

의사결정나무 기반 회귀분석과 SVM 회귀분석을 이용한 커터 관입깊이에 따른 최적 커터간격 비 연구

이기준^{1*} · 류희환² · 권태혁³

¹정회원, 한국과학기술원 건설및환경공학과 박사과정

²정회원, 한국전력연구원 선임연구원

³정회원, 한국과학기술원 건설및환경공학과 부교수

A study on the optimum cutter spacing ratio according to penetration depth using decision tree-based and SVM regressions

Gi-Jun Lee^{1*} · Hee-Hwan Ryu² · Tae-Hyuk Kwon³

¹Ph.D. Student, Dept. of Civil and Environmental Engineering, Korea Advanced Institute of Science and Technology (KAIST)

²Senior Researcher, Korea Electric Power Research Institute (KEPRI)

³Associate Professor, Dept. of Civil and Environmental Engineering, Korea Advanced Institute of Science and Technology (KAIST)

*Corresponding Author : Gi-Jun Lee, gijun@kaist.ac.kr

Abstract

Cutter cutting tests for the cutter placement in the cutter head are being conducted through various studies. Although the cutter spacing at the minimum specific energy is mainly reflected in the cutter head design, since the optimum cutter spacing at the same cutter penetration depth varies depending on the rock conditions, studies on deciding the optimum cutter spacing should be actively conducted. The machine learning techniques such as the decision tree-based regression model and the SVM regression model were applied to predict the optimum cutter spacing ratio for the nonlinear relationship between cutter penetration depth and cutter spacing. Since the decision tree-based methods are greatly influenced by the number of data, SVM regression predicted optimum cutter spacing ratio according to the penetration depth more accurately and it is judged that the SVM regression will be effectively used to decide the cutter spacing when designing the cutter head if a large amount of data of the optimum cutter spacing ratio according to the penetration depth is accumulated.

Keywords: TBM, Cutter spacing, Machine learning, Random forest, SVM

OPEN ACCESS

Journal of Korean Tunnelling and
Underground Space Association
22(5)501-513(2020)
<https://doi.org/10.9711/KTAJ.2020.22.5.501>

eISSN: 2287-4747

pISSN: 2233-8292

Received July 17, 2020

Revised August 31, 2020

Accepted August 31, 2020



This is an Open Access article distributed under the terms of the Creative Commons Attribution

Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Copyright © 2020, Korean Tunnelling and Underground Space Association

www.kci.go.kr

초 록

TBM 터널굴착에서 실질적으로 지반을 굴착하는 역할을 하는 부분인 커터헤드 설계 시, 커터 관입깊이와 커터 간격을 달리하여 커터절삭 시험 시 최소 비에너지에서의 커터간격을 반영하고 있으나, 암반 조건에 따라서 동일한 커터 관입깊이에서의 최적 커터간격이 달라지기 때문에 최적 커터간격을 설정하는 연구가 활발히 진행되어야 한다. 이러한 비선형적인 커터 관입깊이와 커터 간격의 관계에서 커터 관입깊이에 따른 최적 커터간격을 예측하기 위해 머신러닝 기법인 의사결정나무 기반 랜덤 포레스트 회귀 모델과 SVM 회귀모델을 이용하여 커터 관입깊이에 따른 최적 커터 간격을 예측하였다. 랜덤 포레스트 분석기법은 SVM 분석기법보다 데이터 개수에 더 큰 영향을 받기 때문에 커터 관입깊이에 따른 최적 커터간격비의 예측에 SVM이 더 정확한 예측을 하였다. 데이터가 많이 축적되면 SVM 회귀모델이 보다 더 정확한 예측값으로 커터헤드 설계 시 커터간격을 설정하는데 효율적으로 사용될 수 있을 것으로 판단된다.

