

기계학습을 이용한 염화물 확산계수 예측모델 개발

Development of Prediction Model of Chloride Diffusion Coefficient using Machine Learning

김 현 수*
Kim, Hyun-Su

Abstract

Chloride is one of the most common threats to reinforced concrete (RC) durability. Alkaline environment of concrete makes a passive layer on the surface of reinforcement bars that prevents the bar from corrosion. However, when the chloride concentration amount at the reinforcement bar reaches a certain level, deterioration of the passive protection layer occurs, causing corrosion and ultimately reducing the structure's safety and durability. Therefore, understanding the chloride diffusion and its prediction are important to evaluate the safety and durability of RC structure. In this study, the chloride diffusion coefficient is predicted by machine learning techniques. Various machine learning techniques such as multiple linear regression, decision tree, random forest, support vector machine, artificial neural networks, extreme gradient boosting and k-nearest neighbor were used and accuracy of these models were compared. In order to evaluate the accuracy, root mean square error (RMSE), mean square error (MSE), mean absolute error (MAE) and coefficient of determination (R^2) were used as prediction performance indices. The k-fold cross-validation procedure was used to estimate the performance of machine learning models when making predictions on data not used during training. Grid search was applied to hyperparameter optimization. It has been shown from numerical simulation that ensemble learning methods such as random forest and extreme gradient boosting successfully predicted the chloride diffusion coefficient and artificial neural networks also provided accurate result.

Keywords : Multi-Agent reinforcement learning, Deep Q-Network, Optimal structural design, Reinforced concrete beam

1. 서론

철근 콘크리트 구조물에 대한 염화물 침투는 구조물의 내구성에 가장 큰 영향을 미치는 요인 중에 하나이다. 일반적으로 강한 알칼리성의 콘크리트는 보강 철근의 표면에 부동태 피막을 생성하여 철근이 부식되는 것을 막는다. 만약 콘크리트에 침투된 염화물이 특정한 수준을 넘어가게 되면 수동태 피막의 파괴가 일어나고 결과적으로 철근부식으로 인해 구조물의 안전성, 사용성 및 내구성에 큰 영향을 미치게 된다¹⁻³⁾. 따라서 염화물의 침투 과정을 이해하고 염화물의 확산을 정확하게 예측하는 것은 철근 콘크리트 구조물의 수명과 내구성을 연장하는데 중요한 역할을 하게 된다. 그러므로 지금까지 다양한 조건으로 생성된 콘


크리트 내의 염화물 확산 특성을 파악하기 위한 연구가 다수 수행되어 왔다⁴⁻⁶⁾. 이러한 연구는 확산이 콘크리트 내부에서 염화물이 전달되는 주요 메커니즘이라고 가정함으로써 단순화된다. 콘크리트 내부로 염화물이 침투하는 과정은 Fick의 제2법칙에 기반을 둔 비정상상태(non-steady state) 확산계수 평가방법을 사용하는 것이 일반적이다.

이러한 염화물 확산계수를 예측하기 위해서 실험결과를 바탕으로 다양한 회귀분석기법을 사용하여 예측 모델이 발표되어 왔다^{7,8)}. 근래에는 기계학습이 다양한 공학분야에 적용되어 콘크리트의 강도와 탄성계수와 같은 구조물의 재료특성 예측모델 개발에 우수한 성과를 나타내고 있다⁹⁾. 기계학습 기법 중 특히 딥러닝은 구조물의 비선형 응답 예측이나 지진 취약도 모델 개발, 진동제어알고리즘 개발 등 보다 복잡하고 예측이 어려운 문제에 적용되어 좋은 성과를 나타내었다^{10,11)}. 그러나 복잡한 딥러닝 알고리즘을 염화물 확

* 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

산계수 예측과 같은 상대적으로 복잡성이 작은 문제에 적용한다면 학습과정에서 과적합이 발생하여 학습되지 않은 데이터에 대한 예측능력이 저하될 가능성이 있다. 따라서 다양한 기계학습 알고리즘을 활용해서 콘크리트 내부의 염화물 확산계수 예측능을 평가하고 적절한 알고리즘을 선정하는 것이 필요하다. 지금까지 여러 기계학습 알고리즘을 활용한 염화물 확산계수 예측모델을 개발하고자하는 연구^{12,13)}가 있었지만 사용한 기계학습 알고리즘이나 학습용 데이터베이스 분석 등에서 더 많은 연구가 필요한 상황이다.

