

# 표준관입시험결과를 이용한 사질토 지반의 전단파속도 예측 : 인공신경망 모델의 적용

## Prediction of Shear Wave Velocity on Sand Using Standard Penetration Test Results : Application of Artificial Neural Network Model

김 범 주<sup>1</sup> Kim, Bum-Joo  
호 준 기<sup>2</sup> Ho, Joon-Ki  
황 영 철<sup>3</sup> Hwang, Young-Cheol

### Abstract

Although shear wave velocity ( $V_s$ ) is an important design factor in seismic design, the measurement is not usually made in typical field investigation due to time and economic limitations. In the present study, an investigation was made to predict sand  $V_s$  based on the standard penetration test (SPT) results by using artificial neural network (ANN) model. A total of 650 dataset composed of SPT-N value ( $N_{60}$ ), water content, fine content, specific gravity for input data and  $V_s$  for output data was used to build and train the ANN model. The sensitivity analysis was then performed for the trained ANN to examine the effect of the input variables on the  $V_s$ . Also, the ANN model was compared with seven existing empirical models on the performance. The sensitivity analysis results revealed that the effect of the SPT-N value on  $V_s$  is significantly greater compared to other input variables. Also, when compared with the empirical models using Nash-Sutcliffe Model Efficiency Coefficient (NSE) and Root Mean Square Error (RMSE), the ANN model was found to exhibit the highest prediction capability.

### 요 지

전단파 속도는 내진설계시 중요한 설계인자이나 지반조사의 목적으로는 흔히 경제적, 시간적 제약 등으로 시험을 통한 측정이 널리 이루어지지 않고 있다. 본 연구에서는 인공신경망 기법을 이용하여 가장 일반적인 현장 지반조사시험인 표준관입시험 결과를 바탕으로 사질토 지반에서의 전단파 속도를 예측하는 연구를 수행하였다. 650개 데이터 세트를 이용해 표준관입시험 저항치  $N_{60}$ , 함수비, 세립분함량, 비중을 입력변수로 하여 전단파속도를 추정하는 인공신경망 모델을 구축하고 입력변수별 전단파속도에 미치는 영향을 민감도 해석을 통해 조사하였다. 그리고, 기존의 국내외 7개의 표준관입시험을 이용한 전단파속도 예측 경험식들과 인공신경망에 의한 결과를 비교하였다. 민감도 분석결과 표준관입시험 저항치의 영향이 월등히 큰 것으로 나타났으며, 모델효율계수와 평균제곱근오차를 사용하여 기존의 경험식들과 인공신경망 모델의 예측 능력을 비교한 결과 인공신경망 모델의 예측 결과가 가장 좋은 것으로 나타났다.

**Keywords :** Shear wave velocity, Field investigation, Artificial neural network, SPT, Sensitivity analysis

1 정희원, 동국대학교 건설환경공학과 부교수 (Member, Associate Prof., Dept. of Civil and Environmental Engr., Dongguk Univ., bkim1@dongguk.edu, Tel: +82-2-2260-8921 Fax: +82-2-2266-8753, Corresponding author, 교신저자)

2 정희원, 도화엔지니어링, 사원 (Member, Geotechnical & Tunnel Engineer, DOHWA Engr.)

3 정희원, 상지대학교 건설시스템공학과 부교수 (Member, Associate Prof., Dept. of Civil Engr., Sangji Univ.)

\* 본 논문에 대한 토의를 원하는 회원은 2014년 11월 30일까지 그 내용을 학회로 보내주시기 바랍니다. 저자의 검토 내용과 함께 논문집에 게재하여 드립니다.

## 1. 서론

최근 국내외적으로 지진의 발생 빈도가 증가하고 있고 토목구조물 뿐 아니라 일반 주택을 포함한 건축물에 대해서도 내진설계의 필요성이 대두되고 있다. 국내 내진설계기준에서는 지반의 고유 동적 특성으로부터 지반을 분류하고 있으며, 지반분류 방법으로서 상부 30m 평균 전단파속도(shear wave velocity,  $V_s$ )와 표준관입시험 저항값(N) 등을 부차적으로 이용하여 사질토 및 점성토에 모두 적용할 수 있도록 하고 있다(Kim, 2010). 지반의 전단파속도는 이와 같이 내진설계시 중요한 설계인자임과 동시에 부지 고유의 지진응답해석 수행시 지반의 동적 특성을 반영하는 중요한 해석인자이기도 하기에 그 만큼 내진설계 및 해석의 정확도에 영향을 미치는 중요한 물성치라고 할 수 있다.