주요어: TBM, 커터간격, 머신러닝, 랜덤 포레스트, SVM

1. 서론

터널시공에 따른 TBM 수요와 그에 따른 생산량은 2013년부터 2018년까지 꾸준한 상승세를 보이고 있다 (QYResearch, 2013). TBM은 터널시공에서 주된 역할을 하고 있으며 TBM의 성능을 높이기 위해 현장 지반조건에 더욱 적합하도록 맞춤 설계 및 제작을 하고 있다. 터널굴착에서 실질적으로 지반을 굴착해내는 역할을 하는 부분인 커터헤드는 지반굴착에 직접적으로 영향을 끼치는 여러 가지 부품과 배열의 조합으로 설계되기 때문에 TBM 설계 중에서 가장 중요한 부분이다(Rostami and Ozdemir, 1993; Acaroglu et al., 2008; Cho et al., 2010; Lee et al., 2017). 지반굴착 시 주로 경암과 극경암 지역, 그리고 이러한 암뿐만 아니라 다른 매질과 함께 복합적으로 있는 복합지반에서 장비의 다운타임 등 TBM 굴진에 상대적으로 많은 어려움이 발생되고 있다. 따라서 이러한 지반조건에서 최적의 TBM 굴진을 하기 위한 커터배치에 관한 연구가 수행되어 왔다(Huo et al., 2011; Kim et al., 2012; Bae et al., 2014; Rostami and Chang, 2017; Tao et al., 2017). 효과적인 커터배치를 위해서 커터의 선형 절삭 시험을 통해 커터간격에 따른 절삭 시 소요되는 비에너지를 확인하는 연구가 수행되었고(Chang et al., 2006; Gertsch et al., 2007; Jeong et al., 2011; Ma et al., 2016; Tan et al., 2018), 커터헤드가 원형인 점을 고려하여 커터 개수를 늘여가며 로타리 절삭 시험을 통해 커터간격에 따른 절삭 시 소요되는 최소 비에너지를 찾는 연구가 수행되어왔다(Xia et al., 2012; Pan et al., 2018; Peng et al., 2018). 근래에는 커터헤드 전체를 사용하여 커터헤드의 커터에 의한 절삭시험을 할 수 있는 장비가 개발되어 커터절삭시험이 수행되었다(Geng et al., 2016). 이러한 여러 커터 절삭 시험을 통해 최소 비에너지에서의 커터관입깊이와 커터간격비를 확인 할 수 있으나, 모든 연구가 동일 조건 암반시료에 대해 수행된 것이 아니기 때문에 같은 커터관입깊이와 간격비에서 연구별로 최소 비에너지가 다르며, 관입깊이에 따라 최소비에너지의 커터 간격이 달라지기 때문에 TBM 굴진을 해나가면서 최적의 커터 간격이 달라지게 된다. 커터의 배치는 굴진 중에 바꿀 수 있는 사항이 아니기 때문에 효율적인 커터헤드

설계를 위한 커터의 배치는 어떤 지반에서 TBM을 굴진 시킬 것인지, TBM 굴진거리에서 어떤 조건의 매질이 가장 많이 분포하고 있는지를 고려하고 굴진조건에 대해 가장 효율적인 굴진을 할 수 있는 커터배치를 하여야 한다.

동일한 커터 관입깊이어도 암반조건에 따라서 최소 비에너지가 발생하는 커터 간격이 달라질 수 있기 때문에 커터 관입깊이에 따른 최적 커터 간격을 선형회귀로 예측하기 어렵다. 따라서 여러 절삭시험 연구 결과들을 이용해서 머신러닝 기법 중 의사결정나무기반인 랜덤 포레스트와 서포트 벡터 머신을 이용한 회귀모델을 통해 관입 깊이에 따른 최적 커터간격비를 예측해보았다. 의사결정나무기반인 랜덤 포레스트와 서포트 벡터 머신은 대표적인 머신러닝 기법으로써, 두 가지 기법에 의한 결과 비교를 하는 많은 연구가 수행되어 왔다(Larios et al., 2010; Naghibi et al., 2017; Raczko and Zagajewski, 2017; Thanh Noi and Kappas, 2018; Murugan et al., 2019; Aroef et al., 2020).

2. 비에너지

암반 굴착 시 비에너지의 개념적용은 Teale (1965)의 논문에 처음 제시되었으며(Bieniawski et al., 2012), 비에너지는 아래의 식과 같이 산정된다.

$$E = \frac{F}{A} + \frac{2\pi \cdot \omega \cdot T}{A \cdot u} \quad (1)$$

F는 전체 추력이고 A는 굴착되는 면적, ω 는 회전속도로 TBM에서 커터헤드의 회전속도를 나타낸다. T는 토크이며 u는 시간당 굴진거리를 의미한다. 지금까지 Teale의 식이 가장 정확성이 높아 Teale의 비에너지 식이 주로 사용되고 있다(Bieniawski et al., 2012). Teale의 비에너지 식은 추력에 관한 항(F/A)과 드릴 또는 커터로 직접 절삭하는 항($2\pi \cdot \omega \cdot T/A \cdot u$), 두 가지로 이루어져 있다. 이 때 ω/u 는 커터헤드의 1회전 당 관입깊이(P)로 나타낼 수 있기 때문에 최종적으로 비에너지는 아래의 식으로 나타낼 수 있다.

$$E = \frac{F}{A} + \frac{2\pi \cdot T}{A \cdot P} \quad (2)$$

실내시험에서는 커터가 주가 되기 때문에, 실내시험에서는 많은 연구자들이 직접 절삭에 관련된 항만 고려하여 아래의 식과 같이 커터에 절삭 되는 매질의 단위부피당 소요에너지로 비에너지를 산정하고 있다(Acaroglu et al., 2008; Cho et al., 2010; Jeong et al., 2011; Cho et al., 2013; Tan et al., 2018).

$$SE(kWh/m^3, MJ/m^3) = \frac{F_R \cdot R \cdot t}{V} = \frac{F_R}{A} \quad (3)$$

F_R 은 커터가 진행되는 방향의 힘이며 R 은 절삭 속도, t 는 절삭 시간, V 는 절삭되는 매질의 부피, A 는 절삭되는 수직 단면적을 의미한다. 대부분, 암반 절삭에서 비에너지가 최소가 되는 점에서의 커터 간격과 커터 관입깊이의 비를 통해 커터간격을 정하고 있다. 본 논문에서는 각 경우에서의 최소 비에너지를 최적 비에너지(Optimum specific energy)라고 나타내었다(Fig. 1).




