

인공신경망 기반의 TBM 터널 세그먼트 라이닝 부재력 평가

유충식^{1*} · 최정혁²

¹정회원, 성균관대학교 건설환경시스템공학과 교수

²비회원, 성균관대학교 건설환경시스템공학과 석사과정

Prediction of TBM tunnel segment lining forces using ANN technique

Chung-Sik Yoo^{1*}, Jung-Hyuk Choi²

¹Professor, Dept. of Civil Engineering, Sungkyunkwan Univ.

²Graduate Student, Dept. of Civil&Envir Engineering, Sungkyunkwan Univ.

ABSTRACT: This paper presents development of artificial neural network(ANN) based prediction method for section forces of TBM tunnel segment lining in an effort to develop an automatized design technique. A series of design cases were first developed and subsequently analyzed using the two-ring beam finite element model. The results were then used to form a database for use as training and validation data sets for ANN development. Using the database, optimized ANNs were developed that can readily be used to predict maximum sectional forces and their distributions. It is shown that the compute maximum section forces and their distributions by the developed ANNs are almost identical to the computed by the two-ring beam finite element model, implying that the developed ANNs can be used as design tools which expedite routine design calculation process. The results of this study indicate that the neural network model can be effectively used as a reliable and simple predictive tool for the prediction of segment sectional forces for design.

Keywords: TBM Tunnel, Segment lining, Finite element analysis, 2-Ring Beam-Spring Model, Artificial neural network

초 록: 본 논문에서는 TBM 터널의 세그먼트 라이닝 설계 자동화 기술 개발의 일환으로 인공신경망기법을 이용한 세그먼트 라이닝 부재력 산정기법 개발에 관한 내용을 다루었다. 부재력 평가가 가능한 인공신경망을 개발하기 위해 먼저 다양한 설계조건을 도출하고 이에 대해 2-Ring Beam 모델을 이용한 유한요소해석을 수행하여 인공신경망 학습에 필요한 설계조건별 부재력에 관한 DB를 구축하였다. 구축된 DB를 활용하여 인공신경망의 최적화 과정을 통해 최대 부재력 및 분포도를 예측할 수 있는 인공신경망을 구축하였다. 검토 결과 구축된 인공신경망은 유한요소해석과 동일한 정밀도의 부재력 산정 기능을 확보하는 것으로 검토되었으며 따라서 TBM 세그먼트 라이닝 설계시 필요한 부재력 평가를 위한 효율적인 수단으로 활용될 수 있는 것으로 판단된다.

주요어: TBM 세그먼트라이닝, 유한요소해석, 2-Ring Beam 모델, 인공신경망

1. 서 론

도심지의 급속한 성장으로 인해 지하철, 도로, 상하수도 등 각종 사회 기반시설의 확충의 필요성으로 현재 많은 터널이 시공되고 있다. 최근 도심 지역 터널 시공에 있어 시공 시 소음, 진동 등의 피해를 최소화 하고 노동력을 절감할 수 있으며 장대 터널

시공에 경제적인 기계화 터널 공법인 쉴드터널 공법을 많은 터널 공사에 적용하고 있다. 터널 기계화 시공 기술이 더욱 발전하여 현재에는 지하철, 도로 뿐만이 아니라 전력구, 통신구, 등 다양한 종류의 터널 시공에 널리 적용되고 있다.

Fig. 1은 TBM 터널의 핵심 지보공인 콘크리트 세그먼트 라이닝의 설계 순서도를 보여주고 있다. Fig. 1에서 제시된 바와 같이 세그먼트 라이닝의 설계에서는 먼저 라이닝의 두께와 철근량을 가정하고 설계조건에 대한 작용하중(토압)을 산정한 후 이론식이나

*Corresponding author: Chung-Sik Yoo
E-mail: csyoo@skku.edu

Received December 9, 2013; Revised December 19, 2013;
Accepted December 27, 2013

유한요소해석을 수행하여 부재력을 산정하여 세그먼트 발생 응력이 허용응력 이내에 드는지에 대한 검토 과정을 통해 설계가 이루어진다. 이때 사용하는 대표적인 이론식으로는 ITA (2000)에 제시되어 있는 Elastic Equation 모델 및 Muirwood (1975)가 제안한 탄성 모델, 그리고 Duddeck and Erdmann (1985)이 제안한 연속체 해석 방법이 있다. 한편, 유한요소해석에서는 Beam-Spring 해석 개념의 1-Ring 혹은 2-Ring Beam 모델을 이용하며 세그먼트간의 이음부를 모델링을 위해 이음부의 전단 및 수직 스프링계수 적용하여 반복해석을 수행하여야 하는 등 다소의 시간이 소요된다.

본 연구에서는 TBM 터널 세그먼트 설계의 자동화 기술 개발의 일환으로 설계에 필요한 부재력 산정과정의 효율성을 높이기 위해 인공신경망(Artificial Neural Network, ANN)을 이용한 세그먼트 라이닝 부재력 산정 기법의 개발을 시도하였다. ANN은 인공지능기법의 한 종류로서 공학 분야에 있어 기존의 많은 연구자들에 의해 예측의 수단으로서 그 적용성

을 인정받아 왔다. 특히 터널 및 지반공학 분야에서 예측을 위한 도구로서 활용된 바 있으며 대표적인 연구로는 터널 거동 평가 예측 시스템에 적용한 Yoo and Kim (2007)의 연구와 아울러 깊은 굴착에 따른 지표면위 예측(Yoo and Choi 2004), 지보패턴예측 시스템 개발(Yoo et al. 2005), 터널 시공 중 3차원 거동 예측 기법 개발(Yoo et al. 2006b) 등의 연구에서 그 적용성을 검증한바 있다. ANN 구축에 있어 본 연구에서는 2-Ring Beam 모델을 이용한 유한요소 해석을 통해 학습에 필요한 데이터를 확보 하고 이를 토대로 최적화된 인공신경망 엔진을 구축하여 간단한 터널 시공조건에 대한 입력을 통해 세그먼트 라이닝 설계에 필요한 최대 부재력 및 부재력도를 예측할 수 있도록 하였다. 구축된 ANN은 현장 적용성 평가를 위해 임의의 세 개의 조건에 대한 검증을 실시하였으며 검증결과 높은 신뢰성을 확보할 수 있는 것으로 검토되어 설계 시 부재력 예측 수단으로서 활용할 수 있는 것으로 검토되었다.

