

인공신경망을 적용한 지반 전단강도정수와 콘지수 사이의 상관관계 분석 1

문인종¹, 김영욱^{*}
¹명지대학교 토목환경공학과

Correlation Analysis between Soil Shear Strength Parameters and Cone Index Using Artificial Neural Networks - 1

In-Jong Moon¹, Young-Uk Kim^{*}

¹Department of Civil and Environmental Engineering, Myongji University

요약 본 연구에서는 국내 지반의 전단강도정수와 콘지수 사이의 상관관계를 확립하기 위하여 먼저 콘관입 모델을 통한 이론적 상관관계를 정리하고 이의 신뢰도를 높이기 위하여 인공신경망 기법을 적용하였다. 이론적 상관관계는 이론식을 유도하면서 적용한 가정들로 인하여 신뢰성 있는 지반의 거동을 예측하기 어려운 측면이 있다. 따라서 인공신경망 기법을 적용하여 이론적, 경험적 방법과 같은 기존의 방법과는 다른 새로운 측면에서 지반의 거동 특성을 파악할 필요성이 있다. 인공신경망 모델은 국내의 다양한 건설현장에서 수행한 지반조사 보고서를 통해서 입력자료를 확보한 뒤에 모델학습을 수행하였다. 연구결과 측정값과 예측값의 오차가 크지 않았고, 비교적 고르게 분포함을 알 수 있었다. 추후 보강된 인공신경망 모델을 구축하면 국내 특정 지역뿐만 아니라 일반화된 지역에 보편적으로 적용할 수 있을 것으로 기대된다.

Abstract This study has been undertaken to develop a relationship between the shear strength coefficients and the cone index. The theoretic mathematical equations for the relationship were rigorously investigated, and then a Artificial Neural Network(ANN) analysis was adapted to enhance the reliability of the investigation. The theoretical investigation involved various assumptions resulting in the significant error involvement of geotechnical behaviors of ground. Therefore, a model using the ANN has been learned to enhance the prediction of the cone index form the shear strength parameters. Site investigation reports from various construction fields were used for ANN model learning. The results of the study show that the model predicts the cone index from the shear strength parameters of soils very well. The further study that is undertaking has a potential promise of the generalized prediction technique for the cone index from the soil parameters.

Key Words : Shear strength, Cone index, Artificial Neural Network, Geotechnical behaviors

1. 서론

구조물 기초 설계에서 지반조사를 실시할 경우 가장 먼저 알아야 하는 인자들 중 하나가 지반의 강도이다. 지반 강도를 측정하는 기법들은 다양하게 개발되어 왔는데,

그 중 콘(Cone)을 이용한 측정법도 이에 포함된다. 콘을 지반에 관입할 때 저항의 정도를 평가하여 지반의 강도를 예측하는 것으로써 다른 시험들에 비하여 비교적 쉽고 빠르게 값을 얻을 수 있다는 장점이 있어 광범위하게 이용하고 있다[1].

본 연구는 한국 국방과학연구소의 지상체계분석특화연구실과 2014년도 명지대학교 교책중점연구소의 지원을 받았으며, 이에 감사드립니다.

*Corresponding Author : Young-Uk Kim(Myongji Univ.)

Tel: +82-10-3153-6417 email: yukim@mju.ac.kr

Received November 17, 2014

Revised December 29, 2014

Accepted March 12, 2015

Published March 31, 2015

자동차 개발 분야에서도 지반의 강도 평가에 대한 다양한 이론 및 실험이 진행되고 있다. 차량의 이동성을 나타내는 기동성 평가 시 차량의 기계적 성능뿐만 아니라 바퀴의 접지체, 즉, 포장이나 야지의 강도가 매우 중요한 인자로 인식되고 있다[2, 3]. 미육군공병단(US Army Engineer Water- ways Experiment Station, WES)에서는 차량 이동 경로가 야지로 국한될 경우 차량의 기동성 평가에 사용할 지반 강도의 신속한 측정과 적용을 위하여 콘을 사용하도록 제안하고 있다[4].

