

말뚝지지력 예측을 위한 머신러닝 모델 연구

이병식
공주대학교 사회환경공학과

A Study of Machine Learning Models to Estimate a Pile Load Capacity

Byung-Sik Lee

Department of Civil & Environmental Engineering, Kongju National University

요약 이론적, 경험적 방법으로 예측한 말뚝지지력은 현장 재하시험을 통해 신뢰도를 검증해야 한다. 하지만 일반적으로 말뚝재하시험은 비용이 많이 소요되므로 시험횟수에 제약이 따른다. 최근에는 말뚝지지력 예측의 보조수단으로서 머신러닝이나 딥러닝 등 인공지능 모델을 이용한 연구가 수행되고 있다. 인공지능 알고리즘, 개발플랫폼과 하드웨어, 데이터 등의 매우 빠른 변화와 발전을 감안하면 보다 명확하고 타당한 모델의 개발과 적용 가능성은 무한하다. 이 연구에서는 다음의 목적으로 말뚝 지지력 추정을 위한 선형회귀 및 결정트리 알고리즘에 기반한 앙상블 머신러닝 모델들의 적용성을 평가하였다. 1) 오픈소스 파이선 플랫폼, 구글코랩, 주피터노트북 등 인공지능모델 개발을 위한 최신 개발 환경 구축, 2) 말뚝지지력 예측을 위한 머신러닝 모델의 평가, 3) 말뚝기초 인공지능 모델 개발을 위한 기존 말뚝재하시험 데이터베이스 검토 및 활용, 4) 향후 말뚝기초의 침하, 하중-변위 추정까지 모델을 확장하기 위한 기반연구로서 수행하였다. 검토한 머신러닝모델들은 검증데이터셋트에 대해서 결정계수 0.5 이상의 점수로 말뚝지지력을 예측할 수 있는 것으로 평가되었다. 앙상블모델 중 말뚝지지력 예측 적합성이 높은 모델로서 그라디언트부스팅과 XG 부스팅 모델의 적용을 제안하였다. 향후 연구로서 과적합의 효율적 배제 방안, 적절한 하이퍼파라미터 결정, 추가 데이터 축적 등의 문제를 제안할 수 있었다.

Abstract Field pile load tests are essential to ensure the reliability of pile capacities determined using theoretical and empirical methods. However, the number of such tests is generally restricted due to their high cost. Recently, artificial intelligence (AI) models involving machine learning and deep learning are being developed as supplemental methods to estimate pile capacities. Clearer and more reliable models need to be developed on an ongoing basis, considering the rapid evolution of artificial intelligence algorithms, hardware and developing platforms, and data. The applicability of machine learning models using linear regression and decision tree ensemble algorithms to estimate pile bearing capacities were evaluated in this study for the following purposes: 1) building up the environment for developing artificial intelligence models, such as the open-source Python platform, Google Colab, Jupyter Notebook, etc., 2) evaluation of machine learning models for estimating a pile load capacity, 3) reviewing and utilizing the existing pile load test databases for developing AI models of pile foundations, 4) conducting base studies for the future extension of models for the estimation of the settlement and load-displacement of piles. The investigated machine learning models were found to estimate pile load capacities with scores in terms of the coefficient of determinant over 0.5. The most appropriate ensemble models for the pile load estimation were the gradient boosting and XB boosting models. Further studies could include subjects such as eliminating overfitting, deciding on the proper hyperparameters, and accumulating additional data.

Keywords : Artificial Intelligence, Machine Learning, Pile Load Capacity, Random Forest, Gradient Boosting

*Corresponding Author : Byung-Sik Lee(Kongju National Univ.)

email: blee@kongju.ac.kr

Received June 22, 2021

Accepted October 1, 2021

Revised July 22, 2021

Published October 31, 2021

1. 서론

최근 다양한 공학문제 해결에 기계학습이나 딥러닝 등의 인공지능 모델을 적용하려는 연구[1-3]가 수행되고 있다. 말뚝지지력을 예측하기 위한 인공지능 모델의 개발도 동일한 맥락이며 적지 않은 연구가 수행되어 왔다 [4-11]. 경제적이고 안전한 말뚝기초를 설계하기 위해서는 신뢰할 수 있는 말뚝지지력 예측이 필수적이다. 말뚝지지력은 이론적, 경험적 해석으로 추정할 수 있지만 검증을 위한 현장재하시험이 필수적이다. 하지만 일반적으로 말뚝재하시험은 시간과 비용이 많이 소요되므로 시험빈도가 제한된다. 따라서 말뚝지지력 예측에는 적지 않은 불확실성이 내재되어 있다. 이를 극복하기 위해 SPT, CPT, PDA, 확률론적 하중저항계수설계법(LRFD)[12,13] 등과 같은 시험법과 설계방법의 개선이 꾸준히 시도되어 왔다. 이와 더불어서 인공지능모델의 도입도 말뚝지지력 예측의 불확실성 개선에 기여할 수 있는 가능성 높은 한 가지 방안으로 판단된다[10].

