

비압밀-비배수(UU) 삼축실험과 피에조콘 실험결과를 이용한 국내 연약지반의 비배수전단강도 추정 인공신경망 모델 개발

Development of Neural Network Model for Estimation of Undrained Shear Strength of Korean Soft Soil Based on UU Triaxial Test and Piezocone Test Results

김 영 상¹ Kim, Young-Sang

Abstract

A three layered neural network model was developed using back propagation algorithm to estimate the UU undrained shear strength of Korean soft soil based on the database of actual undrained shear strengths and piezocone measurements compiled from 8 sites over the Korea. The developed model was validated by comparing model predictions with measured values about new piezocone data, which were not previously employed during development of model. Performance of the neural network model was also compared with conventional empirical methods. It was found that the number of neuron in hidden layer is different for the different combination of transfer functions of neural network models. However, all piezocone neural network models are successful in inferring a complex relationship between piezocone measurements and the undrained shear strength of Korean soft soils, which give relatively high coefficients of determination ranging from 0.69 to 0.72. Since neural network model has been generalized by self-learning from database of piezocone measurements and undrained shear strength over the various sites, the developed neural network models give more precise and generally reliable undrained shear strengths than empirical approaches which still need site specific calibration.

요 지

본 논문에서는 피에조콘 관입시험 결과와 상재하중으로부터 점토의 비배수전단강도를 간단히 예측하기 위한 피에조콘 인공신경망 모델 구축에 대하여 기술하였다. 피에조콘 인공신경망 모델의 구축을 위하여 먼저 국내 8개 지역에서 수행된 피에조콘 관입시험 결과와 불교란 시료에 대해 수행된 비압밀-비배수 삼축압축실험(UU)으로 얻어진 비배수전단강도 결과를 바탕으로 데이터베이스가 구축되었으며 오차역전파 알고리즘에 의하여 다층 구조를 갖는 최적 인공신경망 모델이 구성되었다. 구성된 인공신경망 모델은 모델 구축 시에 사용되지 않은 새로운 검증자료에 대해 비배수전단강도 예측을 수행하고 실내시험 결과와 비교함으로써 모델의 타당성이 검증되었다. 또한 피에조콘으로부터 비배수전단강도의 예측을 위해 제안된 기존의 경험적 방법으로 예측된 비배수전단강도와 제안된 모델의 예측결과를 비교하였다. 인공신경망 모델들은 사용된 전달함수에 따라 단일 은닉층 내에 존재하는 최적 뉴우런 개수는 다르지만 학습자료와 검증자료에 대해 공통적으로 결정계수 $R^2 = 0.69 \sim 0.72$ 범위의 예측정확도를 보여 국내 연약지반에서 피에조콘 관측결과들과 비배수전단강도 간의 비선형적 상관관계를 정의하는 데에 유용함을 알 수 있었다. 또한 구성된 인공신경망 모델은 지역적인 조정(site calibration)을 필요로 하는 기존의 경험적 방법들에 비하여 전 지역에서 고르게 예측 신뢰성이 높으며 이는 학습과정을 통하여 각 지역의 지반공학적 특성을 일반화하는 데에 성공했기 때문에 인공신경망 모델이 국내 전 지역에서 적용될 수 있는 일반화된 모델로 발전할 수 있음을 의미한다.

Keywords : Korean soft soils, Artificial neural network, Piezocone, UU triaxial test, Undrained shear strength

¹ 정회원, 국립여수대학교 해양공학과 조교수 (Member, Assistant Prof., Ocean Engrg., Yosu National Univ., geoyoungkim@yosu.ac.kr)

* 본 논문에 대한 토의를 원하는 회원은 2006년 4월 30일까지 그 내용을 학회로 보내주시기 바랍니다. 저자의 검토 내용과 함께 논문집에 게재하여 드립니다. 단, 건전한 토의 문화 정착을 위하여 학회에서 내용을 조정할 수 있음을 알려드립니다.

