ensemble learning method) 중 하나인 CatBoost 방법을 제안하고, 이를 훈련한 모델로 UHPC 콘크리트 강도를 예측하였다. 기존 연구에서 사용한 인공신경망 기법은 단일 모델을 사용하여 데이터를 훈련함에 반해 앙상블 학습 기법은 여러 개의 결정 트리(Decision tree)를 결합하여 평가한 후 하나의 예측모델보다 더 좋은 모델을 도출한다. 제안된 기계학습기법은 기존 연구에서 얻은 110개의 데이터 샘플을 통해 훈련되며, 다양한 평가 기법을 통해 정확성을 확인하고 각각의 결과를 비교분석하였다. 이를 통해 얻은 학습모델은 추후 얻는 새로운 UHPC 변수 데이터를 대입하여 최종적으로 콘크리트 강도를 예측할 수 있다.

2. 데이터 세트

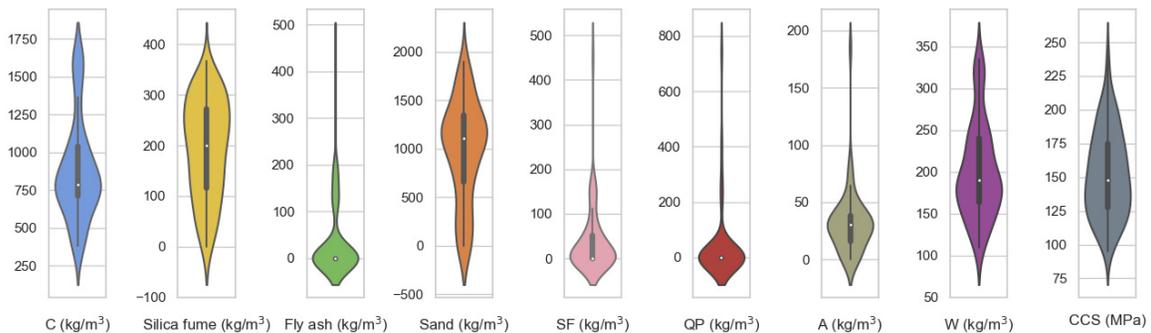
2.1 110 데이터 샘플

UHPC 실험 데이터는 12개의 참고문헌에서 얻은 실험 결과를 토대로 구성한 것이며, 총 110개의 샘플을 사용하였다¹⁰⁾. 12개의 원본데이터는 참고문헌 11번부터 22번까지의 정보에서 찾아볼 수 있다¹¹⁻²²⁾. UHPC의 압축강도를 얻는 각 샘플은 시멘트(Cement: C), 실리카퓌름(Silica fume), 플라이애쉬(Fly ash), 모래(Sand), 강섬유 보강재(Steel Fiber: SF), 규사(Quartz Powder: QP), 물(Water: W), 혼화재(Admixture: A) 총 8개의 변수를 사용하였다. 유동화제 혹은 감수제 계열의 첨가물은 모

두 혼화재에 포함시켜 데이터를 구성하였다. UHPC의 압축강도는 모두 28일 강도를 측정된 것이며, 각 재료는 1m³ 부피의 kg을 측정된 무게(kg/m³)로 통일되었다.

2.2 데이터 샘플의 통계적 분석

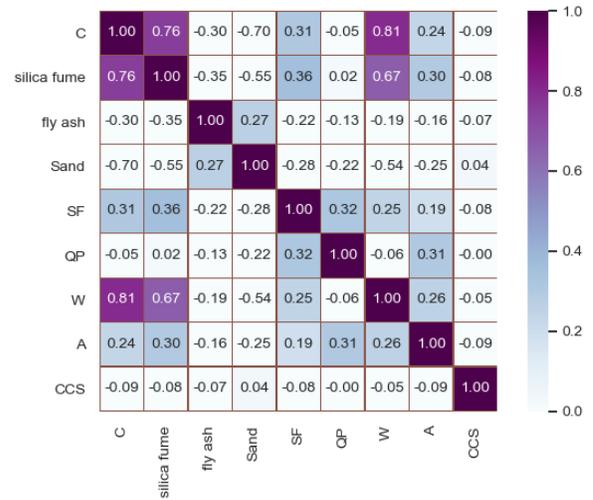
〈Fig. 3〉은 데이터 샘플의 바이올린 플롯(Violin plot)을 나타내고 있다. 바이올린 플롯을 통해 각 입력 변수의 분포와 특징을 알 수 있으며, 데이터의 확률 밀도 또한 알아볼 수 있다. 〈Table 1〉은 각 입력 변수와 출력 변수의 최소·최대값, 평균값 및 표준편차를 나타낸다. 110개의 샘플이 모든 변수들을 포함한 것이 아니므로 입력 변수 대부분의 최소값은 0으로 나타난다. 110개의 데이터 샘플 내에서 UHPC 압축강도의 평균값은 152.2로 FHWA가 정의하는 ‘압축강도가 150MPa 이상’에 부합하는 수치이다.