인공지능 기법을 이용하여 말뚝기초의 지지력, 침하, 하중-변위 관계 등을 알아내기 위한 연구가 지속적으로 수행되어 왔다[6, 10]. 인공지능 알고리즘, 개발플랫폼과 하드웨어, 데이터 등의 매우 빠른 변화를 감안하면 보다 명확하고 타당한 모델 개발과 적용의 가능성은 무한하다.

이와 같은 배경에서 말뚝의 지지력 추정을 위한 다양한 머신러닝 모델의 적용성을 평가하였다. 말뚝지지력 추정은 회귀(regression)문제로 구분되었으며 이를 풀기 위한 머신러닝 모델은 scikit-learn[14] 라이브러리를 사용하여 개발하였다. 모델 개발을 위한 말뚝재하시험 훈련 및 검증 데이터는 문헌[15, 16] 데이터베이스에서 추출하여 사용하였다. 이러한 연구의 목적과 의의는 다음과 같이 정리할 수 있었다.

- 1) 오픈소스 파이선 플랫폼, 구글 코랩, 슈퍼터 노트북 등 인공지능모델 개발을 위한 최신 개발 환경 구축,
- 2) 말뚝지지력 예측을 위한 머신러닝 모델의 평가,
- 3) 말뚝기초 인공지능 모델 개발을 위한 기존 말뚝재하시험 데이터베이스 검토 및 활용,
- 4) 향후 말뚝기초의 침하, 하중-변위 추정까지 모델을 확장하기 위한 기반연구로서 수행

2. 말뚝재하시험 데이터

2.1 데이터베이스

말뚝지지력 모델 개발을 위한 훈련 및 검증 데이터셋 트로서 말뚝재하시험 데이터가 필요하다. 데이터를 얻기 위해 말뚝지지력시험 데이터베이스 구축 사례를 조사한 결과 Table 1에 보인 바와 같이 해외자료 5건과 국내자료 1건을 얻을 수 있었다.

국내자료로는 한국건설기술연구원이 수행한LRFD설계법 개발 연구와 병행하여 수집한 자료가 있었다[12]. 지역특성이 미치는 영향을 고려하여 국내자료의 적용을 검토하였다. 하지만 이 자료는 브라우징, 쿼리 기능을 가진 데이터베이스 형태로 공개되지는 않아 데이터 추출에 어려움이 있었고 이 논문에서는 적용하지 못했다.

Table 1의 데이터베이스들을 검토한 결과 FHWA (Federal Highway Administration)의 DFLTD (Deep Foundation Load Test Database)[15,16]를 사용키로 하였다. DFLTD에는 개관, 폐관 강관말뚝, 콘크리트원형말뚝, 강 H-말뚝, 선긴장 콘크리트말뚝, drilled shaft, 오거캐스트말뚝, 마이크로파일 등 다양한 종류의 말뚝 1,500개에 대한 재하시험과 더불어서 155개의 대구경 개관말뚝(LPOEPs: Large Diameter Open-End Piles)에 대한 축방향 재하시험자료가 포함되어 있었다. 이들 자료 중 강관개관말뚝(SPO)에 대한 정적재하시험자료를 선별하여 모델개발을 위한 데이터셋으로 사용하였다.

Table 1. Summary of Investigated Database

Database	DB Type	Pile Type	Organization	Ref.
DINGO	Excel	Vary	U of Bristol, UK (2019)	[17]
DFLTD	Access	Vary	FHWA (2018)	[15,16]
ZJU-ICL	Unknown	Driven piles in sand	Zhejiang U./ Imperial College London (2016)	[18]
PILOT	Access	Driven Steel H-Piles	Iowa DOT (2011)	[13]
ER Model	MySQL	Drilled shaft load tests	Chung Yuan Christian University, Taiwan (2012)	[19]
Unknown	Unknown	Vary	KICT (2008)	[12]

2.2 데이터 가공

2.2.1 특성과 기준

선별한 자료에는 개관식 원형 강관말뚝에 대한 54개 재하시험자료가 포함되었다. 말뚝은 직경 305~ 253mm, 길이 9.1~92m의 특성을 가졌다. 이 자료를 기반으로 인공지능 모델 개발을 위한 데이터프레임을 가공하였다. 데

이터프레임은 모두 29개의 인덱스에 대해 각각 54개 입력값을 가지는 구조로 만들었다. 29개 인덱스는 자료번호, 프로젝트명, 파일명, 최대하중, 최대변위, 길이, 직경, 항복하중, 선단 포함 6개 깊이별 N값, 주변 토질의 모래, 점토, 실트에 대한 3가지 함유율, 선단 포함 6개 깊이별 콘관입선단저항력과 6개 콘관입마찰저항력 등이다.

