

유틸리티 터널 기술위원회

KTA-Annual Technical Report

국내외 TBM 굴진을 모델 분석

2016. 12.



사단
법인 **한국터널지하공간학회**
Korean Tunnelling and Underground Space Association

■ 목 차 ■

1. 국·내외 TBM 굴진율 모델 조사.....	1
1.1 국내외 TBM 굴진율 예측기법의 종류.....	1
1.2 적용된 TBM 굴진율 예측기법 비교.....	6
1.3 TBM 굴진율 예측 분류체계.....	8
1.4 TBM 굴진율 모델에 사용된 입력 및 출력인자 분석.....	10
1.5 국내 TBM 굴진율 예측모델 현황.....	13
2. TBM 출력인자 선정을 위한 통계적 분석.....	17
2.1 입력인자와 출력인자 간 단순회귀분석.....	17
2.2 Cross validation을 적용한 출력인자 분석.....	20
3. 결론.....	21
참고문헌.....	22

■ 표 목 차 ■

Table.

<1.1> TBM 예측모델에 적용된 다양한 예측 기법.....	4
<1.2> 적용된 최적화 기법의 특징요약.....	5
<1.3> 개발된 모델의 성능.....	6
<1.4> 예측 및 측정된 PR과의 비교.....	7
<1.5> TBM 굴진율과 관련된 용어정리.....	10
<1.6> 각 모델에 대한 종합 정리.....	14
<1.7> 입력인자 적용빈도.....	16
<1.8> 적용된 터널 현장.....	16
<2.1> 단순회귀분석 결과 요약.....	18
<2.2> 피어슨 상관계수 매트릭스.....	19
<2.3> 출력인자에 대한 표준화된 최적 모델 요약.....	21

■ 그림 목 차 ■

Figure.

[1.1] 신경망과 서포트벡터머신을 이용하여 예측 및 측정 PR과의 비교.....	7
[1.2] TBM 굴진을 예측모델에 대한 분류체계.....	9
[2.1] 출력인자 간 관계.....	17
[2.2] FPI와 지반인자간의 단순회귀모델 그래프.....	19
[2.3] Training용 데이터(70%)를 이용한 5-fold cross validation.....	20

1. 국·내외 TBM 굴진율 모델 조사

TBM(Tunnel Boring Machine)을 적용하는 현장에서 장비 선정, 공사기간과 공사비용의 합리적인 산정을 위하여 TBM의 굴진율을 정확하게 예측하는 것은 매우 중요하다. 본 장에서는 최신 문헌들을 바탕으로 기존의 TBM 굴진성능 예측모델들의 평가과정(알고리즘)과 방법론에 대한 분석을 수행하였다. 2000년 이후에 발표된 문헌들에 대한 조사를 토대로 TBM 굴진율 예측모델의 분류체계를 제시하였다. 본 장에서 제시한 분류체계에서는 TBM 굴진성능 예측모델에 필요한 입력인자 선정단계와 예측기법 적용단계로 크게 구분하였다. 또한 각 예측모델에서 사용된 입력인자, 출력인자 그리고 예측모델에서 사용된 인자의 적용빈도를 분석하였다. 마지막으로 TBM 굴진율 예측모델의 현황과 차 후 연구방향에 대하여 정리하였다.

1.1 국내외 TBM 굴진율 예측기법의 종류

2000년 이후에 발표된 27편의 TBM 굴진율 관련 문헌들에 대한 조사를 토대로 적용된 예측기법을 크게 회귀분석과 최적화기법 두 가지로 분류하였다.

1.1.1 다중회귀분석(Multiple regression analysis)

다중회귀분석은 어떤 출력인자(종속변수)가 다른 입력인자(독립변수)에 의해 설명될 수 있다는 전제하에 그 함수 관계를 조사하는 통계적 분석법이다. TBM 굴진율 예측모델에서는 주로 다중회귀분석(선형 또는 비선형)이 적용되었다. 다중회귀분석의 절차로는 각 문헌의 연구자마다 다르게 분석하였는데, 크게 두 가지 방법으로 정리하였다.

(1) 방법 1

출력인자에 대한 입력인자를 선정하고 이에 대해 단계적회귀분석(Stepwise regression analysis)을 실시하여 다중회귀모델을 구축하는데, 단계적회귀분석은 크게 세 가지로 나누어진다. 첫 번째로는 출력인자와 상관관계 및 유의성이 가장 큰 입력인자로부터 시작하여 하나씩 입력인자를 선택하는 전진선택법(Forward selection method), 두 번째로는 전진선택법과는 반대로 모든 변수를 선택한 후 설명력이 가장 낮은 입력인자를 한 개씩 축차적으로 제거하여 선정하는 후진제거법(Backward elimination method), 세 번째로는 전진선택법과 후진제거법의 단점을 보완하기 위해 전진선택법의 각 단계에서 이미 선택된 변수들의 중요도를 다시 검사하여 더 이상 중요하지 않은 변수를 제거하는 방법을

단계별선택법(Stepwise selection method)이라 한다. 일반적으로 단계적회귀분석은 단계별선택법을 의미하기도 한다. 단계적회귀분석을 통하여 최종 선정된 회귀모형은 분산분석(ANOVA)의 한 종류인 F -test을 이용하여 유의성 및 설명력이 가장 좋은 회귀모형임을 의미한다. 한편, 다중회귀분석 중에 입력인자 간에 상관성이 매우 크게 되면 다중공선성문제가 나타나게 된다. 이는 적합 된 회귀계수의 분산이 비정상적으로 크게 발생하기 때문에 이를 반드시 해결해야 설명력 있는 회귀모형이 만들어질 수 있다. 대표적으로 Hassanpour et al (2009), (2010), (2011), Hamidi et al (2010) 등이 있다.

(2) 방법 2

첫 번째 방법과 다르게 다양한 상관분석과 수치해석 및 실험결과를 통해 출력인자에 대한 입력인자를 최종 선정하게 된다. 선택된 입력인자를 가지고 다중회귀모형을 적합한 후, F -test를 통한 유의성 검정, 설명력을 나타내는 R^2 그리고 측정된 굴진율과 모형을 통해 예측된 굴진율과의 선형성 R 값을 통해 모형검증을 하게 된다. 대표적으로는 Yagiz (2006, 1), Gong and Zhao (2009) 등이 있다.

위의 두 가지 방법에서 공통적으로 중요하게 봐야할 점은 가장 적합한 회귀 모형을 만들기 위해 여러 독립변수 중에서 어떠한 입력인자를 선택할 것인지 결정하여야 한다는 것과 여러 독립변수 중에서 서로 간 상관관계가 큰 인자(다중공선성)들이 있는 경우 현장 데이터의 성격에 따라 다양한 방법으로 이를 해결해야 한다는 것이다. 이와 같은 문제를 해결하는 과정은 개인의 경험적 및 공학적 판단에 따라 큰 차이가 발생할 수 있으므로 주어진 현장 데이터베이스의 특성을 고려하여 신중하게 수행되어야 할 것으로 판단된다.

1.1.2 최적화기법(Optimization technique)

통계분석은 일반적으로 가설에 대한 검증 과정 및 설명력이 중요하지만, 최적화 기법은 최적의 해를 찾아내기 위해 사용되는 기법으로 설명력이 아닌 예측력에 초점을 맞춘다는 차이점이 있다. 최적화 기법은 비선형적이고 복잡한 지반공학적 문제들을 해결하기 위해 적용되고 있다(Yagizand Karahan, 2015). TBM 굴진성능 예측모델로는 인공지능망(Zhao et al., 2007; Salimi et al., 2015; Martins and Miranda, 2013; Yagiz et al., 2009; Benardos and Kaliampakos., 2004; Gholamnejad and Tayarani, 2010),

퍼지이론(Ghasemi et al., 2014; Hedayatzadeh et al., 2011), 뉴로-퍼지(Salimi et al., 2015; Oraee et al., 2012; Grima et al., 2000), 입자무리최적화(Yagiz and Karahan, 2011), 서포트벡터머신(Salimi et al., 2015; Martins and Miranda, 2013; Mahdevari et al., 2014) 등이 적용되었고, Yagiz et al. (2015)는 차분진화(Differential evolution), Hybrid Harmony Search 그리고 Grey Wolf Optimizer를 적용하여 굴진성능을 예측하고자 하였다. 다양한 최적화기법의 특징은 표 1.2에 정리하였다. 최적화 기법을 사용하는 모델들의 특징은 현장 데이터베이스를 Training용과 Testing용으로 랜덤하게 나누는 후, Training용 데이터로 TBM 굴진율 모델을 적합한 후 Testing용으로 예측력을 평가하는 것이 일반적이다. Yagiz et al (2009)에서는 ‘Swingler (1996)과 Looney (1996)은 Testing용으로 전체 데이터의 20%와 25%를 권장하였고, Illingworth (1990)과 Nelson (1990)은 20%와 30%를 권장한다’ 고 언급하였다. 한편, Salimi et al (2015)는 데이터 손실을 최소화하기 위해 모든 데이터를 모델 적합에 이용하는 CV(Cross validation)을 적용하였다. CV의 장점은 모든 데이터를 모델 적합에 사용할 수 있다는 것과 동시에 예측력이 가장 높은 모델(또는 예측오차가 가장 작은 모델)을 선정할 수 있다. CV는 fold(데이터 등분)을 어떻게 나누는가에 따라서 Loocv(Leave one out cross validation), 10-fold cv와 5-fold cv등으로 분류할 수 있다.