〈Fig. 3〉 Violin plots showing the distribution of the dataset

〈Table 1〉 Statistical variable of the dataset

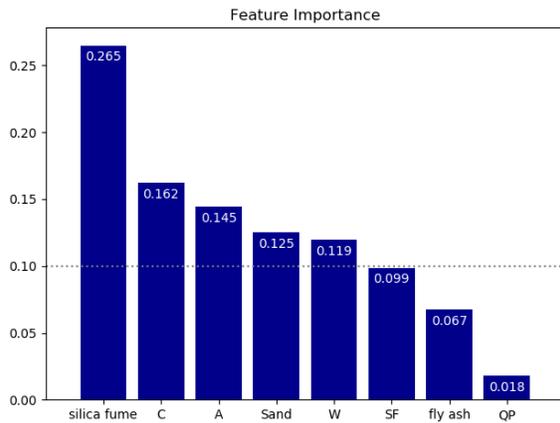
Attributes	Coded	Unit	Min.	Max.	Mean	Standard deviation
Cement	C	kg/m ³	383.0	1600.0	879.7	331.3
Silica fume	-	kg/m ³	0.0	368.0	195.1	96.4
Fly ash	-	kg/m ³	0.0	448.0	33.0	73.0
Sand	-	kg/m ³	0.0	1898.0	980.0	516.2
Steel fiber	SF	kg/m ³	0.0	470.0	39.0	75.1
Quartz powder	QP	kg/m ³	0.0	750.0	36.9	126.5
Water	W	kg/m ³	109.0	334.5	200.6	56.3
Admixture	A	kg/m ³	0	185.0	31.9	28.3
f'c	CCS	MPa	95.0	240.0	152.2	31.6



〈Fig. 4〉 Correlation matrix of features in the dataset

〈Table 2〉 Statistical variable of the dataset

Dataset	Linear terms of the 8 variables	Quadratic terms of the 5 selected variables	Interaction terms of the 5 selected variables	Total number of input variables
Set_1	○			8
Set_2	○	○		13
Set_3	○		○	18
Set_4	○	○	○	23



〈Fig. 5〉 Feature importance of the dataset

〈Fig. 4〉는 데이터 세트의 상관행렬(Correlation matrix)로 이를 통해 각 변수들 간의 상관관계를 알 수 있다. 이는 두 변수 사이의 관계가 있고 없음을 알아보는 것으로 구체적으로 어떤 함수관계가 있는가를 파악하는 것은 아니다. 〈Fig. 4〉만 살펴보면 시멘트와 실리카폼, 물 성분 간의 상관관계가 높게 나타나는데, 이는 고강도콘크리트의 분석에서 시멘트의 양생 시간과 콘크리트 압축강도 간의 상관관계가 높은 값을 보이는 것과 대조적이다²³⁾. 이러한 UHPC의 복잡한 재료 구성과 콘크리트 압축강도 간의 비선형적인 관계 해석을 위해 회귀모델을 훈련하기 전 특성 엔지니어링(Feature engineering) 단계가 필요하다.

3. 특성 엔지니어링

3.1 특성 선별

UHPC 데이터 세트의 총 8가지 입력 변수에 대해 유효한 특성을 선별(Feature selection)하기 위해 〈Fig. 5〉와 같이 중요도를 도출하였다. 이 때 특성의 상대적 중요도를 측정하는데 유용한 랜덤포레스트(RandomForest)²⁴⁾ 기법을 사용하였다. 랜덤포레스트

기법은 결정 트리 모델²⁵⁾에 기반한 앙상블 학습 기법²⁶⁾의 하나로 다수의 결정 트리를 사용하여 일련의 좋은 예측을 얻을 수 있다.

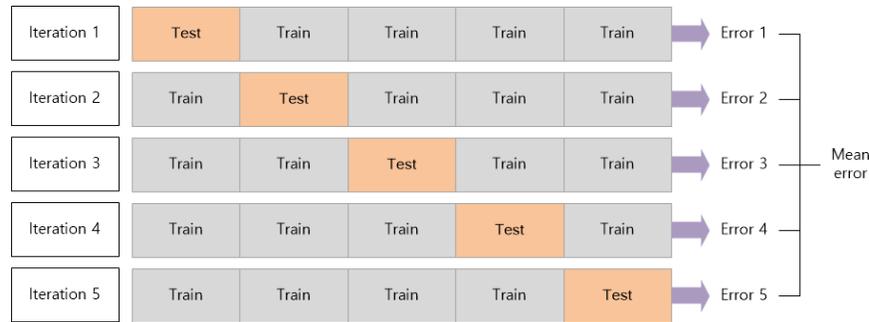
〈Fig. 5〉를 살펴보면 실리카폼이 가장 높은 중요도 특성을 보였으며, 시멘트(C), 혼화재(A), 모래(Sand), 물(W), 강섬유보강재(SF), 플라이애쉬(Fly ash), 규사(QP)의 순으로 중요도 특성을 보였다. 여기서 중요도 0.1 이상의 값을 보이는 상위 5개의 변수를 특성 구축(Feature construction) 단계에 도입하여 예측모델의 성능을 증가시킬 수 있는 다항차수 항을 생성하기로 한다.

