

# 콘크리트 탄산화 및 열효과에 의한 경년열화 예측을 위한 기계학습 모델의 정확성 검토

## Accuracy Evaluation of Machine Learning Model for Concrete Aging Prediction due to Thermal Effect and Carbonation

김 현 수\*  
Kim, Hyun-Su

### Abstract

Numerous factors contribute to the deterioration of reinforced concrete structures. Elevated temperatures significantly alter the composition of the concrete ingredients, consequently diminishing the concrete's strength properties. With the escalation of global CO<sub>2</sub> levels, the carbonation of concrete structures has emerged as a critical challenge, substantially affecting concrete durability research. Assessing and predicting concrete degradation due to thermal effects and carbonation are crucial yet intricate tasks. To address this, multiple prediction models for concrete carbonation and compressive strength under thermal impact have been developed. This study employs seven machine learning algorithms—specifically, multiple linear regression, decision trees, random forest, support vector machines, k-nearest neighbors, artificial neural networks, and extreme gradient boosting algorithms—to formulate predictive models for concrete carbonation and thermal impact. Two distinct datasets, derived from reported experimental studies, were utilized for training these predictive models. Performance evaluation relied on metrics like root mean square error, mean square error, mean absolute error, and coefficient of determination. The optimization of hyperparameters was achieved through k-fold cross-validation and grid search techniques. The analytical outcomes demonstrate that neural networks and extreme gradient boosting algorithms outshine the remaining five machine learning approaches, showcasing outstanding predictive performance for concrete carbonation and thermal effect modeling.

*Keywords : Machine learning, Concrete carbonation, Concrete high temperature, Compressive strength, Carbonation depth*

## 1. 서론

철근콘크리트 원자력발전소 구조물에서 열화가 발생하면 구조재료의 특성이 변화되고 때로는 철근이 부식되어 콘크리트의 탈락으로 구조물의 성능이 감소된다<sup>1,2)</sup>. 특히 지진해석을 수행할 때 구조물의 경년열화는 예상하지 못한 파괴모드를 야기하거나 동적 특성의 변화, 저항성능의 감소, 지진응답의 변화를 유발할 수 있다<sup>3)</sup>. 따라서 노후된 원전구조물의 내진성능평가와 안전한 이용을 위하여 열화를 고려한 구조해석은 필수적이다. 원전 철근콘크리트 구조물에 재료의 특성 및 구조물의 성능 변화를 일으킬 수 있는 열화인자로는 염화물 침투, 콘크리트의 중산화(탄산화), 열효과, 방사선 효과 등이 대표

적이다. 이러한 열화인자들은 철근의 부식, 피복 콘크리트의 탈락, 콘크리트의 강도 및 강성 저하 등 구조물의 구조적 안전성과 지진응답에 영향을 미칠 수 있는 특성 변화를 일으킬 수 있다. 따라서 관련된 연구가 다수 수행되어 이를 예측할 수 있는 열화모델이 개발되어 왔다. 이러한 열화모델의 개발은 대부분 해당 열화인자를 설계변수로 하는 실험적 연구를 통해서 얻은 데이터를 활용하여 수학적 회귀모델을 제안하는 방식으로 이루어져 왔다. 그러나 이러한 회귀모델은 정확도 및 적용성에 한계를 가지고 있다.

근래에는 기계학습(Machine learning, ML)이 다양한 구조공학분야에 적용되어 매우 우수한 성과를 내고 있다. 특히 기계학습은 학습용 데이터베이스가 적절하게 제공된다면 입출력 데이터간의 매우 복잡한 비선형관계를 분석하고 이를 바탕으로 학습에 사용되지 않은 데이터에 대한 예측치를 기존의 회귀분석 방법에 비해서 때

\* 교신저자, 종신회원, 선문대학교 건축학부 교수, 공학박사  
Division of Architecture, Sunmoon University  
Tel: 041-530-2315 Fax: 041-530-2839  
E-mail : hskim72@sunmoon.ac.kr

우 정확도가 높은 결과를 나타낼 수 있다.

본 연구에서는 기계학습기반의 경년열화 예측모델을 개발하고 그 정확성을 검증하였다. 이를 위한 경년열화 인자로는 콘크리트 탄산화와 열효과를 선택하였다. 두 열화인자는 다음과 같은 특성을 가지고 있다.

