

ORIGINAL ARTICLE

지반 조건과 TBM 운영 파라미터를 고려한 디스크 커터 마모 예측

강윤성¹, 고태영^{2*}

¹강원대학교 에너지-인프라 융합학과 석사과정, ²강원대학교 에너지자원-산업공학부 조교수

Prediction of Disk Cutter Wear Considering Ground Conditions and TBM Operation Parameters

Yunseong Kang¹ and Tae Young Ko^{2*}

¹Graduate Student, Department of Integrated Energy and Infra System, Kangwon National University

²Assistant Professor, Department of Energy and Resources Engineering, Kangwon National University

*Corresponding author: tyko@kangwon.ac.kr

Received: April 12, 2024

Revised: April 17, 2024

Accepted: April 18, 2024

ABSTRACT

Tunnel Boring Machine (TBM) method is a tunnel excavation method that produces lower levels of noise and vibration during excavation compared to drilling and blasting methods, and it offers higher stability. It is increasingly being applied to tunnel projects worldwide. The disc cutter is an excavation tool mounted on the cutterhead of a TBM, which constantly interacts with the ground at the tunnel face, inevitably leading to wear. In this study quantitatively predicted disc cutter wear using geological conditions, TBM operational parameters, and machine learning algorithms. Among the input variables for predicting disc cutter wear, the Uniaxial Compressive Strength (UCS) is considerably limited compared to machine and wear data, so the UCS estimation for the entire section was first conducted using TBM machine data, and then the prediction of the Coefficient of Wearing rate(CW) was performed with the completed data. Comparing the performance of CW prediction models, the XGBoost model showed the highest performance, and SHapley Additive exPlanation (SHAP) analysis was conducted to interpret the complex prediction model.

Keywords: TBM, Disc cutter, Wear, Operation parameter, Machine learning

초록

TBM 공법은 발파 공법에 비해 굴착 중 소음과 진동 수준이 낮고, 안정성이 높은 터널 굴착 공법이며, 전 세계적으로 터널 프로젝트에 TBM 공법을 적용하는 사례가 증가하는 추세이다. 디스크 커터는 TBM의 커터헤드에 장착되는 굴착 도구로 지속적으로 막장면 지반과 상호작용하며, 이때 필연적으로 마모가 발생한다. 본 연구에서는 지질 조건과 TBM 운영파라미터, 머신러닝 알고리즘들을 이용하여 디스크 커터 마모를 정량적으로 예측하였다. 디스크커터 마모 예측의 입력변수 중 UCS 데이터의 수가 다른 기계 데이터 및 마모 데이터에 비해 매우 부족하기 때문에, 먼저 TBM 기계 데이터를 이용하여 전체 구간에 대한 UCS 추정을 진행하고, 완성된 전체 데이터로 마모율 계수 예측을 수행하였다. 마모율 계수 예측 모델의 성능을 비교해 본 결과 XGBoost 모델의 성능이 가장 높게 나타났으며, 복잡한 예측 모델의 해석을 위해 SHapley Additive exPlanation (SHAP) 분석을 진행하였다.

핵심어: TBM, 디스크 커터, 마모, 운영 파라미터, 머신러닝



1. 서론

TBM (Tunnel Boring Machine) 공법은 발파 공법에 비해 굴착 중 소음과 진동 수준이 낮고, 안정성이 높은 터널 굴착 공법이며, 이러한 장점으로 인해 전 세계적으로 터널 프로젝트에 TBM 공법을 적용하는 사례가 증가하는 추세이다. 디스크 커터는 TBM의 커터헤드에 장착되는 굴착도구로 커터헤드의 회전에 의해 지속적으로 막장면 지반과 상호작용하며, 이때 필연적으로 마모가 발생한다(Fig. 1). 일정 수준 이상의 마모가 발생한 디스크 커터는 교체되어야 하며, 일부 TBM 프로젝트에서는 커터 유지보수 및 교체에 드는 시간과 비용이 전체 공사비와 공사기간의 30 %까지 차지하는 경우도 있다(Wang et al., 2017). 또한, 디스크 커터가 적절한 시기에 교체되지 않아 과도하게 마모될 경우 높은 토크가 발생하고, 커터헤드가 손상될 수 있다(Su et al., 2020). 이에 따라 디스크 커터의 마모를 정확히 예측하는 것은 TBM 프로젝트에서 가장 중요한 요소 중 하나이다(Mahmoodzadeh et al., 2021).