이러한 배경을 바탕으로 본 연구에서는 다양한 기계학습 알고리즘을 이용해서 염화물 확산계수 예측모델을 개발하고 각 모델의 정확성을 비교·검토 해보았다. 이를 위해서 본 연구에서는 비정상상태의 촉진시험법 중 <Fig. 1>에 나타난 NT Build 492 (전기영동에 의한 비정상 상태의 시험에 의한 염화물 확산계수 산정방법)¹⁴⁾에 의해서 계산된 염화물 확산계수로 구성된 데이터베이스를 활용하였다.



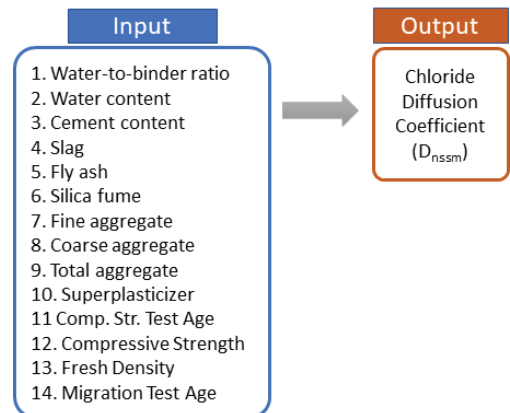
<Fig. 1> Configuration of NT Build 492¹⁴⁾

염화물 확산계수 예측모델 개발을 위하여 다중선형회귀(Multiple Linear Regression; MLR), 결정트리(Decision Tree; DT), 랜덤 포레스트(Random Forest; RF), 서포트 벡터 머신(Support Vector Machine; SVM), 인공신경망(Artificial Neural Networks; ANN), XG 부스트(eXtreme Gradient Boosting; XGBoost), K 최근접 이웃(K-Nearest Neighbor; KNN) 알고리즘을 사용하였다. 개발된 예측모델의 정확성을 검증하기 위해서 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 계산하여 검토하였다. 본 연구를 통해서 앙상블 학습알고리즘이 비교적 정확하고 안정적으로 염화물 확산계수를 예측할 수 있다는 것을 확인하였다.

2. 염화물 확산계수 예측모델 학습을 위한 데이터베이스

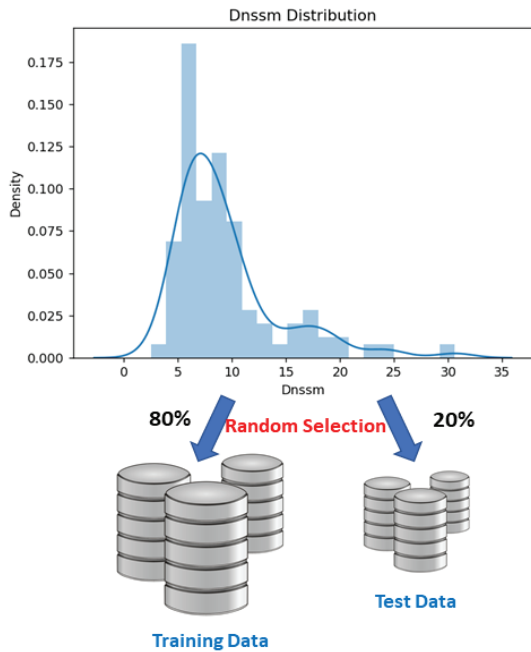
기계학습 기법을 이용하여 염화물 확산계수 예측모델을 개발하기 위해서는 적절한 데이터베이스를 사용하는 것이 필요하다. 본 연구에서는 Taffese와 Espinosa-Leal(2023)⁸⁾의 연구에서 사용했던 데이터베이스에서 누락 값이 있는 데이터를 제거하고 사용하였다. Taffese와 Espinosa-Leal의 연구에서는 비정상상태의 염화물 확산계수(D_{nssm})를 연구 프로젝트와 국제 저널에 발표된 실험 결과로부터 취합하여 843개의 실험결과를 포함하는 데이터베이스를 구축하였다. 데이터베이스의 출력 값은 비정상상태의 염화물 확산계수이고 입력 값은 물/시멘트비, 시멘트, 슬래그, 플라이 애시, 실리카 폼의 양 및 잔골재, 굵은 골재, 유동화제, 공기연행제 등 22개의 항목으로 구성되어 있다. 본 연구에서는 843개의 기본 데이터 중에서 누락된 데이터 등을 제외하는 전처리과정을 통해 <Fig. 2>에 나타난 입출력 변수를 가진 데이터베이스를 구성하였고 총 176개의 데이터를 가진다.