Fig. 1. Concept graph to understand specific energy with ratio of cutter spacing to cutter penetration depth

3. 머신러닝기법을 이용한 회귀분석모델

3.1 의사결정나무(Decision Tree) 회귀분석

의사결정나무 학습법(Decision tree learning)은 데이터를 각 질문에 따라 차례차례 분류하는 기법이다(Fig. 2). 의사결정나무 학습에서 각 노드에서 분기되어 최종 노드까지 데이터를 분류하게 되며 분기의 깊이(depth)설정값에 따라 2가지 또는 n 가지의 단계로 데이터를 분류하게 된다. 이 때, 각 노드에서 분기를 하는 방법은 부모노드에서 정보획득량(Information gain)이 가장 큰 독립 변수와 기준값을 찾아서 자식 노드로 분류하게 된다. 정보획득량은 아래 식과 같이 나타낼 수 있다.

$$IG(D_p, f) = I(D_p) - \sum_{j=1}^n \frac{N_j}{N_p} I(D_j) \quad (4)$$

위의 식에서 D_p 는 부모노드(Parents node)에 존재하는 데이터 세트, D_j 는 j 번째 자식노드(Child node)의 데이터 세트, f 는 분기에 따른 특성값, $I(D_p)$ 는 D_p 데이터의 불순도(Impurity), N_p 는 D_p 의 데이터 개수, N_j 는 D_j 의 데이터 개수, $I(D_j)$ 는 D_j 의 불순도를 의미한다. 불순도는 분류된 데이터에 잘못 분류된 데이터가 얼마나 섞여 있는지를

나타낸다. 본 연구에서 일반 분류와 달리 회귀분석을 수행하기 위해 평균 제곱 오차 Mean square error (MSE)로 불순도를 계산하였다.

$$MSE = \frac{1}{N} \sum_{j=1}^n (y_j - \hat{y}_j)^2 \tag{5}$$

위의 식 (5)에서 y_j 는 측정값, \hat{y}_j 는 예측값을 나타낸다.

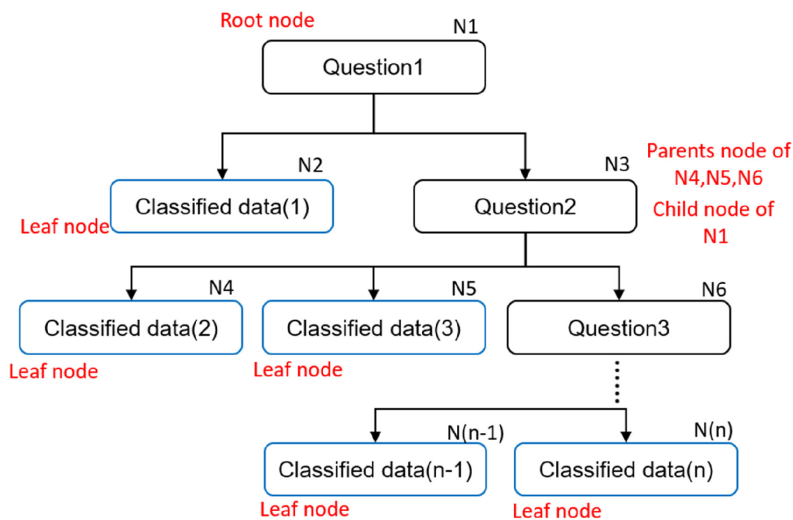


Fig. 2. Concept diagram of decision tree

3.2 랜덤 포레스트(Random Forest) 회귀분석

랜덤 포레스트(Random forest) 알고리즘은 주어진 데이터 세트에서 무작위로 n 개의 데이터를 샘플링해서 여러 개의 의사결정나무를 만든 후 각각의 의사결정나무의 예측결과를 토대로 다수결에 의해 최종 예측을 결정하는 방식이다(Fig. 3). 따라서 랜덤 포레스트는 분류뿐만 아니라 회귀분석에 적합한 알고리즘을 가지고 있다. 랜덤 포레스트에서 생성되는 의사결정나무가 많을수록 다수결에 의한 예측 결과의 품질이 높아지게 된다. 하지만, 생성되는 의사결정나무가 많을수록 분석에 필요한 공간이 더 늘어나게 되며 분석을 수행하는 장비의 더 높은 성능이 요구된다. 본 연구에서는 1,000개의 의사 결정나무를 생성하여 분석하였다. 의사결정나무와 마찬가지로 회귀분석을 위해 정보획득량의 불순도를 MSE를 사용하여 계산하였다.