모델의 복잡성을 배제하고 효율적 훈련을 위해 특성 분석과 데이터 가공할 필요가 있었다. 데이터프레임 자료 중 N값과 콘관입시험값들에는 시험자료가 없어 입력이 누락된 경우가 있었다. 누락된 N값에 대해서는 지반과 콘관입시험값을 기반으로 추정된 값을 입력하였다. 깊이별 N값은 주변에서의 평균값과 선단 N값의 2개 특성으로 정리하였다. 콘관입시험값에 대한 특성은 N값과 중복되는 특성이고 누락된 입력이 있어 데이터프레임에서 제거하였다. 주변 토질에 대한 특성은 간략한 모델개발에 장애가 되므로 제거하였다. 자료번호, 프로젝트명, 파일명 등은 상관성이 없는 자료이므로 제거하였다. 결과적으로 최대하중(MaxF), 최대변위(MaxD), 길이(Len), 직경(Dia), 항복하중(Qu), 주변에서의 평균 N값(mean_N), 선단 N값(NB)의 7개 인덱스를 가진 데이터프레임을 만들어 모델개발에 적용하였다. 데이터프레임의 인덱스명을 MaxF 등과 같이 괄호 안의 기호로 나타냈다.

데이터프레임의 인덱스에 대해서 모델 훈련 및 검증을 위한 데이터셋트의 기준(target, label)을 항복하중(Qu)으로, 나머지 6개 인덱스는 특성(feature)으로 정했다. 기준 및 특성들 간의 상관관계를 나타내면 Fig. 1과 같다. 기준 Qu에 대한 특성간의 상관관계는 Fig. 1의 3행 혹은 3열에서 볼 수 있다. Qu에 대한 상관계수는 MaxF, Dia, Len, NB, mean_N, MaxD의 순으로 0.99, 0.78, 0.56, 0.30, 0.04, -0.75로 구해져 Dia, Len, NB가 상대적으로 중요한 특성을 인지하였다.

각 특성들이 기준에 미치는 영향을 검토하기 위해 특성을 조합한 상관조건에서 Qu 값의 크기 변화를 검토한 예를 Fig.2에 나타냈다. 직경, 길이 증가에 따라 말뚝 지지력이 증가되는 전형적인 추세를 Fig.2에서 볼 수 있었다. mean_N은 증가에 따른 Qu의 증가 경향이 나타났지만 다른 특성에 의한 영향이 더 크게 나타났다. 모든 특성에 대한 상관관계를 검토한 결과 모델개발을 위한 특성으로 Dia, Len, NB, mean_N의 4개 특성을 선정하였다.

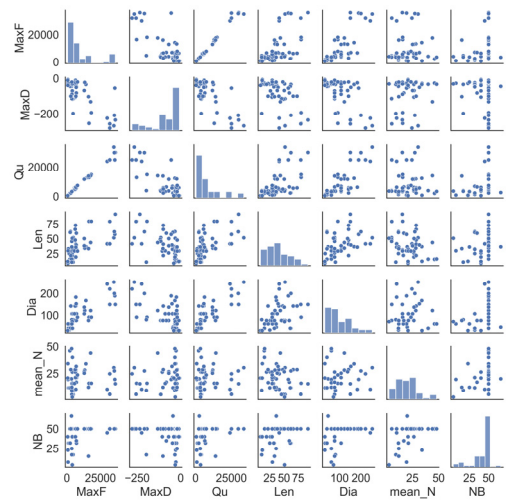


Fig. 1. Correlation between the label and features




Fig. 2. Variation of Qu for the combinations of features

2.2.2 정규화

2.2.1에서 정한 특성의 범위와 단위가 특성별로 상이하므로 데이터를 정규화 할 필요가 있었다. 정규화한 데이터를 사용할 경우 회귀분석에서 결정된 기울기로부터 특성이 미치는 영향을 균등하게 평가할 수 있기 때문이다. 각 특성 입력값을 평균이 0이고 표준편차 1로 정규화한 데이터셋트의 값 분포를 Fig. 3에 나타냈다.

2.2.3 훈련 및 검증 데이터셋트

데이터셋트를 훈련데이터셋트와 검증데이터셋트로 분리하였다. scikit-learn의 train_test_split 함수를 사용하여 random state=42인 조건으로 분리하였다.




Fig. 3. Normalized data to the standard scale

3. 머신러닝 모델

3.1 k-최근접이웃

2절에서 만든 데이터셋트에 대해서 k-최근접이웃(k-Nearest Neighbors)알고리즘을 적용하여 추정된 말뚝지지력을 Fig. 4에 나타냈다. 기준값과 예측값을 훈련셋트와 검증셋트를 구분하여 기준값 순서에 따라 순차적으로 나타내 비교했다. 검토결과 이웃의 수가 1인 조건에서 훈련데이터에 대한 결정계수(R^2)로 나타낸 훈련점