<표 1.1> TBM 예측모델에 적용된 다양한 예측 기법

예측 기법	관련 모델
다중회귀모형 (선형, 비선형)	Gong and Zhao (2009)
	Hamidi et al (2010)
	Hassanpour et al (2009), (2010), (2011)
	Mobarral et al (2013)
	Delisio et al (2013)
	Delisio and Zhao (2014)
	Yagiz (2006), (2008)
	Yagiz and Yagiz (2006)
	Chang et al (2011)
인공신경망	Zhao et al (2007)
	Salimi et al (2015)
	Martins and Miranda (2013)
	Yagiz et al (2009)
	Benardos and Kaliampakos (2004)
	Gholamnejad and Tayarani (2010)
퍼지	Ghasemi et al (2014)
	Hedayatzadeh et al (2011)
뉴로퍼지	Salimi et al (2015)
	Oraee et al (2012)
	Grima et al (2000)
Particle swarm optimization	Yagiz and Karahan (2011)
서포트벡터머신	Salimi et al (2015)
	Martins and Miranda (2013)
	Mahdevari et al (2014)
차분진화	Yagiz et al (2015)
Hybrid harmony search	
Grey wolf optimizer	

<표 1.2> 적용된 최적화 기법의 특징요약

최적화 기법	특징
퍼지	자연 언어 등의 모호함을 정량적으로 표현하는 수리 이론으로 특정 분야의 전문가에게 습득한 언어 정보를 사용할 수 있다는 장점이 있는 반면, 학습능력은 없으므로 오차가 생기면 사용자가 계속해서 조정해야 한다는 어려움이 있음
인경신경망	인간의 뇌를 기반으로 한 추론 모델로, 생물학적 신경망을 모방하여 신경망을 구축하는 시스템. 특징으로는 역전파 알고리즘을 이용하는 학습능력이 있지만, 사용자가 구조를 이해하기 어렵다는 약점이 있음
뉴로퍼지	뉴로퍼지는 인경신경망의 병렬 연산 및 학습능력, 퍼지의 전문가로부터 습득한 언어 정보를 사용하는 설명능력을 결합한 기법으로 자연스럽게 서로를 보완함.
Particle swarm optimization	Kennedy and Eberhart, (1995)가 최초 제시한 최적화 기법으로 무리와 각 개체는 경험과 교류를 통해서 얻은 정보를 이용하여 다차원 공간에서 최적의 해를 찾아가는 진화형 계산기법으로. 기존의 유전자 알고리즘보다 보다 빠른 검색과정 및 지역적 최솟값을 피하는 장점을 가짐(이상춘 2011).
서포트벡터 머신	머신러닝의 일종으로, 회귀문제(regression problem)와 분류 문제(classification problem)를 해결하기 위해 제안된 지도학습 기법임. 이는 해의 과적합을 피하고 예측 정확성을 최대화한다는 특징이 있음(Salimi et al., 2015).
차분진화	차분진화는 Storn and Price (1995)가 최초 제시한 기법으로 집단 크기의 목적변수 벡터를 사용하는 탐색 방법. 차분진화 알고리즘은 구조와 연산이 대단히 간단하지만, 그럼에도 수렴속도가 매우 빠르며 알고리즘의 제어 파라미터가 적어서 사용하기 편리함. 그러나 탐색결과가 알고리즘 제어 파라미터에 매우 민감한 단점이 있음(황희수, 2002).
Hybrid harmony search-BFGS	HS-BFGS 알고리즘은 The harmony search(HS)와 BFGS(broyden, Fletcher, Goldfarb and Shanno) 기법을 통합한 알고리즘임. BFGS의 단점(초기 값에 민감, 지역적 최적 값 수렴, 발산문제)과 HS의 단점(전역적 최적 값의 어려움)을 개선한 알고리즘으로 매우 빠르고 강인한(robust) 기법임. 이는 공학에 관련된 연속적인 어떠한 최적문제에 적용이 가능(Karahan., et al. 2013).
Grey wolf optimizer	Mirjalili., et al (2014)가 최초 제시한 최적화 방법으로 사회 위계와 늑대의 사냥습성을 모방한 기법. 사회 위계를 α , β , δ , ω 파라미터 순으로 나누었으며, 사냥습성으로는 크게 Tracking, encircling 및 Attacking 세 단계로 나뉜다. GWO 진화 연산의 영역의 다른 위계적 알고리즘과 같이 그래디언트 함수를 사용하지 않는 특징을 가지고 있음(Madadi and Motlagh, 2014).

1.2 적용된 TBM 굴진율 예측기법 비교

1.2.1 사례 A (Martins and Miranda, 2013)

Martins and Miranda (2013)은 인공신경망과 서포트벡터머신 기법을 적용하여 TBM 굴진속도를 예측하는 모델을 제시하였다. Queens Water Tunnel #3의 153개의 DB(Data base)를 사용한 Yagiz (2008) 모델의 입력인자 및 DB를 그대로 사용하였다(Uniaxial compressive strength, Brittleness index, the distance between the planes of weakness, the angle between tunnel axis and the planes of weakness). 구축된 두 모델은 기존의 Yagiz (2008)와 Yagiz and Karahan (2011)가 제시하였던 다중회귀모델과 Particle swarm optimization모델과 비교하였다. 그 결과, 인공신경망을 적용한 모델이 가장 낮은 예측오차를 나타냄을 보였으며(표 1.3), 인공신경망을 적용한 모델이 타 모델보다 더 좋은 성능을 나타낸다고 판단하였다. 각 모델의 성능평가로 사용된 척도 MAD(Mean absolute deviation)과 RMSE(Root mean squared error)은 각각 다음과 같이 표현된다.

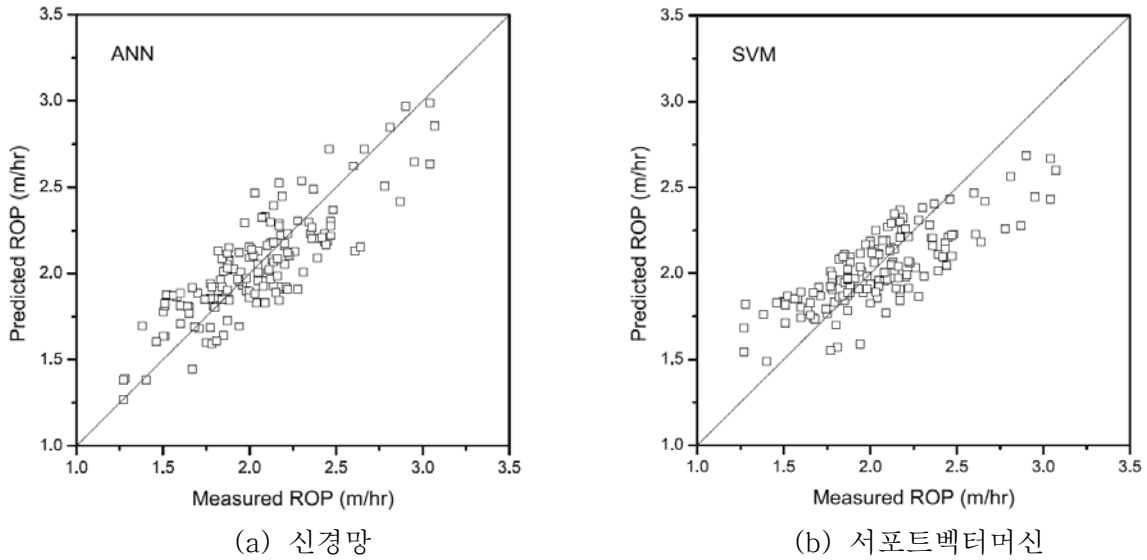
$$MAD = \frac{1}{N} \times \sum_{i=1}^N |y_i - \hat{y}_i|$$

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

그림 1.1은 측정된 굴진속도와 인공신경망과 서포트벡터머신이 적용된 모델로 예측된 굴진속도와 비교한 R 값을 보여준다.