NATO에서도 야지를 차량이 이동할 경우 다양한 조건에서의 최고속력을 예측할 수 있는 프로그램(NATO Referenced Mobility Module, NRMM)을 개발하여 전쟁 시뮬레이션 및 차량 개발 및 설계에 활용하고 있다. 이 프로그램에서 콘지수(Cone Index, *CI*)를 지반 강도의 입력데이터로 활용하고 있으며 기동성 평가를 위해서는 반드시 콘지수를 확보하여 입력 자료로 활용해야만 한다[4].

그러나 일반적인 지반조사나 구조물 기초 설계 시 콘을 사용하는 경우가 드물고 지반 강도 평가 인자로 콘지수보다는 점착력(*c*)과 전단저항각(ϕ)을 주로 사용하고 있다. 콘을 사용하여 지반조사를 하는 경우에는 일부 연약지반조사에 국한되어 있는 실정이다. 따라서, 일반적인 대상 지반의 경우 지반 강도 측정 데이터는 대부분 점착력과 전단저항각으로 이루어져 있으며 많은 양의 데이터가 이미 축적되어 있다고 할 수 있다. 만약 상기의 프로그램을 활용하여 대상 야지의 기동성을 판단하기 위해서는 지반의 점착력과 전단저항각에 대한 값이 이미 존재한다고 하더라도 콘지수를 다시 측정하여 입력 값으로 사용해야 한다. 이는 광범위한 지역에 대한 측정을 요구하는 작업으로 경제적인 측면에서 불리하고, 신뢰성 높은 콘지수를 얻기가 가능하지 않다는 결론에 도달할 수 있다[5]. 그러므로 이미 많이 축적되어 있는 지반 전단강도정수를 콘지수로 변환할 수 있는 상관관계를 도출한다면 경제적인 면에서 유리하고, 이미 측정된 많은 데이터의 사용에 따라 콘지수의 신뢰성을 높일 수 있게 된다.

이 연구에서는 인공신경망 기법을 적용하여 지반의 전단강도정수와 콘지수의 상관관계에 대한 모델을 확립하고자 하였다. 즉, 이미 측정된 지반의 전단강도정수를 활용하여 신뢰성 있는 콘지수를 예측하는 모델 개발에 그 목적이 있다. 이를 위하여 국내의 다양한 건설현장에서 수행한 지반조사 보고서를 바탕으로 여러 종류의 지


반 강도정수를 동일 위치에서의 콘지수와와의 상관성을 조사하고 이를 바탕으로 신경망 학습을 수행하였다.

2. 이론적 관계

2.1 콘지수 (cone index)

기동성 판단에 있어서 지반을 구성하고 있는 흙의 강도는 콘지수로 정의된다. 콘지수는 미육군공병단에서 처음 제안한 것으로 차량의 야지 기동성 평가를 위해서 대상 지반 조사 시 사용된 개념이다. 콘지수는 콘관입시험기를 이용하여 비교적 쉽게 지반의 강도를 측정할 수 있는 장점이 있어 일반적인 지반조사에 많이 이용되어 왔다. 하지만 기동성 판단에서의 콘지수는 기동차량으로 인한 하중분포가 표층에 국한된다는 가정 하에 대상지반을 표층에 한정하여 측정한다. 이는 대상지반에서 상당한 깊이까지 콘관입을 시켜 조사하는 일반적인 지반조사와는 약간의 차이가 있다[1].

미육군공병단에서 개발한 콘관입시험기는 손잡이와 proving ring이 장착된 원형 막대 끝에 저면적(base area)이 3.23cm^2 이고 30° 의 정각을 갖는 원형콘을 부착한 것으로 Fig. 1과 같다. 콘관입시험기는 이것을 지반에 관입하여 지반 반력을 측정하며, 콘지수는 단위 저면적당 지반 속으로의 관입저항으로 정의한다.