현재 지반의 전단파속도를 측정할 수 있는 다양한 방법이 존재하나 보통 지반조사를 위한 목적으로는 시간적, 경제적 제약 등으로 인해 많이 수행되고 있지 못한 실정이다. 따라서, 지반조사시 현장시험방법으로 가장 널리 사용되고 있는 표준관입시험(Standard Penetration Test, SPT) 결과로부터 전단파속도를 추정하기 위한 시도가 여러 연구자들에 의해 있어왔다(Ohta and Goto, 1978; Imai and Tonouchi, 1982; Sykora and Stokoe, 1983; Lee, 1990; Jafari, 1997; Pitilakis et al., 1999; Sun et al., 2007; Cheong, 2009; Do et al., 2011). 그러나, 기존의 표준관입시험결과를 이용하여 지반 전단파속도를 추정한 연구들은 대부분 해외 연구자들에 의해 수행되어 국내 지반조건을 반영하고 있다고 볼 수 없으며, 추정 기법에 있어서도 두 측정치간의 단순한 선형관계 등을 이용하고 있어 추정의 정확도에 불확실성이 클 수 있다(Ho, 2014). 제한적이거나 국내에서 수행된 연구(Sun et al., 2007; Cheong, 2009; Do et al., 2011)들도 해외 연구들과 유사한 방법으로 수행되었다. 따라서, 국

내의 지반조건을 반영할 수 있음과 동시에 추정의 정확도를 높이기 위해 다양한 방법에 대한 연구가 필요하며, 이러한 배경 하에 본 연구에서는 국내에서 사질토 지반에 대하여 수행된 표준관입시험결과를 이용하여 전단파속도를 추정하고, 추정방법으로서 인공신경망 기법을 적용하여 기존 방법과의 예측 능력을 비교, 평가하였다.

## 2. 기존 연구

지반 전단파속도와 표준관입시험결과와의 상관성을 분석한 연구가 다양한 연구자들에 의해 수행되었다. 대표적으로 해외에서는 Imai and Tonouchi(1982)이 일본에서 1967년 이후에 기록된 현장시험자료를 기반으로 전단파속도와 표준관입시험이 동시에 수행된 1,654개의 자료를 수집하여 지반에 따라 분류하고 선형회귀분석을 통하여 둘 사이의 상관관계식을 제시한 바 있다. 또한, Ohta and Goto(1978), Sykora and Stokoe(1983), Lee(1990), Jafari et al.(1997), Pitilakis et al.(1999) 등이 유사한 방법으로 연구를 수행하였다. 국내에서는 Sun et al.(2007)이 충청남도 홍성의 16개소에서 실시한 시추조사 및 표준관입시험 그리고 시추공 탄성파 시험자료를 바탕으로 하여 N값과 전단파속도 사이의 상관관계식을 제시하였으며, Do et al.(2011)도 충청지역의 지층에 대하여 N값과 전단파속도 사이의 상관관계를 통계적으로 분석하여 해외 연구자들에 의해 제시된 경험식과 유사한 형태의 상관관계식을 제시하였다. 이들은 대부분 N값과  $V_s$  측정 데이터들에 대하여 단순회귀분석을 통하여  $V_s=a \times N^b$ 의 형태로 나타낸 식들로서 Table 1에 사질토 지반에 대해서 그러한 대표적인 제안식들을 나타내었다. 일부 제안식은 신뢰도의 의미로서 결정계수( $R^2$ )를 함께 제시하고 있으나 전반적으로 시험방법 자체 및 지반 고유의 내재된 불확실성이 커 수치 자체가 높지 않은 실정이다.

Table 1. The equations for predicting  $V_s$  using SPT-N for sandy soils

Proposer	Equation	Determinant coefficient ( $R^2$ )
Imai & Tonouchi (1982)	$V_s=87.8N^{0.314}$	0.48
Pitilakis (1999)	$V_s=145N^{0.178}$	0.50
Sykora & Stokoe (1983)	$V_s=100.5N^{0.29}$	0.71
Ohta & Goto (1978)	$V_s=88.4N^{0.333}$	-
Lee (1990)	$V_s=57.4N^{0.49}$	-
Sun et al. (2007)	$V_s=82.01N^{0.319}$	-
Jung et al. (2009)	$V_s=173.9N^{0.179}$	-

한편, 본 연구에서 지반 전단파속도의 추정 방법으로 적용한 인공신경망(artificial neural network, ANN) 모델의 경우 지반공학의 매우 다양한 분야에서 적용되어 왔다. Goh(1994)는 일본, 미국 등의 지역에서 90년간 발생한 13차례의 지진 데이터를 바탕으로 인공신경망을 이용하여 액상화 가능성을 평가한 바 있으며, Goh(1995), Chan et al.(1995), Lee and Lee(1996)는 인공신경망을 이용하여 말뚝의 극한 지지력을 예측하고 동재하 시험 결과와 상호 비교, 분석한 바 있다. 또한, Sivakugan et al.(1998)은 얇은기초의 침하량 예측방법으로서 인공신경망을 적용하고 Terzaghi and Peck(1967), Schmertmann and Palacios(1979)의 방법들과 비교, 평가하였다. 국내 연구로는 Kim et al.(2003)이 설계단계에서 연약지반의 침하량 산정시 인공신경망의 적용성을 분석한 바 있으며, Lee and Chang(2006)은 PHC 매입 말뚝의 지지력을 예측하는데 인공신경망 기법을 적용한 바 있다. 또한, Ahn et al.(2009)은 사면 안정성의 신뢰성 해석시 퍼지와 인공신경망을 적용하여 실제 사면에 대하여 기존 해석 방법들의 결과와 비교, 분석을 수행하였다.

위와 같이 인공신경망 모형은 지반의 물성치 예측뿐 아니라 지반구조물의 설계와 안정성 평가 등 다양한 목적에 활용되어 왔다. 그럼에도 불구하고 기존의 연구들 중에서 인공신경망을 지반의 전단파속도를 예측하는데 적용한 사례는 찾기 어려운 실정이다.