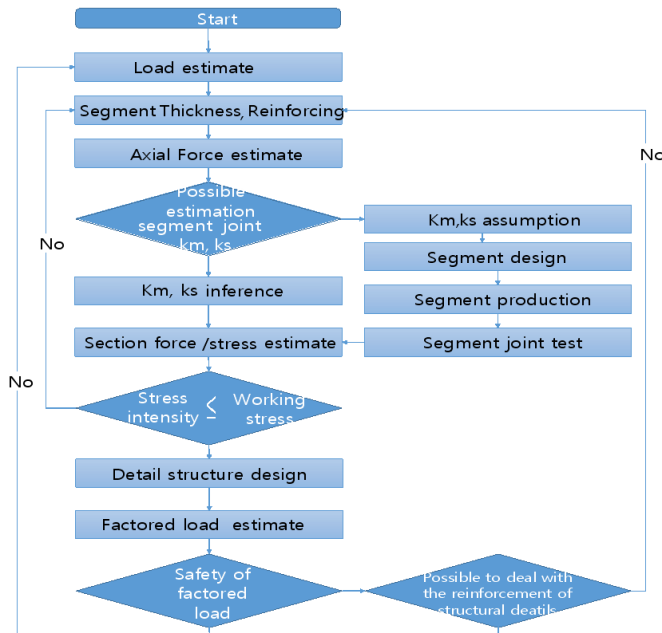


Fig. 1. Example design flow of reinforced concrete segmental lining

2. 인공신경망 기본 이론

2.1 기본개념

인공신경망은 인간두뇌의 신경조직 기본단위인 뉴런 특성을 컴퓨터에 모델링 한 것으로 인공신경망 모델에서 뉴런의 역할은 처리요소와 활성화 함수가 수행한다. Fig. 2는 인공신경망의 구조를 보여주고 있으며 일반적으로 가장 많이 사용되는 인공신경망은 다층퍼셉트론에 근거하며 다층퍼셉트론은 입력층(Input Layer)과 출력층(Output Layer)과 함께 연산 작용을 수행하는 은닉층(Hidden Layer)이 존재한다(Yoo et al. 2006a).

다층퍼셉트론은 비선형 함수로서 다 입력과 다 출력의 사상관계를 표현할 수 있다. 입력데이터와 출력데이터의 상관관계는 신경망 내부 파라미터의 뉴런을 연결한 가중치로 표현되므로 가중치가 바뀌면 신경망의 입출력 역시 바뀌게 된다. 이러한 가중치를 결정하기 위하여 일련의 데이터로 인공신경망을 훈련시키는 과정을 학습과정이라고 하며 역전파 알고리즘이 가장 대표적이다(Yoo et al. 2006b).

역전파 알고리즘은 아래의 식 (1)에 나타난 것처럼 오차 제공들을 합하여 얻어지는 목적함수를 최소화시키는 방식으로 weight와 bias 값을 계산한다. 인공신경망에 대한 구체적인 이론적 내용은 Hecht-Nielsen (1990)에 기술되어 있다.

$$\epsilon^2 = [t_q - f_{qk}]^2 \quad (1)$$

여기서, t_q : 목표 타겟

f_{qk} : 네트워크 출력 값

ϵ : 가중치 Matrix

3. ANN 기반의 TBM 세그먼트 라이닝 부재력 산정

3.1 기본개념

앞서 기술한 바와 같이 TBM 터널의 세그먼트 라이닝 설계에서는 주어진 설계 조건에 대한 작용토압을 산정하여 세그먼트에 발생하는 부재력을 산정하여야 한다. 부재력은 일반적으로 관용법 등의 이론식이나 1-Ring 혹은 2-Ring Beam 모델을 이용한 유한요소해석을 사용하여 산정하게 되는데 해석 단면의 수가 많아질 경우 루틴한 모델링이 반복적으로 수행되어야 한다. 이 본 연구에서는 세그먼트 라이닝 설계시 필요한 세그먼트 라이닝의 부재력 평가 작업의 자동화의 일환으로서 인공지능의 일종인 인공신경망(Artificial Neural Network, ANN)을 이용한 부재력 평가 기법의 개발을 시도하였다. Fig 3은 본 연구에서 시도한 인공신경망 기반의 세그먼트 라이닝 자동화 평가 개념도로서 다양한 시공조건을 도출하고 이에 대한 2-Ring Beam 모델을 이용한 유한요소해석을 통해 세그먼트 부재력에 대한 DB를 구축한 후 이에 대한 학습을 통해 설계조건에 대한 부재력 예측이 가능한 ANN을 개발 수단으로 활용하는 것에 기본 개념을 두고 있다.