<표 1.3> 개발된 모델의 성능

파라미터	다중회귀모형 (Yagiz, 2008)	Particle Swarm Optimization (Yagiz, 2011)	인공신경망	서포트벡터머신
MAD	0.184	0.178	0.163	0.185
RMSE	0.216	0.207	0.195	0.227
R	0.815	0.817	0.838	0.796



[그림 1.1] 신경망과 서포트벡터머신을 이용하여 예측 및 측정 PR과의 비교

1.2.2 사례 B (Yagiz, 2015)

Yagiz (2015)은 Queens water tunnel의 DB를 사용하여 differential evolution(DE), Hybrid Harmony Search(HS-BFGS), Grey Wolf Optimizer(GWO)를 포함한 여러 최적화 기술을 사용하여 TBM 굴진속도를 예측하는 모델을 개발하였고, 기존의 모델 Yagiz (2008), Yagiz and Karahan (2011) 및 Ghasemi (2014)과 성능을 비교하였다. 과적합(over-fitting)을 막고 최적의 파라미터를 찾기 위해서, Training용 데이터에서 무작위로 전체 데이터의 80%를 선택하였고, 나머지 20%는 Testing용으로 사용하였다. 비교한 결과, 측정된 굴진속도와 예측된 각 모델의 굴진속도와의 차이는 모두 크지 않았지만 그 중에서 Fuzzy logic을 적용한 방법이 가장 근접함을 확인할 수 있다(표 1.4).

<표. 1.4> 예측 및 측정된 PR과의 비교

파라미터	관측 PR (m/h)	LMR PR (m/h)	퍼지이론 PR (m/h)	PSO PR (m/h)
평균	2.05	2.11	2.04	2.06
표준편차	0.38	0.32	0.38	0.33
파라미터	관측 PR (m/h)	HS-BFGS PR (m/h)	차분진화 PR (m/h)	GWO PR (m/h)
평균	2.05	2.05	2.05	2.05
표준편차	0.38	0.30	0.29	0.29

1.3 TBM 굴진율 예측 분류체계

본 연구에서는 2000년 이후 발표된 27건의 논문을 분석하여 TBM 굴진성능 예측모델에 대하여 분석하였고, 이를 바탕으로 그림 1.2와 같은 분류체계를 제시하였다. 본 연구에서 제시한 분류체계는 크게 두 단계로 체계화할 수 있으며, 입력인자 선정단계와 예측기법 적용단계로 구분할 수 있다.

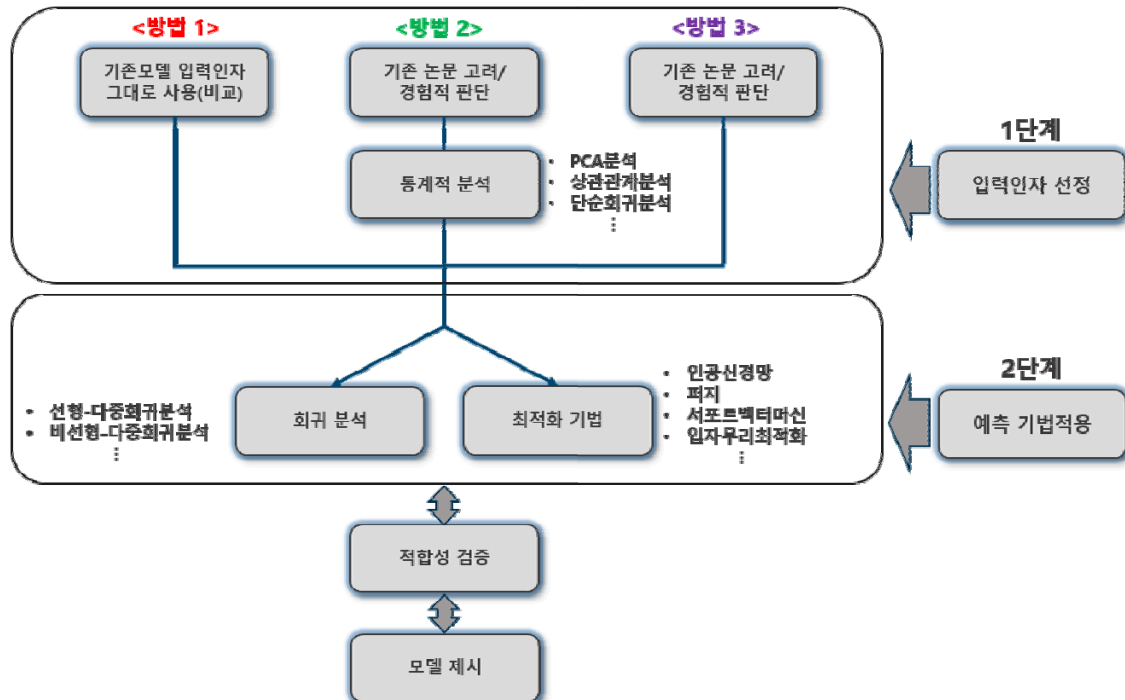
1.3.1 단계 1: 입력인자 선정(Selection of input parameter)

TBM의 굴진성능을 보다 정확하게 예측할 수 있는 예측모델을 제시하기 위해서는 우선 굴진성능에 영향을 미치는 주요 인자를 합리적으로 도출하여야 한다. 그러나 출력인자와 입력인자와의 상관도가 높다 하더라도 현장의 실무자가 획득하기 어려운 입력인자일 경우 예측모델의 활용도가 떨어질 수 있다. 반대로 활용성을 극대화하는데 초점을 맞춘다면, 오히려 예측모델의 정확성을 저하시킬 가능성이 있다. 또한 최적의 영향인자를 도출했을 지라도 TBM 굴진면의 매핑(Mapping)이 불가능한 것과 같이 현장 지반에 대한 조사가 불가능할 경우 정량적인 값으로 획득할 수 없다. 그러므로 현장에서 획득 가능한 영향인자에 대한 결정이 선행되어야 한다. 입력인자 선정단계는 다시 세 가지 방법으로 세분화할 수 있다. 방법 1은 앞서 제시된 예측모델에 사용된 현장의 데이터베이스 및 입력인자를 그대로 이용하여 예측모델에 적용한 경우이다. 제안된 예측기법이 그 전에 연구자가 제시하였던 예측기법보다 적합하다는 것을 입증하고자 하는 경우 방법 1이 용이하게 적용되었다(Zhao et al., 2007; Yagiz and Karahan, 2011, 2015; Martins and Miranda, 2013; Ghasemi et al., 2014). 방법 2는 분석한 문헌에서 가장 많이 사용하는 방법으로 기존의 여러 논문을 참고하여 주요 입력인자를 획득하고 더불어 경험적 및 공학적 판단을 통해 영향인자를 선택한 후 주성분분석(Principal component analysis), (Salimi et al., 2015; Grima et al., 2000), 단순회귀분석 또는 상관관계분석(Hamidi et al., 2010; Hassanpour et al., 2009, 2010; Mobarral et al., 2013; Delisio et al., 2013; Delisio and Zhao, 2014; Yagiz, 2006, 2008; Yagiz and Yagiz, 2006; Yagiz et al., 2009; Hedayatzadeh et al., 2011; Chang et al., 2011)등의 통계적인 방법을 통해 입력인자의 적합성을 검증하는 방법이다. 방법 3은 기존의 여러 논문을 참고하여 주요 입력인자를 획득하고 경험적 및 공학적 판단을 통해 입력인자를 선택하는 경우이다. 방법 3은 일반적으로 이전의 연구를 통해 충분한 경험적 지식이 있는 경우와 단계 2인 예측기법

적용단계에서 입력인자를 조정하고자 할 때 적용한 경우이다.(Gong and Zhao, 2009; Hassanpour et al., 2011; Benardos et al., 2004; Gholamnejad and Tayarani, 2010; Oraee et al., 2012; Mahdevari et al., 2014; Benato and Oreste, 2015). 예측모델의 신뢰성은 이용된 현장의 데이터 베이스의 신뢰성에 의해서도 큰 영향을 받게된다. 본 연구에서는 모델 구축에 이용된 데이터 베이스의 신뢰성에 대해서는 논외로 하였다.