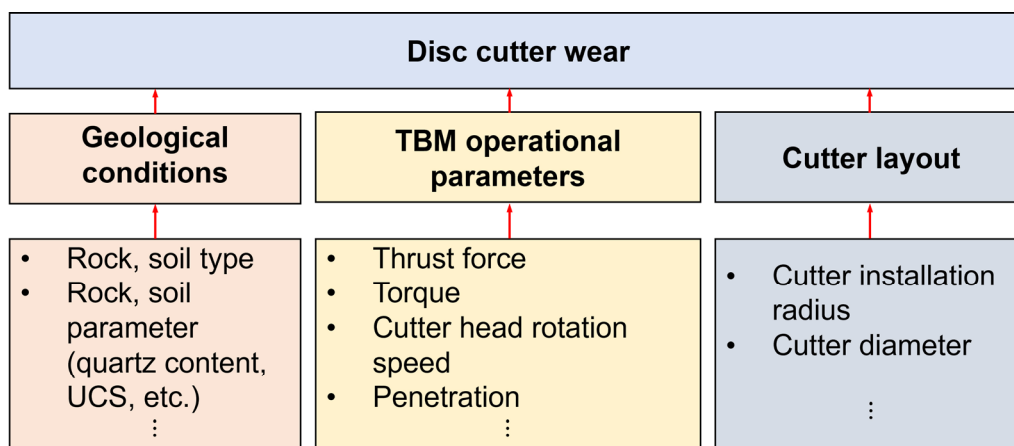


Fig. 1. Factors affecting disc cutter wear

디스크 커터의 마모에 영향을 미치는 요인들은 Fig. 1와 같이 지질 조건, TBM 운영 파라미터, 커터 제원 및 커터헤드 설계 정보 3가지 주요 범주로 분류될 수 있으며(Amoun et al., 2017, Frenzel et al., 2008), 이러한 3가지 요인들을 모두 고려하지 않을 경우 커터 마모 예측 정확도가 큰 편차를 보이고, 전반적인 예측능력이 낮아질 수 있다(Ding et al., 2022).

대표적인 디스크 커터 수명 예측 모델에는 NTNU 모델(Brulan, 1998), CSM 모델(Rostami and Ozdemir, 1993), Gehring 모델(Gehring, 1995)이 있다. NTNU 모델에서는 경암 터널링 케이스만 고려한 모델이며, 디스크 커터 수명을 예측하기 위해 사용되는 커터 수명 지수(Cutter Life Index, CLI)를 계산하기 위한 실험에 많은 시간과 비용이 소요된다는 단점이 있다. CSM과 Gehring 모델에서는 지질조건으로 세르샤 마모지수(Cerchar Abrasivity Index, CAI)만 고려하고, 운전조건으로는 penetration 만 고려하여 커터 수명 예측의 정확도가 낮을 수 있다는 단점이 있다.

이러한 단점을 극복하기 위해 고차원 데이터에서 복잡한 패턴을 학습하여 예측을 수행할 수 있는 인공지능(Artificial Intelligence, AI)을 활용하여 디스크 커터 수명을 예측하는 연구가 최근에 많이 수행되었지만(Elbaz et al., 2020, Elbaz et al., 2021, Kilic et al., 2022, Loy-Benitez et al., 2024, Mahmoodzadeh et al., 2021), 디스크 커터 마모를 정량적으로 예측하는 연구는 상대적으로 부족한 상황이다. 따라서 본 연구에서는 지질 조건과 TBM 운영 파라미터, 다양한 머신러닝 알고리즘을 이용하여 슬러리 TBM의 디스크 커터 마모를 정량적으로 예측하고자 하였다.