3.2 특성 구축

8개의 입력 변수와 UHPC 압축강도 간의 비선형 특성을 반영한 예측모델을 구축하기 위해 변수의 다항식(Polynomial) 값을 사용한 새로운 데이터 세트를 생성하였다. 이는 원본 데이터 간 상호작용을 통한 더 많은 특성을 비선형 예측모델에 부과하기 위함이다. 본 연구에서는 2차 다항식을 생성하였으며, 이 때 앞 절에서 선별한 5개의 우세한 입력 변수(실리카폼, 시멘트, 혼화재, 모래, 물)만 사용하였다.

일반적으로 2차 다항식을 사용한다는 것은 지정된 차수보다 작거나 같은 변수의 모든 다항식 조합으로 구성된 새 특성 행렬을 의미한다. 이 때 각 변수의 원본 값 및 제곱근을 나열하며, 각 특성 간 상호교차 곱의 값을 추가한다. 하지만 어떤 특성 간의 조합이 예측모델의 성능을 증가시키는지 알 수 없으므로 다양한 조합의 데이터 세트를 사용하여 회귀모델을 시험하여 보았다. 〈Table 2〉는 회귀모델을 훈련 및 검증하기 위한 데이터 세트의 다양한 조합을 나타내고 있다.

앞서 수행한 특성 선별 과정에서 5개의 우세한 특성을 추출하였지만 모든 데이터 세트에 8개 원본 특성의 1차 항 값은 모두 사용하였다. UHPC 제작 과정에 있어 각각의 특성이 모두 중요한 역할을 수행하고 있고, 110개



〈Fig. 6〉 5-fold cross-validation

의 데이터 세트에서 발견하지 못한 미세한 특성이 추후 새 데이터 세트에서 발현될 수 있기 때문이다.

4. UHPC 데이터를 위한 회귀모델

4.1 CatBoost

본 연구에서는 UHPC 데이터를 위한 회귀모델을 위해 CatBoost(Categorical gradient Boosting) 기법을 선택하였다. CatBoost는 앙상블 학습의 부스팅(Boosting) 기법 중 하나로 최근 제안되었다²⁷⁾. 부스팅은 다수의 트리(분류기)를 사용하는 과정에서 약한 분류기를 결합하여 강한 분류기를 만드는 기법을 뜻한다²⁸⁾. 기존의 부스팅 기법이 일괄적으로 모든 훈련 데이터를 대상으로 잔차(Residual)를 계산했다면, CatBoost 기법은 일부만 사용하여 잔차를 계산한 뒤 이를 통해 모델을 구축하고 나머지 데이터를 사용하여 검증단계를 거친다. 훈련에 사용하는 데이터의 비율을 점차 증가시켜 반복적인 훈련 과정을 거친다. 이를 통해 기존 부스팅 기법이 가지고 있는 느린 학습 속도와 과적합(Over-fitting) 문제를 개선할 수 있다. 본 연구에서는 Yandex사에서 개발한 오픈소스를 사용하였다.

4.2 평가 기법

훈련 세트와 테스트 세트를 일정한 비율로 나누고 훈련 세트를 사용하여 모델을 학습 이후에 테스트 세트로 검증하는 방법은 새로운 데이터를 예측하는데 있어 안정적이지 못하다. 교차검증(Cross-validation)은 훈련 세트와 테스트 세트를 여러 번 반복해서 나누고 각각에

대해 학습하기 때문에 전자의 방법보다 훨씬 안정적이다. 가장 널리 사용되는 방법은 k-겹 교차 검증(k-fold cross-validation)이다. k개의 폴드(Fold)로 나누어진 데이터는 각 단계의 순번에 해당하는 폴드를 테스트 세트로, 나머지 데이터를 훈련 세트로 사용하는 방법으로 k번 반복하여 검증 단계를 수행한다. 결국 학습모델은 k개의 정확도를 얻게 된다. 본 연구에서는 5-겹 교차 검증 방법을 사용하였다(Fig 6).