1.3.2 단계 2: 예측기법 적용(Utilization of prediction technique)

두 번째 단계는 선정된 입력인자를 바탕으로 TBM의 굴진성능 예측을 위한 모델을 구축하는 단계이다. 예측기법 적용단계를 표 1.1과 같이 회귀분석, 최적화 기법으로 세분하였다. 몇 개의 문헌은 회귀분석과 최적화 기법 모두 사용하여 서로 비교하고자 하였다(Yagiz et al., 2009; Oraee et al., 2012; Mahdevari et al., 2014). 통계 프로그램에 있는 단계적회귀분석을 실시한 경우 여러 회귀모델 중에 결정계수(R^2)값이 가장 큰 조합을 만들기 위하여 예측기법을 적용하면서 입력인자가 재조정된 경우도 있다(Hamidi et al., 2010; Hassanpour et al., 2009, 2010, 2011; Yagiz, 2008).



[그림 1.2] TBM 굴진을 예측모델에 대한 분류체계

1.4 TBM 굴진율 모델에 사용된 입력 및 출력인자 분석

1.4.1 TBM 굴진율 출력인자

일반적으로 TBM의 굴진성능을 나타내는 용어로는 굴진속도(Penetration rate), 관입깊이(Penetration per revolution) 그리고 암반의 Boreability를 나타내는 Field penetration index 또는 Boreability index 등이 이용되고 있다. TBM의 굴진성능과 관련된 용어와 단위를 표 1.5에 정리하였다.

<표 1.5> TBM 굴진율과 관련된 용어정리

약어	용어	단위
PR	Penetration rate	$m/h, mm/min$
RPM	Revolution per minute	rev/min
P_{rev}	Penetration per revolution	mm/rev
$Utilisation$	Operating ratio	%
AR	Advance rate	m/day
BI	Boreability index	$kN/cutter/mm/rev$
$SRMBI$	Specific rock mass boreability index	$kN/cutter/mm/rev$
F_n	Thrust per disc cutter	$kN/cutter$
FPI	Field penetration index	$kN/cutter/mm/rev$
FPI_{blocky}	Field penetration index in blocky rock mass (2013, 2014)	$kN/mm/rev$ (2013) $kN/m/mm/rev$ (2014)

굴진속도는 TBM이 굴진하는 시간 당 굴진거리로 정의되며 일반적으로 m/h 또는 mm/min 으로 표현되고 있다.

$$PR = \frac{\text{굴진거리}}{\text{TBM의 굴진 시간}} \quad (1)$$

식 (1)에서 PR 은 굴진속도를 의미하며 커터헤드 회전 당 굴진거리를 나타내는 관입깊이를 계산하는데 사용될 수 있다. 관입깊이는 다음과 같이 표현할 수 있다.

$$P_{rev} = \frac{1000 \times PR}{60 \times RPM} \quad (2)$$

식 (2)에서 P_{rev} 은 관입깊이, RPM 은 분 당 커터헤드의 회전수로 각각 mm/rev ,

rev/min 으로 표현된다. 한편, PR 과 가동율로부터 TBM의 실굴진율을 다음 식 (3)과 같이 계산할 수 있다. 실굴진율은 설계단계에서 공사비와 공사기간을 예측하는데 사용되는 중요한 인자이다. 여기서, 가동률은 % 단위이며 굴진시간을 전체 가동시간으로 나눈 값이다.

$$AR(m/day) = PR(mm/min) \times Utilisation(\%) \times \left(\frac{60 \times 24}{1000} \right) \quad (3)$$

식 (3)에서 AR 은 실굴진율, $Utilisation$ 은 가동율을 의미한다. 한편, $Utilisation$ 은 TBM과 현장의 지반상태 및 작업자의 숙련도에 따라 차이가 크기 때문에 대부분의 연구자들은 TBM 굴진성능 예측을 위해 직접적으로 AR 을 도출하기보다는 PR 또는 P_{rev} 의 예측을 위한 모델을 주로 제시하고 있다.

Field penetration index(또는 Boreability)는 일반적으로 암반에서 암석절삭기기의 성능을 설명하는데 사용된다. 이는 굴진압이나 TBM 커터의 개수 및 종류에 따른 관입율의 관점에서 암석의 굴진 특성을 표현하는 값으로 정의된다(Commission on engineering and technical systems of USA 1984). 암반의 FPI는 TBM과 암반사이의 상호작용의 결과를 표현하는 파라미터(Gong et al., 2007)로 암반의 특성, TBM의 사양 및 작동인자와 관련된 포괄적인 변수라 할 수 있다. 어떤 연구자들은 암반의 특성에 따른 FPI를 측정하기 위하여 BI (Boreability Index)와 FPI (Field Penetration Index)를 제안(Sundin and Wanstedt, 1994; Hamilton and Dollinger, 1979)하였지만, 이 지수들은 표현 방법이 다를 뿐 동일한 파라미터로 볼 수 있다(Gong et al., 2007).

$$FPI = \frac{F_n}{P_{rev}} \quad (4)$$

여기서, F_n 은 작용된 커터 당 추력으로 $kN/cutter$ 로 표현되며, FPI 는 F_n 을 P_{rev} 으로 나눈 값으로 단위는 $kN/cutter/mm/rev$ 을 사용한다. Mobarral et al. (2013)은 PR 보다는 FPI 가 지반공학적 인자와 더 밀접한 상관관계가 있는 것으로 분석하였다. 그리고 FPI 와 F_n 로부터 PR 또는 P_{rev} 를 용이하게 계산할 수 있다(Hassanpour et al., 2009; Mobarral et al., 2013; Delisio and Zhao, 2014; Salimi et al., 2015). 해외에서는 암반의 Boreability의 예측을 위한 여러 모델들이 제시되었으며, FPI 또는 BI 와 암반의 특성을

나타내는 여러 인자간의 상관관계에 대한 연구가 현재도 활발히 진행되고 있다(Hamidi et al., 2010; Hassanpour et al., 2009, 2010, 2011; Mobarral et al., 2013; Salimi et al., 2015). 기존의 BI 는 RPM 또는 F_n 과 같은 TBM 작동인자의 영향으로 인해 같은 암반조건에서도 값이 달라지기 때문에 TBM 작동인자의 영향을 소거하기 위하여 Gong et al. (2007)은 $1mm/rev$ 에서의 BI 를 의미하는 $SRMBI$ (Specific Rock Mass Boreability Index)를 제시하였다. 이는 서로 다른 암반조건에서 암반의 Boreability를 측정하는데 용이하게 적용될 수 있다. 이후에 $SRMBI$ 를 예측하기 위한 모델이 제시되었다(Zhao et al., 2007; Gong and Zhao, 2009). Delisio et al (2013)과 Delisio and Zhao (2014)는 blocky rock 조건에서는 기존의 FPI 만으로는 Boreability를 명확하게 고려하지 못한다고 판단하여 FPI_{blocky} (Field penetration index in blocky rock mass)를 제안하였고, 이를 예측할 수 있는 모델을 제시하였다. 한편, 국내에서는 FPI 에 대한 연구가 전무하고 이에 대한 용어 또한 정립되지 않은 실정이므로 향후 이에 대한 기초연구가 필요할 것으로 판단된다.

1.4.2 TBM 굴진율 입력인자

TBM 굴진성능 예측모델에 사용된 입력 및 출력인자와 해당 연구 개발이 이루어진 국가를 포함한 종합적인 정리를 표. 1.6로 나타내었다. 또한 정리한 모델 안에서 사용된 입력인자의 적용 빈도를 표. 1.7에 제시하였다. 주요 영향인자의 적용 빈도에 따른 서열로는 일축압축강도, 절리의 간격, 절리의 방향, 취성지수, RQD, 체적절리개수(The volumetric joint count) 그리고 인장강도 순으로 나타난다. 여기서 일축압축강도는 암석의 강도를 나타내며, 나머지는 주로 암반의 절리조건과 관련된 인자임을 알 수 있다. 즉, 암석의 강도뿐만 아니라 암반의 상태를 나타내는 인자들이 PR , P_{rev} , FPI 을 결정하는 지배적인 영향인자로 적용되고 있음을 알 수 있다. Chang et al., (2011)은 커터의 관입깊이는 절삭조건보다는 암석의 강도 특성 및 NTNU(Norwegian University of Science and Technology)모델 변수들에 의해 좌우됨을 회귀분석 결과로부터 확인하였다. 그리고 실내실험으로부터 획득한 암석의 일축압축강도는 현장의 암반상태를 대표할 수 없기 때문에 일축압축강도만으로 굴진성능을 정확하게 예측할 수 없다(Yagiz, 2008). 이는 절리의 간격, 절리의 방향 및 체적절리개수 등과 같은 암반상태와 관련된 인자들 또한 TBM 굴진성능에 큰 영향을 미친다는 것을 의미한다. Grima et al., (2000), Hassanpour et al., (2011), Chang et al., (2011)을 제외한 대부분의 모델은 주로 1~2개의 현장 자료로부터

구축되었기 때문에 새로운 현장에 일반화되어 적용되기에는 무리가 있을 것으로 예상된다.