Fig. 2. Artificial neural network structure

3.2 ANN 엔진 구축

3.2.1 대상 조건

본 연구에서는 Table 1에서 제시된 터널 및 지층 조건을 대상으로 하였다. 즉, Table 1에서와 같이 고려한 시공조건은 외경 $D=7\sim 10$ m의 TBM 터널이 심도 $H=30$ m에 시공되는 조건을 대상으로 하였으며 관통 지층은 충적층내지 풍화암으로 이루어지는 조건 고려하여 지반의 지반공학적 특성으로서 점착력 $c=0\sim 100$ kPa, 내부마찰각 $\phi=25\sim 30^\circ$, 측압계수 $k_0=0.4$

~ 0.6 , 지반의 변형계수 $E=20\sim 70$ MPa 범위의 값을 고려하였다. 한편, 라이닝에는 길이 1.5 m 두께 0.4 m의 세그먼트가 적용되며 한 개의 세그먼트 링에 대해서 설치각도 18.94° 의 Key 세그먼트를 포함하여 7개 세그먼트로 조립되는 것으로 가정하였다.

3.2.2 구조해석을 통한 DB 구축

ANN 학습을 위한 DB 구축을 위해 앞서 기술한 조건에 대해 다양한 단면을 형성하고 구조해석프로그램인 SAP2000을 이용하여 유한요소해석을 수행 하였

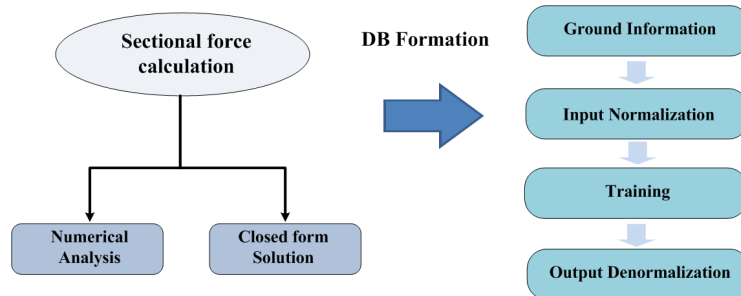


Fig. 3. Concept of ANN-based section forces prediction

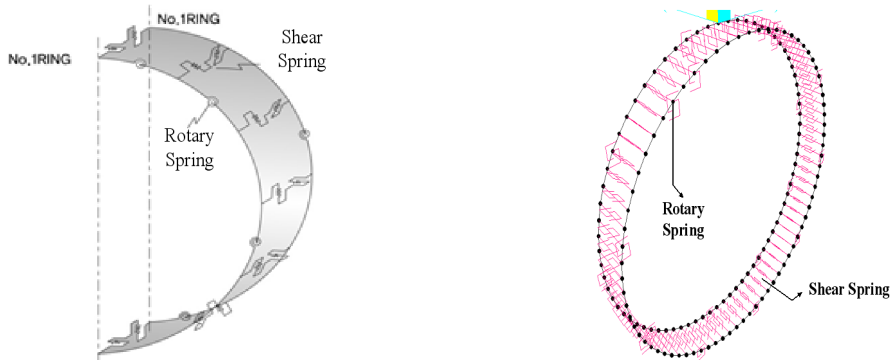


Fig. 4. 2-Ring Beam-Spring Model

Table 1. Range of design variables considered

Data Range	D (m)	H (m)	c (kPa)	ϕ ($^\circ$)	E (MPa)	γ (kN/m^3)	k_0	ν
Maximum	10	30	100	35	70	20	0.6	0.29
Minimum	7	10	0	25	20	18	0.4	

Notice) c = Cohesion, ϕ = Friction angle, E = Young modulus, γ = Unit weight, H = Depth of soil, k_0 = Lateral earth pressure coefficient, ν = Poisson Ratio, D = Tunnel Diameter,

다. 총 해석단면의 수는 54개 해석조건 이며 때 2-Ring Beam-Spring 모델(Fig. 4)을 사용하였다.

일반적으로 Beam-Spring 모델은 지반을 반력스프링으로 고려하는 방법으로서 이음부를 고려하는 방법에 따라 강성일체법, 회전스프링법, 그리고 힌지법으로 분류되며(KTA, 2008) 본 논문에서는 회전스프링법을 이용한 모델을 구축하여 해석을 수행하였다.

2-Ring Beam-Spring 모델에서는 이음부 스프링 정수 값이 필요하며 이들은 아래 식 (2), (3), (4), (5)를 이용하여 산정하였다. 회전스프링계수 산정 시 필요한 압축외연에서 중심축까지의 거리 x 는 식 (3)을 이용하여 산정하였으며 영계수 비(n)는 7을 적용하였다(Yoo and Jeon 2012).

$$K_m = \frac{M}{\theta} = \frac{x(3h-2x)bE_c}{24} \quad (2)$$

$$x = \frac{nA_b}{b} \left(-1 + \sqrt{1 + \frac{2bd}{nA_b}} \right) \quad (3)$$

여기서, M : 휨모멘트

b : 세그먼트의 폭

A_b : 볼트의 단면적

θ : 회전각

x : 압축외연에서 중심축까지의 거리

H : 세그먼트의 두께

d : 유효 깊이

n : 영계수 비

전단 스프링 계수(K_s)는 반경방향과 접선방향 두 방향으로 적용되며 프와송비 0.32를 적용하였고 세그먼트의 폭과 높이를 이용하여 단면2차모멘트를 계산하여 적용 하였다. 반경방향의 전단스프링 계수(K_{sr})와 접선방향 전단스프링 계수 산정에는 각각 식 (4)와 식 (5)를 사용하였다(Yoo and Jeon 2012).

$$K_{sr} = \frac{192EI}{(2b)^3} = \frac{24EI}{b^3} \quad (4)$$

$$K_{st} = \frac{b'hG}{b} = \frac{b'hE}{2b(1+v)} \quad (5)$$

여기서, E : 콘크리트의 탄성계수

I : 세그먼트의 단면이차 모멘트

b : 세그먼트의 폭

b' : 세그먼트 축방향의 이음간격

h : 세그먼트 높이

G : 전단탄성계수

v : 프와송 비

3.3 최대 부재력 산정 ANN 구축 및 학습

3.3.1 ANN 구조

ANN 엔진은 Math Works Inc.에서 개발한 Matlab R2012b (MATrix LABoratory, 2012)를 사용하였으며 인공신경망의 모델을 구축하기 위한 훈련방법으로 역전파(back propagation neural network) 알고리즘을 적용하였다. ANN은 일반화된 델타 규칙을 접목시켜




Fig. 5. ANN optimization process

출력 뉴런들의 전체 제곱오차를 감소시켰으며 오차의 최소값을 구하기위해서 가중치 표면의 기울기를 이용하는 최급 하강법을 사용하였다. 또한 오차를 계산하기 위한 알고리즘으로 오차표면에서 기울기가 가장 큰 기울기의 방향을 찾는 것으로 오차를 줄이기 위한 방향을 결정하는 알고리즘을 사용하였다.