<Fig. 2> Inputs and output of database

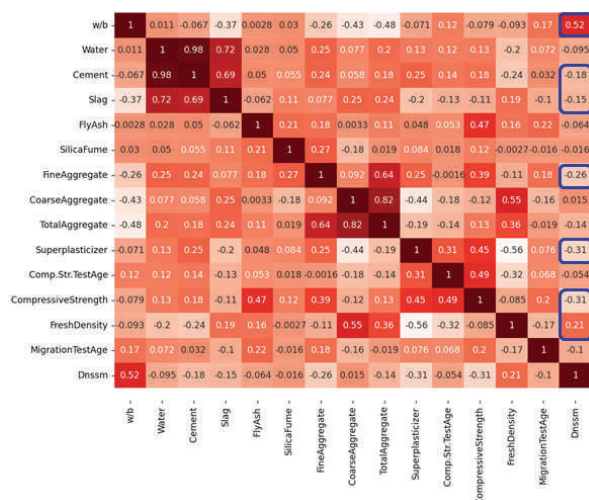
본 연구에서 사용한 데이터베이스의 출력값(D_{nssm})의 분포를 보면 <Fig. 3>에 나타난 바와 같이 비정상상태 염화물 확산계수가 약 $7.5 \times 10^{-12} \text{m}^2/\text{s}$ 의 값을 중심을 많이

분포되어 있고 그 보다 큰 값들도 다수 분포된 것을 알 수 있다. 이렇게 생성한 데이터베이스는 임의로 선택하여 80%는 학습용으로 20%는 학습된 모델의 검증용으로 사용하였다.



<Fig. 3> Configuration of database

구성한 데이터베이스 입출력 특성(feature)간의 상관관계를 분석하기 위해서 <Fig. 4>에 특성 상관관계 히트맵을 나타내었다.



<Fig. 4> Feature correlation heatmap

그림을 보면 물/시멘트비(w/b)가 출력값(D_{nssm})과 가장 큰 양의 상관관계(0.52)를 나타내는 것을 알 수 있다. 즉 물/시멘트비가 커지면 비정상상태의 염화물

확산이 더 잘 일어나는 것을 의미한다. 입력 변수 중 유동화제(Superplasticizer)와 콘크리트 압축강도의 상관계수는 모두 -0.31로서 가장 큰 음의 상관관계를 나타낸다. 즉, 유동화제가 많이 포함되거나 콘크리트의 압축강도가 높다면 콘크리트 내 염화물 확산이 잘 일어나지 않게 된다. 이외에도 잔골재, 시멘트 및 슬래그 양이 주요한 음의 상관관계를 나타내었다. 양의 상관관계는 비례, 음의 상관관계는 반비례 관계를 의미한다.

3. 염화물 확산계수 예측을 위한 기계 학습 기법

최근까지 다양한 기계학습 알고리즘이 실험 데이터를 학습 데이터로 활용하여 구조물의 특성치를 예측하는 모델 개발에 활용되어 왔다⁹⁾. 이러한 목적에 사용되는 기계학습 알고리즘은 지도학습(supervised learning) 중 회귀(regression) 모델에 해당한다. 본 연구에서는 <Table 1>에 나타난 7개의 회귀 지도학습 알고리즘을 사용하여 염화물 확산계수 예측모델을 생성하였다.