1.5 국내 TBM 굴진율 예측모델 현황

국내의 TBM 굴진성능 예측모델로는 선형절삭시험 결과에 근거한 Chang et al., (2007)모델과 국내의 여러 현장자료와 선형절삭시험 결과에 근거하여 다중회귀분석을 적용한 Chang et al., (2011)모델이 있다. 이 모델들은 해외의 CSM모델과 NTNU모델의 장점을 살려 여러 현장의 데이터와 국내 주요 암석에 대한 절삭시험을 통하여 다양한 암석특성을 고려한 최적의 절삭조건을 제시하였고, 커터작용력, 커터 압입깊이(P_{rev}), 비에너지(SE) 등 여러 가지 값을 산정할 수 있다.

해외에서는 NTNU모델과 같이 특수한 시험(Siever's J-value test, The brittleness test, The abrasion test)을 요구하는 영향인자 대신에 실무자가 터널 현장의 예비단계에서 쉽게 획득할 수 있는 영향인자를 입력인자로 고려하여 예측모델을 제안하고 있다. 또한, 비선형적이고 영향인자간의 관계가 매우 복잡한 TBM 굴진성능 예측문제를 해결하기 위해서 통계적 모델에서 더 나아가 인공지능을 포함한 최적화 기법을 도입하고 있는 추세이고, 그 가능성이 여러 연구자들에 의해 검증되었다(Martins and Miranda, 2013; Yagiz and Karahan, 2015; Yagiz et al., 2009; Oraee et al., 2012; Mahdevari et al., 2014). 물론 대부분 해외에서 소개된 예측모델은 보통 1~2개의 현장자료를 토대로 제시하였기 때문에 일반화하여 적용하기 어렵다.

한편, 국내의 경우 TBM의 굴진성능 예측을 위한 최적화 기법의 적용에 대한 연구는 아직 미진한 실정이다. 인공지능을 포함한 최적화 기술은 예측 정확성이 뛰어나고, 기계학습을 사용하기 때문에 새로운 현장 데이터베이스가 추가된다 하더라도 스스로 학습하여 적응성이 있는 강력한 예측모델을 제시할 수 있을 것으로 판단된다. 또한 국내에서 제시된 TBM 성능 예측 모델은 실무자들이 획득하기 난해한 영향인자들을 포함하고 있다. 물론, 획득하기 용이한 영향인자만을 고려한다면 예측의 정확성이 감소될 수 있기 때문에 향후 효율성과 정확성을 모두 고려한 신뢰성 있는 예측모델에 대한 연구 개발이 필요할 것으로 판단된다. 그리고 현재 신뢰성 있는 국내 TBM의 현장자료가 많이 부족한 실정이므로 향후 지속적으로 신뢰성 높은 데이터베이스를 구축한다면 국내외의 어느 현장에서도 적용할 수 있는 범용적인 TBM 굴진 성능 예측모델을 개발하는데 도움이 될 것으로 판단된다.

<표 1.6> 각 모델에 대한 종합 정리

NO	모델	입력인자 선정	예측기법 적용	출력인자	직경	주요 인자		국가
						지반	기계	
②	Alireza Salimi et al, 2015	방법 2	인공신경망 뉴로퍼지 서포트벡터머신	Field Penetration Index (kN/cutter/mm/rev)	6.73m (TBM 직경)	UCS, J_s	-	독일
②	Jafar Khademi Hamidi et al, 2010	방법 2	다중회귀분석 비선형다중회귀분석	Field Penetration Index (kN/cutter/mm/rev)	6.73m	UCS, RQD, J_c, α	-	이란
⑨	Mansour Hedayatzadeh et al, 2011	방법 2	퍼지	Penetration Rate (m/hr)	5.2m (터널 직경)	F_Q, F_α, F_f	-	이란
③	Yasser Mobarral et al, 2013	방법 2	다중회귀분석	Field Penetration Index (kN/cutter/mm/rev)	4.525m	UCS, $I_s(50)$	-	이란
① ④ ⑦	Javad Gholamnejad et al, 2010	방법 3	인공신경망	Penetration Rate (m/hr)	-	UCS, DPW, RQD	-	이란
⑧	Q.M Gong et al, 2009	방법 3	비선형다중회귀분석	a Specific rock mass boreability index (kN/cutter/mm/rev)	3.6m 3.3m (터널 내부직경)	UCS, Bi, J_v, α	-	중국
	Zhiye Zhao et al, 2007	방법 1	인공신경망(종류: ENN)	a Specific rock mass boreability index (kN/cutter/mm/rev)	3.6m, 3.3m (터널 내부직경)		-	싱가포르
①	Saffet Yagiz et al, 2006(1)	방법 2	다중회귀분석	Penetration Rate (m/hr)	7.06m	UCS, BTS, J_s, PI	-	터키
①	Saffet Yagiz et al, 2006(2)	방법 2	다중회귀분석	Penetration Rate (m/hr)	-	Bi, RFI(= α, J_s)	$CSM_{(b-rop)}$	터키
①	Saffet Yagiz et al, 2008	방법 2	다중회귀분석	Penetration Rate (m/hr)	7.06m (터널 직경)	UCS, Bi, DPW, α	-	터키
	Saffet Yagiz et al, 2009	방법 2	비선형다중회귀분석 인공신경망					터키
	Saffet Yagiz et al, 2011	방법 1	입자무리최적화					터키
	Martins F.F et al, 2013	방법 1	서포트벡터머신 인공신경망					포르투갈
	Ebrahim Ghasemi et al, 2014	방법 1	퍼지					이란
	Saffet Yagiz et al, 2015	방법 1	차분진화 Hybrid Harmony					터키

			Search(HS-BFGS) Grey Wolf Optimizer(GWO)					
①	Satar Mahdevari et al, 2014	방법 3	다중회귀분석 서포트벡터머신	Penetration Rate (mm/min)	7.06m (터널 직경)	UCS, BTS, Bi, DPW, α	SE, TF, CP, CT	이란
① ⑦	K. Oraee et al, 2012	방법 3	비선형다중회귀분석 뉴로퍼지	Penetration Rate	-	UCS, DPW, RQD	-	영국
⑦	J. Hassanpour et al, 2009	방법 2	단순회귀분석 다중회귀분석	Field Penetration Index (kN/cutter/mm/rev)	6.73m (TBM 직경)	- RMC UCS, RQD	-	터키
⑥	J. Hassanpour et al, 2010	방법 2	단순회귀분석 다중회귀분석	Field Penetration Index (kN/cutter/mm/rev)	4.65m (TBM 직경)	RMC $UCS_{r,m}$ UCS, J_s	-	터키
⑩	J. Hassanpour et al, 2011	방법 3	다중회귀분석	Field Penetration Index (kN/cutter/mm/rev)	-	UCS, RQD	-	터키
⑪	A. Benato et al, 2015	방법 3	통계적방법	Penetration Rate (mm/rev)	-	UCS, GSI,	$-F_N$	이탈리아
⑩	Chang et al, 2011	방법 2	다중회귀분석	Penetration Rate (mm/rev)	8.06m 3.82m 7.93m (TBM 직경)	UCS, BTS (S_t), S_{20} , DRI, CLI	-	한국
⑫	A.G Benardos et al, 2004	방법 3	인공신경망	Penetration rate (m/hr)	-	RQD, overload factor, UCS, water table surface, Rock mass weathering, RMR, overburden, permeability	-	그리스
⑬	A. Delisio et al, 2013	방법 2	다중회귀분석	Field Penetration Index_Blocky1 (kN/mm/rev)	9.43m (TBM 직경)	UCS, J_v	-	스위스
⑬ ⑭	A. Delisio et al, 2014	방법 2	비선형다중회귀분석	Field Penetration Index_Blocky2 (kN/m/mm/rev)	-	UCS, J_v	-	스위스
⑩	M. Alvarez Grima et al, 2000	방법 2	뉴로퍼지 다중회귀분석	Penetration Rate (m/hr)	-	UCS, CFF, RPM	thrust per cutter, cutter diameter	네덜란드