본 연구에서는 위 기법을 근간으로 하여 기본 구조로서 입력노드와 출력 뉴런 사이에는 2개의 은닉층이 존재하는 구조를 선택하였으며 학습율과 모멘텀(Momentum), 그리고 은닉층의 뉴런 수 조절을 통해 최적화되어 예측이 가능한 구조를 채택하였다. Fig. 5는 ANN 구조 최적화 과정을 나타낸 것으로 ANN 구조를 최적화하기 위해서 은닉층 뉴런의 범위 1~10 안에서 각각의 은닉층 수를 변화를 주어 학습을 수행하였으며 학습율의 RMSE (Root Mean Square Error) 을 학습시 고려하는 과정을 통해 ANN구조를 최적화시켰다. 본 연구에서 수행된 ANN 내적인자 연구결과 은닉층의 뉴런을 6개로 사용할 경우 학습률이 최적화 되는 것으로 검토되었다.

Table 2는 ANN 엔진 구축에 적용된 입력 파라메타와 출력 파라메타를 보여주고 있다. 입력 파라메타의 경우 터널의 기하조건 및 시공조건, 그리고 관통하는 지층의 지반공학적 특성을 반영하여 8개의 항목을 입력 파라메타로 선정하였으며 세그먼트 라이닝 설계시 필요한 세그먼트 축력 및 모우멘트 그리고 전단력

등 부재력을 출력 파라메타로 선정하였다.

3.3.2 ANN 학습

ANN 학습을 수행하기에 앞서 대상 시공조건에 대한 해석결과에 대한 DB를 분류하였다. 데이터 분류는 학습 세트(training set), 신뢰성 검증 세트(validation set)과 시험을 위한 테스트 세트(testing set) 등 세 그룹으로 분류하였다. 이때 학습데이터가 과 적합(Over fitting)되어 학습 시 사용되지 않은 데이터들에 의한 예측 신뢰도가 저하되는 것을 방지하기 위하여 전체 데이터를 정성, 정량적 분포가 균등하도록 하였다. 학습 데이터의 분배는 단면(100%)의 학습 자료는 학습 세트 41개 단면(75%)과 신뢰성 검증 세트 5개 단면(10%), 그리고 테스트 세트 8개 단면(15%)로 배분하여 학습에 적용하였다. 구조해석을 통해 구축된 DB에 대한 각 부재력 항목별 범위가 Table 3에 제시되어 있다.

본 연구에서는 ANN 엔진을 적용하기 위한 과정으로서 ANN의 weight (W)와 bias (b)를 추출하여 공학적 연산이 가능하도록 다음의 식 (6)의 관계를 정의하여 구축하였으며, p_n 은 입력정보를 표현하는 항으로 정규화 과정을 거쳐서 p_n 으로 입력하게 된다.

$$t_n = 1 + f_2 \{ W_2 \times f_1 (W_1 (1 - abs (2 \times (p_n - 1)))) + b_1 \} + b_2 / 2 \quad (6)$$

Table 2. Input and output parameters for ANN

Input parameter		Output parameter
·Tunnel diameter	·Lateral pressure ratio	·Axial force ·Shear force ·Bending moment
·Density	·Cohesion	
·Depth of soil	·Friction angle	
·Poisson ratio	·Young modulus	

Table 3. Data ranges used for ANN generalization

Data range	Axial force, N (kN)	Bending moment, M (kN·m)	Displacement, δ (mm)	Shear Force, V (kN)
Maximum	2662.3	175.4	50.23	719.1
Minimum	309.9	15.9	5.95	64.5

여기서, p_n 과 t_n 은 각각 정규화 된 입력 값과 목표 값이며, $W_1 \sim W_2$ 은 weight (W), $b_1 \sim b_2$ 는 bias (b)를 나타낸다. 그리고 f_1, f_2 는 전이함수로서 f_1 는 은닉층의 활성화함수로 식 (7)의 Tansigmoid 함수를 나타낸 것이며 Input 을 $-1 \sim 1$ 로 정규화 시켜주는 함수이다. f_2 는 출력층 활성화함수로 식 (8)의 Purelin 함수로 정의하였다.

$$f_1 = \text{tansig}(n) = y = \frac{2}{1 + \exp(-2n)} - 1 \quad (7)$$

$$f_2 = y = f(x) \quad (8)$$

여기서, n 과 y 은 각각 입력 및 출력치를 나타낸다. 위의 연산 계산식을 이용하여 학습을 수행하였으며 학습결과를 결정계수(R^2)를 이용하여 학습율의 신뢰성을 확인 하였으며 결정계수(R^2) 0.99% 이상 확보 시 학습을 종료 하였다 .