[Fig. 1] Cone penetrometer

2.2 전단강도정수(shear strength parameters)

Coulomb은 2가지의 물체가 접촉하여 미끄러질 때 접촉면에 발생하는 활동저항 S 는 그 면에 수직으로 작용하는 힘 N 에 비례하는 사실을 발견하였다. 이 관계를 접촉면의 단위면적당의 힘, 즉 전단응력 τ 와 수직응력 σ 를 써서 정수항을 더한 일반식으로 나타내면

$$\tau = \sigma \tan \phi + c \quad (1)$$


로 된다. 토질역학에서는 위의 식을 지반 내부의 활동면에 적용하고 ϕ 를 전단저항각, c 를 점착력이라 부르며, ϕ 와 c 를 지반을 구성하고 있는 흙의 전단강도정수라 한다.

전단강도정수를 구하는 방법에는 실내시험, 현장시험, 현장 실험치를 이용한 수치해석 방법과 경험식 등이 있다. 실내시험의 경우, 시료의 채취, 운반, 성형에 따른 시료 교란 문제가 발생할 수 있기 때문에 현장에서 직접 구한 전단강도정수보다 신뢰성이 떨어진다. 특히 사질토 경우에는 이러한 문제가 더욱 심각하기 때문에 가능하다면 전단강도정수를 현장에서 직접 측정하는 것이 바람직하다[6]. 하지만 현장시험을 수행하기 어려운 지역적인 특수성, 모든 현장을 시험할 수 없는 경제적, 시간적인 제약 등의 문제가 존재할 경우에는 현장 실험치를 이용한 수치해석 방법과 경험식 등을 사용할 수 있다.


2.3 이론적 상관관계

(1) 콘관입 모델

Behzad Rohani and George Y. Baladi(1981)[7]은 Vesic(1972)[8]이 제안한 구형공동팽창 이론을 콘의 관입 모델에 적용하여 흙의 전단강도정수로 콘지수를 예측하는 콘지수식을 유도하였다. 콘의 관입 모델의 기본 가정은 탄·소성 거동을 보이는 지반은 콘이 지중으로 관입함에 따라 구형의 공동(cavity)으로 연속적인 팽창을 한다는 것이며, 흙의 강성특성(stiffness characteristic)을 고려한 것으로서 흙의 거동을 강소성(rigid plasticity)으로 다룬 기존의 콘관입 모델을 한층 개량한 것이다[9].



[Fig. 2] Geometry of cone penetration



[Fig. 3] Expanding spherical cavity (Vesic, 1972)

(2) 콘지수식

콘관입 시 저항하는 응력은 콘선단 주변의 전단응력 (τ_m)과 구형공동면상의 전단응력($\sigma_r \tan \alpha$)이다. 이 응력들을 콘주면을 따라서 적분하면 관입력(F_z)을 구할 수 있다. 콘관입을 형상화한 Fig. 2과 Fig. 3에서 작용력의 정적평형상태로부터 콘의 관입력 또는 저항력을 다음과 같이 계산할 수 있다.

$$F_z = \int_0^L (\sigma_r \tan \alpha + \tau_m)(2\pi r) dh \quad (2)$$

여기에서, $r = \eta \tan \alpha$

콘지수는 콘의 저항력 혹은 관입력에 콘의 단면적으로 나눈 값으로 정의된다.

$$CI = \frac{F_z}{\pi R^2} \quad (3)$$

깊이 $Z+L-\eta$ 에서 연직방향의 지중응력(q)을 구하면 $q = (Z+L-\eta) \cdot \gamma$ 이므로 이것을 공동반경방향응력(σ_r)에 대입한 후 Eq. 2에 대입한 결과를 적분하면 F_z 가 결정되고, Eq. 3의 콘지수식으로부터 다음과 같은 일반식을 얻을 수 있다.

$$CI = 6 \bar{G}^m \frac{\tan \alpha}{\tan \phi} \left(\frac{1 + \sin \phi}{3 - \sin \phi} \right) \times \left[\frac{\tan \alpha + \tan \phi}{(R \gamma \tan \phi)^2} \right] \Omega - C \cot \phi \quad (4)$$