### 3. 전단파 속도 예측을 위한 인공신경망 모델

인공신경망은 인간의 뇌 구조에서 학습되고 축적되는 기존 지식의 운용체계를 모사한 수학적 모델로서 뉴런(neuron) 혹은 노드(node)로 불리는 단위처리개체(simple processing unit)로 이루어져 있다. 각 노드는 입력신호에 대한 연산을 수행한 후 연결고리(connection)

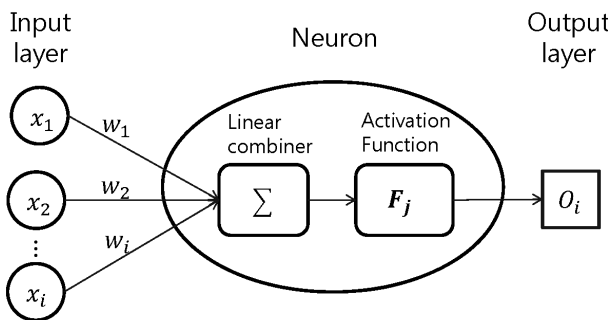


Fig. 1. Structure of artificial neural network

들을 통하여 다음 뉴런에 정보를 전달하는 처리개체이다. 여기서, 연결고리는 하나의 노드로부터 다음 노드로의 정보 흐름을 의미한다. 가중치는 연결고리를 통하여 할당되고, 결과적으로 가중치가 고려된 입력 신호값이 다음 뉴런에 전달된다. 그래서 인공신경망은 크게 자료들을 제공받는 입력층(input layer), 입력과 출력 사이의 복잡한 관계를 나타내는 은닉층(hidden layer), 그리고 출력층(output layer)으로 나뉘어진다(Fig. 1). 그리고 주어진 자료를 바탕으로 처리 요소들 간의 연결강도를 스스로 조정하는 과정을 학습(training)이라고 하는데, 본 연구에서는 이러한 학습을 위해 일반적으로 인공신경망 모델에서 가장 많이 사용되고 있는 역전파 알고리즘(backpropagation algorithm)을 사용하였다(Fig. 2). 해당 알고리즘에서는 전달함수를 이용하여 입력값으로부터 출력값을 도출한 후 목표값과 계산값의 차이를 역방향으로 진행시키면서 오차가 최소화 되도록 층과 층 사이의 연결강도를 조절하게 된다. 출력값은 사용된 전달함수에 따라 달라지게 되는데 본 연구에서는 인공신경망 모델의 전달함수로 가장 많이 사용되는 비선형 함수인 Sigmoid 함수를 사용하였다. 그리고, 위와 같은 일련의 인공신경망의 연산을 위한 소프트웨어로서 Matlab(7.10.0)을 사용하였다.

인공신경망 적용을 위한 데이터베이스는 국내 49개

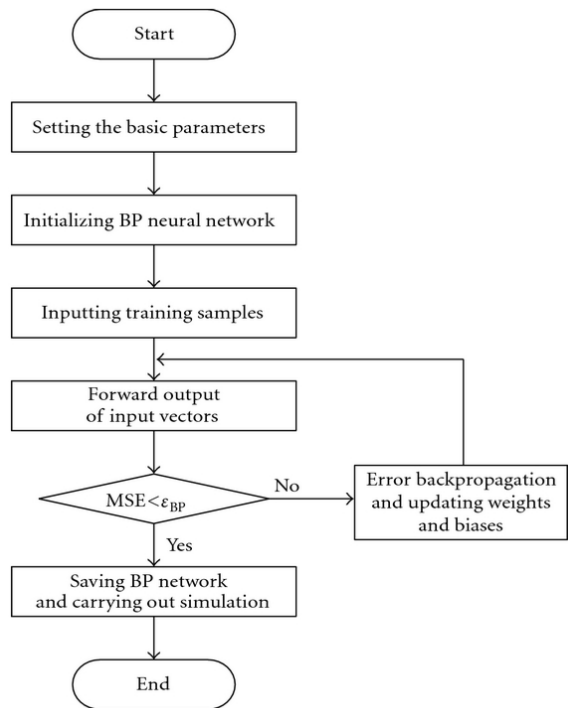


Fig. 2. Flow chart for artificial neural network training

아파트 건설 현장의 지반조사 보고서를 수집하여 구축하였다. 즉, 수집된 지반조사보고서로부터 사질토로 분류되는 지층에 대하여 표준관입시험과 Suspension PS 검층을 통한 전단파속도 측정이 동시에 이루어진 시추공 자료와 샘플 시료에 대해 측정된 기초 지반 물성 자료를 분류하여 데이터베이스화 하였다. 기초 지반 물성으로는 비중과 함수비, 세립분 함량(200번체 통과량)을 포함하였고, 표준관입시험 저항치 N값은 에너지효율 60%로 보정, 변환한  $N_{60}$ 값을 사용하였다. 이 때 N값의 범위로는 일반적으로 N값을 기준으로 풍화토와 풍화암을 구분시 적용하는 기준인 50/10(KGS, 2009) 이내의 값을 사용하였다. 총 680개 데이터 세트가 만들어졌으며, Table 2는 그 중 일부를 나타낸 것이다.