2. 데이터 수집, 전처리

본 연구에 사용된 전체 데이터는 싱가포르 TBM 터널 프로젝트 데이터를 사용하였다. 이 프로젝트에서는 총 길이 약 5.53 km인 터널을 3.14 km와 2.21 km 두 구간으로 나누어, 각 구간을 동일한 사양의 TBM 두 대(TBM #1, TBM #2)로 굴착하였다. 두 TBM의 사양은 Table 1에 요약되어 있다. 전체 구간은 대부분 Bukit Timah Granite로 구성되며, 일부 구간은 Kallang 퇴적층, 혼합지반을 통과한다. 디스크 커터 마모 데이터는 Fig. 2와 같이 Cutterhead Intervention (CHI) 중 작업자가 수동으로 디스크 커터의 반경 감소량을 측정하여 기록한 자료를 사용하였다. 지질 조건은 CHI 중 수행된 막장면 지질 조사에서 Table 2의 BS5930:1990(BS, 1999)를 기준으로 분류된 풍화 등급과 사전 지질 조사에서 얻은 일축압축강도(Uniaxial Compressive Strength, UCS) 데이터를 사용하였다. 입력변수 중 UCS 데이터는 전체 구간에서 총 56개 지점에 대한 데이터만 존재하여 20 mm 굴진마다 기록되는 기계 데이터와 191개 구간에서의 디스크 커터 마모 데이터에 비해 상당히 부족하다. 이러한 문제를 해결하기 위해, 먼저 TBM 기계 데이터와 UCS 데이터를 이용하여 기계 데이터가 기록된 전체 구간에 대한 UCS 추정을 진행하였다.

Table 1. Summary of the TBM and disc cutter wear specifications

TBM type	Slurry
TBM diameter	6.9 m
Torque	0-6,250 kN·m
Thrust force	0-51,200 kN
Cutterhead rotation speed	0-6 rpm
Number of disc cutter	48
Disc cutter diameter	483 mm



Fig. 2. Manual measurement of disc cutter wear(Liu et al., 2017)

Table 2. BS5930:1990 approach 2 weathering classification (BS, 1999)

Geo notation	Grade	Classifier	Typical characteristics
G1	I	Fresh	Unchanged from original state
G2	II	Slightly weathered	Slight discoloration, slight weakening
G3	III	Moderately weathered	Considerably weakened, penetrative discoloration; large pieces cannot be broken by hand

Table 2. BS5930:1990 approach 2 weathering classification (BS, 1999) (continued)

Geo notation	Grade	Classifier	Typical characteristics
G4	IV	Highly weathered	Large pieces cannot be broken by hand; Does not readily disaggregate (slake) when dry sample immersed in water
G5	V	Completely weathered	Considerably weakened; Slakes; Original texture apparent
G6	VI	Residual soil	Soil derived by in situ weathering but retaining none of original texture or fabric

3. UCS 추정

UCS 예측을 위해 시추조사수행 지점을 중심으로 앞뒤 50 mm 구간의 UCS 값이 일정하다고 가정하고 데이터베이스를 구축하였다.

3.1 입력변수 선정

TBM이 굴착을 진행하는 동안 Thrust force, Torque, Cutterhead rotation speed 등을 포함하는 약 2000개의 인자가 약 20 mm 굴진 주기로 기록된다. 과도하게 많은 입력변수를 사용할 경우 머신러닝 알고리즘 기법을 이용한 예측 모델들이 복잡해지고, 계산 시간도 증가하기 때문에 UCS 예측에 중요하지 않은 변수를 제거해야 한다. 따라서 본 연구에서는 UCS 추정을 위해 Thrust Force (TF), Torque (TQ), Advance Rate (AR), Feed Pressure (FP), Cutterhead Rotation Speed (CHRS), Field Penetration Index (FPI) 을 입력변수로 선정하였다.

3.2 데이터 전처리

TBM이 약 1.4 m 길이의 하나의 ring을 굴착하는 동안 일반적으로 기계 데이터는 계속 변화한다. 이러한 변화는 크게 시작 단계 (Start-up phase), 안정 단계(Stable phase), 종료 단계(End phase)로 나눌 수 있다(Fig. 3). 하나의 ring에 대한 TBM 기계 데이터에서 시작 단계는 TBM이 불안정한 상태로 작동하기 때문에 제거하였고, TBM이 굴착을 하지 않는 상태인 종료 단계도 제거하였다 (Xu et al., 2023). 굴착 사이클이 시작되는 지점으로부터 20 mm 굴진이 이루어진 지점까지를 시작 단계로 결정하였으며, 입력 변수 중 하나라도 0 이하의 값을 가지거나 결측된 경우 해당 레코드를 제거하였다.