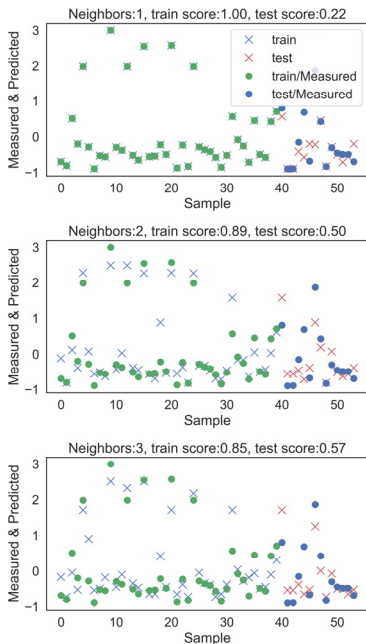


Fig. 4. Result obtained from k-Nearest Neighbors model

수(score)가 1.0으로 검증데이터에 대해서는 0.53으로 구해졌다. 이들 값의 차이가 크게 나타나 모델이 훈련셋트에 과적합된 것으로 판단되었다. 이웃의 수 3 이상인 조건에서 모델은 훈련 및 검증데이터에 대해서 모두 점수(R^2)가 0.57 이상으로 말뚝지지력을 잘 예측하는 것으로 나타났다. 이 모델은 특성 수가 증가하면서 모델훈련과 예측에 시간이 많이 걸리는 단점으로 실무에 드물게 적용되는 것으로 알려져 있다[20].

3.2 선형모델

선형회귀(linear regression), 과대적합을 방지하기 위해 l_2 규제를 적용한 릿지(ridge) 모델, l_1 규제를 적용한 라소(lasso)모델, 이 두 모델을 혼합한 ElasticNet 모델, 선형 SVR(support vector regressor)모델 등의 적용성을 검토하였다.

선형회귀모델을 이용하여 예측한 말뚝의 지지력을 기준값과 비교하여 Fig. 5(a)에 보였다. 점수(R^2)는 훈련셋트에 대해서 0.712, 검증셋트에 대해서 0.434로 나타났다. 예측값에 미치는 특성의 중요도를 검토하기 위해 기울기(coefficient) 값을 Fig. 5(b)와 같이 비교하였다. 표준편차에 대해 정규화한 데이터에 대해서 직경(Dia)에 대한 기울기가 가장 크므로 작은 변화로도 예측값을 크게 변화시키는 중요한 특성으로 확인되었다.

선형모델과 규제를 적용한 릿지(ridge), 라소(lasso), ElasticNet, 선형 SVR모델에 대한 훈련곡선으로부터 모델에 부과한 규제 효과를 검토하였다. 이를 위해 각 모델에 대해 교차검증과 훈련셋트 크기를 변화시키면서 구한 결정계수 평균값의 변화를 Fig. 6에 나타냈다. 그림의 결과에서 선형모델과 선형 SVR은 상대적으로 높은 훈련점수를 얻는 반면에 검증점수는 낮게 나타났다. 규제를 적용한 릿지, 라소, ElasticNet 모델의 경우는 검증점수가 상대적으로 높아 규제로 인한 모델의 일반화를 볼 수 있었다. 하지만 말뚝 데이터셋트에 대해서 훈련한 선형모델들은 훈련 및 검증 셋트에 대해서 가 약 0.6 정도로 유사하게 나타났다. 데이터셋트의 크기가 상대적으로 작기 때문에 규제에 대한 영향이 크게 나타나지 않은 것으로 판단된다.

Fig. 7에 Fig. 6의 모델들로부터 구한 예측값과 기준값을 비교하였다. 이 그림에서는 훈련셋트와 테스트셋트를 2개의 그림으로 구분했다. 모델훈련 및 검증 시 보인 점수의 차이에도 불구하고 예측치와 기준치 간의 오차는 모델별로 크게 차이나지 않는 것으로 나타났다.

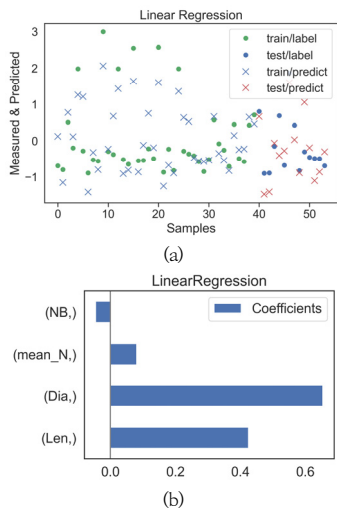


Fig. 5. Result obtained from the linear regression model
(a) Label vs. predicted data, (b) Coefficients for features




Fig. 6. Comparison of scores for linear models

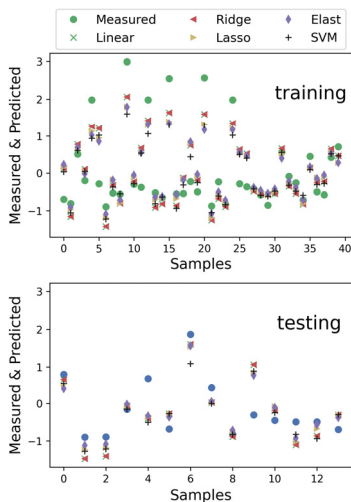


Fig. 7. Predicts vs. labels for linear models

3.3 결정트리, 랜덤포레스트, 앙상블메소드

결정트리(Decision Tree) 모델을 이용하여 말뚝지지력을 예측하였다. 최고깊이(max_depth)는 4, 최소분기 데이터수(min_sample_leaf)가 5인 경우에 결정트리 모델에서 전개된 결정단계를 Fig. 8에 나타냈다. 이 모델에서 훈련셋과 테스트셋 점수는 각각 0.678과 0.738로 구해졌다. 이 결과는 과다적합을 피하기 위해 하이터 파라미터인 최고깊이와 분기최소데이터수의 적절한 값을 임의로 정해 구한 결과이다. 모델의 적합성을 향상시키기 위해서는 적절한 하이퍼파라미터 결정에 대한 검토가 필요한 것으로 판단되었다.