탄산화는 이산화탄소 또는 액상 속에 녹은 탄산이온으로 수화물이 탄산화를 받아 그 조직이 변화 또는 분해하는 반응인데 이때 알칼리농도가 저하하여 중성으로 변화하므로 이를 중성화 또는 탄산화라고 한다. 콘크리트의 탄산화는 부동태피막의 파괴에 따른 콘크리트 내부 철근의 부식에 크게 영향을 끼친다는 점에서 철근의 단면감소에 따른 구조체의 내력상 매우 중요한 반응이다. 이러한 콘크리트 탄산화에 대한 실험적 연구는 시멘트 양, 대기 중의 탄산가스( $\text{CO}_2$ ) 농도, 물-결합재 비, 상대습도 등의 주변 환경 변화에 따라 탄산화 깊이가 어떻게 달라지는 지에 대한 연구가 주로 수행되고 있다<sup>4,5</sup>.

콘크리트는 양생 시 또는 양생 후 외부의 온도변화에 따라서 강도가 변화되는 특성을 가지고 있으므로 해석 및 설계 시 이를 고려하는 것이 필요하다. 시멘트의 수화 반응은 양생 온도에 따라 현저한 영향을 미치는데 저온에서 양생한 것은 초기 재령시의 강도는 적으나 신장도는 큰데 비하여 높은 온도에서 양생한 것은 2주 후 부터 강도가 저하한다. 이것은 온도가 높으면 시멘트의 응결이 빨라져 시멘트 표면만이 경화하고 내부에는 빈약한 구조의 다공질의 수화 생성물이 만들어져 대부분의 공극이 채워지지 않고 그대로 남아 있기 때문이다<sup>6</sup>.

콘크리트가 화재에 노출된다면 내부온도의 상승에 따라 수분의 이동, 공극압의 증가, 골재와 모르타르 경계면의 분리 등 콘크리트 내부조직이 변화하게 되며, 이러한 변화는 변형을 발생시켜 콘크리트의 성능 특히 강도를 저하시키게 된다. 강도저하는 300℃까지는 거의 없지만 500℃(성능보존한계온도) 초과하면 50% 이하로 저하되고 탄성계수도 가열에 의해 저하하며 500℃에서 거의 반으로 줄어들게 된다. 이러한 강도저하 정도는 사용재료의 종류, 배합, 재령 등에 의해 다르다<sup>7</sup>. 따라서 이를 효과적으로 예측할 수 있는 경년열화모델이 필요하다.

이러한 배경을 바탕으로 본 연구에서는 철근콘크리트 구조물의 거동에 영향을 미치는 탄산화 및 열효과에 의한 구조적 특성변화를 예측할 수 있는 경년열화모델을 기계학습을 기반으로 개발하였다. 콘크리트 탄산화 열화

인자에 대해서는 물/결합재 비,  $\text{CO}_2$  농도, 상대습도, 노출 시간 등을 입력특성으로 하고 탄산화 깊이를 출력(예측 목표)으로 하는 기계학습 모델을 개발하였다. 열효과 열화인자에 대해서는 콘크리트 배합조건 및 외부 온도 등을 입력 특성으로 하고 콘크리트 압축강도를 출력(예측 목표)으로 하는 기계학습 모델을 개발하였다.


예측성능이 우수한 기계학습기반 경년열화모델을 개발하기 위해서는 적절한 데이터베이스를 구성하는 것이 필요하다. 콘크리트 탄산화 및 열효과에 의한 재료적, 구조적 특성변화에 대한 실험적 연구가 다수 수행되었고 본 연구에서는 기존에 수행된 실험결과를 데이터베이스로 활용하였다. 지금까지 매우 다양한 기계학습 알고리즘이 발표되었다<sup>8</sup>. 그 중 본 연구에서는 구조공학분야에 많이 적용되는 기계학습 알고리즘 7개를 선정하였고 이를 통해서 개발된 경년열화모델의 정확성을 비교·검증하였다. 기계학습 모델의 예측성능을 검토하기 위해서는 실험 결과치와 모델 예측치의 차이를 계산해서 평가하는 방법이 일반적이다. 본 연구에서는 다양한 기계학습 모델 성능평가지수 중에서 평균 제곱근 오차(Root Mean Square Error; RMSE), 평균제곱오차(Mean Squared Error; MSE), 평균 절대 오차(Mean Absolute Error; MAE) 및 결정계수 (Coefficient of determination;  $R^2$ )를 이용하였다.