인공신경망 입·출력변수로서 표준관입시험 저항치 N값( $N_{60}$ )과 비중, 함수비, No.200체 통과율을 입력변수로, 그리고 전단파 속도를 출력변수로 적용하였다. 이 때, 변수들간 값의 범위에 큰 차이가 발생하고 이러한 차이가 예측에 미치는 영향을 줄이기 위하여 스케일링(scaling)을 통하여 각 변수 값들을 다음 식을 사용하여 정규화하였다. 이 과정은 예측된 결과의 분포에 보다 적합하게 입력변수들의 분포를 수정하는 것이다(Shi, 2000).

$$Y_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

여기서,  $Y_i$ 는 정규화된 변수값,  $X_i$ 는 실측 데이터값,  $X_{\max}$

와  $X_{\min}$ 은 각각 해당 변수에 대한 데이터베이스 상의 최대값과 최소값을 의미한다. Table 3에 데이터베이스상의 입·출력변수 값들의 최대 및 최소값을 나타내었다.

대부분의 인공신경망은 은닉층 수가 2개 이상으로 증가하여도 단일 은닉층을 가지는 신경망과 비교하여 예측값의 정확도가 나아지지 않는 것으로 알려져 있으므로(Dutta and Shekhar, 1988; Salchenberger et al., 1992; Kim and Kim, 2000), 입·출력층 이외에 1개의 은닉층을 갖고 은닉층의 뉴런은 5개로써,  $4 \times 5 \times 1$ 의 구조를 갖는 인공신경망 모델을 구축하였다.

#### 4. 해석결과 및 분석

##### 4.1 인공신경망 학습결과

Fig. 3은 구축된 인공신경망을 통해 학습한 결과를 나타낸다. 전체 680개 데이터세트 중 추후 모델의 예측 능력을 검증하기 위하여 사용된 30개의 데이터세트를 제외한 650개 데이터세트를 이용한 결과이다. 데이터들은 각각 80%와 10%, 10%의 비율로 학습(training)과 검증(validation), 그리고 시험(test) 과정에 사용되었다. 그리고 학습모델의 성능(performance)은 정규화한 전단파속도값에 대한 측정값과 예측값간의 상관계수(coefficient of correlation)로 나타내었다.

전체적으로 상관계수값은 0.7 정도로 그리 높지 않은 수준을 보이고 있으나 데이터베이스상의 원 데이터의

Table 2. Database for ANN model for this study

No.	Soil type	Specific gravity	water content (%)	% weight of #200 sieve passage (%)	$N_{60}$ (blow)	$V_s$ (m/sec)
1	Silty Sand	2.71	7.5	5.7	120	395
2	Silty Sand	2.67	25	35	93	457
⋮	⋮	⋮	⋮	⋮	⋮	⋮
679	Clayey Sand	2.67	25	35	7	208
680	Silty Sand	2.67	25	35	141	462

Table 3. The range of input and output variable values for ANN model

Input variable	Maximum value ( $X_{\max}$ )	Minimum value ( $X_{\min}$ )
Specific gravity	2.71	2.61
Water content (%)	33.4	6.8
% weight of No.200 sieve passage (%)	91.7	5.7
SPT $N_{60}$	258	0
Shear wave velocity (m/s)	805	89.1