일군의 예측모델을 융합하여 모델을 훈련하는 경우를 앙상블훈련이라 하며 더 나은 모델을 얻을 가능성이 있다. 앙상블훈련에 적용되는 알고리즘인 앙상블메소드에는 bagging, boosting, voting stacking 등이 있다[21].

랜덤포레스트(Random Forest) 모델은 결정트리 앙상블을 bagging 메소드로 훈련한 모델이다. 랜덤포레스트 모델에 대해서 n_estimators=500, max_leaf_nodes=16의 조건에서 훈련점수와 검증점수는 각각 0.946, 0.717로 구해졌다. 이 결과는 bagging 메소드로 훈련한 n_estimators=500, max_leaf_nodes=16 조건의 결정트리에 대한 값 0.945, 0.710과 유사하였다. 결정트리 모델에 그라디언트부스팅 메소드를 앙상블한 GBRT (Gradient Boosted Regression Tree) 모델을 검토하였다. n_estimators=500, max_depth=4, learning_rate=0.1과 1.0의 두 가지 조건에서 모두 훈련점수 1.0에 비해 검증점수가 낮게 나타나 모델이 과적합된 것으로 판단되었다.

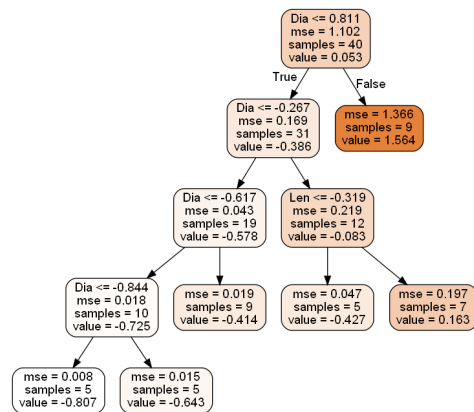


Fig. 8. Decision tree of max_depth = 4, min_samples_leaf = 5

결정트리 앙상블 모델과 3.2에서 기술한 선형모델들에 대해서 voting 앙상블 회귀모델을 사용하여 추정한 예측값과 기준값을 비교하여 Fig. 9에 보였다. voting 모델은 다른 모델들의 평균값을 기준으로 훈련되는 것을 Fig. 9의 결과에서 확인할 수 있었다.

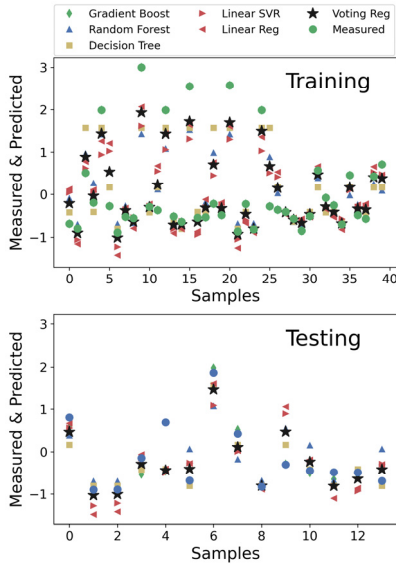


Fig. 9. Voting regression compared with other models

각 모델에 대해서 적합한 하이퍼파라미터와 값을 정리 하면 Table 2와 같다. 하이퍼파라미터 max_depth, min_samples_leaf, n_estimators, learning_rate 등은 각각 트리의 최대성장깊이, 분기최소샘플수와 앙상블 훈련량을 조절하는 트리의 개수, 훈련속도 등을 지정하는 값이다. Table 2의 조건에서 Voting 모델은 훈련 및 검증셋트에 대해서 각각 0.829와 0.692의 점수를 얻어 비교적 적합한 모델로 판단되었다.

Table 2의 하이퍼파라미터에 대한 검증을 통해 모델들의 적합성을 보다 향상시킬 수 있을 것으로 판단되었다. 랜덤포레스트의 경우에 min_samples_leaf를 1로 감소시킨 경우에 훈련점수 0.933과 및 검증점수 0.705의 결과를 얻어 훈련셋트에 대한 과적합이 개선되는 결과를 얻었다. GBRT 모델은 랜덤포레스트 모델보다 최소 손실로의 수렴이 빠르므로 early stopping 방법으로 적절한 n_estimators 값을 찾아 적용하였다. learning_rate를 0.1로 적용한 경우에 최적 n_estimators를 구한 결과를 Fig. 10에 나타냈다. 최소손실이 RMSE 0.342일 때 최적 n_estimators는 17로 구해졌다. 이 조건에서 훈련 및 검증셋트에 대한 점수는 각각 0.967과 0.807이었다.