<Table 1> Machine learning algorithms

Algorithms	Base
Multiple Linear Regression (MLR)	Model
Decision Tree (DT)	Model
Random Forest (RF)	Model
Support Vector Machine (SVM)	Model
Artificial Neural Networks (ANN)	Model
eXtreme Gradient Boosting (XGBoost)	Model
K-Nearest Neighbor (KNN)	Instance

다중 선형 회귀(MLR) 기법은 식 (1)에 나타난 것처럼 여러 개의 독립변수(x)들을 사용하여 종속변수(y)를 예측하기 위한 회귀모델을 만들기 위한 방법으로 널리 사용되어 왔다.

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

종속변수를 정확하게 예측할 수 있는 가중치(w)와

편향(b)을 찾기 위해서는 일반적으로 식 (2)에 나타난 것처럼 실제값(\hat{y})과 예측값(y) 사이의 평균제곱오차 (Mean Squared Error, MSE)를 최소화하는 값을 찾는다. 보통 다중 선형 회귀 모델은 과적합 (overfitting)되는 경향이 있다. 이로 인하여 일반화 능력이 떨어져 새로운 데이터를 제대로 예측하지 못하는 경우가 발생하는데 이를 보완하기 위해서 식 (3)과 (4)에 나타난 Lasso와 Ridge 기법이 제안되었다. 일반적으로 MLR 모델의 가중치(w)가 너무 크면 과적합되는 경향이 있기 때문에 가중치 절대값의 합 (Lasso)이나 가중치 제곱의 합(Ridge)을 MSE와 합하여 최소화시킨다.

$$\text{Linear: } \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{2}$$


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

$$\text{Ridge: } \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \alpha \sum_{i=1}^n w_i^2 \tag{4}$$

여기서, n은 관측치의 개수, α 는 가중치를 결정하는 하이퍼파라미터이다.


결정 트리(Decision Tree, DT)는 예측값의 오차를 가장 잘 줄일 수 있는 변수를 기준으로 분기를 만들어 결과를 예측하는 매우 단순한 모델이다. 어떤 변수가 중요한지, 변수의 값에 따라 예측 결과가 무엇인지만 눈에 볼 수 있어서 추론과정을 이해하기 쉬운 장점이 있다.

랜덤 포레스트(Random Forest, RT)는 분류, 회귀 분석 등에 사용되는 앙상블 학습 방법의 일종으로, <Fig. 5>에 나타난 바와 같이 훈련 과정에서 구성한 다수의 결정 트리로부터 평균 예측치를 출력함으로써 동작한다. 랜덤 포레스트는 결정트리에서 발생할 수 있는 과적합 문제를 개선할 수 있는 알고리즘으로 알려져 있다. 그림에서 몇몇의 결정 트리들이 과적합을 보일 수 있지만 다수의 트리를 기반으로 예측하기 때문에 그 영향력이 줄어들게 되어 좋은 일반화 성능을 보인다.




<Fig. 5> Concept of random forest

서포트 벡터 머신(Support Vector Machine, SVM)은 특성이 다른 두 범주로부터 최대한 멀리 떨어져 있는 결정 경계를 찾는 것을 목표로 하며 선형이나 비선형 분류, 회귀 등에 사용할 수 있는 강력한 성능을 갖는 지도 학습 모델로 알려져 있다. 서포트 벡터 머신은 <Fig. 6>에 나타난 바와 같이 기본적으로 마진 (Margin)이라는 아이디어를 사용한다. 마진은 두 데이터 범주를 구분하는 도로의 경계를 뜻하는데 SVM에서 폭이 넓은 도로를 찾는 것이 최적의 결정 경계를 찾는 것이고 이를 통해 최적의 예측치를 얻을 수 있다.



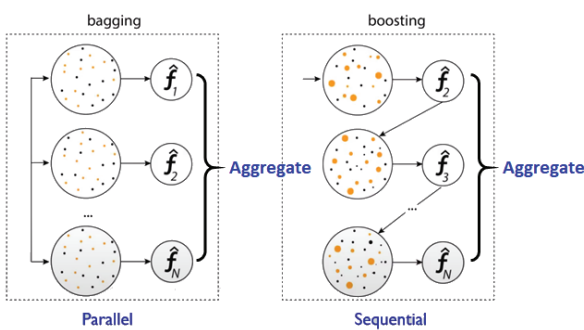
<Fig. 6> Concept of support vector machine