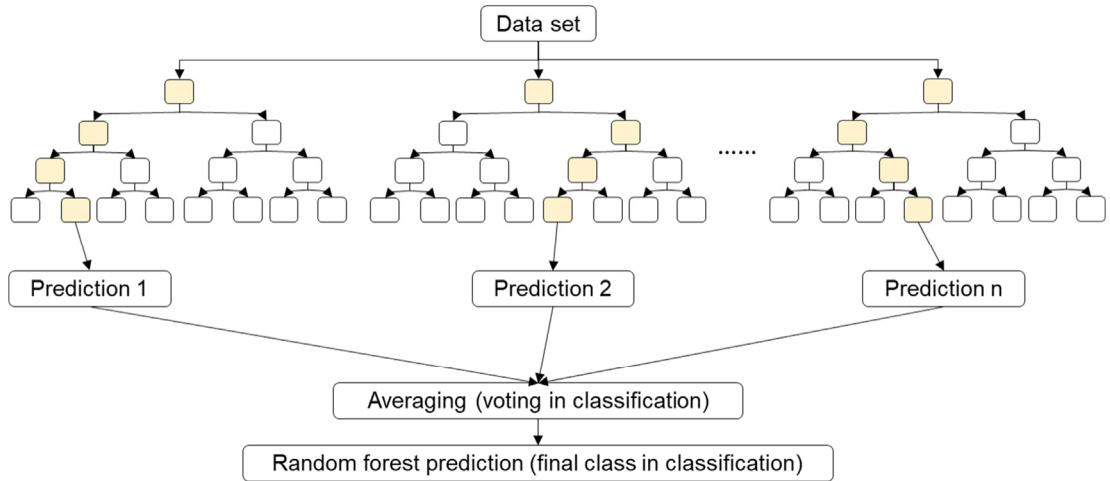


Fig. 3. Concept diagram of random forest

3.3 서포트 벡터 머신(Support Vector Machine, SVM) 회귀분석

서포트 벡터 머신(SVM)은 2차원에서 구분이 힘든 데이터를 유한 차원 공간에서 초평면(Hyperplane)을 통해 데이터를 분류할 수 있는 알고리즘이다. 주어진 데이터에서 분류하고자 하는 데이터 사이의 간격이 최대가 되는 Margin을 갖는 초평면을 통해 데이터를 정확하게 구분하여 예측할 수 있다(Fig. 4). 이 때, Margin의 경계선에 걸쳐 있는 값들을 서포트 벡터(Support vector)라고 하며 서포트 벡터에 의해 Margin값이 달라지게 된다. SVM 기법은 데이터를 선형으로 분류할 수 없는 경우에도 커널 함수를 사용해서 비선형으로 데이터를 분류할 수 있다(La et al., 2019). 본 연구에서는 두 개의 벡터 x_i, x_j 벡터를 매개로한 비선형 커널함수인 아래의 가우시안 방사 기저함수인 Radial basis function (RBF) 커널을 사용해서 SVM 회귀분석을 수행하였다.

$$k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (6)$$

위의 식에서 γ 는 하이퍼파라미터로 데이터 경계면을 결정하는데 영향을 끼치는 인자다. γ 값에 따라 가우시안 함수에서 그래프의 곡률이 달라진다. γ 값이 클수록 하나의 데이터가 영향력을 행사하는 범위가 넓은 폭이 큰 그래프를 띄게 되며 γ 값이 작을수록 폭이 좁은 그래프를 띄게 된다. 본 회귀모델에서 사용되는 데이터의 수가 18개임을 고려하여 데이터가 다른 클래스에 속하는 것을 허용하는 정도인 Cost (C)값을 100으로 설정하고 특성개수의 역수인 1로 γ 를 설정하였다.

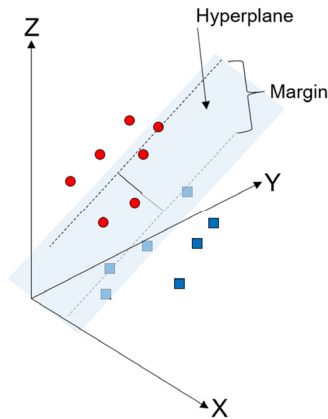


Fig. 4. Concept of data classification by SVM

4. 자료수집

커터절삭시험의 데이터를 토대로 관입깊이에 따른 최적 커터간격비를 제시하기 위해 Chang et al. (2006)의 12개의 선형절삭시험 결과, Cho et al. (2010)의 42개의 선형절삭시험 결과, Jeong et al. (2011)의 17개의 선형절삭시험 결과, Tan et al. (2018)의 16개의 선형절삭시험 결과, 그리고 Lee and Choi (2013)의 6개의 수치해석 결과 총 93개의 결과를 이용하였다. 각 연구에서의 최소비에너지를 구하고 최소비에너지에서의 커터간격과 커터관입깊이의 비를 분석하였다. 각 연구에서 사용한 암의 조건은 Table 1과 같다.