3.3.3 ANN 학습 결과

Fig. 6와 7에서는 각각 학습결과 및 검증결과를

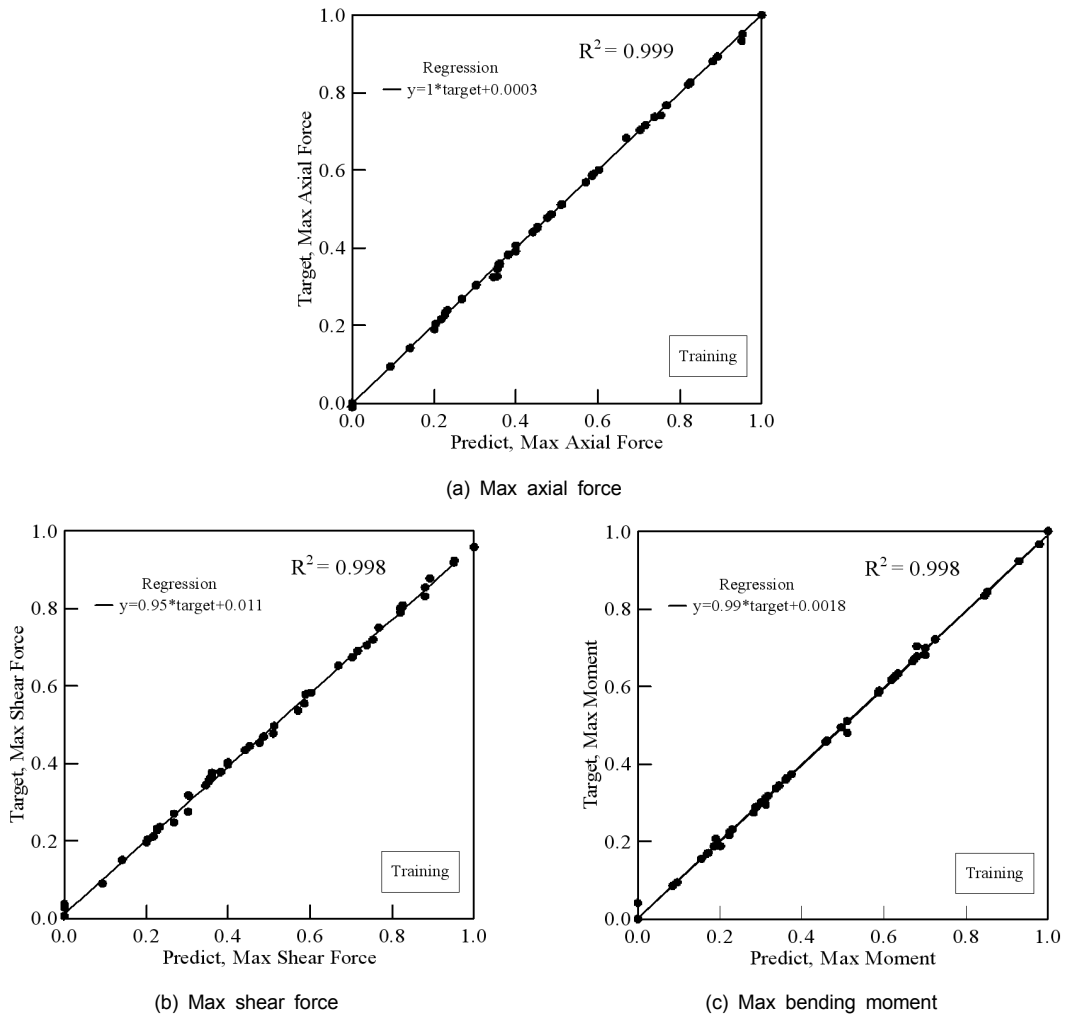


Fig. 6. Comparison of computed versus predicted values for training

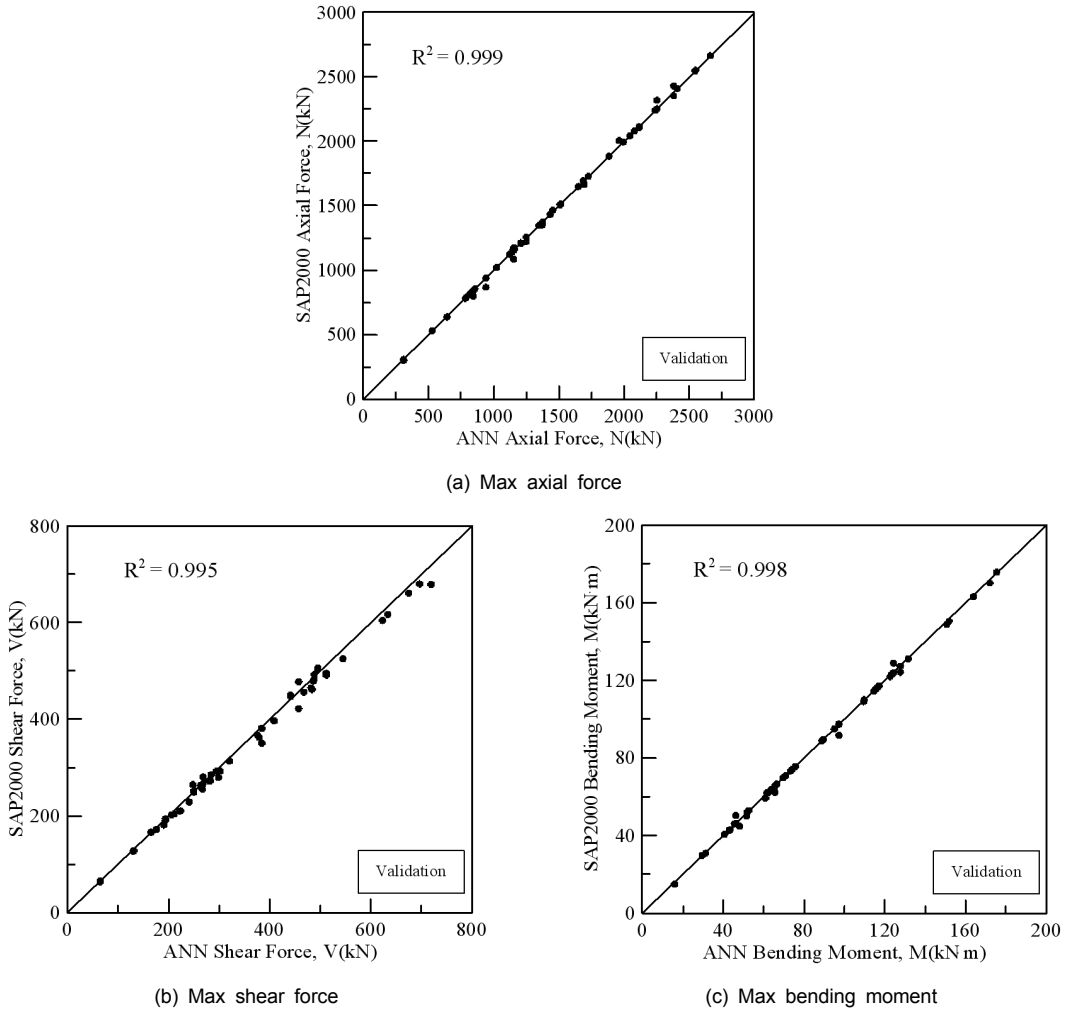


Fig. 7. Comparison of computed versus predicted values for validation

Table 4. Performance of ANN

Classification		Displacement, δ (mm)	Bending Moment, M (kN·m)	Axial Force, N (kN)	Shear Force, V (kN)
R^2	Training	0.99	0.99	0.99	0.99
	Testing	0.99	0.97	0.96	0.97
	Validation	0.86	0.99	0.99	0.99
$RMSE$	Training	0.99	0.94	0.69	0.20
	Testing	3.21	0.87	1.54	1.29
	Validation	5.51	1.12	1.24	1.84
MAE	Training	0.81	0.35	0.36	0.28
	Testing	1.06	0.58	0.78	0.95
	Validation	1.7	0.12	0.70	0.90

보여주고 있다. 학습대상 조건에 대한 유한요소해석 결과와 ANN 예측 결과를 비교하고 있는 이 Fig에서는 모든 부재력에 있어서 각 부재력에 대한 학습결과는 예측값과 비교 시 최대값의 결정계수(R^2)가 평균 99% 이상으로 분석되었으며 검증결과에서도 99% 이상의 결정계수를 확보하는 것으로 검토되었다. 또한 Table 4에서는 구축된 ANN의 예측기능을 통계지수인 결정계수(R^2), RMSE (Root Mean Square Error), MSE (Mean Square Error)를 이용하여 나타내었으며 매우 우수한 예측 성능을 보유하는 것으로 검토되었다. 이러한 결과는 본 연구에서 구축한 ANN 엔진의 학습 결과가 높은 신뢰성을 확보하는 것을 의미하며 아울러 TBM 터널의 세그먼트 라이닝 부재력 산정 시 예측수단으로서 유한요소해석을 수행하는 대체수단으로서 본 연구에서 구축된 ANN을 활용할 수 있음을 확인하였다.