## 2. 경년열화모델 학습을 위한 데이터베이스

콘크리트 탄산화 및 열효과에 의한 경년열화 예측모델을 기계학습을 이용하여 생성하기 위해서는 적절한 데이터베이스를 구축하고 이를 학습과 검증에 활용하는 것이 필요하다. 본 연구에서는 기존에 수행되었던 실험적 연구의 결과를 이용하여 기계학습 데이터베이스로 활용하였다

Chen et al. (2022)은 기존에 수행된 십여 건의 콘크리트 탄산화와 관련한 실험적 연구의 결과데이터를 취합하여 데이터베이스를 구축하였고 이에 대한 입출력 관계를 <Fig. 1>에 나타내었다. 그림에서 확인할 수 있듯이 입력 특성은 시멘트 양(B), 플라이애시 양(FA), 물-결합재 비(w/b),  $\text{CO}_2$  농도, 상대습도(RH), 노출 시간(t)의 6개이고 출력은 탄산화 깊이이다. 이 데이터베이스

스는 Chen et al. (2022)의 연구에서 직접 수행한 실험 결과가 아니라 기존에 발표된 다양한 실험연구 결과 데이터를 수집하여 작성한 것으로 총 데이터의 수는 532개로 구성되었다.



〈Fig. 1〉 Inputs and output of concrete carbonation database

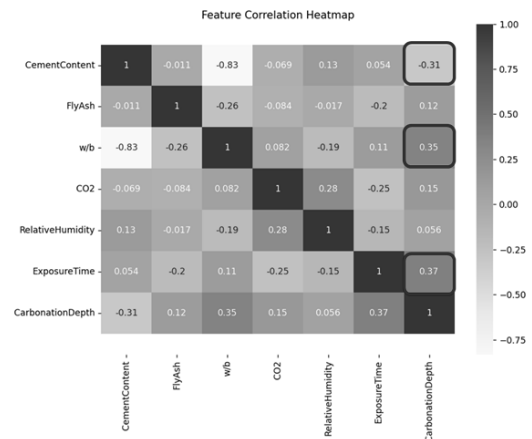
사용한 데이터베이스 입력특성의 통계적 특성치 (최대값, 최소값, 평균, 표준편차)를 〈Table 1〉에 나타내었다. 이를 통해서 데이터베이스를 구성하는 데이터들의 각 입력 특성별 특징을 정량적으로 파악할 수 있다. 예를 들어 콘크리트 실험체 주변의 CO<sub>2</sub> 농도의 최소값은 0.03%, 최대값은 100%, 평균은 15%, 표준편차는 20.68이다.

〈Table 1〉 Statistical values of carbonation DB

Input	Max	Min	Mean	SD*
B(kg/m <sup>3</sup> )	500	222	366	61.50
FA(%)	70	0	19	20.22
w/b	0.65	0.28	0.47	0.09
CO <sub>2</sub> (%)	100	0.03	15	20.68
RH(%)	90	40	65	5.13
t(√day)	23	2	7	4.57

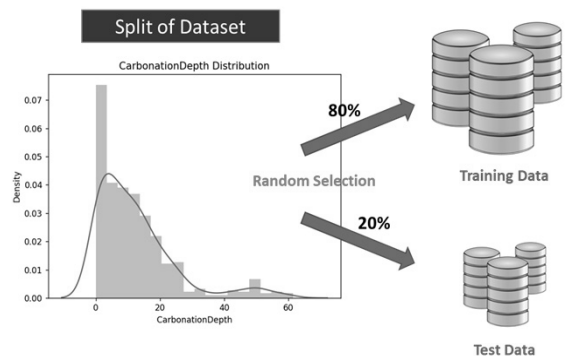
\*SD: Standard Variation

구성한 데이터베이스 입출력 특성(feature)간의 상관관계를 분석하기 위해서 〈Fig. 2〉에 특성 상관관계 히트맵을 나타내었다. 그림을 보면 노출시간(Exposure Time)이 출력값(탄산화 깊이)과 가장 큰 양의 상관관계(+0.37)을 나타내는 것을 알 수 있다. 즉 노출시간이 커지면 탄산화 깊이가 더 커지는 것을 의미한다. 입력 변수 중 물-결합재 비도 노출 시간만큼 큰 양의 상관관계(+0.35)를 나타내고 있다. 시멘트의 상관계수는 -0.31로서 가장 큰 음의 상관관계를 나타낸다. 즉, 시멘트 양이 많이 사용된다면 탄산화가 잘 일어나지 않아서 탄산화 깊이가 줄어들게 된다.



〈Fig. 2〉 Correlation heatmap of carbonation DB


본 연구에서 사용한 데이터베이스의 출력값의 분포를 보면 〈Fig.3〉에 나타낸 바와 같이 기존에 수행된 실험적 연구에서 예측한 콘크리트 탄산화의 깊이가 0mm~30mm 사이에 많이 분포되어 있고 그 보다 큰 값들도 포함하고 있는 것을 알 수 있다. 탄산화 깊이 데이터의 분포를 보면 0mm를 대칭 기준으로 본다면 전반적으로 정규분포의 형태를 나타내고 있는 것을 볼 수 있다. 즉, 구성된 데이터베이스는 정규분포 형태의 오른쪽 부분만 표현하고 있다. 본 데이터베이스는 실험적 연구결과를 취합하여 구축하였기 때문에 향후 추가적인 연구가 수행된다면 데이터베이스를 업데이트하여 보완하는 것이 더 정확한 예측모델 생성을 위해 필요하다고 판단된다. 이렇게 생성한 데이터베이스는 임의로 선택하여 80%는 학습용으로 20%는 학습된 모델의 검증용으로 사용하였다.