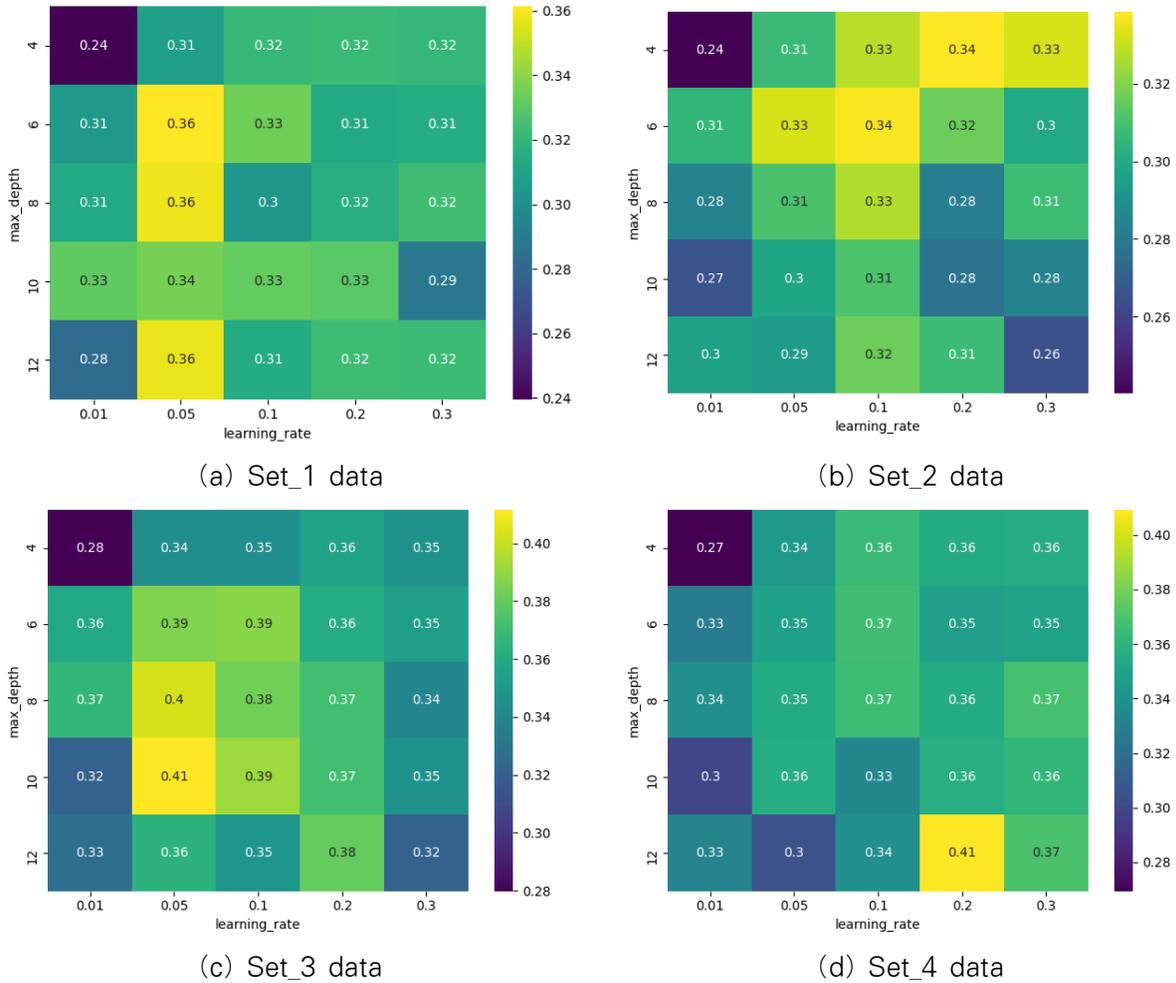
제안된 회귀모델을 평가하기 위해 평균 제곱근 오차(Root Mean Squared Error: RMSE), 평균 제곱 오차(Mean Squared Error: MSE), 평균 절대 오차(Mean Absolute Error: MAE), 결정계수(Coefficient of determination: R²) 값을 사용하였다. 특히 결정계수 R² 지표는 독립변수(출력 값)가 종속변수(입력 값)에 대해 얼마나 설명력을 갖게 되는지를 의미하는 수치로 1에 가까운 수일수록 양의 상관관계를 의미한다. n개의 데이터 샘플을 사용하였을 때 4가지 성능 평가 지표의 식은 아래와 같다.

- Coefficient of determination (R²)

$$R^2 = \left(\frac{n \sum ty - (\sum t)(\sum y)}{\sqrt{n(\sum t^2) - (\sum t)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \right)^2 \quad (1)$$

- Root Mean Square Error (RMSE)

$$SE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2} \quad (2)$$



〈Fig. 7〉 R² scores of tuning hyper-parameter

- Mean Square Error (MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2 \quad (3)$$

- Mean Absolute Error (MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |t_i - y_i| \quad (4)$$

여기서 t와 y는 각각 실제 값과 예측 값을 뜻한다.