여기에서, $k = \gamma \tan \phi$ 라 하면

$$\Omega = \frac{[c + (Z+L)k]^{3-m}}{(2-m)(3-m)} - \frac{[c + (Z+L)k + (2-m)Lk](c + Zk)^{2-m}}{(2-m)(3-m)}$$

사질토의 경우($c = 0$), Eq. 4로부터 Eq. 5를 얻을 수 있다.

$$CI = 6 \bar{G}^m \frac{\tan \alpha}{\tan \phi} \left(\frac{1 + \sin \phi}{3 - \sin \phi} \right) \left[\frac{\tan \alpha + \tan \phi}{(R \gamma \tan \phi)^2} \right] \Omega \quad (5)$$

여기에서,

$$\Omega = \frac{[(Z+L)k]^{3-m}}{(2-m)(3-m)} - \frac{[(Z+L)k + (2-m)Lk](Zk)^{2-m}}{(2-m)(3-m)}$$

$\phi = 0$ 인 점성토의 경우, Eq. 4로부터 Eq. 6을 얻을 수 있다.

$$CI = \frac{4}{3} c \left(1 + \ln \frac{G}{c} \right) + c \cot \alpha + \left(Z + \frac{L}{3} \right) \gamma \quad (6)$$

Eq. 4 ~ 6은 콘지수를 흙의 특성인자와 전단강도정수로 나타낸 이론관계식이다. 하지만 유도된 이론관계식에는 적용한 가정과 적용된 흙의 특성인자들의 가정사항이 너무 많다. 이로 인해 신뢰성 있는 지반 거동을 예측하기 어려운 측면이 존재할 수 있다. 이러한 점을 개선하기 위해서 이론적, 경험적 방법 등 기존의 방법과는 다른 새로운 측면에서 지반 거동을 분석하기 위해 인공신경망 이론을 적용하여 값 도출의 신뢰성을 높일 수 있다.

3. 인공신경망 모델

3.1 신경망 시스템

인간의 뇌는 뉴런(neuron)이라 불리는 수많은 요소들

이 복잡하게 연결 및 구성되어 있으며, 뉴런은 수상돌기(dendrite), 신경세포체(cell body), 축삭돌기(axon) 등의 제가지 주요한 성분들로 이루어져 있다. 뉴런과 뉴런사이의 접촉점은 시냅스(synapse)라 하고 임의의 외부 자극에 대한 반응을 다른 뉴런에 전달해 주는 역할을 한다. 인간의 신경망은 복잡한 화학작용에 의해 결정된 각각의 시냅스의 강도와 뉴런들의 배열들에 의해 이루어진다.

인공신경망 모델도 인공뉴런들과 뉴런들을 연결시켜 주는 매개체로 구성된다. 인공신경망에서 입력은 weight와 bias에 의해 가중입력값이 결정되며, 이 값은 전달함수(transfer function)를 통해 출력된다. 일반적으로 전달함수는 사용자가 선택하고 weight와 bias는 뉴런의 입력과 출력관계가 일정한 목표를 만족하도록 하는 학습(learning rule)에 의해 조정 가능한 값이다. Table. 1을 통해 인간의 신경시스템과 인공신경망의 시스템을 비교할 수 있다[10].

[Table 1] Comparison of neural network system

Nervous System	Artificial Neural Network
Neuron	Processing Element
Dendrite	Combining Function
Cell Body	Transfer Function
Axon	Output
Synapse	Weight

3.2 구조 및 학습과정

인공신경망의 구조는 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer)으로 구성되어 있으며, 각 층내의 연결과 출력층에서 입력층으로 직접적인 연결은 존재하지 않는 전방향(FeedForward)의 네트워크이다. 이러한 네트워크 내에서 입력층의 각 요소에 입력 패턴을 주면, 이 신호는 각 요소에서 변환되어 은닉층에 전달되고 출력층에서 신호를 출력하게 된다.