〈Fig. 3〉 Configuration of carbonation DB

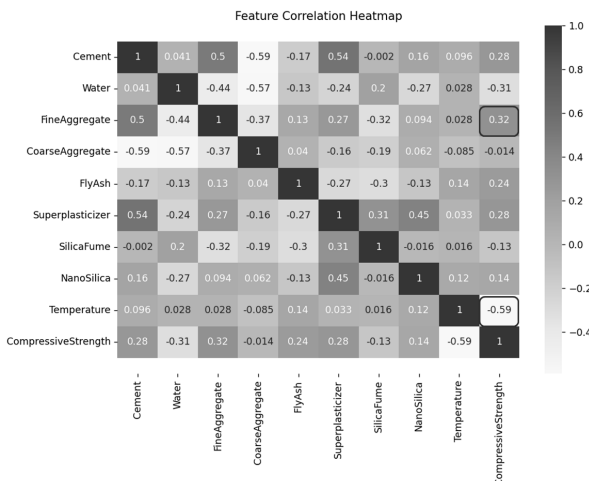
Ahmad et al. (2021)은 기존에 수행된 다양한 조건의 열효과에 따른 콘크리트 압축강도 변화와 관련한 실험적 연구의 결과데이터를 취합하여 발표하였고 본 연구

에서는 이를 이용한 데이터베이스를 구축하여 사용하였다. 본 연구에서 기계학습 모델의 훈련에 사용하는 데이터베이스의 데이터 수는 207개이고 입출력 변수의 개수는 각각 9개, 1개인데 이에 대한 구체적인 내용은 <Fig. 4>에 나타난 것과 같다. 즉 입력변수는 시멘트의 양, 물의 양, 잔골재 양, 굵은 골재 양, 플라이 애시 양, 유동화제 양, 나노실리카 양, 실리카 폼 양, 온도로 구성되어 있고 출력은 콘크리트 압축강도이다.



<Fig. 4> Inputs and output of concrete thermal effect database

사용한 데이터베이스 입력특성 중 가장 핵심적인 콘크리트 실험체 노출온도의 최소값은 20°C, 최대값은 1000°C, 평균은 354.52°C, 표준편차는 287.65이다. 구성된 데이터베이스 입출력 특성(feature)간의 상관관계를 분석하기 위해서 <Fig 5>에 특성 상관관계 히트맵을 나타내었다. 그림을 보면 잔골재 양(Fine Aggregate)이 출력값(콘크리트 압축강도)과 가장 큰 양의 상관관계(+0.32)을 나타내는 것을 알 수 있다. 즉 잔골재의 양이 커지면 콘크리트 압축강도가 더 커지는 것을 의미한다. 온도의 상관계수는 -0.59로서 가장 큰 음의 상관관계를 나타낸다. 즉, 온도가 높다면 콘크리트의 압축강도가 줄어들게 된다.



<Fig. 5> Correlation of thermal effect DB

본 연구에서 사용한 데이터베이스의 출력값의 분포 검토한 결과를 보면 실험적 연구에서 계측한 콘크리트 압축강도가 0~100MPa 사이에 많이 분포되어 있고 정규분포의 모양을 어느 정도 갖추고 있었다. 이렇게 생성한 데이터베이스는 임의로 선택하여 80%는 학습용으로 20%는 학습된 모델의 검증용으로 사용하였다.

### 3. 경년열화모델 개발을 위한 기계학습 알고리즘

구조공학분야에 기계학습기법이 적용되어 재료나 구조적 특성을 예측하기 위한 모델 개발에 다양하게 적용되어 왔다. Thai(2002)는 1989년부터 2022년까지 발표된 485개의 논문을 분석하여 구조공학분야에 적용된 기계학습 방법을 정리하였다. 이 연구결과를 보면 인공신경망 56%, 부스팅 알고리즘 11%, 서포트 벡터머신 10%, 랜덤 포레스트 6%, 결정 트리 5%, 다중선형회귀 8%의 비율로 사용되었다. 이러한 내용을 바탕으로 본 연구에서는 <Fig. 6>에 나타난 7개의 기계학습 방법을 선정하여 경년열화모델을 개발하였다. 그림에서 보는 바와 같이 7개의 알고리즘 중 KNN알고리즘은 모델 생성을 하지 않은 인스턴스 기반 학습에 의해 예측치를 계산하고 나머지 6개의 알고리즘은 모델기반 학습을 수행한다. 선택한 7개의 기계학습 알고리즘에 대해서 본 절에서 간략히 설명하였다.