Fig. 3. Variations in Torque during tunneling

UCS 추정에 사용된 변수들의 기술 통계량은 Table 3에 요약되어 있으며, 데이터 편향을 줄이고 신뢰성 있는 모델 성능 평가를 위해 전체 데이터를 무작위로 5개의 훈련/테스트 세트로 나누어 5겹 교차검증(5-fold cross validation)을 수행하였다.

Table 3. Descriptive statistics summary of variables in UCS prediction model

Variables	Mean	Std	Min	Max	Count
TF (kN)	22795.6	3125.3	6208.0	13541.0	267
TQ (kN·m)	1005.6	215.7	447.0	1780.0	267
AR (mm/min)	8.99	3.85	2.08	23.33	267
FP (kPa)	384.2	71.2	213.0	545.0	267
CHRS (rpm)	3.12	0.59	0.83	3.99	267
FPI ((kN/cutter)/(mm/rev))	84.78	50.88	8.48	307.68	267
UCS (MPa)	77.79	32.18	17.00	144.00	267

※Std : Standard deviation, Min : Minimum value, Max : Maximum value

3.3 UCS 추정 방법론

본 연구에서는 UCS 추정을 위해 K-Nearest Neighbors (KNN), Support Vector Machine (SVM), Random Forest (RF) eXtreme Gradient Boosting (XGBoost), Categorical Boosting (CatBoost), Light Gradient Boosting Machine (LGBM)과 같은 지도학습 기반 머신러닝 알고리즘을 사용하였으며, 이 중 KNN과 SVM은 거리 기반 알고리즘으로 변수 간의 스케일 차이에 민감하기 때문에 MinMaxScaling을 적용하여 연속형 독립변수들의 범위를 [0, 1]로 변환하였다.

또한, 머신러닝 알고리즘의 성능을 향상시키기 위해 Tree-structured Parzen Estimator (TPE) 알고리즘을 사용하여 하이퍼파라미터 최적화를 진행하였고, 최적화 과정에서 과적합을 방지하기 위해 5겹 교차검증을 수행하였다. TPE 알고리즘은 베이지안 최적화의 변형 알고리즘으로 효율적으로 최적의 하이퍼파라미터 조합을 찾기 위해 이전 조합의 성능 평가 정보를 활용하는 알고리즘이다(Bergstra et al., 2011). 최적화가 완료된 모델들은 회귀 모델에의 성능 평가지표로 자주 사용되는 평균 제곱근 오차 (Root Mean Squared Error, RMSE)와 결정계수 (Coefficient of determination, R^2)를 사용하여 성능을 비교, 평가하였다. RMSE는 예측의 오차를 나타내기 때문에 그 값이 작을수록 예측 성능이 높은 것을 의미하며, R^2 는 1에 가까울수록 예측 모델의 설명력이 높음을 의미한다.

3.4 UCS 추정 결과

UCS 추정 모델의 성능을 비교해 본 결과, 테스트 데이터 세트에 대한 CatBoost 모델의 평균 RMSE가 12.27로 가장 낮고, R^2 가 0.85로 가장 높게 나타났다(Fig. 4). 따라서 5개의 CatBoost 모델들의 평균 UCS 예측값으로 기계 데이터가 기록된 전체 구간의 UCS를 추정하였다.