인공신경망 모델에서의 학습은 ① 훈련에 필요한 자료수집, ② 네트워크 구조와 내부 함수 결정, ③ 네트워크의 훈련, ④ 훈련된 네트워크를 이용한 새로운 입력에 대해 모사 등의 과정을 통해 이루어진다. 인공신경망 모델은 학습한 자료를 바탕으로 추론을 수행하는 능력을 지니고 있기 때문에 이론적, 경험적 방법으로 데이터베이스(database)화 하기 어려운 불확실한 정보의 처리가 가

능한 특성이 있다. 따라서 지반거동에 대한 예측 시에도 인공신경망 모델을 적용하여 이론적, 경험적 방법과는

다른 새로운 측면에서 지반의 거동특성을 파악할 수 있다[11].

[Table 2] Database (100 sets)

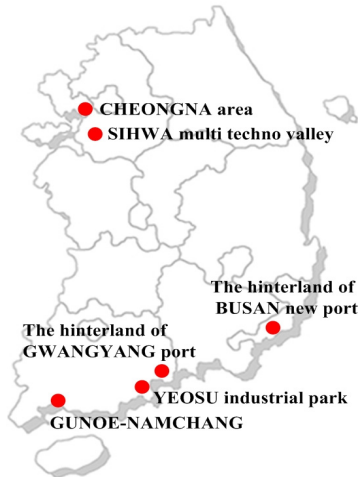
Input data				Output	Input data				Output
USCS	w [%]	c [kPa]	ϕ [°]	CI	USCS	w [%]	c [kPa]	ϕ [°]	CI
CH	90.03	6.00	0.00	4.55	CH	67.75	21.00	0.00	7.01
CH	77.20	11.50	15.55	12.77	SM	91.45	15.00	18.60	8.60
CH	70.10	8.00	20.90	10.39	CH	66.80	27.00	0.00	7.59
CH	72.70	9.00	23.70	10.05	CH	99.00	8.10	19.80	12.48
CH	87.80	18.00	17.60	11.83	CH	80.78	7.15	0.00	17.85
CL	34.00	65.00	0.00	4.12	CL	75.52	23.00	14.65	9.38
CH	90.15	4.50	18.70	8.63	CH	70.60	10.60	22.20	37.36
CH	74.75	17.50	24.10	14.49	CL	61.45	14.95	0.00	13.02
CH	80.65	3.00	10.00	10.22	CH	88.03	4.60	0.00	12.17
CH	78.00	17.00	15.50	22.83	CH	90.15	5.90	0.00	9.37
CH	83.38	9.00	17.50	6.87	CH	81.53	20.35	0.00	6.94
CH	73.23	15.38	28.90	6.43	CH	71.94	9.20	12.70	13.99
CH	112.35	4.00	15.60	16.99	CH	87.63	15.50	19.05	6.78
CH	84.50	13.00	16.40	10.07	CH	79.53	9.40	14.70	16.23
CH	78.75	16.50	19.70	3.05	CH	77.80	15.70	0.00	8.87
CL	69.39	13.00	12.30	8.54	SM	34.20	29.80	33.80	6.83
CH	75.40	21.50	15.80	9.70	CL	40.45	6.00	7.40	26.99
CH	79.75	8.50	13.40	12.42	SM	33.15	2.95	27.97	14.78
CL	59.69	15.14	23.00	9.64	SM	23.30	9.20	0.00	9.89
CH	99.10	3.00	10.40	12.54	CL	30.55	14.00	14.20	8.37
CH	96.35	9.00	15.30	18.54	CL	31.50	2.50	27.50	7.81
CH	70.30	11.00	15.90	9.34	SM	24.30	5.20	26.00	9.13
CL	54.96	29.38	26.85	16.36	GM	24.50	1.90	28.40	8.35
CH	89.55	5.50	15.80	11.52	CL	33.39	3.05	31.72	11.28
CL	66.95	22.50	15.20	12.63	CL	36.90	1.40	26.90	23.26
CH	80.55	7.00	20.50	12.05	CL	35.00	15.00	14.20	7.81
CH	74.82	14.00	33.20	13.41	ML	27.00	2.30	26.75	27.45
CH	91.45	6.00	18.60	12.71	CH	69.00	1.00	17.50	12.45
CL	66.80	27.00	17.30	2.03	CH	76.70	4.00	14.30	20.79
CH	57.10	9.00	0.00	23.18	CH	76.90	3.20	16.96	15.50
CH	80.70	7.00	0.00	9.61	CH	71.90	3.88	17.65	13.70
CH	74.95	10.00	0.00	17.46	GM	32.75	1.70	35.00	19.81
CH	80.65	4.00	10.00	14.99	SM	35.90	1.75	31.00	24.56
CH	78.00	17.00	0.00	11.36	SM	38.67	2.00	30.00	21.02
CH	80.53	8.00	0.00	12.74	ML	35.90	0.06	23.50	19.41
CH	73.40	11.00	0.00	12.98	SM	17.67	0.16	17.50	21.12
CH	112.35	15.00	15.60	2.32	CL	34.22	11.00	24.30	11.78
CH	84.50	13.00	0.00	13.23	CL	31.21	24.00	28.84	16.63
SM	64.90	16.65	0.00	13.67	CH	45.80	31.40	33.42	9.33
CH	70.35	10.00	0.00	9.45	CH	50.38	30.11	31.21	18.85
CH	75.40	21.50	0.00	16.00	CL	35.21	32.60	25.70	16.91
ML	69.40	8.70	0.00	13.81	CL	37.23	11.25	30.90	28.97
CH	59.20	6.00	0.00	8.97	CL	33.25	12.88	25.22	14.78
CH	99.10	5.00	10.40	5.04	CL	37.54	11.22	26.02	14.77
CH	96.35	9.00	0.00	11.62	CL	36.11	9.00	28.60	13.26
CL	68.48	7.00	0.00	22.93	CL	33.62	10.88	25.56	13.74
CH	60.70	18.00	0.00	18.51	CL	34.55	10.12	26.87	16.66
SC	89.55	17.00	15.80	9.10	CL	35.71	13.20	25.10	15.27
CH	66.95	22.50	0.00	13.52	CL	36.47	12.32	26.99	15.40
CH	84.13	7.00	0.00	11.51	ML	23.73	29.39	25.83	14.43