- Multiple Linear Regression
- Decision Tree
- Random Forest
- Support Vector Machine (SVM)
- Neural Networks (NN)
- eXtreme Gradient Boosting (XGBoost)
- K-Nearest Neighbor (KNN) → Instance Based Learning

<Fig. 6> Selected ML algorithms

다중 선형 회귀(Multiple Linear Regression, MLR)는 여러 개의 독립 변수와 하나의 종속 변수의 선형 관계를 모델링하는 알고리즘이고 이를 식 (1)에 나타내었다.

$$y = W \times X + b = \sum_{i=1}^n w_i \times x_i + b \tag{1}$$

여기서 y는 예측치를 의미하고 관측치를 정확하게 예측할 수 있도록 최적의 가중치(w)와 편향(b)을 찾는 작업

을 기계학습을 통해서 수행한다. 이때 가중치가 너무 크면 과적합(overfitting)이 발생할 가능성이 커지는데 이를 방지하기 위해서 식 (2)와 (3)에 나타난 Lasso와 Ridge 기법이 제안되어 사용되고 있다.


$$\text{Lasso: } \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \alpha \sum_{i=1}^n |w_i| \quad (2)$$

$$\text{Ridge: } \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \alpha \sum_{i=1}^n w_i^2 \quad (3)$$

여기서, n은 관측치의 개수, α는 가중치를 결정하는 하이퍼파라미터를 의미한다.

결정트리(Decision Tree, DT)는 분류와 회귀 문제에 모두 활용이 가능한 지도 학습 모델 중 하나이다. 결정 트리는 스무개 하듯이 예/아니오 질문을 이어가며 학습한다. 이러한 방법을 반복하여 데이터에 있는 규칙을 학습을 통해 자동으로 찾아내 트리 (Tree)기반의 분류 규칙을 만드는 것으로 이 모양이 나무를 닮아 트리모델이라고 한다.

랜덤 포레스트(Random Forest, RT)는 <Fig. 7>에 나타난 바와 같이 결정트리를 다수 사용하여 예측치를 하나의 모델에 의지하지 않고 여러 모델 결과의 평균치를 사용하는 앙상블 학습기법이다. 랜덤 포레스트의 가장 큰 특징은 랜덤성(randomness)에 의해 트리들이 서로 조금씩 다른 특성을 갖는다는 점이다. 이 특성은 각 트리들의 예측(prediction)들이 비상관화(decorrelation) 되게 하며, 결과적으로 일반화(generalization) 성능을 향상시킨다. 또한, 랜덤화(randomization)는 포레스트가 노이즈가 포함된 데이터에 대해서도 강인하게 만들어 준다.



<Fig. 7> Concept of random forest<sup>9)</sup>

서포트 벡터 머신(Support Vector Machine, SVM)은 두 카테고리 중 어느 하나에 속한 데이터의 집합이 주어졌을 때 주어진 데이터 집합을 바탕으로 하여 새로운 데이터가 어느 카테고리에 속할지 판단하는 비확률적인 선형 분류 모델을 만든다. 만들어진 분류 모델은 데이터가 사상된 공간에서 경계로 표현되는데 SVM 알고리즘은 그 중 가장 큰 폭을 가진 경계를 찾는 알고리즘이다. 서포트 벡터 머신은 기본적으로 마진(Margin)이라는 아이디어를 사용한다. 마진은 두 데이터 클래스를 구분하는 도로의 경계를 뜻한다. SVM이 클래스 사이에 가장 폭이 넓은 도로를 찾는 것이 최적의 결정 경계를 찾는 것이고, 최적의 결정 경계를 찾으면 도로 폭을 최대화하여 마진을 최대로 가질 수 있게 된다.

인공신경망(ANN)은 인간의 두뇌 신경세포인 뉴런을 기본으로 한 기계학습기법으로 하나의 뉴런이 다른 뉴런들과 연결되어 신호를 전달, 처리하는 구조를 본뒀다. 입력 데이터가 들어가면서 신호의 강도에 따라 가중치 처리되고 활성화 함수를 통해 출력이 계산되는데 학습을 거쳐 원하는 결과가 나오게끔 가중치가 조정된다는 점이 주요 특징이다. 입력 데이터가 들어가면서 신호의 강도에 따라 가중치 처리되고 활성화 함수를 통해 출력이 계산되는데 학습을 거쳐 원하는 결과가 나오게끔 가중치가 조정된다는 점이 주요 특징이다.