이 훈련모델로 구한 검증셋트의 예측값은 Fig. 10에 나타난 바와 같이 기준값을 양호하게 예측함을 알 수 있었다.

Table 2. Hyper-parameter and scores of models applied to the voting regressor

Model	Hyper-parameter	Scores	
		Training	Testing
GBRT	n_estimators=500 max_depth=4 learning_rate=1.0 min_samples_leaf=1	1.000	0.812
Random Forest	n_estimators=500 max_depth=4 min_samples_leaf=5	0.722	0.444
Decision Tree	max_depth=4 min_samples_leaf=5	0.678	0.738
Linear SVR	epsilon=0.01 max_iter=2000	0.682	0.458
Linear Regression	-	0.712	0.434
Voting	-	0.829	0.692

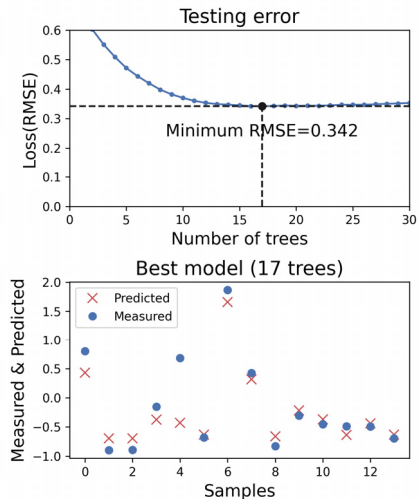


Fig. 10. Gradient boost model results for the best number of trees

GBRT 메소드보다 빠른 수렴이 가능한 앙상블 메소드인 XG Boost 라이브러리 알고리즘이 널리 사용된다 [21]. 이의 적용성을 평가하기 위해 GBRT와 동일한 조건에서 모델을 훈련하였다. 훈련한 모델을 사용하여 훈련 및 검증에 대해 얻은 점수는 각각 1.000과 0.640이었다. 예측값을 기준값과 비교한 결과는 Fig. 11과 같고 이 결과로부터 XG Boost 모델이 훈련셋트에 대해 과적합 되었음을 알 수 있었다.




Fig. 11. Over fitting for the trained data in the gradient boosting with XGBoost

과적합을 개선하기 위해 early stopping을 적용한 경우에 learning_rate=1과 0.1인 조건에서 최적나무수 결정을 위한 손실곡선은 Fig. 12와 같았다. 훈련 및 검증에 대한 점수는 각각 0.915, 0.720과 0.965, 0.792로 구해져 과적합이 개선된 것으로 나타났다. 최소 RSME 값을 비교하면 learning_rate=1 조건에서 0.413, learning_rate=0.1인 조건에서 0.355로 구해졌다. 이 결과와 learning_rate=1 조건에서 구한 손실곡선의 불확실성을 고려할 때 learning_rate=1 조건의 모델은 최소손실로 수렴하지 못한 것으로 판단되었다. 따라서 learning_rate=0.1의 훈련조건 모델을 적합성이 높은 최종 모델로 결정하였다.

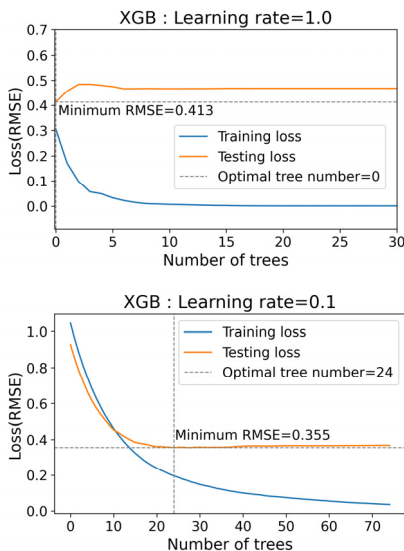


Fig. 12. Early stopping training curve

최종 XG Boost 모델을 사용하여 훈련셋과 검증셋에 대한 기준값과 예측값을 비교하여 Fig. 13에 나타났다. 그림의 결과로부터 XG Boost 모델을 이용하여 말

뚝의 지지력을 큰 오차 없이 예측할 수 있음을 볼 수 있었다. 특히 Fig. 11의 결과와 비교하여 검증셋에 대한 예측값의 과적합이 Fig. 13에서 개선되었음을 알 수 있었다.