Table 1. Information for linear cutting machine (LCM) tests

Reference	Rock type	Rock properties		Diameter of disc cutter (in)
		Unconfined compressive strength, UCS (MPa)	Brazilian tensile strength, BTS (MPa)	
Chang et al. (2006)	Hwangdeung granite	183	9.8	17
Cho et al. (2010)	Macheon granite	108	10.4	17
Cho et al. (2010)	Hudong granite	91	12.3	17
Cho et al. (2010)	Sungnam gneiss	92	15.2	17
Cho et al. (2010)	Paldang gneiss	124	13.8	17
Cho et al. (2010)	Yeongwol limestone	64	8.9	17
Cho et al. (2010)	Busan granite	36	4.7	17
Cho et al. (2010)	Busan tuff	115	25.2	17
Jeong et al. (2011)	Unknown (vertical joint)	241	13.4	Unknown
Jeong et al. (2011)	Unknown (parallel joint)	186	10.7	Unknown
Tan et al. (2018)	Marble	24.92	4.72	17
Lee and Choi (2013)	Busan tuff (simulation)	111 ± 10	29.9 ± 5	400 (mm)

5. 결과 및 논의

선형절삭 시험을 통해 커터 관입깊이(Penetration depth, P)를 고정시키고 커터 간격(Spacing, S)을 바꾸면서 찾은 최소 비에너지에서의 적정 커터 간격과 커터 관입깊이 의 비, S/P를 분석하였다(Table 2).

Table 2. Optimum ratio of cutter spacing to penetration depth

P (mm)	S (mm)	S/P	Optimum specific energy (MJ/m ³)	Reference
2	20	10	6.8	Tan et al. (2018)
3	20	6.7	19.4	Tan et al. (2018)
4	60	15	14.6	Tan et al. (2018)
6	40	6.7	25	Tan et al. (2018)
2	30	15	4.9	Chang et al. (2006)
4	60	10	24.5	Chang et al. (2006)
6	60	10	15.7	Chang et al. (2006)
4	48	12	14.31	Lee and Choi (2013)
5.6	40	10	39.4	Cho et al. (2010)
6	48	8	41.6	Cho et al. (2010)
6.4	48	7.5	50.0	Cho et al. (2010)
6.9	60	8.8	29.2	Cho et al. (2010)
7.3	72	9.9	32.2	Cho et al. (2010)
7.7	72	9.3	15.5	Cho et al. (2010)
8.1	60	7.4	26.7	Cho et al. (2010)
8.6	60	7	42.2	Jeong et al. (2011)
9	60	6.7	38.7	Jeong et al. (2011)
9.4	80	8.5	33.8	Jeong et al. (2011)

5.1 최소 비에너지에서의 커터 관입깊이와 커터 간격 비

각각의 암반상태가 동일하지 않기 때문에 같은 관입깊이에서 최소 비에너지가 발생하는 커터 간격이 다르게 나타났다. 관입깊이가 클수록 최소비에너지가 발생하는 커터간격은 전체적으로 증가하는 경향성이 약하게 나타났다. 하지만, 관입깊이가 클수록 커터 관입깊이와 커터간격의 비는 전체적으로 감소하는 경향을 보였으며 이는 커터 관입깊이의 증가량보다 커터 간격의 증가량이 상대적으로 작기 때문이다(Fig. 5).




Fig. 5. Regression analysis results: (a) Linear (b) Decision tree, (c) Random forest, and (d) SVM regression models

5.2 머신러닝 회귀분석 모델

커터 관입깊이에 따른 최소비에너지가 발생하는 최적 커터간격의 데이터 18개에 대하여 커터 관입깊이를 입력변수로 한 회귀분석결과, 선형회귀의 결정계수 $R^2 = 0.33$ 보다 의사결정나무, 랜덤포레스트, SVM의 회귀모델 결정계수가 각각 0.67, 0.67, 0.61로 더 높게 나타났다(Fig. 5). 의사결정나무와 랜덤 포레스트 회귀분석 결과 결정계수가 0.67로 동일하게 나왔으나, 최적 S/P의 범위가 상대적으로 좁은 커터 관입깊이가 6 mm 보다 큰 경우에서 의사결정나무, 랜덤 포레스트, SVM 회귀모델의 MSE는 각각 0.15, 0.08, 0.01로서 랜덤 포레스트 회귀모델과 SVM 회귀모델이 의사결정나무 회귀모델보다 실제 측정값과 잘 맞는 것을 확인 할 수 있었다. 랜덤 포레스트는 의사결정나무를 기반으로 한 여러개의 의사결정나무의 예측결과에 대해 다수결에 따라 최종 예측값을 결정하기 때문에 의사결정나무 회귀모델보다 더욱 정확한 예측값을 도출해 낼 수 있다(Esmaily et al., 2018). 따라서 데이터 개수가 증가함에 따라 랜덤 포레스트 회귀모델의 결정계수값이 의사결정나무 회귀모델의 결정계수보다 조금

더 증가할 것으로 예상된다. 랜덤 포레스트 회귀모델과 SVM 회귀모델에 대하여 전체 18개의 관입깊이와 최적 S/P 데이터 중, Jeong et al. (2011)의 3개 데이터(17%)를 제외한 15개의 데이터(83%)를 훈련 데이터로 사용하고 Jeong et al. (2011)의 새로운 커터 관입깊이에 대한 최적 S/P를 예측한 결과, SVM 회귀모델이 72%의 정확도로 랜덤 포레스트 회귀모델보다 높은 정확도의 예측결과를 보였다(Fig. 6). 현 연구결과에서 일반적인 결론을 이끌어기에는 데이터 수와 케이스가 부족하다. 하지만 현재 머신러닝 연구분야의 일반적으로 알려진 결과들을 바탕으로 추정해보면, 랜덤 포레스트 기법은 집단 학습을 통해 데이터를 분류하고 예측하기 때문에 데이터 수에 타 머신러닝 기법보다 상대적으로 민감하다(Ali et al., 2012). 따라서 유한차원에서 비선형으로 데이터를 분류하는 SVM기법이 18개의 적은 데이터 개수에서 랜덤 포레스트 회귀모델보다 새로운 조건에 대한 값을 예측하는데 효율적이다.