3.4 부재력도 산정을 위한 ANN 구축 및 학습

3.4.1 개념

TBM 세그먼트 설계를 위해서는 최대 부재력 산정 뿐만 아니라 세그먼트 링 전반에 걸쳐 분포하는 부력의 산정이 필요하다. 이에 본 연구에서는 이전 3.3절에서 기술한 최대 부재력 산정 ANN 구축과정에서 구축한 다양한 조건에 대한 유한요소해석 결과를 활용하여 부재력도에 대한 DB를 구축하고 이를 활용하여

부재력도를 산정하는 ANN 엔진을 구축하였다.

Fig. 8은 ANN 엔진을 이용한 부재력도 산정에 대한 흐름도를 나타낸 것으로서 부재력도 산정은 유한요소 해석 모델의 각 Node별 부재력에 대해서 정규화를 시켜 DB를 구축하고 구축된 Node별 부재력 DB를 앞서 ANN엔진에서 사용된 입력 파라미터를 이용하여 학습을 시켜 부재력도 예측 ANN을 구축하였다.

3.4.2 학습 DB 구축 및 엔진구축

ANN 학습을 위한 DB 구축을 위해 먼저 기 구축된 DB를 활용하여 Node별 부재력을 추출하여 아래 식 (9)을 이용하여 Node별 부재력에 대한 정규화된 DB를 구축하였다. 식 (9)에서 x 는 입력 값이며 x_{max} 와 x_{min} 은 구축된 DB에서 터널 직경별 최대값과 최소값을 나타낸다.

$$x_{target} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (9)$$

$$output = x_{target}(x_{max} - x_{min}) + x_{min} \quad (10)$$

이러한 방법으로 구축된 학습 DB를 이용하여 앞서 기술한 동일한 방법으로 ANN 엔진을 구축하였다.

3.4.3 구축된 ANN 검증

본 절에서는 ANN DB로 구축된 지층 조건 중에서

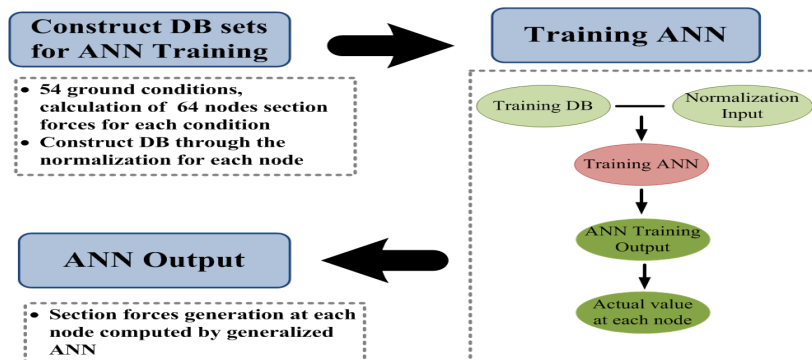


Fig. 8. Concept of ANN development for section force distribution

3개의 케이스를 무작위로 선정하였으며 예측값을 통해 얻은 부재력도와 SAP2000을 이용하여 수치해석을 통해 얻은 부재력도를 비교하였다. 아래 Table 5는 검증에 적용된 임의의 Case에 대한 시공조건을 정리한

것으로 시공조건은 앞서 ANN Input DB 구축에 사용된 입력 파라미터를 사용하였다.