<표 1.7> 입력인자 적용빈도

입력인자	빈도수
• UCS: Uniaxial Compressive Strength	24
• α : Angle between plane of weakness and TBM-driven direction	11
• DPW: Distance between plane of weakness	9
• Bi: Brittleness Index	10
• RQD: Rock Quality Designation	6
• RMCI: Rock Mass Cuttability Index	2
• J_s : Joint spacing	5
• J_c : Joint condition	1
• $J_{s(50)}$: Point Load Strength Index having 50mm diameter	1
• J_v : The volumetric joint count	3
• BTS: Brazilian tensile strength	3
• SE: Specific Energy	1
• TF: Thrust Force	1
• CP: Cutterhead Power	1
• CT: Cutterhead Torque	1
• $CSM_{(b-r_{op})}$: CSM model basic rate of penetration	1
• F_Q : fabric index of Q system	1
• F_α : The ratio UCS/cutter load	1
• F_f : $\log ArcSin(Sin\alpha_f * Sin(\alpha_t - \alpha_s))$	1
• PI: Punch penetration index	1
• F_N : Contact force applied to the disk	1
• GSI: Geological Strength Index	1
• S_{20} : Brittleness Index	1
• DRI: Drill Rate Index	1
• CLI: Cutter Life Index	1
• RMR: Rock Mass Rating	1
• overload factor	1
• overburden	1
• water table surface	1
• permeabilit	1
• Rock Mass Weathering	1
• CFF: The Core Fracture Frequency	1
• RPM	1
• Thrust per cutter	1
• cutter diameter	1

<표 1.8> 적용된 터널 현장

번호	터널명
①	The Queens Water Tunnel(미국)
②	Zagros Tunnel(이란)
③	Golab Water Transfer Tunnel(이란)
④	Karaj-Tehran Water Transfer Tunnel(이란)
⑤	Nowsood Water Conveyance Tunnel(이란)
⑥	Karaj Water Coneyance Tunnel(이란)
⑦	Gilgel Gibe II Hydroelectric Project(에티오피아)
⑧	The Deep Tunnel Sewerage System(싱가포르)
⑨	Alborz service tunnel(이란)
⑩	기타 여러 터널 사용(4곳 이상)
⑪	Alpine tunnel(이탈리아)
⑫	Athens Metro(그리스)
⑬	Lötschberg Base Tunnel(스위스)
⑭	Second Manapouri Tailrace Tunnel(뉴질랜드)

2. TBM 출력인자 선정을 위한 통계적 분석

본 연구는 “OO지역 전기공급시설 전력구공사(OO~OO구간)”의 DB를 이용하여 통계분석을 실시하였다. 해당 현장의 TBM의 기계데이터와 지반조사보고서를 참고하여 시추구간을 DB를 구축하여 여러 가지 입출력 인자 중 영향이 있는 인자를 최초 선정하였다. 선정된 입력인자와 출력인자간의 통계분석을 실시하여 지반인자를 가장 잘 나타내는 출력인자를 선정하고자 하였다.

상관관계 분석에 사용된 DB는 “OO지역 전기공급시설 전력구공사”의 현장데이터를 사용하였고, 설계단계에서 획득 가능한 지반인자를 최초 선정하였다(TCR , RQD , UCS , E , RMR). 국외 문헌을 근거하여 TBM 굴진율과 관계된 출력인자인 굴진속도 PR , 관입깊이 P_e , Field penetration index FPI 세 가지를 선정하였다. P_e 의 경우, PR 을 RPM 으로 나누어서 산정하였고, FPI 는 커터당 추력($kN/cutter$)을 P_e 로 나누어서 계산하였다.

$$\textcircled{3} \quad FPI = \frac{F_n (kN/cutter)}{P_e (mm/rev)} \quad \textcircled{2} \quad P_e = \frac{PR (mm/min)}{RPM (rev/min)} \quad \textcircled{1} \quad PR = \frac{\text{Segment ring width (mm)}}{\text{Net excavated time (min)}}$$

[그림 2.1] 출력인자 간 관계

2.1 입력 및 출력인자 간 단순회귀분석

선정된 지반인자(TCR , RQD , UCS , E , RMR)와 출력인자(PR , P_e , FPI)와의 단순회귀분석을 실시하였다. 각 관계는 linear, exponential, polynomial, quadratic 함수 중 가장 적합한 모형을 선정하였다. 분석 결과, 표 2.1과 같이 출력인자들 중에서 FPI 가 각 지반인자간의 상대적으로 가장 높은 설명력 R^2 을 나타내었고, 이는 FPI 가 기계인자 즉, 추력과 RPM 의 영향을 모두 제거한 인자이기 때문에 지반인자를 가장 잘 설명한다고 판단할 수 있다. 그림 2.2는 FPI 와 각 지반인자간의 단순회귀모형을 시각화하여 나타낸 그래프이다.

<표 2.1> 단순회귀분석 결과 요약

파라미터	결정계수, R^2			모형	관계식
	PR (mm/min)	Pe (mm/rev)	FPI (KN/cutter/mm/rev)		
TCR (%)	0.085	0.091	0.1542	Exponential	$FPI = 155.4 \times e^{-0.013TCR}$
RQD (%)	0.058	0.064	0.090	Polynomial	$FPI = 64.4258 \times e^{-0.000698RQD}$
UCS (Mpa)	매우 낮음	매우 낮음	0.007	Linear	$FPI = 53.045 + 0.118UCS$
Elastic Modulus (Kpa)	매우 낮음	매우 낮음	0.004	Linear	$FPI = 14.749 + 0.022E$
RMR	0.1142	0.099	0.1145	exponential	$FPI = 85.03 \times e^{-0.011R}$

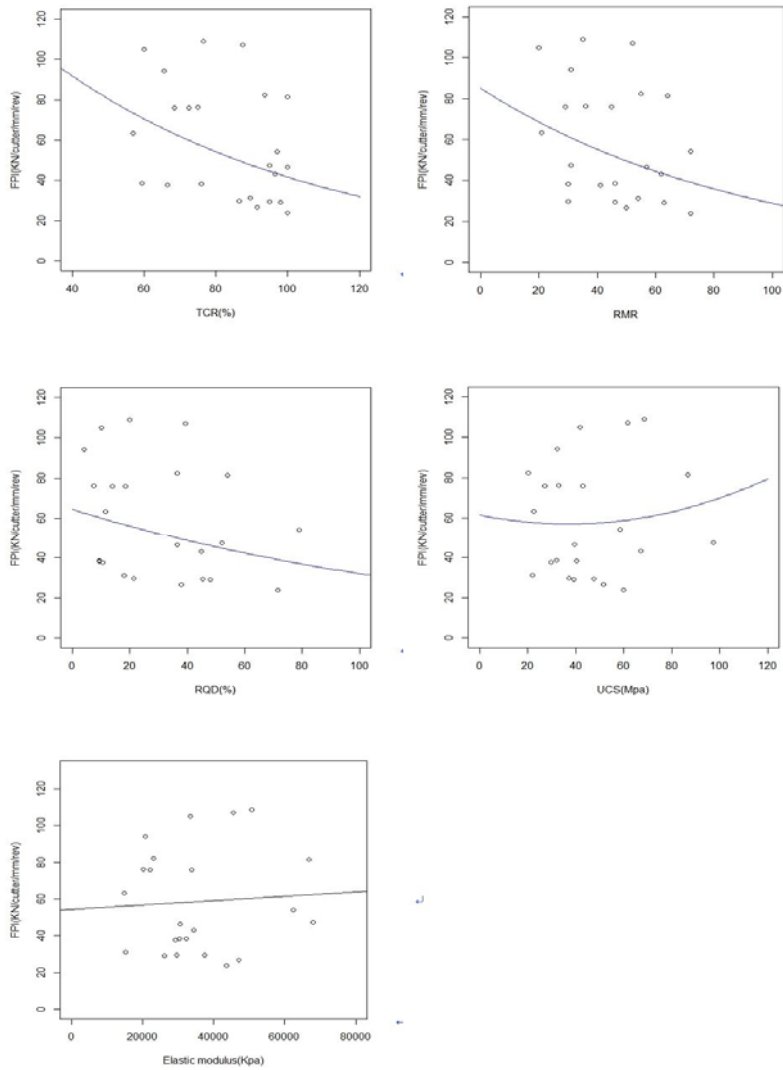
더불어, 표 2.2와 같이 피어슨 상관계수(R) 행렬을 이용하여 각 인자 간 상관도를 분석하였다. 여기서 상관계수 R 은 인자 간 선형상관성을 나타내는 측도로 절댓값 1에 가까울수록 상관성이 높음을 의미하고, 0에 가까울수록 상관성이 없음을 의미한다.

$$\text{(피어슨 상관계수), } r_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

여기서, \bar{x} 와 \bar{y} 는 각각 x_1, \dots, x_n 과 y_1, \dots, y_n 의 평균을 나타낸다. 표 2.2에서 알 수 있듯이 FPI 가 PR 과 P_e 에 비해 지반인자와의 선형상관성이 높은 것으로 분석되었다. FPI 와의 상관정도는 TCR , RMR 이 절댓값 0.3 이상으로 가장 높았으며, RQD 가 그 뒤를 따랐다. 반면, UCS 와 E (elastic modulus)는 관련성이 상당히 낮게 나옴을 확인할 수 있었는데, 이는 실제 시추했던 위치와 터널의 위치가 설계변경으로 인하여 차이가 발생한 것으로 판단된다.