앙상블 학습 기법은 여러 개의 약한 학습기(Weak Learner)를 결합하여 강력한 학습기(Strong Learner)를 구성하는 방법을 의미한다. 앙상블 학습기법에 속한 부스팅은 약한 학습기들을 순차적으로 학습시켜 가중치를 부여하여 강력한 학습기를 만드는 방법이다. 초기에는 전체 학습 데이터 세트를 사용하여 약한 학습기를 학습시키고, 이후에는 이전 학습기가 잘못 예측한 샘플에 가중치를 부여하여 다음 학습기를 학습시킨다. 이렇게 반복적으로 학습과 가중치 업데이트를 진행하면서 약한 학습기들이 순차적으로 강화되어 최종 예측기를 형성하게 된다. 다양한 부스팅 알고리즘 중에서 본 연구에서는 효율성을 기존 알고리즘 대비 향상시킨 XGBoost 알고리즘을 사용하였다.

KNN 알고리즘은 가장 간단한 기계학습 기법 중의 하나로 이 알고리즘은 비슷한 특성을 가진 데이터는 비슷한 범주에 속하는 경향이 있다는 가정 하에 사용한다. KNN은 모델을 생성하지 않고 입력 데이터와 비슷한 특

성을 가진 데이터 K개의 평균값을 출력으로 제공하는 알고리즘이다.

7개의 기계학습 방법으로 생성된 경년열화모델의 예측 성능을 검토하기 위해서 회귀분석 연구에서 일반적으로 사용하는 4개의 평가지표를 선택하였고 이를 식 (4)-(7)에 나타내었다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$


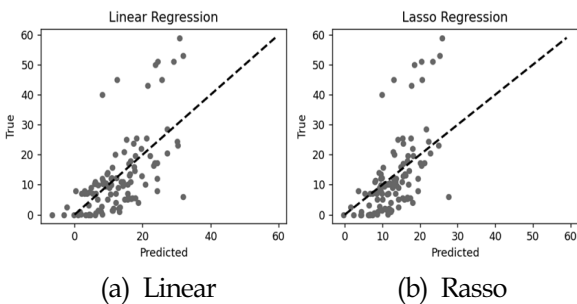
$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{MSE}{Var(y)} \quad (7)$$

여기서, n은 관측치의 개수,  $\hat{y}_i$ 는 예측치,  $y_i$ 는 관측치,  $\bar{y}$ 는 관측치의 평균값, 그리고 Var은 목표값에 대한 분산을 의미한다.

#### 4. 기계학습기반 경년열화모델의 예측 정확성 평가

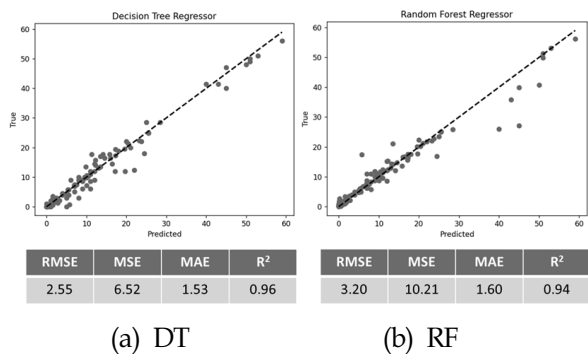
본 연구에서 선택한 7개의 알고리즘을 사용하여 콘크리트 탄산화 예측모델을 생성하였고 정확성을 검토해보았다. 우선 MLR의 예측 결과를 <Fig. 8>에 나타내었다. 가로축은 예측치이고 세로축은 관측치이므로 예측치가 대각선위에 나타나면 정확도가 높은 것을 의미한다. 그림을 보면 세 개의 모델에서 큰 차이를 발견하기는 어려운 것을 알 수 있다.