[Fig. 4] Artificial neural network model

3.3 데이터베이스(Database)

인공신경망 모델의 구축을 위해서는 학습단계와 검증 단계(교차검증세트와 시험세트)에 사용될 신뢰성 있는 자료의 축적이 요구된다. 이 연구에서는 국내 6개 지역 (Fig. 5 참고)에 해당하는 16개의 지반보고서를 통해 “흙의 종류-함수비-점착력-전단저항각-콘지수”를 한 개의 set로 하는 총 100sets의 자료를 추출하였다.



[Fig. 5] Ground investigation sites

여기에서 인공신경망에 사용될 입력 자료는 흙의 종류, 함수비, 점착력, 전단저항각이고, 출력자료는 콘지수이다. 100sets의 자료 중에서 80sets는 학습과정에서의 학습자료, 나머지 20sets는 검증과정에서의 검증자료로 사용되었다.

3.4 인공신경망 모델의 적용

이 연구에서는 인공신경망 모델을 구축하기 위해 NeuroDimension에서 개발한 상용소프트웨어인 NeuroSolutions™ Ver. 5.05를 사용하여 시뮬레이션환경을 구성하였다. 적용된 모델은 다층퍼셉트론(Multilayer perceptron) 모델이며, 학습규칙은 오차역전파(Backpropagation) 알고리즘을 사용하였다. 오차역전파 알고리즘은 입력값과 결과값의 비선형적인 관계를 구축하는 함수근사화에 매우 효율적인 것으로 알려져 있다 [9].