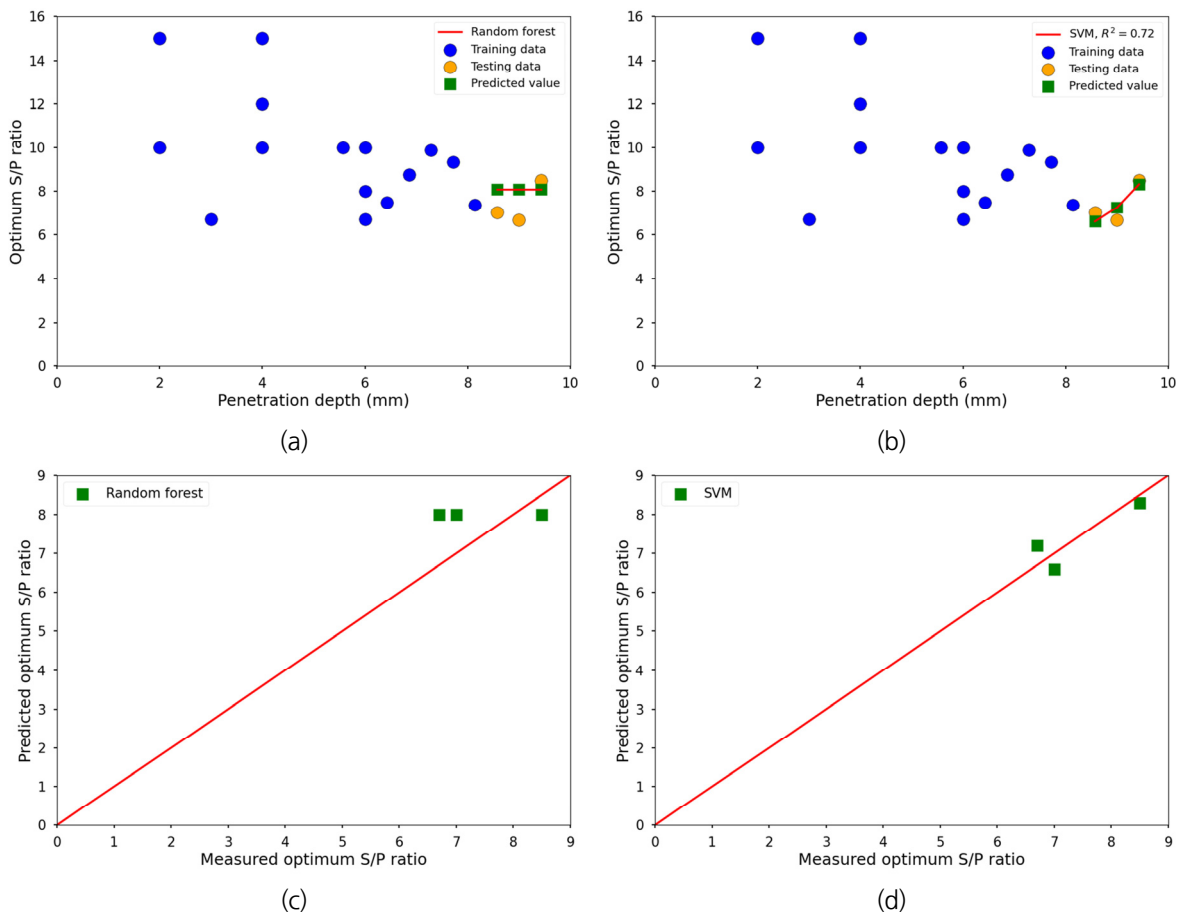


Fig. 6. Random forest and SVM regressions for predicted optimum S/P with penetration depth by training data: (a) Random forest regression, (b) SVM regression, (c) Relationship between measured optimum S/P ratio and predicted optimum S/P ratio by random forest regression model, and (d) Relationship between measured optimum S/P ratio and predicted optimum S/P ratio by SVM regression model

본 연구에서 훈련된 모델들의 경우, 관입깊이와 최적 S/P간의 물리적 관계를 고려하지 않고 있음을 유의해야 한다. 이는 훈련 데이터 수가 많아질 경우, 보완될 것으로 예상된다.