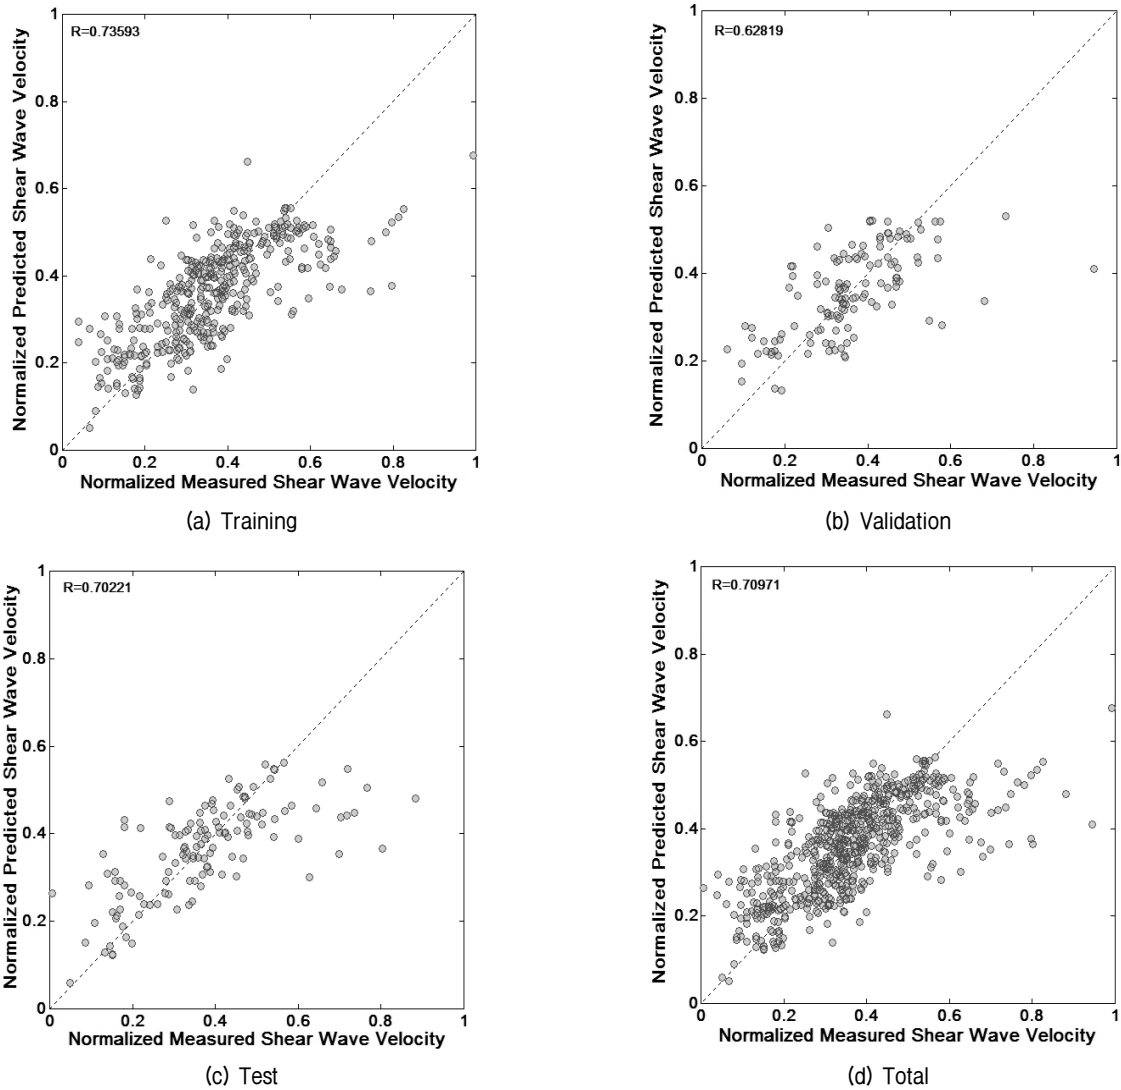


Fig. 3. Training results of ANN model

분포 범위가 크고 데이터 자체의 변동성 또한 매우 큰 편이었음을 감안해야 할 것으로 판단하였다. 특히 전단 파속도 값의 범위가 큰 경우에는 상대적으로 예측 정도가 크게 떨어지는 것으로 확인되었다. 학습에 사용된 데이터가 국내에서 수행된 지반조사자료를 기반으로 하고 있으나 지역적 특성이 반영되지 않아 지역에 따라, 혹은 특정 지반조건에 대한 데이터들로서 세분화되어 학습되었다면 예측정도가 크게 증가할 수 있을 것으로 판단된다.

#### 4.2 인공신경망 모델 입력변수의 민감도 분석

학습된 인공신경망 모델의 각 입력변수들이 출력변수에 미치는 영향의 상대적인 크기를 조사하기 위하여 민감도 해석을 수행하였다. 해석에는 Shin(2001)에 의해

개발된 알고리즘과 계산 코드(GDAP)를 이용하였다. 해당 알고리즘에서는 각 입력노드에 대한 출력노드의 1차 편미분값을 계산함으로써 민감도를 결정하게 되며, 이때 편미분값의 계산은 은닉층 노드를 통한 출력노드 값을 변수로 연쇄법칙을 적용하여 이루어진다. 아래 식은 입력층 노드에 대한 출력층 노드의 정규화된 편미분값을 나타내며, 보다 상세한 과정은 Shin(2001)에 기술되어 있다.

$$DNN_{ik}(o_k, o_i) \times \frac{Max(o_i) - Min(o_i)}{Max(t_k) - Min(t_k)} = \frac{\partial o_k}{\partial o_i} \quad (2)$$

여기서,  $DNN_{ik}$ 은 인공신경망의 편미분 성분들로 이루어진 입력노드수×출력노드수 차수의 행렬을 의미하며,  $o_i$ 와  $o_k$ 는 입력노드값과 출력노드값, 그리고  $t_k$ 는 목표값

(target variable)을 각각 의미한다.

Table 4는 민감도 해석 결과로서 입력변수별 식 (2)의 값들을 포함하여 민감도를 의미하는 편미분값에 대한 %로 나타낸 상대적인 크기를 나타낸다. 민감도는  $N_{60}$ 이 다른 변수들과 비교해 월등히 큰 것으로 나타났으며, 결과적으로 가장 지반 전단파속도에 영향을 미치는 요소는 표준관입시험 저항치이며 그 다음으로 비중과 세립 분함량, 함수비 등이 크진 않지만 영향을 미치는 것으로 나타났다. 본 인공지능망 모델의 입력요소 구성은 데이터베이스 구축시 획득 가능한 지반 물성을 기초로 하였으나, 지반 전단파속도와 상관성이 있을 수 있는 다른 지반 물성을 입력요소로 사용할 수 있을 것이며, 이러한 민감도 분석 과정을 통해 예측 정확도가 가장 높은 입력 요소들로 최적의 인공지능망 모델을 구성할 수 있을 것이다.