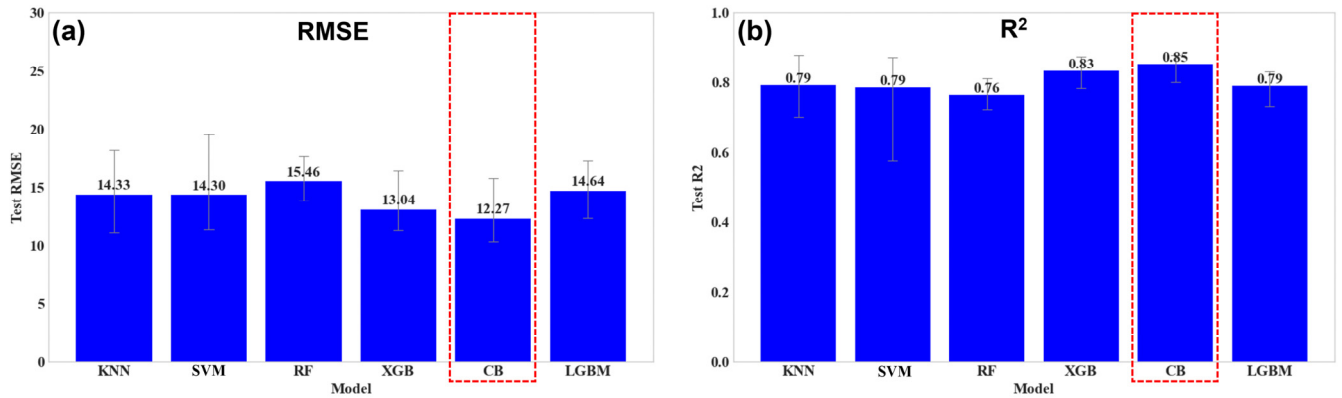


Fig. 4. (a) Mean test RMSE and (b) Mean test R² of the UCS estimation models

4. 디스크 커터 마모 예측

디스크 커터 마모 예측은 페이스 커터의 정상마모만을 고려하였으며, 191번의 CHI에서 측정된 디스크 커터의 반경 감소량 데이터를 사용하여 식 (1)과 같이 디스크 커터 반경 감소량을 해당 커터의 이동 거리로 나눈 마모율 계수 (Coefficient of Wearing rate, CW)를 계산하여 종속변수로 사용하였다.

$$CW(mm/km) = \frac{Cutterwear(mm)}{Cutterrollingdistance(km)} \quad (1)$$

4.1 입력변수 선정

디스크 커터 마모 예측을 위해 약 2000개의 TBM 운영 파라미터 중 TF, TQ, AR, FP, 디스크 커터 당 작용력(Normal force per disc cutter, Fn)를 입력변수로 선정하였고, 지질 조건으로는 UCS, 풍화 등급(Weathering Grade)을, 커터 제원 및 커터헤드 설계 정보는 디스크 커터가 정상적으로 회전한다고 가정하고 아래 식 (2)를 통해 개별 디스크 커터의 회전속도(Disc cutter rotation speed, CRS)를 계산하여 입력변수로 사용하였다.

$$v_d = \frac{2r_i}{d_i} v_c \quad (2)$$

여기서, v_d 는 디스크 커터 회전속도(rpm), r_i 는 i 번째 디스크 커터의 설치 반경(m), d_i 는 i 번째 디스크 커터의 직경(m), v_c 는 커터헤드 회전속도(rpm)이다.

4.2 데이터 전처리

TBM 기계 데이터에는 전자기 간섭, 센서 오류, 데이터 전송 오류 등에 의해 이상치가 존재할 수 있다(Yu et al., 2021). 본 연구에서는 0 이하인 데이터 포인트를 이상치로 판단하였으며, Isolation forest 알고리즘을 이용하여 이상치를 탐지하였다. 탐지된 이상치는 주변 유효한 데이터를 이용하여 대체하는 작업을 수행하였다(Fig. 5).




Fig. 5. (a) Detection of outliers, (b) Replacement of outliers in TBM #2 No. 1043-1065 ring

디스크 커터 마모 데이터에도 수동 측정, 특정 면에 대한 마모 측정, 재사용 커터 정보 누락 등의 이유로 이상치가 존재할 수 있다. 따라서 CW가 0.1 이상인 데이터는 정상적인 마모 데이터가 아니라고 판단하여 제거하였고, 커터 회전속도와 커터 마모율 계수를 Isolation forest 알고리즘으로 분석하여 탐지된 이상치도 제거하였다.

전처리가 끝난 변수들에 대한 기술 통계량은 Table 4에 요약되어 있으며, 마모 측정 데이터가 존재하는 191개 구간에 대해 구간별 기계 데이터의 평균값을 계산하여 마모 데이터와 기계 데이터를 매칭하였다. 전체 데이터는 무작위로 5개의 훈련/테스트 세트로 나누어 5겹 교차검증(5-fold cross validation)을 수행하였다.