6. 결론

커터 관입깊이에 따라 굴착 시 최소 비에너지가 발생하는 최적 커터 간격은 암반의 일축압축강도와 절리 및 조건에 따라 달라질 수 있다. 따라서 동일한 커터 관입깊이에서 최적 커터 간격이 현장조건에 따라 달라질 수 있기 때문에 선형 회귀분석으로 커터 관입깊이에 따른 최적 커터간격 비를 예측하기 어렵다. 머신러닝 기법 중 데이터 분류뿐만 아니라 회귀모델로도 사용가능한 의사결정나무기반의 회귀분석과 SVM 회귀분석을 사용하여 새로운 커터관입깊이에 대한 최적 커터간격비를 예측할 수 있었다. 커터관입깊이에 따른 최적 커터간격비의 데이터 축적을 통해 위의 머신러닝 기법들을 사용할 경우, 더욱 정확한 커터관입깊이에 따른 최적 커터간격비를 예측할 수 있을 것으로 판단된다. 또한, 동일 추력에서 암반의 조건에 따라 관입깊이가 달라질 수 있지만 커터간격은 커터헤드를 교체하지 않는 이상 변경하기가 어려운 값이기 때문에 암반조건에서의 굴진성능을 고려한 전반적인 커터 관입깊이에 따른 커터헤드 설계 시, 커터간격을 설정하는데 SVM 회귀모델이 효율적으로 사용될 수 있을 것으로 판단된다. 뿐만 아니라, SVM 회귀모델은 특정한 커터간격으로 이미 제작된 커터헤드가 어떤 지반에서 효율적으로 사용될 수 있을지 역으로 사용될 수 있을 것으로 판단된다.

감사의 글

본 연구는 과학기술정보통신부의 재원으로 시행하는 한국연구재단의 원자력기술개발사업(과제번호: NRF-2020 M2C9A1062949)과 한국전력공사 자체연구개발 과제(R18SA04)의 지원을 통해 수행되었습니다. 연구지원에 감사드립니다.

저자 기여도

이기준은 데이터 수집, 해석 및 분석과 원고작성을 하였고, 류희환은 연구 개념 및 설계를 하였고, 권태혁은 원고 검토를 하였다.

References

1. Acaroglu, O., Ozdemir, L., Asbury, B. (2008), "A fuzzy logic model to predict specific energy requirement for TBM performance prediction", *Tunnelling and Underground Space Technology*, Vol. 23, No. 5, pp. 600-608.
2. Ali, J., Khan, R., Ahmad, N., Maqsood, I. (2012), "Random forests and decision trees", *International*

Journal of Computer Science Issues (IJCSI), Vol. 9, No. 5, pp. 272-278.

3. Aroef, C., Rivan, Y., Rustam, Z. (2020), "Comparing random forest and support vector machines for breast cancer classification", *Telkomnika*, Vol. 18, No. 2, pp. 815-821.
4. Bae, G.J., Chang, S.H., Park, Y.T., Choi, S.W., Lee, G.P., Kwon, J.Y., Han, K.T. (2014), "Manufacturing of an earth pressure balanced shield TBM cutterhead for a subsea discharge tunnel and its field performance analysis", *Journal of Korean Tunnelling and Underground Space Association*, Vol. 16, No. 2, pp. 161-172.
5. Bieniawski, R.Z.T., Celada, B., Tardaguila, I., Rodrigues, A. (2012), "Specific energy of excavation in detecting tunnelling conditions ahead of TBMs", *Tunnels and Tunnelling International*, February 1, pp. 65-68.
6. Chang, S.H., Choi, S.W., Bae, G.J., Jeon, S. (2006), "Performance prediction of TBM disc cutting on granitic rock by the linear cutting test", *Tunnelling and Underground Space Technology*, Vol. 21, No. 3, pp. 271-277.
7. Cho, J.W., Jeon, S., Jeong, H.Y., Chang, S.H. (2013), "Evaluation of cutting efficiency during TBM disc cutter excavation within a Korean granitic rock using linear-cutting-machine testing and photogrammetric measurement", *Tunnelling and Underground Space Technology*, Vol. 35, pp. 37-54.
8. Cho, J.W., Jeon, S., Yu, S.H., Chang, S.H. (2010), "Optimum spacing of TBM disc cutters: A numerical simulation using the three-dimensional dynamic fracturing method", *Tunnelling and Underground Space Technology*, Vol. 25, No. 3, pp. 230-244.
9. Esmaily, H., Tayefi, M., Doosti, H., Ghayour-Mobarhan, M., Nezami, H., Amirabadizadeh, A. (2018), "A comparison between decision tree and random forest in determining the risk factors associated with type 2 diabetes", *Journal of Research in Health Sciences*, Vol. 18, No. 2, pp. 412-418.
10. Geng, Q., Wei, Z., Meng, H., Macias, F.J. (2016), "Mechanical performance of TBM cutterhead in mixed rock ground conditions", *Tunnelling and Underground Space Technology*, Vol. 57, pp. 76-84.
11. Gertsch, R., Gertsch, L., Rostami, J. (2007), "Disc cutting tests in Colorado Red Granite: Implications for TBM performance prediction", *International Journal of Rock Mechanics and Mining Sciences*, Vol. 44, No. 2, pp. 238-246.
12. Huo, J., Sun, W., Chen, J., Zhang, X. (2011), "Disc cutters plane layout design of the full-face rock tunnel boring machine (TBM) based on different layout patterns", *Computers and Industrial Engineering*, Vol. 61, No. 4, pp. 1209-1225.
13. Jeong, H.Y., Jeon, S.W., Cho, J.W., Chang, S.H., Bae, G.J. (2011), "Assessment of cutting performance of a TBM disc cutter for anisotropic rock by linear cutting test", *Tunnel and Underground Space*, Vol. 21, No. 6, pp. 508-517.
14. Kim, S.H., Kim, J.T., Lim, C.H. (2012), "A study on the arrangement design of Shield-TBM cutter bit", *Journal of the Korean Geotechnical Society*, Vol. 28, No. 5, pp. 67-76.
15. La, Y.S., Kim, M.I., Kim, B. (2019), "Prediction of replacement period of shield TBM disc cutter using SVM", *Journal of Korean Tunnelling and Underground Space Association*, Vol. 21, No. 5, pp. 641-656.
16. Larios, N., Soran, B., Shapiro, L.G., Martínez-Muñoz, G., Lin, J., Dietterich, T.G. (2010), "Haar random forest features and SVM spatial matching kernel for stonefly species identification", *Proceedings of the 2010 20th International Conference on Pattern Recognition, IEEE, Istanbul*, pp. 2624-2627.