Fig. 9~11은 Table 5의 세 가지 시공조건에 대해 ANN으로 예측한 부재력도와 유한요소해석으로부터

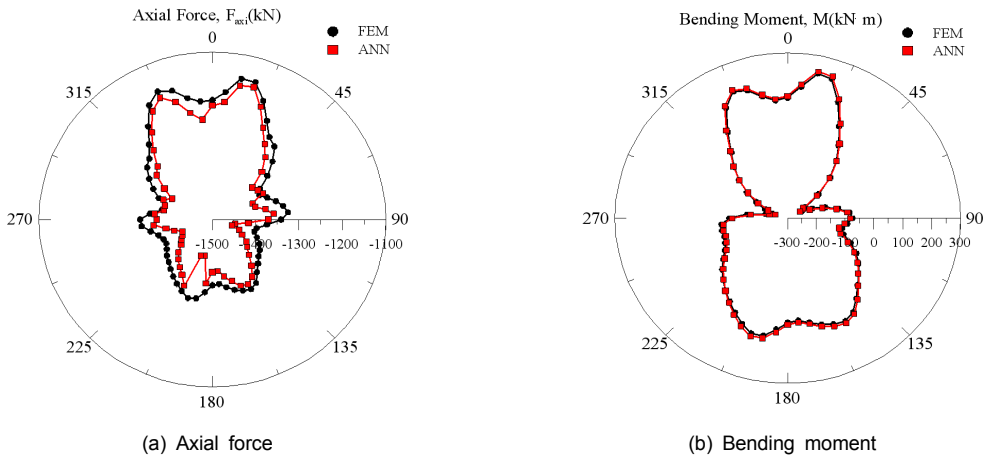


Fig. 9. Comparison of predicted section forces by ANN with computed by FEA - Case 1

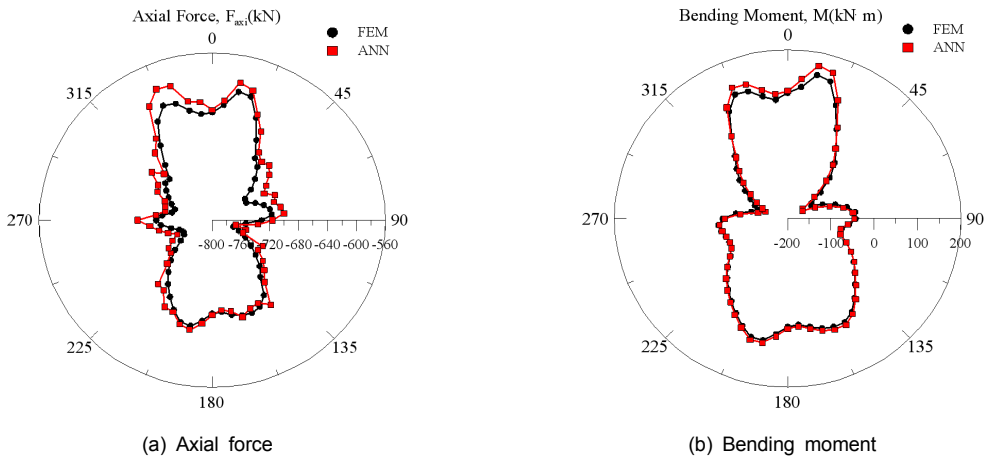


Fig. 10. Comparison of predicted section forces by ANN with computed by FEA - Case 2

Table 5. Segment lining geometries and ground conditions considered for validation

Case	Ground	D (m)	H (m)	c (kPa)	ϕ ($^{\circ}$)	E (kPa)	γ (kN/m^3)	k_0	ν
1	Alluvial layer	7	10	5	25	20,000	19	0.577	0.29
2	Alluvial layer	7	10	10	30	30,000	18	0.5	0.29
3	Alluvial layer	10	10	5	25	20,000	19	0.577	0.29

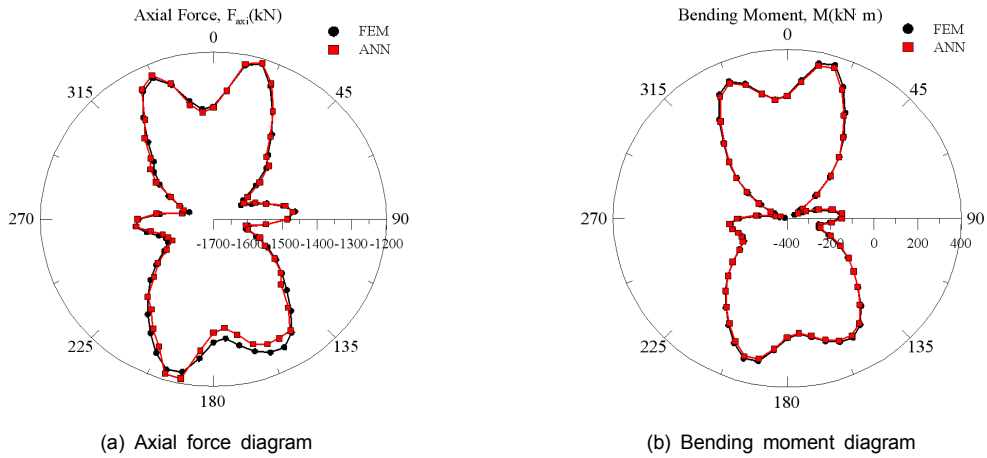


Fig. 11. Section force diagram compare results graph - Case3

얻어진 부재력도의 비교를 나타내고 있다. 이 Fig들에서 관찰할 수 있는 바와 같이 힘 모멘트의 경우 3개 Case의 평균 결정계수(R^2) 99.8% 이상인 것으로 나타났다. 이에 비해 축력도의 경우 Case 별로 결정계수 차이가 나타났으며 평균 95.8%으로 나타났다.