4.3 하이퍼파라미터 조정

CatBoost 기법은 내부적인 알고리즘에서 사용하는 변수들이 기본적으로 최적화가 잘 되어 있어 하이퍼파라미터 조정(Hyperparameter tuning) 과정을 거치지 않아도 된다. 하지만 UHPC 데이터 샘플의 수가 극히 적고

각 변수와 콘크리트 압축강도 출력 값 사이에 복잡한 비선형 관계가 형성되므로 본 연구에서는 2개의 하이퍼파라미터(learning_rate, max_depth)에 대해 최적의 값을 찾는 과정을 수행하였다.

learning_rate 파라미터는 최소의 손실(Loss)을 찾는 반복되는 학습 과정에서 보폭(Step size)을 뜻하는 학습률을 말한다. max_depth는 트리 기반의 앙상블 학습에서 최대 트리 깊이를 뜻한다. 각 부모세대 노드에서 가지를 치듯이 뻗어 나가면서 학습하는 과정은 학습 시간이 적게 걸리면서 정확도가 높은 적절한 개수의 트리가 필요하다. 결정된 최적의 하이퍼파라미터는 과적합을 극복하고 결과적으로 모델의 성능을 향상시키는데 도움이 된다. 〈Table 3〉은 각 데이터 세트에 대해 얻은 최적의 하이퍼파라미터 값을 보여주고 있다.

〈Fig. 7〉은 데이터 세트에 대한 모든 조합의 결과를 보여주는 히트 맵(Heat map)을 나타내고 있다. 색이 밝

〈Table 3〉 Optimal values for hyper-parameters of CatBoost method

Dataset	learning_rate	Random_strength
Set_1	0.05	6
Set_2	0.1	6
Set_3	0.05	10
Set_4	0.2	12

〈Table 4〉 Performance of CatBoost method in four datasets with 5-fold cross validation

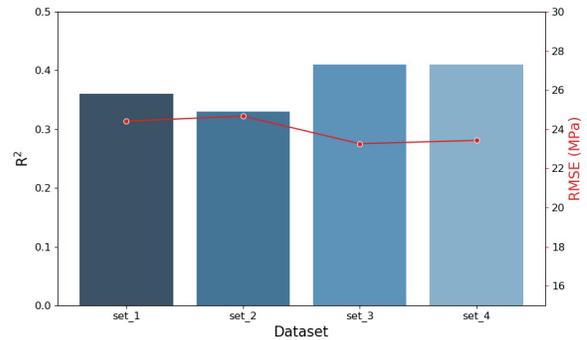
Dataset	5-1 Train		5-1 Test		
	R ²	R ²	RMSE (MPa)	MSE (MPa)	MAE (MPa)
Set_1	0.96	0.36	24.41	18.57	601.29
Set_2	0.93	0.33	24.67	18.50	611.36
Set_3	0.96	0.41	23.26	18.15	543.65
Set_4	0.96	0.41	23.43	18.25	551.86

을수록 더 좋은 성능을 나타낸다. 예를 들어 〈Fig. 7 (a)〉의 Set_1 경우는 max_depth가 6일 때와 learning_rate가 0.05일 때의 조합이 최적임을 알 수 있다. 하이퍼파라미터 조정 과정에서 얻은 두 파라미터를 사용하여 CatBoost를 학습하였으며, 이를 통해 콘크리트 압축강도를 예측할 수 있었다.

5. 결과 및 고찰

예측모델을 통해 얻은 성능 결과를 〈Table 4〉에 나타내었다. 모든 결과는 5-겹 교차검증을 통해 얻은 성능의 평균값을 의미한다. 5-1 Train은 테스트 겹(Fold)이 아닌 나머지 4개의 겹을 사용한 훈련 값에 대한 결과, 5-1 Test는 지정된 테스트 겹에 대한 결과 값을 의미한다.

〈Table 4〉를 살펴보면 8개 변수의 1차 항과 우세한 특성으로 선별된 5개의 변수에 대한 상호교차 곱을 사용한 Set_3의 경우가 가장 좋은 예측 결과를 보여주고 있다. 결정계수 R² 지표만 살펴본다면 모든 변수, 즉 8개 변수의 원본 값, 선별된 5개의 변수에 대한 제곱근 및 상호교차 곱의 값을 모두 추가한 Set_4 또한 좋은 성능을 보이고 있다. 이는 원본 데이터만을 사용할 때는 입력 변수에 한계가 있어 입력 변수와 출력 변수(콘크리트