<표 2.2> 피어슨 상관계수 매트릭스

	TCR	RQD	UCS	E	RMR	PR	Pe	FPI	
TCR	1	0.84	0.49	0.47	0.76	0.28	0.30	-0.37	
RQD	∴	1	0.61	0.68	0.77	0.25	0.25	-0.29	
UCS		∴	1	0.91	0.24	0.01	0.01	0.08	
E			∴	1	0.31	0.02	0.03	0.06	
RMR				∴	1	0.33	0.31	-0.33	
PR	Symmetry					∴	1	0.99	-0.89
Pe						∴	1	-0.92	
FPI							∴	1	

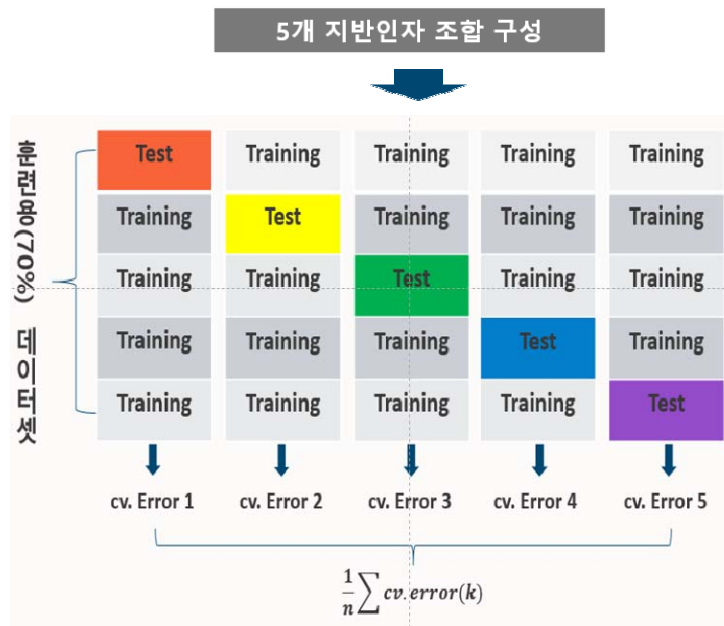


[그림 2.2] FPI와 지반인자간의 단순회귀모델 그래프

2.2 Cross validation을 적용한 출력인자 분석

각 출력인자(PR , P_e , FPI)에 대한 다중회귀모델의 예측력을 판단하게 위해서 5-fold cross validation을 이용한 평가척도를 선택하였다. 5-fold cross validation 원리는 DB를 동일 사이즈로 랜덤하게 다섯 샘플로 나눈다. 그 다음, 각 하나의 샘플은 그 나머지 샘플들로 적합 된 회귀모형을 테스트하게 되는데, 각 세트마다 얻어진 에러($y_i - \hat{y}_i$)를 평균한 값(Mean absolute deviation, MAD)으로 예측력을 판단하게 된다. cross validation은 모든 데이터를 훈련데이터로 사용할 수 있다는 장점이 있다.

본 연구에서는 DB를 해외모델(Hassanpour, 2011)과 추후 비교를 위해서 Training용(70%)과 Testing용(30%)으로 나누었다. 우선 Training용으로 그림 2.3과 같이 선정된 5개의 지반인자의 31가지 조합(${}_5C_1 + {}_5C_2 + {}_5C_3 + {}_5C_4 + {}_5C_5 = 31$)으로 분류한 후, 각 출력인자 별로 31번의 5-fold cross validation을 실시하였다.



[그림 2.3] Training용 데이터(70%)를 이용한 5-fold cross validation

출력인자 간 비교를 위해서 DB의 지반인자와 출력인자를 표준화 시킨 후 분석을 실시하였다. 그 결과에 대한 요약은 표 2.3과 같다. 각 출력인자 별로 최적의 지반인자 조합은 TCR 과 RQD 로 동일하였으며, 예측오차의 척도인 Cross validation

MAD 및 AIC(Akaike information criterion)은 FPI 가 1.633 및 52.65로 상대적으로 가장 작은 값을 나옴을 확인할 수 있었다. 이는 FPI 가 TBM 굴진을 예측 출력인자로 선정하는 것이 합리적인 선택이라 판단된다.

<표 2.3> 출력인자에 대한 표준화된 최적 모델 요약

출력인자	표준화된 최적 모델	Cross validation MAD	AIC
PR	$PR = 0.5617TCR - 0.1964RQD - 0.00985$	1.838	54.10
P_e	$P_e = 0.6655TCR - 0.2913RQD - 0.0144$	1.833	53.80
FPI	$FPI = -0.8008TCR + 0.3192RQD + 0.0848$	1.633	52.65

3. 결론

국외에서는 TBM 굴진을 예측을 위한 출력인자로 주로 굴진속도 PR , 관입깊이 P_e , Field penetration index FPI 세 가지로 선정하여 모델을 제시하였다. 본 연구에서는 위의 세 가지의 출력인자 중 지반인자를 가장 잘 설명하는지 또한 잘 예측하는지 결정하기 위하여 통계분석을 실시하였다. 단순회귀분석 및 피어슨 상관매트릭스분석 결과, FPI 가 5개의 지반인자(TCR , RQD , UCS , E , RMR)와의 R^2 가 가장 높은 것으로 분석되었다. PR 과 다르게 FPI 는 TBM의 작동인자인 추력과 RPM 의 영향을 고려한 종합적인 인자로 TBM의 작동인자의 영향을 제거할 수 있기 때문에 지반인자를 잘 설명하는 것으로 판단된다. 더불어, Cross validation을 적용하여 FPI 를 예측하는 모델이 가장 작은 예측오차(MAD)를 나타내었고, 이는 PR 및 P_e 보다는 FPI 를 예측하는 것이 TBM 굴진율의 신뢰성을 높일 수 있는 합리적이 방안으로 판단된다. 또한, 각 출력인자와 입력인자간의 상관분석의 결과를 가지고, 추 후 퍼지이론의 가장 중요한 초기조건인 Membership function을 정의하는데 사용할 예정이다.

최근 국외에서는 비선형적이고 영향인자간의 관계가 매우 복잡한 TBM 굴진율 예측문제를 해결하기 위해서 통계적 모델에서 더 나아가 인공지능을 포함한 최적화 기법을 도입하고 있는 추세이고, 그 가능성이 여러 연구자들에 의해 검증되었다(Martins and Miranda, 2013; Yagiz and Karahan, 2015; Yagiz et al., 2009; Oraee et al., 2012; Mahdevari et al., 2014). 반면, 국내의 경우 TBM의 굴진성

능 예측을 위한 최적화 기법의 적용에 대한 연구는 아직 미진한 실정이다. 인공지능의 일부인 최적화 기술은 예측 정확성이 상당히 뛰어나고, 기계학습을 사용하기 때문에 새로운 현장 데이터베이스가 추가된다 하더라도 스스로 학습하여 적응성이 있는 강력한 예측모델을 제시할 수 있을 것으로 판단된다. 몇 가지의 논문을 조사하여 여러 가지 기법 중에서 퍼지와 인공신경망을 적용한 모델이 정확성이 높은 것으로 분석되었으며, 이는 앞으로 연구하게 될 신경망에 퍼지이론을 도입한 뉴로퍼지를 적용한 TBM 굴진율 예측모델의 신뢰성에 도움이 될 것으로 예상된다.