인공신경망(ANN)은 딥러닝의 가장 핵심적인 기술로써, 신경 세포인 뉴런을 추상화한 인공 신경으로 구성된 네트워크이다. 인공 신경망은 <Fig. 7>에 나타난 바와 같이 여러 계층으로 구성된 네트워크로 이루어져 있으며 각 계층은 다수의 뉴런으로 구성되어 있다. 뉴런은 입력값을 받아 가중치와 활성화 함수를 통해 출력값을 계산하고, 계층 간에 정보를 전달한다. 학습을 통해서 정확한 출력값을 예측할 수 있는 가중치 (w)와 편향(b)을 찾게 되고 계산된 값에 활성화함수를 적용하여 비선형을 효과적으로 표현할 수 있게 한다.




〈Fig. 7〉 Concept of artificial neural network

기계학습에서 앙상블(ensemble)은 여러 개의 모델을 조화롭게 학습시켜서 그 모델들의 예측 결과들을 이용해 더 정확하고 안정적인 예측값을 계산할 수 있는 기법을 의미한다. 앙상블 기법은 학습 데이터가 부족한 상황에서 모델의 성능을 향상시킬 수 있다고 알려져 있으며 대표적으로 〈Fig. 8〉에 나타난 배깅(bagging)과 부스팅(boosting) 기법이 있다. 배깅은 랜덤 샘플링을 통해 학습데이터를 늘리는 방법으로서 랜덤 포레스트 알고리즘이 여기에 해당하고 부스팅은 예측이 잘못된 데이터에 가중치를 부여하여 표본 재추출 후 연속적으로 학습하는 방법으로 대표적으로 XGBoost 알고리즘이 있다.



〈Fig. 8〉 Types of ensemble learning

KNN 알고리즘은 〈Fig. 9〉에 나타난 것처럼 입력 데이터 주변의 가장 가까운 K개의 샘플값을 통해 출력값을 예측하는 방식으로 작동한다. 가장 간단한 방식으로는 K개 데이터의 평균을 출력으로 사용할 수 있다.



〈Fig. 9〉 Concept of KNN (K=5)

〈Table 1〉에서 볼 수 있듯이 KNN 알고리즘은 인스턴스 기반 학습이고 나머지 알고리즘은 모두 모델 기반 학습이다. 따라서 나머지 알고리즘은 학습데이터를 이용해서 기계학습 모델을 생성하고 KNN은 모델 생성을 하지 않고 입력된 데이터를 중심으로 거리가 가까운 K개의 다른 데이터의 출력값을 활용하여 예측한다. 앞서 소개한 7개의 알고리즘을 통해서 생성한 염화물 확산계수 예측모델의 정확성을 검증하기 위해서 회귀 모델의 정확성을 평가하기 위해서 일반적으로 사용되는 4개의 성능평가지표를 식(5)-(8)에 나타내었다.

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

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{6}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{7}$$

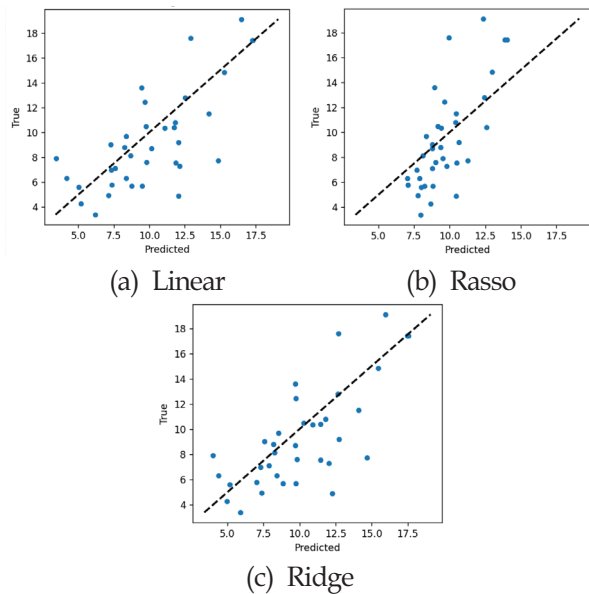
$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{MSE}{Var(y)} \tag{8}$$

여기서, n은 관측치의 개수, \hat{y}_i 는 예측값, y_i 는 실제 목표값, \bar{y} 는 실제 목표값의 평균값, 그리고 Var은 목표값에 대한 분산을 의미한다.