Table 4. Descriptive statistics summary of variables in CW prediction model

	Variables	Mean	Std	Min	Max	Count
TBM operational parameters	TF (kN)	22827.5	2947.9	12637.5	29356.0	1545
	TQ (kN·m)	1007.4	107.8	643.3	1503.1	1545
	AR (mm/min)	9.27	2.97	2.75	19.75	1545
	FP (kPa)	371.8	73.0	209.1	546.1	1545
	Fn (kN/cutter)	209.1	45.0	84.8	319.4	1545

Table 4. Descriptive statistics summary of variables in CW prediction model (continued)

	Variables	Mean	Std	Min	Max	Count
Geological conditions	UCS (MPa)	80.8	14.3	40.8	104.9	1545
	Weathering grade	-	-	-	-	1545
Cutter layout	CRS (rpm)	26.9	7.2	5.0	46.6	1545
Cutter wear	CW (mm/km)	0.0209	0.0138	0.0022	0.0887	1545

4.3 CW 예측 방법론

CW 예측을 위해 3.3절의 UCS 예측과 같이 KNN, SVM, RF, XGBoost, CatBoost, LGBM 알고리즘을 사용하였으며, MinMaxScaling으로 변수의 범위를 [0, 1]로 변환하였다. 하이퍼파라미터 최적화는 TPE 알고리즘과 5겹 교차검증을 통해 수행하였다. 추가적으로 복잡한 머신러닝 알고리즘의 해석을 위해 특정 변수를 포함시키거나 제외시켰을 때 목표값의 평균 변화를 계산한 값인 Shapely value를 기반으로 변수 중요도를 평가하는 SHapely Additive exPlanation (SHAP) 분석을 진행하였다(Lundberg and Lee, 2017).

4.4 CW 예측 결과

CW 예측 모델들의 성능 평가 지표를 비교해 본 결과, 앙상블 알고리즘인 RF, XGBoost, CatBoost, LGBM 알고리즘들의 예측 성능이 단일 알고리즘인 KNN, SVM 보다 높게 나타났으며, 테스트 데이터 세트에 대한 XGBoost 모델의 평균 RMSE가 0.0091로 가장 낮고, 평균 R²가 0.564로 가장 높아, 예측 성능이 가장 우수한 것으로 나타났다(Fig. 6).




Fig. 6. (a) Mean test RMSE and (b) Mean test R² of the CW prediction models

Fig. 7은 가장 높은 예측 성능을 보인 XGBoost 모델들에서 예측한 CW와 실제 CW를 나타내는 산점도이며, Fig. 8은 XGBoost 모델들에 대한 SHAP 분석을 통해 얻은 Mean absolute SHAP value를 나타낸 그래프이다. Mean absolut SHAP value가 높을수록 모델에서 CW 예측에 중요도가 높은 변수임을 의미한다. 따라서 XGBoost 모델에 대한 SHAP 분석 결과 AR, TQ, TF, CRS, FP, Fn, UCS 순으로 CW 예측에 중요도가 높은 변수로 나타났다.