Fig. 13. Measured vs. predicted obtained from the gradient boosting with XGBoost under an early stopping option

3.4 훈련손실 분석

검토한 모든 모델들의 훈련손실과 검증손실 점수를 비교하여 Fig. 14에 나타났다. 하이퍼파라미터에 대한 검증이 부족한 조건이지만 그림의 결과로부터 각 모델들의 신뢰도와 적합성을 비교 평가할 수 있었다. 결정계수의 값은 GBRT, XG Boost, 결정트리 순으로 높은 것으로 나타났다. 3.3에서 기술한 바와 같이 랜덤포레스트의 경우에 하이퍼파라미터 검토를 통해 점수를 GBRT 수준으로 올릴 수 있음을 알 수 있었다. 이러한 검토를 통해서 결정트리에 기반한 GBRT, XG Boost, 랜덤포레스트 모델들이 말뚝지지력 예측을 위한 모델로도 적절하게 활용될 수 있음을 확인하였다. 이 모델들은 머신러닝 모델 중에 적용성이 이미 잘 알려지고 자주 활용되는 모델들이다[20]. 또한, 훈련데이터의 수가 많아질 경우에 훈련의 경제성을 위해서는 XGBoost나 GBRT 모델을 적용하는 것이 유리할 것으로 판단되었다.




Fig. 14. Comparison of training and testing scores of the models

4. 결론

말뚝지지력을 예측하기 위한 머신러닝모델의 적용성을 검토하였다. 말뚝의 지지력을 기준으로 설정하고, 이를 예측하기 위한 특성으로 말뚝의 길이, 직경, 주변지반의 평균표준관입시험치, 선단지반의 표준관입시험치를 설정하였다. 기준에 대한 특성의 선형회귀모델로서 선형 모델로 구분되는 선형회귀, 릿지, 라소, ElasticNet, 선형 SVR모델을 검토하였다. 또한 결정트리모델과 더불어서 결정트리를 기반으로 하여 앙상블메소드를 적용한 랜덤 포레스트, GBRT, XG Boost 모델들의 적용성도 검토하였다. 이들 알고리즘을 말뚝지지력 예측을 위한 머신러닝 모델 개발을 위해 적용하여 검토한 결과 다음의 결론을 얻었다.

- 1) 선형모델에 대비하여 결정트리기반 모델의 훈련 및 검증점수가 상대적으로 높게 나타났다. 훈련점수만으로만 판단한다면 결정트리기반 모델의 적합성이 우수한 것으로 판단되었다. 하지만 과다적합의 문제점을 배제하기 위해서는 적절한 하이퍼파라미터의 지정이 중요하여 이에 대한 검토가 수행되어야 할 것으로 판단되었다.
- 2) 향후 대규모 말뚝 지지력 데이터를 분석하여 모델을 개발하는 경우에 유리한 모델로서 부스팅 앙상블 메소드를 적용한 GBRT, XG Boost 모델을 제안할 수 있었다. 특히 훈련시간을 절약하기 위해서는 XG Boost 모델의 적용을 제안할 수 있었다.
- 3) 말뚝지지력을 특성으로부터 예측하는 회귀분석 모델은 머신러닝 알고리즘만으로도 충분히 적합한 모델을 개발할 수 있음을 확인하였다. 같은 문제에 대해서 딥러닝 알고리즘과 대비하여 적합성 및 효율성을 평가하기 위한 검증을 수행하여 장단점을 파악해야 할 필요가 있을 것이다.
- 4) 모델의 신뢰도를 향상하기 위한 데이터베이스의 확충이 필요하다. 기존 데이터베이스의 분석과 더불어서, 문헌, 보고서, 연구논문 등 산재한 자료와 현행 현장시험자료 등을 데이터베이스화 하여 활용할 수 있는 기반 구축이 필요하다.

References

- [1] M. Shahin, 8-Artificial Intelligence in Geotechnical Engineering: Applications, Modeling Aspects, and Future Directions, *Metaheuristics in Water, Geotechnical and Transport Engineering*, p.484, Elsevier Inc., 2013, pp.169-204.
DOI:<https://doi.org/10.1016/B978-0-12-398296-4.00008-8>
- [2] L. Bragagnolo, R. V. da Silva, J. M. V. Grzybowski, "Artificial neural network ensembles applied to the mapping of landslide susceptibility", *CATENA*, Vol.184, 104240, 2020.
DOI: <https://doi.org/10.1016/j.catena.2019.104240>
- [3] R. A. T. M. Ranasinghe, M. B. Jaksa, F. Pooya Nejad, Y. L. Kuo, "Genetic programming for predictions of effectiveness of rolling dynamic compaction with dynamic cone penetrometer test results", *Journal of Rock Mechanics and Geotechnical Engineering*, Vol.11, No.4, pp.815-823, 2019.
DOI: <https://doi.org/10.1016/j.irmge.2018.10.007>
- [4] H. Harandizadeh, "Developing a new hybrid soft computing technique in predicting ultimate pile bearing capacity using cone penetration test data", *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, Vol.34, No.1, pp.114-126, 2020.
DOI: <https://doi.org/10.1017/S0890060420000025>
- [5] R. U. Kulkarni, D. M. Dewaikar, "Prediction of Interpreted Failure Loads of Rock-Socketed Piles in Mumbai Region using Hybrid Artificial Neural Networks with Genetic Algorithm", *International Journal of Engineering Research & Technology (IJERT)*, Vol.6, No.6, pp.365-372, 2017.
DOI: <http://dx.doi.org/10.17577/IJERTV6IS060196>
- [6] M. A. Shahin, "State-of-the-art review of some artificial intelligence applications in pile foundations", *Geoscience Frontiers*, Vol.7, No.1, pp.33-44, 2016.
DOI: <https://doi.org/10.1016/j.gsf.2014.10.002>
- [7] A. Benali, B. Boukhatem, M. N. Hussien, A. Nechnech, M. Karray, "Prediction of axial capacity of piles driven in non-cohesive soils based on neural networks approach", *Journal of Civil Engineering and Management*, Vol.23, No.3, pp.393-408, 2017.
DOI: <https://doi.org/10.3846/13923730.2016.1144643>
- [8] A. Kordjazi, F. P. Nejad, M. B. Jaksa, "Prediction of ultimate axial load-carrying capacity of piles using a support vector machine based on CPT data", *Computers and Geotechnics*, Vol.55, 91-102, 2014.
DOI: <https://doi.org/10.1016/j.compgeo.2013.08.001>
- [9] J. M. Park, Y. B. Han, Y. S. Jang, "Estimation of Ultimate Bearing Capacity of Gravel Compaction Piles Using Nonlinear Regression Analysis", *Journal of Korean Society of Coastal and Ocean Engineers*, Vol.25, No.2, pp.112-121, 2013.
DOI: <https://doi.org/10.9765/kscoe.2013.25.2.112>
- [10] M. A. Shahin, "Intelligent computing for modeling axial capacity of pile foundations", *Canadian Geotechnical Journal*, Vol.47, No.2, pp.230-243, 2010.
DOI: <https://doi.org/10.1139/T09-094>
- [11] I.-M. Lee, J.-H. Lee, "Prediction of pile bearing capacity using artificial neural networks", *Computers*