4. 기계학습 모델에 따른 정확성 검토

앞 절의 〈Table 1〉에 소개한 7개의 알고리즘을 사용하여 염화물 확산계수 예측모델을 생성하였고 정확성을 비교해보았다. 우선 다중 선형 회귀 알고리즘의

예측 정확성을 <Fig. 10>과 <Table 2>에서 비교하여 보았다. 그림의 가로축은 예측값이고 세로축은 실제값을 나타낸다. 따라서 기계학습 모델에 의해서 예측한 값이 점선으로 나타난 대각선위에 표시된다면 정확도가 높은 것이고 대각선에서 멀어질수록 오차가 큰 것을 의미한다. 그림을 보면 세 개의 모델이 비슷한 경향을 보이지만 Rasso 모델이 다른 두 모델에 비해서 예측성능이 좋지 않은 것을 볼 수 있다. 각 모델의 예측 정확성을 정량적으로 살펴보기 위해서 <Table 2>의 결과를 보면 Ridge 모델이 가장 정확하고 Rasso 모델이 가장 부정확하지만 큰 차이는 없는 것을 알 수 있다.




<Fig. 10> Predictions of MLR

<Table 2> Prediction errors of MLR

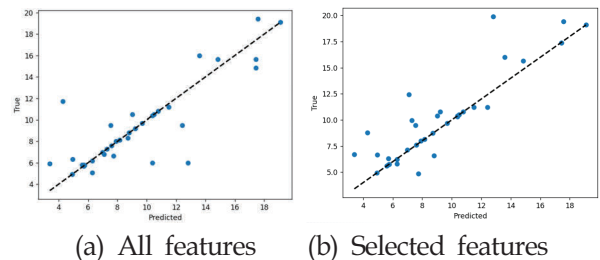
Model	RMSE	MSE	MAE	R ²
Linear	2.88	8.27	2.23	0.48
Lasso	2.96	8.74	2.33	0.45
Ridge	2.85	8.11	2.15	0.49

결정 트리 기법은 알고리즘의 특성상 입력 변수 (feature)가 예측값 계산에 미치는 중요도를 <Fig. 11>에 나타난 바와 같이 얻을 수 있다. 그림에서 보면 물시멘트비의 중요도가 압도적으로 크고 그 뒤로 콘 크리트 압축강도, 확산계수 실험시 재령 등의 순으로 중요도가 계산되는 것을 알 수 있다. 따라서 앞서 소개한 14개의 모든 입력변수를 사용한 결정트리 모델과 <Fig. 11>에 나타난 중요도가 높은 4개의 입력변

수를 사용한 결정트리 모델의 예측결과를 <Fig. 12>에 비교하였다. 그림을 보면 두 모델의 정확도 차이가 별로 나지 않는 것을 알 수 있다. 보다 정확한 비교를 위해서 <Table 3>에 성능평가지표 오차값들을 나타내었다. 표를 보면 전체 입력변수를 모두 사용한 모델보다 중요도가 높은 4개의 입력변수만 사용한 모델이 모든 오차값에 대해서 더 작은 값을 나타내는 것을 알 수 있다. 이것은 중요도가 작은 변수를 많이 사용하면 결정 트리 모델에 더 많은 정보를 주는 것이 아니라 오히려 헛갈리게 할 수 있는 것으로 판단된다.