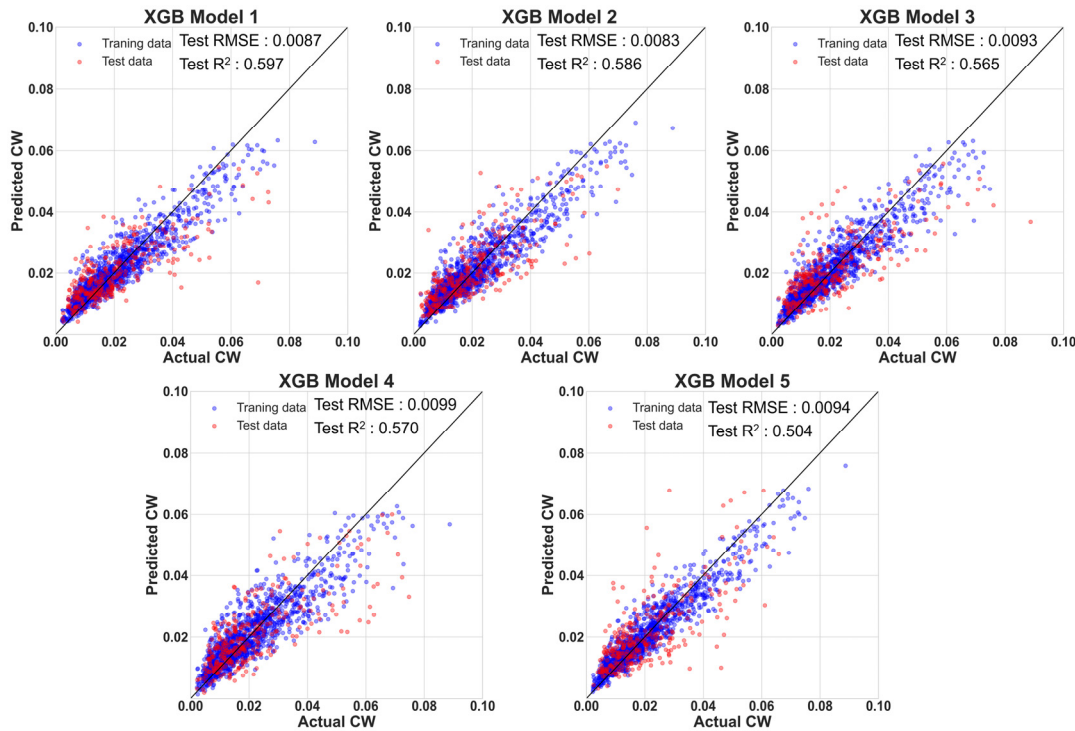


Fig. 7. Plots of XGBoost models




Fig. 8. Mean absolute SHAP values of XGBoost models

5. 결론

본 연구에서는 지반 조건과 TBM 운영 파라미터, 머신러닝 알고리즘을 이용하여 슬러리 TBM의 디스크 커터 마모를 예측하였다. 디스크 커터 마모 예측을 위한 입력변수 중 UCS 데이터의 수가 다른 기계 데이터 및 마모 데이터에 비해 매우 부족하기 때문에,

먼저 기계 데이터를 이용하여 UCS 추정을 진행하였다. UCS 추정을 통해 완성된 전체 데이터 세트를 이용하여 CW 예측을 수행하였으며, 이 과정을 통해 도출한 결론은 다음과 같다.

- 1) UCS 추정을 위해 TF, TQ, AR, FP, CHRS, FPI를 입력변수로 선정하고, 안정상태 추출, MinMaxScaling을 수행하였으며, 6가지 지도학습 기반 머신러닝 알고리즘(KNN, SVM, RF, XGBoost, CatBoost, LGBM)과 TPE 하이퍼파라미터 최적화알고리즘을 이용하여 UCS 추정 모델을 만들고 이들의 평균 성능 평가 지표를 비교하였다. 그 결과 테스트 데이터에 대한 CatBoost 모델들의 평균 RMSE가 12.27로 가장 낮고, 평균 R^2 가 0.85로 가장 높게 나타나 CatBoost 모델들을 사용하여 기계 데이터가 기록된 터널 전체 구간에 대한 UCS를 추정하였다.
- 2) CW 예측을 위해 TF, TQ, AR, FP, Fn, UCS, Weathering grade, CRS를 입력변수로 선정하고, 이상치 제거, MinMaxScaling을 수행하였으며, UCS 추정과 같이 6가지 머신러닝 알고리즘과 TPE 하이퍼파라미터 최적화를 이용하여 CW 예측 모델을 만들고 이들의 평균 예측 성능을 비교하였다. 그 결과 단일 알고리즘들보다 앙상블 알고리즘들의 예측 성능이 높게 나타났으며, XGBoost 모델의 평균 Test RMSE가 0.0091로 가장 낮고, 평균 Test R^2 가 0.564로 가장 높아, 예측 성능이 가장 우수한 것으로 나타났다. 추가적으로 XGBoost 모델들에 대한 SHAP 분석 결과 모델에서 AR, TQ, TF, CRS, FP, Fn, UCS 순으로 변수 중요도가 높은 것으로 나타났다.
- 3) 후속 연구에서는 다양한 TBM 프로젝트 데이터를 추가하고, 시계열 데이터 처리가 가능한 알고리즘을 활용하여 데이터의 변동성을 충분히 고려한다면 디스크 커터 마모 예측 성능과 일반화 성능이 향상될 수 있을 것으로 생각된다.