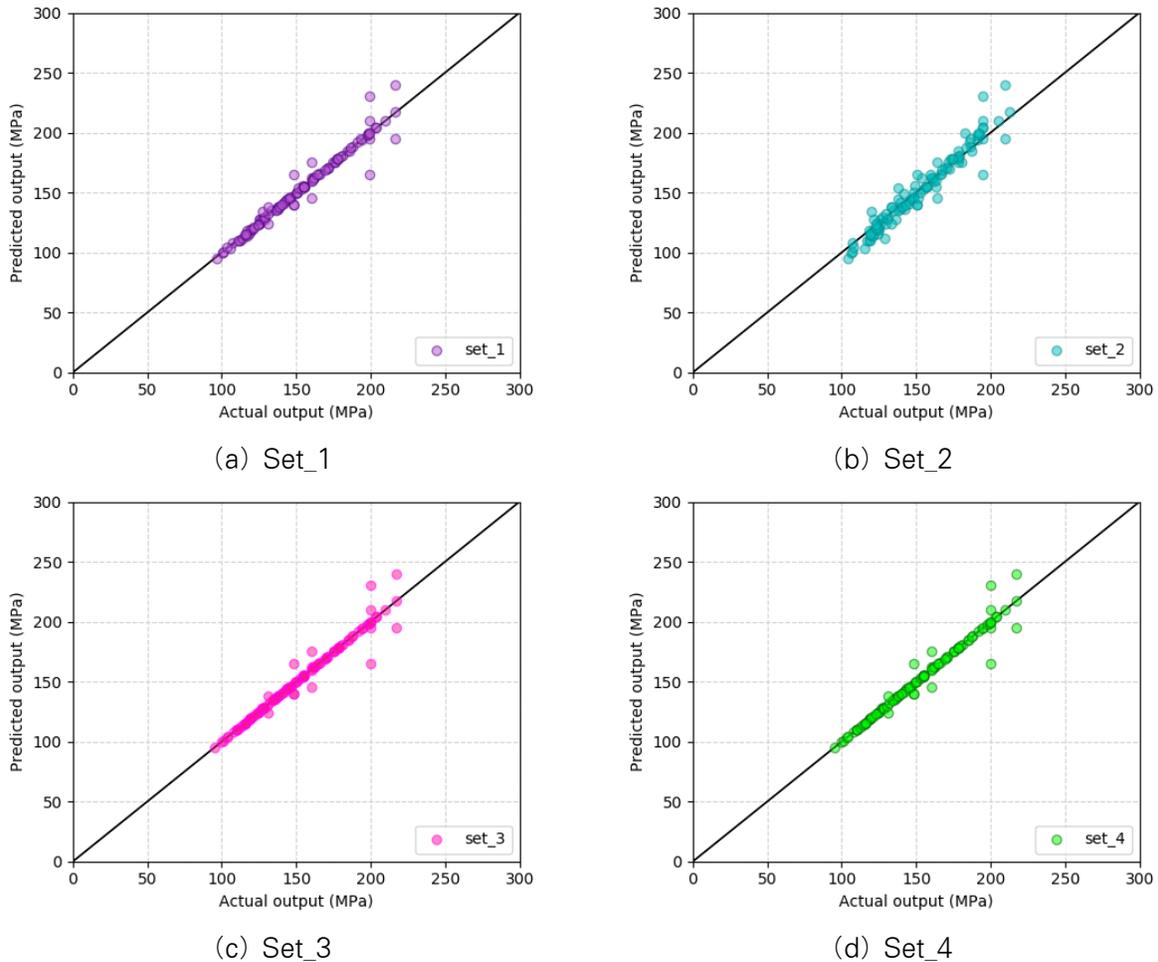
〈Fig. 8〉 Comparison of the results using R² and RMSE score values

압축강도)와의 비선형적인 상관관계를 알기 어려웠지만 새로운 변수(제곱근 혹은 상호교차 곱)를 추가하면 전자보다 더 명확한 상관관계를 예측할 수 있음을 의미한다.

각 세트에 대한 R² 지표와 RMSE 값을 〈Fig. 8〉과 같이 비교하였다. 테스트 데이터에 대한 R² 지표가 낮은 이유는 상당히 적은 수의 UHPC 데이터 문제에서 기인한다. 여러 선행 연구에서 수집한 UHPC 데이터는 각 실험에서 사용한 변수가 상이하고, 실험 모수가 적어 현재로서는 더 나은 R² 지표를 기대하기 어렵다. 5-겹 교차검증을 통하기 위해서는 총 110개의 실험 결과 샘플을 5등분을 해야 하는데, 이 과정에서 특수한 실험 결과가 예측할 수 없는 범주에 놓일 수 있기 때문이다. 〈Fig. 9〉는 각 데이터 세트에 대한 정규분포 분위수 대조도(Q-Q Plot: Quantile-Quantile Plot)를 나타내고 있다. 모든 데이터 세트가 100MPa와 150MPa에서는 상당히 좋은 예측을 보여주고 있지만 150MPa이 넘는 구간에서는 범주를 상당히 벗어나는 샘플을 확인할 수 있다. 가장 좋은 결과를 보인 Set_3의 경우도 동일하다. 이는 높은 구간의 UHPC 압축강도와 입력으로 제시하는 변수와의 관계가 상당히 비선형적이라는 것을 알 수 있다. 더 나은 예측을 위해서는 훈련 과정에 추가적인 데이터 또는 정보가 필요하다. 이를 위해서는 추가적으로 더 많은 실험 결과와 정규분포를 신뢰할 수 있는 양질의 데이터가 필요하다 할 수 있다.