(c) Ridge

<Fig. 8> Predictions of MLR (Carbonation)

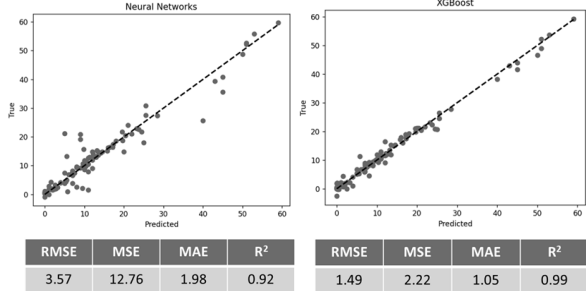
선택한 7개의 기계학습 모델 중 앞서 설명한 MLR을 제외한 6개의 기계학습 모델(DT, RF, SVM, KNN, ANN, XGBoost)의 탄산화 깊이 예측성능을 <Fig. 9>에 나타내었다. 그림을 보면 결정 트리과 랜덤 포레스트 모델의 R<sup>2</sup>값이 각각 0.96과 0.94로서 탄산화 깊이를 매우 정확하게 예측할 수 있는 능력이 있다는 것을 알 수 있다. 이것은 단순한 결정트리 모델로 탄산화 깊이 예측에 매우 우수한 결과를 얻을 수 있다는 것을 의미한다. 또한 앙상블 모델인 RF 보단 단일 DT 모델이 더 우수한 결과를 나타낸 것도 특이한 점이다. SVM 모델의 예측 성능은 MLR 모델과 거의 차이가 없을 정도로 정확도가 떨어지는 것을 알 수 있다. 이에 비해 KNN 모델의 R<sup>2</sup>값은 0.84로서 상대적으로 양호한 예측성능을 발휘하였다. ANN과 XGBoost모델도 탄산화 깊이에 대해 매우 우수한 예측성능을 보여주었다. 특히 XGBoost 모델의 R<sup>2</sup>값은 무려 0.99로서 매우 뛰어난 예측성능을 보여주었다.





(c) SVM

(d) KNN




(e) ANN

(f) XGBoost

〈Fig. 9〉 Predictions of MLs (carbonation)


콘크리트 강도에 미치는 열효과를 예측하기 위해 개발한 세 가지 종류의 MLR 모델의  $R^2$ 값은 모두 0.6 후반대로서 별다른 차이가 없는 것으로 나타났다. 그러나 콘크리트 탄산화 예측모델의  $R^2$ 값이 0.3~0.4대 인 것과 비교하면 정확도가 높아졌다.

MLR을 제외한 6개의 기계학습모델의 예측성능을 비교하여 〈Fig. 10〉에 나타내었다. 그림을 보면 결정 트리 와 랜덤 포레스트 모델의  $R^2$ 값이 각각 0.79와 0.85로서 MLR 모델보다 콘크리트 열효과를 더 정확하게 예측할 수 있었다. 또한 결정트리모델보다 랜덤 포레스트 모델의 예측성능이 더 우수한 것을 통해서 앙상블 모델이 단일 모델보다 더 우수한 성능을 나타내는 것을 확인하였다.



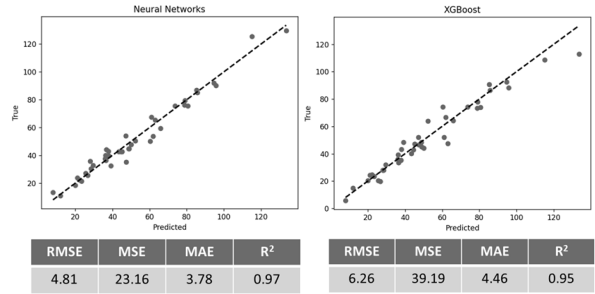
(a) DT

(b) RF



(c) SVM

(d) KNN



(e) ANN

(f) XGBoost

〈Fig. 10〉 Predictions of MLs (temperature)

SVM 모델의 예측 성능은 MLR 모델보다 약 10% 정도 더 예측성능이 우수한 것을 알 수 있다. 그러나 다른 기계학습 모델의 예측성능과 비교해서는 정확성이 떨어지는 것을 알 수 있다. 이에 비해 KNN 모델의  $R^2$ 값은 0.80로서 상대적으로 양호한 예측성능을 발휘하였다. 다른 기계학습 알고리즘은 모두 모델을 개발하기 위해서 학습이 필요하지만 KNN 모델은 학습을 하지 않고 곧바로 출력치를 예측할 수 있는 Instance Based Learning 이라는 것이 중요한 차이점이다. ANN과 XGBoost 모델도 콘크리트 탄산화 예측과 마찬가지로 콘크리트 열효과도 매우 우수한 예측성능을 보여주었다. ANN 모델과 XGBoost 모델의  $R^2$ 값은 각각 0.97과 0.95로 나타나서 두 모델 모두 매우 뛰어난 예측성능을 보여주었다. 앞서 적용하였던 콘크리트 탄산화 예측의 경우에는 XGBoost 모델이 가장 우수한 예측 성능을 보였으나 콘크리트 열효과에 경우에는 ANN 모델이 가장 정확도가 높은 예측치를 제공하였다.