### 5. 기존 경험식과 인공지능망 모델의 비교

학습을 거친 인공지능망 모델의 성능을 평가하기 위하여 데이터베이스로부터 학습에 사용되지 않은 30개 데이

터세트를 인공지능망 모델에 적용하였다. 그리고 이를 국내외의 기존 연구자들에 의한 제안된 경험식의 적용 결과와 비교하여 모델의 적합성을 평가하였다. 평가도구로는 Nash and Sutcliffe(1970)에 의해 제안된 모델 효율 계수(Nash-Sutcliffe Model Efficiency Coefficient, NSE)와 평균 제곱근 오차(Root Mean Square Error, RMSE)를 사용하였다.

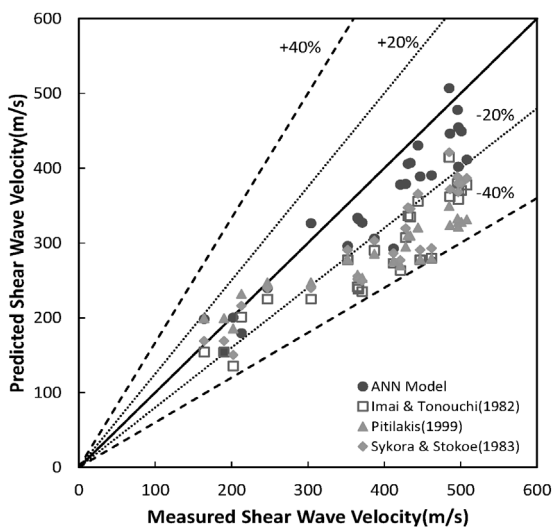
NSE는 측정값과 예측값과의 관계가 1:1 직선에 얼마나 근접하여 위치하는지를 나타내는 지표로서 다음 식과 같이 표현된다.

$$NSE = 1 - \frac{\sum(M_i - P_i)^2}{\sum(M_i - \bar{M})^2} \quad (3)$$

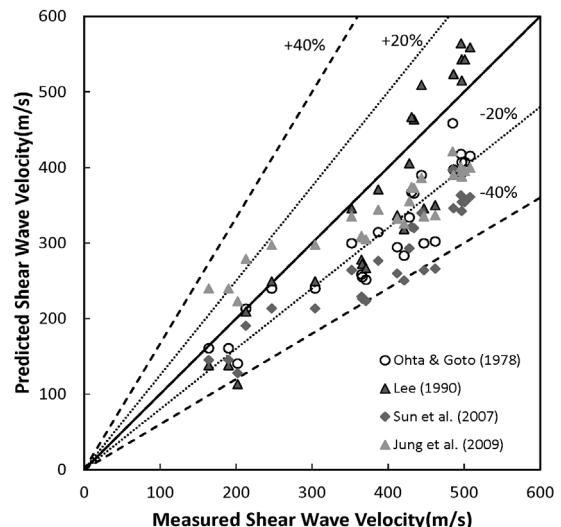
위 식에서  $M_i$ 와  $P_i$ 는 각각 측정값과 예측값을 의미하며,  $\bar{M}$ 와  $\bar{P}$ 는 각각 측정값과 예측값의 평균을 나타낸다. 따라서, NSE값은 0보다 작을 경우 모델의 예측결과가 좋지 않거나 측정자료가 일관성이 없음을 의미하고, 1.0일 경우 예측값과 측정값이 완전히 일치함을 의미한다. 결과적으로 NSE값이 0보다 크고 1.0에 가까울수록

Table 4. Results of sensitivity analysis

Input variable	$\frac{Max(o_i) - Min(o_i)}{Max(t_k) - Min(t_k)}$	$DNN_{ik}(o_k, o_i)$ (Non-normalized)	$\partial o_k / \partial o_i$ (Normalized)	Relative magnitude (sensitivity, %)
1	Specific gravity	0.0001	555.4729	9.13
2	water content	0.0324	-1.0833	4.13
3	% weight of #200 passage	0.0738	0.4765	4.14
4	SPT $N_{60}$	0.1970	3.5625	82.6



(a) 4 models - part 1



(b) 4 models - part 2

Fig. 4. Relationships between the measured  $V_s$  and the predicted  $V_s$  for 8 models

Table 5. Comparison between ANN model and empirical equations

Model	NSE	RMSE
ANN model	0.759	57.388
Imai & Tonouchi (1982)	0.027	115.329
Pitilakis et al. (1999)	-0.275	132.018
Sykora & Stokoe (1983)	0.193	105.013
Ohta & Goto (1978)	0.385	91.722
Lee (1990)	0.668	67.408
Sun et al. (2007)	-0.204	128.315
Jung et al. (2009)	0.478	84.451

모델의 예측결과가 좋다고 할 수 있다. 한편, RMSE는 예상한 값과 실제 관측한 값이 평균적으로 얼마나 차이가 나는가에 대한 통계학적 측도 중 하나로서 다음과 같이 표현된다.

$$RMSE = \sqrt{\frac{1}{n} \sum (M_i - P_i)^2} \quad (4)$$

Fig. 4는 7개의 국내외 기존 경험식들과 본 연구에서 적용한 인공신경망 모델에 대하여 전단파속도의 측정값과 예측값의 관계를 나타내며, Table 5는 각 모델들에 대해 계산된 NSE값과 RMSE값을 나타낸 것이다. 그림에서 보듯이 전체적으로 데이터들이 1:1 직선의 아래쪽에 분포하여 대부분 모델들이 전단파속도를 실제보다 보수적으로 과소하게 예측하는 경향을 보임을 알 수 있다. NSE값은 -0.204~0.759의 범위를 보여 모델간 차이가 비교적 큰 것으로 나타났으며 그 중에서 인공신경망 모델의 NSE값이 0.7 이상으로 예측결과가 가장 좋은 것으로 나타났다. 반면 Pitilakis et al.(1999)의 NSE값은 -0.275로 가장 작은 값을 보여 예측 결과가 가장 낮게 나타났다. RMSE의 범위는 57.388m/s ~ 132.018m/s를 보였으며, NSE의 결과에서 나타난 바와 같이 ANN 모델의 RMSE값이 가장 작아 예측 결과가 상대적으로 좋은 것으로 나타났다.