6. 결론

본 논문에서는 UHPC의 압축강도를 예측하기 위해 최신 앙상블 학습 기법인 CatBoost 회귀 기법을 적용하



〈Fig. 9〉 The correlation (Q-Q Plot: Quantile-Quantile Plot) between actual output and predicted output

였다. 선행 연구에서 수집한 110개의 실험 결과를 사용하여 모델을 훈련하였으며, 훈련된 기법은 k-겹 교차검증과 4개의 오차 평가 기법을 통해 정확성을 확인하였다. 8개의 입력 변수와 UHPC 압축강도 간의 비선형 특성을 반영한 예측모델을 구축하기 위해 상세하게 선별된 변수의 다항식(Polynomial) 값을 사용하여 총 4개의 새로운 데이터 세트를 생성하였다. CatBoost 회귀 기법은 훈련전 하이퍼파라미터 조정 과정을 거쳐 최적의 learning_rate과 max_depth을 도출하였으며, 이를 훈련 과정에 반영하였다. 8개 변수의 1차 항과 상세한 특성으로 선별된 5개의 변수에 대한 상호교차 곱을 사용한 Set_3의 경우가 가장 좋은 예측 결과를 보였다. 이는 원본 데이터만을 사용할 때는 입력 변수에 한계가 있어 입력 변수와 출력 변수와의 비선형적인 상관관계가 알기 어려웠지만, 새로운 변수를 추가하면 전자보다 더 명확

한 상관관계를 알 수 있다는 것을 의미한다. 테스트 데이터에 대한 R^2 지표가 낮은 이유는 상당히 적은 수의 UHPC 데이터에 기인한다. 또한 압축강도가 올라갈수록 더 선명해지는 입력 변수와 출력 변수 간의 비선형적인 관계에서도 그 이유를 찾을 수 있다. 더 나은 예측 성능을 위해 추후 연구에서는 양질의 UHPC 실험 결과를 추가적으로 수집하여 신뢰성이 높은 회귀모델을 구축하는데 적용하기로 한다.

감사의 글

본 연구는 교육과학기술부 재원 한국연구재단의 신진연구지원사업(NRF-2018R1C1B6004751)에 의해 수행되었습니다.

References

1. de Larrard, F., & Sedran, T., "Optimization of ultra-high-performance concrete by the use of a packing model", *Cement and Concrete Research*, Vol.24, No.6, pp.997~1009, 1994, doi: 10.1016/0008-8846(94)90022-1
2. Lee, N. K., Koh, K. T., Park, S. H., & Ryu, G. S., "Microstructural investigation of calcium aluminate cement-based ultra-high performance concrete (UHPC) exposed to high temperatures", *Cement and Concrete Research*, Vol.102, pp.109~118, 2017, doi: 10.1016/j.cemconres.2017.09.004
3. Kang, T. H. K., Kim, S. H., Kim, M. S., & Hong, S. G., "Impact Resistance of UHPC Exterior Panels under High Velocity Impact Load", *Journal of the Korea Concrete Institute*, Vol.28, No.4, pp.455~462, 2016, doi: 10.4334/JKCI.2016.28.4.455
4. Azmee, N. M., & Shafiq, N., "Ultra-high performance concrete: From fundamental to applications", *Case Studies in Construction Materials*, Vol.9, pp.e00197, 2018, doi: 10.1016/j.cscm.2018.e00197
5. Park, C. J., Koh, K. T., Ahn, G. H., & Han, M. C., "Effect of Silica Fume Types on the Mechanical Properties of Ultra-High Performance Concrete", *Journal of the Korean Recycled Construction Resources Institute*, Vol.3, No.3, pp.220~227, 2015, doi: 10.14190/JRCR.2015.3.3.220
6. Ghafari, E., Costa, H., & Júlio, E., "Statistical mixture design approach for eco-efficient UHPC", *Cement and Concrete Composites*, Vol.55, pp.17~25, 2015, doi: 10.1016/j.cemconcomp.2014.07.016
7. Ghafari, E., Bandarabadi, M., Costa, H., & Júlio, E., "Prediction of fresh and hardened state properties of UHPC: comparative study of statistical mixture design and an artificial neural network model", *Journal of Materials in Civil Engineering*, Vol.27, No.11, pp.04015017, 2015, doi: 10.1061/(ASCE)MT.1943-5533.0001270
8. Abellán-García, J., "Four-layer perceptron approach for strength prediction of UHPC", *Construction and Building Materials*, Vol.256, pp.119465, 2020, doi: 10.1016/j.conbuildmat.2020.119465
9. Stulp, F., & Sigaud, O., "Many regression algorithms, one unified model: A review", *Neural Networks*, Vol.69, pp.60~79, 2015, doi: 10.1016/j.neunet.2015.05.005
10. Abuodeh, O. R., Abdalla, J. A., & Hawileh, R. A., "Assessment of compressive strength of Ultra-high Performance Concrete using deep machine learning techniques", *Applied Soft Computing*, Vol.95, pp.106552, 2020, doi: 10.1016/j.asoc.2020.106552
11. Habel, K., Viviani, M., Denarié, E., & Brühwiler, E., "Development of the mechanical properties of an Ultra-High Performance Fiber Reinforced Concrete (UHPFRC)", *Cement and Concrete Research*, Vol.36, No.7, pp.1362~1370, 2006, doi: 10.1016/j.cemconres.2006.03.009
12. Ghrici, M., Kenai, S., & Said-Mansour, M., "Mechanical properties and durability of mortar and concrete containing natural pozzolana and limestone blended cements", *Cement and Concrete Composites*, Vol.29, No.7, pp.542~549, 2017, doi: 10.1016/j.cemconcomp.2007.04.009
13. Graybeal, B. A., "Compressive Behavior of Ultra-High-Performance Fiber-Reinforced Concrete", *ACI Materials Journal*, Vol.104, No.2, pp.146~152, 2007
14. Hassan, A. M. T., Jones, S. W., Mahmud, G.