and *Geotechnics*, Vol.18, No.3, pp.189-200, 1996.
DOI: [https://doi.org/10.1016/0266-352X\(95\)00027-8](https://doi.org/10.1016/0266-352X(95)00027-8)

- [12] Korea Institute of Construction Technology, Determination of Resistance Factors for Foundation Structure Design by LRFD, In Construction and Transportation R&D Report, Korea, pp.68-136.
URL: <https://scienceon.kisti.re.kr/srch/selectPORSrchReport.do?cn=TRKO201100004338>
- [13] M. Roling, S. Sritharan, M. Suleiman, Development of LRFD Procedures for Bridge Pile Foundations in Iowa Volume I: An Electronic Database for Pile Load Tests (PILOT), Iowa Department of Transportation, U.S.A., pp.1-46. URL: <http://publications.iowa.gov/20067/>
- [14] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, et al., "Scikit-learn: Machine Learning in Python", *Journal of Machine Learning Research*, Vol.12, 2825--2830, 2011.
<http://jmlr.org/papers/v12/pedregosa11a.html>
- [15] FHWA, Deep Foundation Load Test Database (DFLTD) -Version 2.0 [Internet]. Federal Highway Administration, 2014 [cited 2021 June 16]. Available From: <https://www.fhwa.dot.gov/software/research/infrastructure/structures/bridges/dfltd/index.cfm> (accessed June. 16, 2021)
- [16] N. Machairas, G. A. Highley, M. G. Iskander, "Evaluation of FHWA Pile Design Method against the FHWA Deep Foundation Load Test Database Version 2.0", *Transportation Research Record*, Vol.2672, No.52, pp.268-277, 2018.
DOI: <https://doi.org/10.1177/0361198118773196>
- [17] P. Vardanega, E. Voyagaki, J. Crispin, C. Gilder, K. Ntasiou, "The DINGO Database, v1.0.", University of Bristol, 2019. DOI: <https://doi.org/10.5523/bris.3r14qbdhv648b2p83gjqby2f18>
- [18] Z. Yang, R. Jardine, W. Guo, F. Chow, Description of the Extended ZJU-ICL Database, A Comprehensive Database of Tests on Axially Loaded Piles Driven in Sand, p.250, Elsevier Inc., 2016, pp.15-29, DOI: <https://doi.org/10.1016/B978-0-12-804655-5.00003-X>
- [19] M. Marcos, S.-S. Lin, R.-M. Liao, J. Huang, Y. Chen, "Development of a Database for Pile Load Tests", *Geotechnical Special Publication*, 2012.
DOI: <https://ascelibrary.org/doi/10.1061/9780784412121.031>
- [20] A. C. Müller, Introduction to Machine Learning with Python: A Guide for Data Scientists, p.400, O'Reilly Media, 2016, pp.25-129.
- [21] A. Géron, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, p.856, O'Reilly Media, Inc., 2019, pp.189-211.

이 병 식(Byung-Sik Lee)

[정회원]



- 1987년 8월 : 고려대학교 대학원 토목공학과 (공학석사)
- 1996년 5월 : 텍사스주립대학교 대학원 토목공학과 (공학박사)
- 1996년 8월 ~ 현재 : 공주대학교 사회환경공학과 교수

<관심분야>

지반공학, 지반환경, 인공지능