17. Lee, G.J., Kwon, T.H., Kim, K.Y., Song, K.I. (2017), "Relationship between brittleness index of hard rocks and TBM penetration rates", *Journal of Korean Tunnelling and Underground Space Association*, Vol. 19, No. 4, pp. 611-634.
18. Lee, S.J., Choi, S.O. (2013), "Three dimensional numerical analysis on rock cutting behavior of disc cutter using particle flow code", *Tunnel and Underground Space*, Vol. 23, No. 1, pp. 54-65.
19. Ma, H., Gong, Q., Wang, J., Yin, L., Zhao, X. (2016), "Study on the influence of confining stress on TBM performance in granite rock by linear cutting test", *Tunnelling and Underground Space Technology*, Vol. 57, pp. 145-150.
20. Murugan, A., Nair, S.A.H., Sanal Kumar, K.P. (2019), "Detection of skin cancer using SVM, Random Forest and kNN classifiers", *Journal of Medical Systems*, Vol. 43, No. 8, pp. 269-277.
21. Naghibi, S.A., Ahmadi, K., Daneshi, A. (2017), "Application of support vector machine, random forest, and genetic algorithm optimized random forest models in groundwater potential mapping", *Water Resources Management*, Vol. 31, No. 9, pp. 2761-2775.
22. Pan, Y., Liu, Q., Peng, X., Kong, X., Liu, J., Zhang, X. (2018), "Full-scale rotary cutting test to study the influence of disc cutter installment radius on rock cutting forces", *Rock Mechanics and Rock Engineering*, Vol. 51, No. 7, pp. 2223-2236.
23. Peng, X., Liu, Q., Pan, Y., Lei, G., Wei, L., Luo, C. (2018), "Study on the influence of different control modes on TBM disc cutter performance by rotary cutting tests", *Rock Mechanics and Rock Engineering*, Vol. 51, No. 3, pp. 961-967.
24. QYResearch (2013), Deep research report on global and China tunnel boring machine industry.
25. Raczko, E., Zagajewski, B. (2017), "Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images", *European Journal of Remote Sensing*, Vol. 50, No. 1, pp. 144-154.
26. Rostami, J., Chang, S.H. (2017), "A closer look at the design of cutterheads for hard rock tunnel-boring machines", *Engineering*, Vol. 3, No. 6, pp. 892-904.
27. Rostami, J., Ozdemir, L. (1993), "A new model for performance prediction of hard rock TBMs", *Proceedings of the Rapid Excavation and Tunneling Conference*, Boston, pp. 793-809.
28. Tan, Q., Yi, L., Xia, Y.M. (2018), "Performance prediction of TBM disc cutting on marble rock under different load cases", *KSCE Journal of Civil Engineering*, Vol. 22, No. 4, pp. 1466-1472.
29. Tao, Y., Yu, H., Yang, W.L., Xi, H.B., Wang, J.B. (2017), "Cutter layout design for tunnel boring machine (TBM) using fuzzy collaborative optimization model", *Proceedings of the 2017 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, IEEE, pp. 1315-1320.
30. Teale, R. (1965), "The concept of specific energy in rock drilling", *International Journal of Rock Mechanics and Mining Sciences and Geomechanics Abstracts*, Vol. 2, No. 1, pp. 57-73.
31. Thanh Noi, P., Kappas, M. (2018), "Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery", *Sensors*, Vol. 18, No. 1, pp. 18-37.
32. Xia, Y.M., Ouyang, T., Zhang, X.M., Luo, D.Z. (2012), "Mechanical model of breaking rock and force characteristic of disc cutter", *Journal of Central South University*, Vol. 19, No. 7, pp. 1846-1852.