<Fig. 11> Feature importance



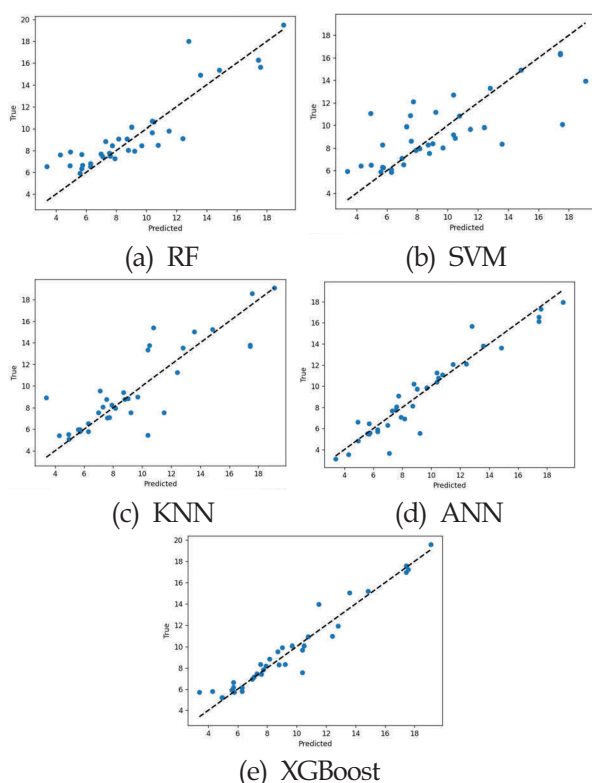
(a) All features (b) Selected features
<Fig. 12> Predictions of decision tree

<Table 3> Prediction errors of ML models

Model	RMSE	MSE	MAE	R ²
DT(All)	2.15	4.62	1.17	0.71
DT(Sel.)	2.07	4.27	1.19	0.73
RF	1.7	2.88	1.27	0.82
SVM	2.57	6.61	1.82	0.58
KNN	2.1	4.41	1.41	0.72
ANN	1.21	1.47	0.85	0.91
XGBoost	0.97	0.94	0.69	0.94

결정 트리 이외에 나머지 5개의 기계학습 모델(RF, SVM, KNN, ANN, XGBoost)의 염화물 확산계수 예측결과를 <Table 3>과 <Fig. 13>에 나타내었다. 그림을 보면 SVM의 예측치가 실제값인 대각선에서 가장 멀리 떨어져서 분포하는 것을 볼 수 있고 XGBoost와 ANN이 대각선과 가장 가까운 예측치는 나타내는 것을 알 수 있다.

〈Table 3〉에 나타난 오차값을 검토해보면 XGBoost와 ANN의 R^2 값이 각각 0.94와 0.91로 매우 정확한 예측성을 나타내는 것을 알 수 있었고 그 뒤로 RF가 0.82의 값으로 우수한 성능을 나타내었다. SVM은 MLR 알고리즘들 보다 조금 우수한 성능을 나타냈지만 R^2 값이 0.58로 염화물 확산계수 예측모델로 사용하기에는 정확도가 많이 부족한 것으로 판단된다. DT와 KNN은 비슷한 정확도를 나타냈으며 DT의 앙상블 모델은 RF는 DT보다 10%이상의 정확도 향상을 가져온 것을 알 수 있다.



〈Fig. 13〉 Predictions of ML models

5. 결론

본 연구에서는 콘크리트의 안전성 및 내구성에 큰 영향을 미치는 염화물 확산계수의 예측을 위해서 다양한 기계학습 알고리즘을 이용하여 예측모델을 개발하였고 정확성을 비교·검토하였다. 본 연구에서는 널리 사용되고 있는 기계학습 알고리즘인 MLR, DT, RF, SVM, KNN, ANN, XGBoost를 사용하여 예측모델을 개발하였고 정확성을 비교·검토하였다. 모델의 학습을 위해 비정상상태의 촉진시험법 중 NT Build 492 실험에 의해서 얻은 염화물 확산계수 데이터베이스

를 활용하였다. 7개의 기계학습 알고리즘을 통해서 생성한 염화물 확산계수 예측모델의 정확성을 검증하기 위해서 4개의 오차 평가지표(RMSE, MSE, MAE, R^2)를 계산해서 비교한 결과 XGBoost가 가장 우수한 예측성을 나타낸 것으로 나타났다. 그 뒤로 ANN과 RF의 정확도가 높았으며 MLR과 SVM은 정확도가 가장 낮았다. 가장 우수한 예측성을 나타낸 XGBoost의 R^2 값이 0.94로서 매우 정확한 염화물 확산계수를 예측할 수 있었고 이를 바탕으로 신뢰성 있는 철근콘크리트 구조물의 내구성 및 안전성 평가가 가능함을 확인할 수 있었다.