4. 결론

본 논문에서는 TBM 터널 세그먼트 설계의 자동화 기술 개발의 일환으로 설계에 필요한 부재력 산정과정의 효율성을 높이기 위해 인공신경망(Artificial Neural Network, ANN)을 이용한 세그먼트 라이닝 부재력 산정 기법의 개발 내용에 대해 다루었다. ANN 구축에 있어 2-Ring Beam 모델을 이용한 유한요소 해석을 통해 학습에 필요한 데이터를 확보 하고 이를 토대로 최적화된 인공신경망 엔진을 구축하여 간단한 터널 시공조건에 대한 입력을 통해 세그먼트 라이닝 설계에 필요한 최대 부재력 및 부재력도를 예측할 수 있도록 하였다. 구축된 ANN은 현장 적용성 평가를 위해 임의의 세 개 조건에 대한 검증을 실시하였으며 검증결과 높은 신뢰성을 확보할 수 있는 것으로 검토되어 설계 시 부재력 예측 수단으로서 활용할 수 있는 것으로 검토되었다. 그 결과를 요약하면 다음과 같다.

1. 2-Ring Beam 모델을 이용한 최대축력 및 모우멘트 등 부재력 DB를 토대로 구축된 ANN은 본 연구에서 대상으로 한 시공조건에 대한 검증 결과 99%이상의 결정 계수를 보이는 것으로 나타나 부재력 예측에 있어 매우 높은 신뢰도를 을 확보하는 것으로 검토되었다.
2. 최대 부재력과 아울러 세그먼트 전체에 대한 부재력도 예측을 위한 ANN 구축 결과 최대 부재력 평가를 위한 ANN 보다는 예측에 있어서의 신뢰도가 다소 떨어지나 예측결과를 유한요소해석 결과와의 비교 시 95%이상의 결정계수를 보이는 것으로 나타나 실무에서의 적용이 가능한 것으로 평가되었다.
3. 본 연구를 통해 구축된 ANN은 학습 DB 구축을 위해 고려한 시공조건에는 실무적 적용이 가능한 것으로 검토되었다. 다만 구축된 ANN의 현장 적용성을 높이기 위해서는 향후 추가적인 연구를 통해 지층조건 및 세그먼트 라이닝의 기하조건 등 보다 다양한 조건에 대한 고려가 필요할 것으로 판단되며 향후 현장계측 자료를 이용한 신뢰성 검증이 필요할 것으로 판단된다.

감사의 글

본 논문은 한국건설교통기술평가원의 건설기술혁신사업인 “TBM 핵심 설계·부품기술 및 TBM터널의 최적 건설기술”(과제번호: 10기술혁신E09) - “세그먼트 라이닝의 지식 기반형 자동화 설계 시스템 개발”와 “해저터널 기술개발”(과제번호 13건설연구T01) - “Mechanical-Hydraulic Coupling이 고려된 BIM 기반하의 안정성 자동화 해석 기술”의 일환으로 작성되었습니다.

References

1. Yoo, C.S., Choi, B.S. (2004), “Prediction of deep Excavation-induced ground surface movements using artificial neural network”, Journal of Korean Geotechnical Society, Vol. 20, No. 3, pp. 53-65.
2. Yoo, C.S., Jung, H.Y., Kim, J.M. (2005), “Development of support pattern prediction system using ANN”, KSCE Conference, pp. 5563-5566.
3. Yoo, C.S., Kim, J.M., Kim, S.B., Jung, H.Y. (2006), “Tunnel design/construction risk assessment base on GIS-ANN”, Journal of the Korean Society of Civil Engineers, Vol. 26, No. 1C, pp. 63-72.
4. Yoo, C.S., Kim, S.B., Byun, J., Han, D.H. (2006), “ANN-Based prediction on tunnel behavior”, KGS Fall Conference, pp. 2073-2080.
5. Yoo, C.S., Jeon, H.M. (2012), “A comparative study on methods for shield tunnel segment lining sectional forces”, Journal of Korean Tunnelling and Underground Space Association, Vol. 14, No. 3, pp. 159-181.
6. Yoo, C.S., Kim, J.M. (2007), “Tunneling performance prediction using an intergrated GIS and neural network”, Computers and Geotechnics, Vol. 34, pp. 19-30.
7. KTA (2008), “3rd Mechanized tunnel construction tunnel design service Technical Conference”, KTA, pp. 457-458.
8. Muirwood, A.M. (1975), “The circular tunnel in elastic ground”, Geotechnique, Vol. 25, No. 1, pp. 115-127.
9. Duddeck, H., Erdmann, J. (1985), “Structure design for tunnels”, Tunnel82, Proceedings of the 3rd international symposium, Brighton, 7-11 June 1982, pp. 83-91.
10. Hecht-Nielsen, R. (1990), Nerocomputing, Addison-Wesly, Readings, Mass.
11. International Tunnelling Association Working Group No. 2. (2000), “Guidelines for the Design of Shield Tunnel Lining”, Tunnelling and Underground Space Technology, Vol. 15, No. 3, pp. 303-331.