## 5. 결론

본 연구에서는 콘크리트의 안전성 및 내구성에 영향을 미치는 탄산화와 열효과에 대한 예측을 위해서 다양한 기

계학습 방법을 적용하여 경년열화 예측모델을 개발하였다. 본 연구에서는 구조공학분야에 적용된 비율에 따라 선택한 7개의 기계학습 알고리즘을 적용하여 콘크리트 탄산화 및 열효과 예측모델을 개발하였고 정확성을 검토하였다. 모델의 학습을 위해 기존에 발표된 실험적 연구의 결과를 이용해 구성된 데이터베이스를 이용하였다. 개발된 경년열화모델의 예측성능을 평가하기 위해서 회귀분석모델 평가에 주로 사용되는 4개의 지표(RMSE, MSE, MAE,  $R^2$ )를 사용하였다. 개발된 기계학습 모델의 정확도를 평가해보면 MLR이 가장 오차가 큰 것으로 나타났다. DT와 RF는 콘크리트 탄산화에 대해서는 우수한 예측성능을 보여주었지만 열효과에 대해서는 그러지 못했다. SVM은 두 열화인자에 대해서 가장 좋지 않은 예측성능을 보여주었고 KNN은 그보다 조금 더 향상된 성능을 보여주었다. 두 열화인자에 대해서 XGBoost와 ANN이 매우 우수한 예측성능을 나타낸 것으로 확인하였다. 특히 XGBoost는 콘크리트 탄산화와 열효과 모두에 대해서 0.95보다 큰  $R^2$ 값을 보여주었고 이 모델을 사용하면 철근콘크리트 구조물의 내구성 및 안전성 평가가 가능할 것이라고 판단된다. 추후 실제 프로젝트에 XGBoost를 적용하여 보다 다양한 조건에 대해 경년열화 모델로서의 정확성 검증이 필요하다고 판단된다.

### 감사의 글

본 논문은 2022년도 가동원전 안전성향상 핵심기술 개발사업의 지원으로 수행되고 있는 과제(과제번호: 20224B10200080) 내용의 일부입니다. 산업통상자원부와 한국에너지기술평가원의 연구비 지원에 깊은 감사를 드립니다.

### References

1. Kitsutaka, Y., Takesue, N. and Tsukagoshi, M., "Aging evaluation of nuclear power plant concrete structures", The 3rd International Conference on Nuclear Power Plant Management, Salt Lake City, Utah, USA, 2012
  2. Kitsutaka, Y. and Tsukagoshi, M., "Method on the aging evaluation in nuclear power plant concrete structures", Nuclear Engineering and Design, Vol. 269, pp. 286-290, 2012  
DOI:<http://dx.doi.org/10.1016/j.nucengdes.2013.08.041>
  3. Arel, H.S., Aydin, E. and Kore, S.D., "Ageing management and life extension of concrete in nuclear power plants", Powder Technology, Vol. 321, pp. 390-408, 2017  
DOI:<https://doi.org/10.1016/j.powtec.2017.08.053>
  4. Chen, Z. Lin, J, Sagoe-Crentsil, K. and Duan, W., "Development of hybrid machine learning-based carbonation models with weighting function", Construction and Building Materials, Vol. 321, 126359, 2022  
DOI:<https://doi.org/10.1016/j.conbuildmat.2022.126359>
  5. Zhang, J.S., Cheng, M. and Zhu, J.H., "Carbonation depth model and prediction of hybrid fiber fly ash concrete", Advances in Civil Engineering, Vol. 2020, 9863963, 2020  
DOI:<https://doi.org/10.1155/2020/9863963>
  6. Bodnárová, L., Valek, J., Sitek, L. and Foldyna, J., "Effect of high temperatures on cement composite materials in concrete structures", Acta Geodyn. Geomater., Vol. 10, pp. 173-180, 2013  
DOI:<https://doi.org/10.13168/AGG.2013.0017>
  7. Memon, S.A., Shah, S.F.A., Khushnood, R.A. and Baloch, W.L., "Durability of sustainable concrete subjected to elevated temperature-A review", Construction and Building Materials, Vol. 199, pp. 435-455, 2019  
DOI:<https://doi.org/10.1016/j.conbuildmat.2018.12.040>
  8. Thai, H.T., "Machine learning for structural engineering: A state-of-the-art review", Structures, Vol. 38, pp. 448-491, 2022  
DOI:<https://doi.org/10.1016/j.jstruct.2022.02.003>
  9. Yehoshua, R., "Random Forests", Retrieved November 11, 2023 from <https://medium.com/@roiyeho/random-forests-98892261dc99>, 2023
- Received : November 13, 2023
  - Revised : November 22, 2023
  - Accepted : November 22, 2023