감사의 글

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

References

- Pontes, J., Bogas, J.A., Real, S. and Silva A., "The rapid chloride migration test in assessing the chloride penetration resistance of normal and lightweight concrete", *Applied Science*, Vol. 11, 7251, 2021.
DOI:<https://doi.org/10.3390/app11167251>
- Nguyen, T.S., Lorente, S. and Carcasses, M., "Effect of the environment temperature on the chloride diffusion through CEM-I and CEM-V mortars: An experimental study", *Construction and Building Materials*, Vol. 23, pp. 795 - 803, 2009.
DOI:<https://doi.org/10.1016/j.conbuildmat.2008.03.004>
- Ye, H., Jin, X., Fu, C., Jin, N., Xu, Y. and Huang, T., "Chloride penetration in concrete exposed to cyclic drying-wetting and carbonation", *Construction and Building Materials*, Vo. 112, pp. 457 - 463, 2016.

- DOI:<https://doi.org/10.1016/j.conbuildmat.2016.02.194>
4. Torres-Luque, M., Bastidas-Arteaga, E., Schoefs, F., Sanchez-Silva, M. and Osma, J.F., "Non-destructive methods for measuring chloride ingress into concrete: State-of-the-art and future challenges", *Construction and Building Materials*, Vol. 68, pp. 68 - 81, 2014.
DOI:<https://doi.org/10.1016/j.conbuildmat.2014.06.009>
 5. Choi, Y.C., Park, B., Pang, G.S., Lee, K.M. and Choi, S., "Modelling of chloride diffusivity in concrete considering effect of aggregates", *Construction and Building Materials*, Vol. 136, pp. 81 - 87, 2017.
DOI:<https://doi.org/10.1016/j.conbuildmat.2017.01.041>
 6. Elfmarkova, V., Spiesz, P. and Brouwers, H.J.H., "Determination of the chloride diffusion coefficient in blended cement mortars", *Cement and Concrete Research*, Vol. 78, pp. 190 - 199, 2015.
DOI:<https://doi.org/10.1016/j.cemconres.2015.06.014>
 7. Homayoonmehr, R., Rahai, A. and Ramezani-pour, A.A., "Predicting the chloride diffusion coefficient and surface electrical resistivity of concrete using statistical regression-based models and its application in chloride-induced corrosion service life prediction of RC structures", *Construction and Building Materials*, Vol. 357, 129351, 2022.
DOI:<https://doi.org/10.1016/j.conbuildmat.2022.129351>
 8. Taffese, W.Z. and Espinosa-Leal, L., "Multitarget regression models for predicting compressive strength and chloride resistance of concrete", *Journal of Building Engineering*, Vol. 72, 106523, 2023.
DOI:<https://doi.org/10.1016/j.jobe.2023.106523>
 9. 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.istruc.2022.02.003>
 10. Kim, H.S., "Development of seismic response simulation model for building structures with semi-active control devices using recurrent neural network", *Applied Sciences*, Vol. 10, 3915, 2020.
DOI:<https://doi.org/10.3390/app10113915>
 11. Wen, W., Zhang, C. and Zhai, C., "Rapid seismic response prediction of RC frames based on deep learning and limited building information", *Engineering Structures*, Vol. 267, 114638, 2022.
DOI:<https://doi.org/10.1016/j.engstruct.2022.114638>
 12. Taffese, W.Z. and Espinosa-Leal, L., "A machine learning method for predicting the chloride migration coefficient of concrete", *Construction and Building Materials*, Vol. 348, 128566, 2022.
DOI:<https://doi.org/10.1016/j.conbuildmat.2022.128566>
 13. Al Fuhaid AF and Alanazi H. "Prediction of chloride diffusion coefficient in concrete modified with supplementary cementitious materials using machine learning algorithms", *Materials*, Vol. 23, 1277, 2023.
DOI:<https://doi.org/10.3390/ma16031277>
 14. Hasholt, M.T. and Jensen, O.M., "Chloride migration in concrete with superabsorbent polymers", *Cement and Concrete Composites*, Vol. 55, pp. 290 - 297, 2015.
DOI:<https://doi.org/10.1016/j.cemconcomp.2014.09.023>
- Received : August 01, 2023
 - Revised : August 11, 2023
 - Accepted : August 11, 2023