## 6. 결론

국내 사질토 지반에서 수행된 표준관입시험과 SPS 검층을 통한 전단파속도 결과 등을 바탕으로 인공신경망 기법을 적용하여 표준관입시험 저항치 N값을 기반으로 전단파속도를 추정하는 연구를 수행하였으며 그로부터 얻은 결론은 다음과 같다.

- (1) 표준관입시험 저항치 N값(N<sub>60</sub>)과 비중, 함수비, 세립분함량(No.200체 통과율)을 입력변수로 하고 전단파속도를 출력변수로 하는 인공신경망을 구성하고 650개 데이터셋을 이용하여 학습을 수행한 결과, 전단파속도의 측정치와 예측치간의 상관계수값은 0.7로서 그리 높지 않은 수준을 나타내었으며, 이는 특히 전단파속도 값의 범위가 상대적으로 큰 경우(대략 400m/s 이상) 예측 정도가 크게 떨어지는 것에 기인한 것으로 파악되었다.
- (2) 학습된 인공신경망 모델의 각 입력변수들이 전단파속도에 미치는 영향을 민감도 분석을 통해 조사한 결과, 표준관입시험 저항치의 영향이 월등히 큰 것으로 나타났으며, 그 다음으로 상대적으로 크진 않으나 비중과 세립분함량, 함수비의 순서로 영향을 미치는 것으로 나타났다.
- (3) 예측 모델의 적합도를 평가하기 위하여 모델효율계수(NSE)와 평균제곱근오차(RMSE)를 평가도구로 하여 국내외에서 제안된 기존의 7개 경험식과 인공신경망 모델의 결과를 비교한 결과 인공신경망 모델의 예측결과가 가장 좋은 것으로 나타났다.
- (4) 본 연구에 적용된 인공신경망 모델은 전국적 데이터에 기반하고 획득 가능한 지반 물성을 토대로 구축되었으나, 향후 추가 연구를 통해 지역적 특성을 반영한 지반조건 데이터를 이용하고 민감도 분석 등을 통해 전단파속도와 상관성이 큰 지반물성을 기초로 인공신경망을 구축한다면 모델의 예측 능력이 크게 증가하여 적용성이 증대될 수 있을 것으로 판단된다.

## 감사의 글

본 연구는 국토교통부가 출연하고 국토교통과학기술진흥원에서 위탁 시행한 건설기술혁신사업(과제#11 기술혁신E02)의 연구비 지원에 의해 수행되었으며 이에 감사드립니다. 또한, 지반조사 자료를 제공해 주신 한국 LH공사에 감사드립니다.

## 참고문헌 (References)

1. Ahn, J. P., Kim, I. G., and Heo, H. G. (2009), "The Comparison Study on Assessment Method of Stability in Soil Slopes", Korean Society of Civil Engineering Conference, pp.890-893.
2. Chan, W. T., Chow, Y. K., and Liu, L. F. (1995), "Neural network:

- An alternative to pile driving formulas”, *Journal of Computers and Geotechnics*, No.17, pp.135-156.
3. Cheong, N. H. (2009), Behavior of Shear Wave Velocity Based on Suspension PS Logging Tests, Ph.D Thesis, Dankuk University, pp.20-95.
  4. Do, J. N., Hwang, P. J., Chung, S. R., and Chun B. S. (2011), “Analysis on Relation of S-wave Velocity and N Value for Stratum in Chungcheong Buk-do”, *Journal of Korean Geo-Environmental Society*, Vol.12, No.10, pp.13-22.
  5. Dutta, S. and Shekhar, S. (1988), “Bond Rating: a Nonconservative Application of Neural Networks”, *IEEE International Conference on Neural Networks*, Vol.2, pp.443-450.
  6. Goh, A. T. C. (1995), “Modeling Soil Correlations using Neural Networks”, *Journal of Computing in Civil Engineering*, ASCE, Vol.9, No.4, pp.1467-1480.
  7. Goh, A. T. C. (1994), “Seismic Liquefaction Potential assessed by Neural Network”, *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, Vol.120, No.9, pp.1467-1480.
  8. Ho, J. K. (2014), A Study of Prediction of Soil Shear Wave Velocity Using Standard Penetration Test Results, M.s. Thesis, Dongguk University.
  9. Imai, T. and Tonouchi, K. (1982), “Correlation of N value with S-wave Velocity and Shear Modulus”, *Proceedings 2nd Europe Symposium on Penetration Testing*, Vol.1, pp.67-72.
  10. Jafari, M. K., Asghari, A., and Rahmani, I. (1997), “Empirical Correlation between Shear Wave Velocity(Vs) and SPT-N Value for South of Tehran Soils”, *4th Proceedings of International Conference on Civil Engineering*, Tehran, Iran, Vol.2, pp.355-365.
  11. Kim, D. S. (2010), “Problems and Suggested Improvements in Evaluation of Earthquake Ground Motion in Korean Seismic Codes”, *Korea Society of Seismic Isolation and Vibration Control Technical Reports*, No.12, pp.55-68.
  12. Kim, J. B. and Kim, Y. I. (2000), “The Influence of Weight Adjusting Method and the Number of Hidden Layer's Node on Neural Network's Performance”, *Journal of Korea Association of Information Systems*, Vol.9, No.1, pp.27-44.
  13. Kim, Y.S., Jeong, H. C., Lee, S.W., and Jeong, W. S. (2006) “Prediction of Various Properties of Soft Ground Soils using Artificial Neural Network”, *Korean Society of Civil Engineering Conference*, Vol.2003, No.10, pp.3463-3468.
  14. Korean Geotechnical Society(2009), *Commentaries of Structural Foundation Design Code*, Korea Geotechnical Society, certified Ministry of Land, Transport and Maritime Affairs in Korea (in Korean)
  15. Lee, I. M. and Lee, J. H. (1996), “Prediction of Pile Bearing Capacity Using Artificial Neural Network”, *Computers and Geotechnics*, Vol.18, No.3, pp.189-200.
  16. Lee, S. H. H. (1990), “Regression Models of Shear Wave Velocities”, *Journal of Chinese institute of Engineering*, Vol.13, pp.515-532.
  17. Lee, S. and Chang, J. W. (2006), “Evaluation of Bearing Capacity on PHC Auger-Drilled Piles Using Artificial Neural Network”, *Journal of the Korea institute for structural maintenance inspection*, Vol.10, No.6, pp.213-221.
  18. Nash, J. E. and Sutcliffe J. V. (1970), “River flow Forecasting through Conceptual Model Part 1-A Discussion of principles”, *Journal of Hydrology*, Vol.10, No.3, pp.398-409.
  19. Ohta, Y. and Goto, N. (1978), “Empirical Shear Wave Velocity Equation in Terms of Characteristic Soil Index”, *Earthquake Engineering and Structural Dynamics*, Vol.6, No.2, pp.167-187.
  20. Okamoto, S., Kokusho, T., Yoshida, Y., and Kusunoki, K. (1989), “Comparison of Surface vs Subsurface Wave Source for P-S Logging in Sand Layer”, *Proceedings 44th Annual Conference, JSCE*, Vol.3, pp.996-997.
  21. Ptilakis, K., Raptakis, D., Lontzetidis, K., Tika-Vassilikou, T., and Jongmans, D. (1999), “Geotechnical and Geophysical Description of Euro-Seistests, Using Field and Laboratory Tests, and Moderate Strong Ground Motion”, *Japan Earthquake Engineering*, Vol.3, No.3, pp.381-409.
  22. Salchenberger, L. M., Cinar, E. M., and Lash, N. A. (1992) “Neural Networks : A New Tool for Predicting Thrift Failures”, *Decision Sciences*, Vol.23, pp.899-916.
  23. Schmertmann, J.H. and Palacios, A. (1979), “Energy Dynamics of SPT”, *Journal of Geotechnical Engineering*, Division, ASCE, Vol.105, No.8, pp.909-926.
  24. Shi, J. (2000), “Reducing Prediction Error by Transforming Input Data for Neural Networks”, *Journal of Computing in Civil Engineering*, Vol.14, No.2, pp.109-116.
  25. Shin, H. S. (2001), *Neural Network Based Constitutive Models For Finite Element Analysis*, Ph.D Thesis, University of Wales Swansea, pp.11-14.
  26. Sivakugan, N., Eckersley, J. D., and Li, H. (1998), “Settlement Predictions Using Neural Network”, *Australian Civil Engineering Transactions*, CE40, pp.49-52.
  27. Stokoe, K. H., Joh, S. H., and Woods, R. D. (2004), “Some Contributions of in situ Geophysical Measurements to Solving Geotechnical Engineering problems”, *International Site Characterization ISC'2 Porto, Portugal*, pp.19-42.
  28. Sun C. G., Chung, C. K., and Kim, D. S. (2007), “Determination of Mean Shear Wave Velocity to the Depth of 30m Based on Shallow Shear Wave Velocity Profile”, *Journal of Earthquake Engineering Society of Korea*, Vol.11, No.1, pp.45-57.
  29. Sun C. G., Kim, H. J., and Chung, C. K. (2007), “Deduction of Correlations between Shear Wave Velocity and Geotechnical In-situ Penetration Test Data”, *Journal of Earthquake Engineering Society of Korea*, Vol.12, No.4, pp.1-10.
  30. Sykora, D. E. and Stokoe, K. H. (1983), “Correlations of in-situ measurements in sands of shear wave velocity”, *Soil Dynamics and Earthquake Engineering*, pp.20-36.
  31. Terzaghi, K. and Peck, R. B. (1967), *Soil Mechanics in Engineering Practice (2nd Edition)*, John Wiley & Sons.

Received : December 31<sup>st</sup>, 2013

Revised : March 4<sup>th</sup>, 2014

Accepted : March 5<sup>th</sup>, 2014