- H., "Experimental test methods to determine the uniaxial tensile and compressive behaviour of ultra high performance fibre reinforced concrete (UHPFRC)", *Construction and Building Materials*, Vol.37, pp.874~882, 2012, doi: 10.1016/j.conbuildmat.2012.04.030
15. Wille, K., & Boisvert-Cotulio, C., "Material efficiency in the design of ultra-high performance concrete", *Construction and Building Materials*, Vol.86, pp.33~43, 2015, doi: 10.1016/j.conbuildmat.2015.03.087
 16. Jang, H. O., Lee, H. S., Cho, K., & Kim, J., "Experimental study on shear performance of plain construction joints integrated with ultra-high performance concrete (UHPC)", *Construction and Building Materials*, Vol.152, pp.16~23, 2017, doi: 10.1016/j.conbuildmat.2017.06.156
 17. Hassan, M., & Wille, K., "Experimental impact analysis on ultra-high performance concrete (UHPC) for achieving stress equilibrium (SE) and constant strain rate (CSR) in Split Hopkinson pressure bar (SHPB) using pulse shaping technique", *Construction and Building Materials*, Vol.144, pp.747~757, 2017, doi: 10.1016/j.conbuildmat.2017.03.185
 18. Shafieifar, M., Farzad, M., & Azizinamini, A., "Experimental and numerical study on mechanical properties of Ultra High Performance Concrete (UHPC)", *Construction and Building Materials*, Vol.156, pp.402~411, 2017, doi: 10.1016/j.conbuildmat.2017.08.170
 19. Alsaman, A., Dang, C. N., Prinz, G. S., & Hale, W. M., "Evaluation of modulus of elasticity of ultra-high performance concrete", *Construction and Building Materials*, Vol.153, pp.918~928, 2017, doi: 10.1016/j.conbuildmat.2017.07.158
 20. Zhong, R., Wille, K., & Viegas, R., "Material efficiency in the design of UHPC paste from a life cycle point of view", *Construction and Building Materials*, Vol.160, pp.505~513, 2018, doi: 10.1016/j.conbuildmat.2017.11.049
 21. Alkaysi, M., & El-Tawil, S., "Factors affecting bond development between Ultra High Performance Concrete (UHPC) and steel bar reinforcement", *Construction and Building Materials*, Vol.144, pp.412~422, 2017, doi: 10.1016/j.conbuildmat.2017.03.091
 22. Sohail, M. G., Wang, B., Jain, A., Kahraman, R., Ozerkan, N. G., Gencturk, B., ... Belarbi, A., "Advancements in Concrete Mix Designs: High-Performance and Ultrahigh-Performance Concretes from 1970 to 2016", *Journal of Materials in Civil Engineering*, Vol.30, No.3, pp.04017310, 2018, doi: 10.1061/(ASCE)MT.1943-5533.0002144
 23. Feng, D. C., Liu, Z. T., Wang, X. D., Chen, Y., Chang, J. Q., Wei, D. F., & Jiang, Z. M., "Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach", *Construction and Building Materials*, Vol.230, pp.117000, 2020, doi: 10.1016/j.conbuildmat.2019.117000
 24. Liaw, A., & Wiener, M., "Classification and Regression by RandomForest", *R news*, Vol.2, No.3, pp.18~22, 2002, Retrieved from <https://cogns.northwestern.edu/cbmg/LiawAndWiener2002.pdf>
 25. Safavian, S. R., & Landgrebe, D., "A survey of decision tree classifier methodology", *IEEE Transactions on Systems, Man, and Cybernetics*, Vol.21, No.3, pp.660~674, 1991, doi: 10.1109/21.97458
 26. Liu, Y., & Yao, X., "Ensemble learning via negative correlation", *Neural networks*, Vol.12, No.10, pp.1399~1404, 1999, doi:

10.1016/S0893-6080(99)00073-8

27. Dorogush, A. V., Ershov, V., & Gulin, A.,
“CatBoost: gradient boosting with categorical
features support”, arXiv:1810.11363, 2018
28. Avnimelech, R., & Intrator, N., “Boosting
Regression Estimators”, Neural Computation,
Vol.11, No.2, pp.499~520, 1999, doi:
10.1162/089976699300016746

- Received : September 09, 2020
- Revised : October 16, 2020
- Accepted : October 20, 2020