감사의 글

이 논문은 2024년도 정부(산업통상자원부)의 재원으로 해외자원개발협회의 지원(2021060003, 스마트 마이닝 전문 인력 양성)과 2024년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.NRF-2022R1F1A1063228)

REFERENCES

- Amoun, S., Sharifzadeh, M., Shahriar, K., Rostami, J., and Azali, S.T., 2017, Evaluation of tool wear in EPB tunneling of Tehran Metro, Line 7 Expansion, Tunnelling and Underground Space Technology, 61, 233-246.
- Bergstra, J., Bardenet, R., Bengio, Y., and Kégl, B., 2011, Algorithms for hyper-parameter optimization, Advances in neural information processing systems, 24.
- Bruland, A., 1998, Hard rock tunnel boring : Advance rate and cutter wear. NTNU.
- BS, B., 1999, 5930: 1999 Code of practice for site investigations, British Standard.
- Ding, X., Xie, Y., Xue, H., and Chen, R., 2022, A new approach for developing EPB-TBM disc cutter wear prediction equations in granite stratum using backpropagation neural network, Tunnelling and Underground Space Technology, 128104654.
- Elbaz, K., Shen, S.-L., Zhou, A., Yin, Z.-Y., and Lyu, H.-M., 2020, Data in intelligent approach for estimation of disc cutter life using hybrid metaheuristic algorithm, Data in Brief, 33, 106479.

- Elbaz, K., Shen, S.L., Zhou, A., Yin, Z.Y., and Lyu, H.M., 2021, Prediction of disc cutter life during shield tunneling with AI via the incorporation of a genetic algorithm into a GMDH-type neural network, *Engineering*, 7(2), 238-251.
- Frenzel, C., Käsling, H., and Thuro, K., 2008, Factors influencing disc cutter wear, *Geomechanik und Tunnelbau: Geomechanik und Tunnelbau*, 1(1), 55-60.
- Gehring, K., 1995, Leistungs- und Verschleißprognosen im maschinellen Tunnelbau, *Felsbau*, 13(6), 439-448.
- Kilic, K., Toriya, H., Kosugi, Y., Adachi, T., and Kawamura, Y., 2022, One-Dimensional convolutional neural network for pipe jacking EPB TBM cutter wear prediction, *Applied Sciences*, 12(5), 2410.
- Liu, Q., Liu, J., Pan, Y., Zhang, X., Peng, X., Gong, Q., and Du, L., 2017, A wear rule and cutter life prediction model of a 20-in. TBM cutter for granite: a case study of a water conveyance tunnel in China, *Rock Mechanics and Rock Engineering*, 50, 1303-1320.
- Loy-Benitez, J., Lee, H.K., Song, M.K., Choi, Y., and Lee, S.S., 2024, Transfer component analysis-driven domain adaptation approach for estimating the life of tunnel boring machine disc cutters, *Tunnelling and Underground Space Technology*, 147, 105714.
- Lundberg, S.M. and Lee, S.I., 2017, A unified approach to interpreting model predictions, *Advances in neural information processing systems*, 30.
- Mahmoodzadeh, A., Mohammadi, M., Ibrahim, H.H., Abdulhamid, S.N., Ali, H.F.H., Hasan, A.M., Khishe, M., and Mahmud, H., 2021, Machine learning forecasting models of disc cutters life of tunnel boring machine, *Automation in Construction*, 128, 103779.
- Rostami, J. and Ozdemir, L., 1993, A new model for performance prediction of hard rock TBMs. In: *Proceedings of the rapid excavation and tunneling conference*.
- Su, W., Li, X., Jin, D., Yang, Y., Qin, R., and Wang, X., 2020, Analysis and prediction of TBM disc cutter wear when tunneling in hard rock strata: a case study of a metro tunnel excavation in Shenzhen, China, *Wear*, 446, 203190.
- Wang, L., Li, H., Zhao, X., and Zhang, Q., 2017, Development of a prediction model for the wear evolution of disc cutters on rock TBM cutterhead, *Tunnelling and Underground Space Technology*, 67, 147-157.
- Xu, D., Wang, Y., Huang, J., Liu, S., Xu, S., and Zhou, K., 2023, Prediction of geology condition for slurry pressure balanced shield tunnel with super-large diameter by machine learning algorithms, *Tunnelling and Underground Space Technology*, 131, 104852.
- Yu, H., Tao, J., Qin, C., Xiao, D., Sun, H., and Liu, C., 2021, Rock mass type prediction for tunnel boring machine using a novel semi-supervised method, *Measurement*, 179, 109545.