weight와 bias를 최적화하기 위해 평균제곱오차(mean squared error, MSE)가 이용되었으며 Eq. 7과 같이 정의된다. 이 연구에서는 평균제곱오차 값이 목표하고 있는 평균제곱오차 값($\epsilon = 0.01$)보다 작아지거나 최대 훈련 반복횟수에 도달되면 학습을 종료하도록 설정하였다.

$$MSE = \frac{1}{2} \sum_{k=1}^Q e(k)^2 = \frac{1}{2} \sum_{k=1}^Q [t(k) - a(k)]^2 \quad (7)$$

여기에서,

MSE : 평균제곱오차

Q : 학습에 사용된 전체 자료의 수

$e(k) = t(k) - a(k)$: 목표값과 출력값의 차이


3.5 인공신경망 학습 결과

구성된 인공신경망을 바탕으로 학습을 시킨 결과는 Fig. 6과 Table. 3과 같다. 인공신경망 학습은 “흙의 종류-함수비-점착력-전단저항각-콘지수”의 정보가 포함되어 있는 100sets 중에서 80%에 해당하는 80sets가 학습에 이용되었고, 20%에 해당하는 20sets는 입력변수 값에 대응하는 신경망 예측이 사용되었다.

Fig. 6에서 가로축(x 축)은 자료 수집을 통해 얻은 측정 콘지수 값을, 세로축(y 축)은 학습을 통해 얻은 예측 콘지수 값을 나타낸다. 최적 설계된 인공신경망에서 학습이 잘 이루어진다면 그래프 위의 점들은 선형적 관계를 나타내는 $y = x$ 의 직선 주위에 가깝게 분포하게 됨을 의미하는데, 이 연구에서 수행한 인공신경망 학습 결과는 그래프 위의 점들이 다소 작은 오차범위 안에서 고르게 분포함을 알 수 있다.

Table. 3은 신경망 예측에 사용된 20sets에 해당하는 콘지수 값과 학습 결과를 통해 예측한 콘지수 값을 대응

시켜 놓았으며, 값들 간의 오차율을 정리한 표이다. 20sets의 각 오차율의 범위는 0.4 ~ 91.1%로 다소 큰 범위를 보이지만, 평균 오차율은 약 23.276%로 다소 작은 평균오차율을 보이고 있다.



[Fig. 6] Result of learning - Visualization

[Table 3] Result of learning - Table

Measured CI	Predicted CI	Error [%]	Measured CI	Predicted CI	Error [%]
28.97	31.33	8.1	6.78	8.85	30.5
14.78	11.21	24.2	11.28	10.09	10.6
13.74	13.10	4.7	2.03	3.88	91.1
16.96	15.00	11.6	9.61	9.57	0.4
19.81	16.98	14.3	14.99	16.49	10.0
15.50	21.60	39.4	16.00	13.08	18.3
9.33	14.87	59.4	13.67	14.96	9.4
37.36	31.02	17.0	22.93	18.50	19.3
6.83	8.25	20.8	7.01	8.55	22.0
8.87	9.72	9.6	10.07	14.09	39.9

4. 결론

이 연구는 국내 6개 지역에 대해서 실시한 지반조사 보고서로부터 데이터를 획득하고, 획득한 데이터를 인공신경망 기법을 적용하여 지반의 전단강도정수와 콘지수 사이의 상관관계에 대한 모델을 확립하고자 하였다. 연구의 결론을 요약하면 다음과 같다.

- 1) 연구결과를 통해 인공신경망 학습 결과는 다소 작은 오차범위를 보이고 있음을 알 수 있었다. 이는 국내 지반에 대한 전체 학습 자료에서 임의로 추출

된 검증자료임에도 불구하고 오차가 작았다는 것을 의미한다. 따라서 이 연구를 수행함에 있어 새로운 측면에서의 접근(인공신경망 기법 적용)이 효과적이었다고 판단된다.