참고문헌

1. Gong, Q.M., Zhao J., Jiang Y.S. (2007), “In situ TBM penetration tests and rock mass boreability analysis in hard rock tunnels”, *Tunnelling and Underground Space Technology*, Vol. 22, No. 2, pp. 303 - 316.
2. Bruland, A. (1998). “Hard rock tunnel boring”, Ph.D. Thesis, Norwegian University of Science and Technology.
3. Zhao, Z., Gong, Q.M., Zhang, Y. & Zhao, J. (2007), “Prediction model of tunnel boring machine performance by ensemble neural networks”, *Geomechanics and Geoengineering*, Vol. 2, No. 2, pp. 123-128.
4. Gong, Q.M., Zhao J. (2009), “Development of a rock mass characteristics model for TBM penetration rate prediction”, *Rock Mechanics and Mining Sciences*, Vol. 46, No. 1, pp. 8-18.
5. Hamidi, J.K., Shahriar, K., Rezai, B., Rostami, J. (2010), “Performance prediction of hard rock TBM using Rock Mass Rating(RMR) system”, *Tunnelling and Underground Space Technology*, Vol. 25, No. 4, pp. 333-345.
6. Hassanpour, J., Rostami, J., Khamehchiyan, M. and Bruland, A. (2009), “Developing new equations for TBM performance prediction in carbonate-argillaceous rocks: a case history of Nowsod Water conveyance tunnel”, *Geomechanics and Geoengineering*, Vol. 4, No. 4, pp. 287-297.
7. Hassanpour, J., Rostami, J., Khamehchiyan, M., Bruland, A., Tavakoli, H.R. (2010), “TBM performance Analysis in Pyroclastic Rocks: A Case History of Karaj Water Conveyance Tunnel”, *Geomechanics and Geoengineering*, Vol. 43, No. 4, pp. 427-445.

8. Hassanpour, J., Rostami, J., Zhao, J. (2011), “A new hard rock TBM performance prediction model for project planning”, Vol. 25, No. 5, pp. 595-603.
9. Mobaral, Y., Anbaranil, M.R., Akbaril, E. (2013), “A statistical model for the prediction of TBM penetration rate using rock mass characteristics in the TBM-driven Golab Water Transfer Tunnel”.
10. Delisio, A., Zhao, J., Einstein, H.H. (2013), “Analysis and prediction of TBM performance in blocky rock conditions at the Löttschberg Base Tunnel”, *Tunnelling and Underground Space Technology*, Vol 33, pp. 131-142.
11. Delisio, A., Zhao, J. (2014), “A new model for TBM performance prediction in blocky rock conditions”, *Tunnelling and Underground Space Technology*, Vol. 43, pp. 440-452.
12. Salimi, A., Moormann, C., Singh, T.N., Jain, P. (2015), “TBM performance prediction in rock tunneling using various artificial intelligence algorithms”, 11th Iranian and 2nd Regional Tunnelling Conference "Tunnels and the Future".
13. Yagiz, S., Karahan, H. (2011), “Prediction of hard rock TBM penetration rate using particle swarm optimization”, *Rock Mechanics and Mining Science*, Vol. 48, No. 3, pp. 427-433.
14. Martins, F.F., Miranda, T.F.S. (2013), “Prediction of hard rock TBM penetration rate based on Data Mining techniques”, *Proceedings of the 18th international conference on Soil Mechanics and Geotechnical engineering*.
15. Ghasemi, E., Yagiz, S. and Ataei, M. (2014), “Predicting penetration rate of hard rock tunnel boring machine using fuzzy logic”, *Engineering Geology and the Environment*, Vol. 73, No. 1, pp. 23-35.
16. Yagiz, S., Karahan, H. (2015), “Application of various optimization techniques and comparison of their performances for predicting TBM penetration rate in rock mass”, *Rock Mechanics and Mining Science*, Vol. 83, pp. 308-315.
17. Grima, M.A., Bruines, P.A. and Verhoef, P.N.W. (2000), “Modelling tunnel boring machine performance by neuro-fuzzy methods”, *Tunnelling and Underground Space Technology*, Vol. 15, No. 3, pp 259-269.
18. Yagiz, S. (2006), “TBM performance prediction based on rock properties”, *Proceedings of Multiphysics Coupling and Long Term Behavior in Rock Mechanics*, EUROCK,

Vol. 6, pp. 663-670.

19. Yagiz, S. Yagiz, A. (2006), “A model for the prediction of tunnel boring machine performane”, In Proceedings of 10th IAEG Congress, pp. 1-10.
20. Yagiz, S. (2008), “Utilizing rock mass properties for predicting TBM performance in hard rock condition”, Tunnelling and Underground Space Technology, Vol. 23, No. 3, pp. 326-339.
21. Yagiz, S., Gokceoglu, C., Sezer, E., Iplikci, S. (2009), “Application of two non-linear prediction tools to the estimation of tunnel boring machine performance”, Engineering Application of Artificial Intelligence, Vol. 22, No. 4, pp. 808-814.
22. Hedayatzadeh, M., Shahriar, K., Hamidi, J.K. (2011), “A fuzzy logic model to predict the performance of hard rock tunnel boring machine”, First Asian and 9th Iranian Tunnelling Symposium November 2011 Tehran Iran.
23. Chang, S.H., Choi S.W., Lee, G.J., Bae, G.J. (2011), “Rock TBM design model derived from the multi-variate regression analysis of TBM driving data”, Journal of Korean Tunnelling and Underground Space Association, Vol. 13, No. 6, pp. 531-555.
24. Benardos, A.G., Kaliampakos, D.C. (2004), “Modelling TBM performance with artificial neural networks”, Tunnelling and Underground Space Technology, Vol. 19, No. 6, pp. 597-605.
25. Gholamnejad, J., Tayarani, N. (2010), “Application of artificial neural networks to the prediction of tunnel boring mahine penetration rate”, Mining Science and Technology, Vol. 20, No. 5, pp. 727-733.
26. Oraee, K., Khorami, M.T., Hosseini, N. (2012), “Prediction of the penetration rate of TBM using adaptive neuro fuzzy inference system(ANFIS)”, Proceeding of SME Annual Meeting and Exhibit, pp. 297-302.
27. Mahdevari, S., Shahriar, K., Yagiz, S., Shirazi, M.A. (2014), “A support vector regression model for predicting tunnel boring machine penetration rates”, Rock Mechanics and Mining Science, Vol. 72, pp. 214-229.
28. Benato, A., Oreste, P. (2015), “Prediction of penetration per revolution in TBM tunneling as a function of intact rock and rock mass characteristics”, Rock Mechanics and Mining Science, Vol. 74, pp. 119-127.
29. Rostami, J., Ozdemir, L., Nilsen, B. (1996), “Comparison between CSM and NTH hard

- rock TBM performance prediction models”, In Proceedings of The Annual Conference of the Institution of Shaft Drilling Technology (ISDT), pp. 11.
30. Rostami, J. (1997), “Development of a force estimation model for rock fragmentation with disc cutters through theoretical modeling and physical measurement of crushed zone pressure”, Ph.D. Thesis, Colorado School of Mines, pp. 249.
31. Chang, S.H., Choi, S.W., Bae, G.J., Jeon, S.W. (2007), “A parametric study of rock properties and mechanical cutting conditions for deriving an optimum design model of a TBM cutterhead equipped with disc cutters”, Journal of The Korean Society of Civil Engineers, Vol. 21, No. 1(C), pp. 87-98.
32. Ali, M., and Motlagh, M.M., (2014), "Optimal control of DC motor using grey wolf optimizer algorithm", TJEAS Journal Vol. 4, No. 4, pp. 373-379.
33. Commission on Engineering and Technical Systems of USA (1984), Geotechnical site investigation for underground projects, vol. 1 and vol. 2, pp. 182.
34. Sundin, N.O., Wanstedt, S. (1994), “A boreability model for TBM’s”, In 1st North American Rock Mechanics Symposium, American Rock Mechanics Association, pp. 311 - 318.
35. Hamilton, W.H., Dollinger, G.L. (1979), “Optimizing tunnel boring machine and cutter design for greater boreability”, RETC Proceedings, Vol. 1, pp. 280 - 296.
36. 이상춘 (2011), "Particle Swarm Optimization을 이용한 공동주택의 공사비 예측에 관한 연구", 대한건축학회연합논문집, Vol. 13, No. 2, pp. 233-240.
37. 황희수(2002), "적응성 있는 차분 진화에 의한 함수최적화와 이벤트 클러스터링", 한국지능시스템학회논문집, Vol. 12, No.5, pp. 451-461.