- 2) 전체 자료가 서해안과 남해안에서 얻어져 지역에 따라 다소 상이한 지반특성들을 보인다. 하지만 학습결과를 통해 예측결과와 오차가 크지 않고, 비교적 고르게 분포되고 있기 때문에 이 연구 및 추후 연구를 통해 구축된 인공신경망 모델을 특정 지역 뿐만 아니라 국내 일반화된 지역에도 적용할 수 있을 것으로 판단된다.
- 3) 다양한 지반특성에 대해 상관관계를 예측하기 위하여 국내 시공된 현장자료의 지속적인 축적이 필요한 것으로 판단된다.
- 4) 성공적인 인공신경망 모델을 확립하기 위해서는 경험적인 반복법을 통해 은닉층의 수, 입력변수, 전달함수, 훈련규칙과 최적화 기법, 수렴기준 등을 제시해야 할 필요가 있다. 또한 학습된 모델을 상관계수(r)를 이용하여 모델을 검증한 뒤 각각의 입력요소가 출력요소에 어느 정도의 영향을 미치는지에 대한 민감도 분석(sensitivity analysis)이 추후 연구에서 함께 이루어져야 할 것으로 판단된다.

References

- [1] K. J. Han, S. N. Oh, W. Y. Kim and M. M. Kim, "Applicability Review of Cone Index Concept for Determination of Off-Road Tractive Performance", *Korean Society of Civil Engineers, KSCE 1992 Convention*, Vol.1, pp. 671-674, 1992.
- [2] J. Y. Wong, "Terramechanics and off-road vehicles", *Elsevier*, pp. 251 pp, 1989.
- [3] B. Y. Lee, S. H. Goo and Y. J. Shin, "Understanding and Development Trend of Terramechanics", *The Forum of Weapon System*, pp. 76-87, 2011.
- [4] Behzad Rohani and George Y. Baladi, "Correlation of Mobility Cone Index with Fundamental Engineering Properties of Soil", *U. S. Army Engineer Waterways Experiment Station*, 1981.
- [5] Y. U. Kim and I. J. Moon, "Cone Index Prediction through Shear Strength Parameters of Soil", *Journal of Korean Society of Mechanical Engineers*, pp. 1-2, 2014.
- [6] Y. H. Park, "Study on Interaction of Soil-Tracked

Vehicle”, *Seoul National University, Domestic Thesis*, 1996.

- [7] Behzad Rohani and George Y. Baladi, “Correlation of Cone Index with Soil Properties”, *Journal of ASCE*, pp. 128-144, 1981.
- [8] A. S. Vesic, “Expansion of Cavities in Infinite Soil Masses”, *Journal of ASCE*, Vol. 98, No. SM3, pp. 265-290, 1972.
- [9] K. J. Han, “A Study on Estimation of Shear Strength Parameters Using Cone Index”, *Seoul National University, Domestic Thesis*, 1993
- [10] S. J. Lee, S. R. Lee and B. S. Jang, “Prediction of Apparent Cohesion of Unsaturated Soil using Artificial Neural Network Model”, *Journal of Korean Society of Civil Engineers*, Vol. 22, No. 3-C, pp. 331-344, 2002.
- [11] Y. U. Kim, Y. S. Kim, N. S. Goo and J. H. Park, “Application of Artificial Neural Network Reliable to Estimation Rigidity Index of Korean Soft Clay”, *Journal of Korean Society of Civil Engineers*, Vol. 26, No. 6C, pp. 421-429, 2006.

김 영 옥(Young-Uk Kim)

[정회원]



- 1991년 2월 : 고려대학교 토목환경 공학과 (공학석사)
- 2000년 5월 : The Pennsylvania State University 토목환경 공학과 (공학박사)
- 2001년 3월 ~ 현재 : 명지대학교 토목환경공학과 교수

<관심분야>

토양오염 복원, 환경공학, 토질역학

문 인 중(In-Jong Moon)

[정회원]



- 2012년 2월 : 명지대학교 토목환경 공학과 (공학사)
- 2012년 3월 ~ 현재 : 명지대학교 토목환경공학과 석박사통합과정

<관심분야>

토질역학, 기초공학