1. 서론

피에조콘(piezocone)은 관입시험과 간극수압의 소산 시험을 통해 현장지반의 공학적 분류와 압밀계수의 추정, 지반의 응력이력과 비배수전단강도의 추정이 가능한 매우 유용한 원위치시험(in-situ test) 장비로 국내에서도 활용이 매우 높다. 이 중 비배수전단강도는 연약지반 상 지반구조물 설계에 있어서 가장 중요한 지반정수 중 하나로 일반적으로 불교란시료를 채취하여 실내시험으로부터 결정해 왔다. 그러나 실내시험을 활용하는 방법은 시료채취 과정에서 발생하는 교란효과(disturbance effect)를 피할 수 없으며 무엇보다 대상 지역이 방대한 경우 많은 시간과 경비가 요구되는 단점이 있다. 피에조콘을 이용한 비배수전단강도의 추정은 실내시험에 비하여 매우 빠르고 경제적인 뿐 아니라 시료채취에 의한 교란효과를 피할 수 있다는 장점이 있으나 피에조콘 관측 값으로부터 비배수전단강도를 예측하는 경험적 상관관계들은 적용 전에 콘계수(cone factor) 결정을 위한 지역적인 보정(site specific calibration)이 요구된다.

지금까지 국내외에서 이론적인 연구와 경험적인 연구들을 통하여 피에조 콘으로부터 비배수전단강도 결정을 위한 다양한 노력들이 이루어져 왔다. 그러나 어떠한 방법도 피에조콘 관측 값으로부터 비배수전단강도를 결정하는 데에 지역적 특성을 극복하고 일반화된 방법으로 인정받지 못하고 있어 각 국가 또는 지역에 맞는 경험적 방법의 개발을 위한 노력이 집중되어 왔다. 이러한 시도들에서는 입력변수 값과 비배수전단강도 간의 복잡한 상관관계를 통계적인 기법을 이용하여 연결하려 하였으나, 다양한 노력에도 불구하고 상관관계를 정의하는 경험적 콘 계수들의 분산이 매우 커서 지역적 특성에 맞는 경험적 방법들의 사용에도 한계가 있는 것으로 판단된다. 국내외의 경험적 비배수전단강도 산정법에서 대부분 사용되고 있는 통계적 기법인 회귀분석(regression)은 그 특성상 최초에 부여된 수학적 관계식이 자료들의 경향을 얼마나 잘 표현할 수 있는지에 따라 얻어진 예측식의 예측결과가 큰 영향을 받으며 경험식을 제안한 제안자의 의도와 지식, 경험에 따라 예측 신뢰도가 달라질 수 있다. 한편 최근 지반공학 분야에서 다양하게 도입되고 있는 인공신경망이론을 이용한 모델링은 다양한 입력변수에 대한 검토가 가능할 뿐 아니라 부적절하거나 다른 변수들로부터 추론이 가능한 입력변수에 대해서는 학습과정을 통하여 매우 낮은 연결

강도가 부여되므로 생략하거나 조정을 통하여 최적의 구조를 가질 수 있어 통계적 회귀분석 모델에 비해 제안자의 오류를 최소화 할 수 있다. 또한 경험적 상관관계에서는 현장지반의 다양성과 함께 현장에서 채취되는 시료들이 실내로 운반되는 과정에서 불가피하게 겪게 되는 교란효과(disturbance effect)가 분산을 크게 하며 결과적으로 상관관계의 예측 신뢰성 저하를 유발한다. 그러나 현장 피에조콘 자료에 대해 학습된 인공신경망 모델은 현장지반의 변화와 입력된 자료의 부정확성을 다룰 수 있도록 학습되므로 기존의 경험적 상관관계보다 높은 신뢰성을 확보할 수 있을 것으로 기대된다(Goh, 1994; 김영상, 2003).

본 논문에서는 피에조콘 관측 값으로부터 비배수전단강도를 예측하는 데에 인공신경망 이론이 매우 유용하다는 기존연구(김영상, 2003)를 바탕으로 국내 연약지반의 비배수전단강도 추정을 위한 최적의 피에조콘 인공신경망 모델 구축하고 모델의 전달함수 및 연결강도를 제시하여 국내 지반공학자들이 피에조콘으로부터 비배수전단강도를 추정할 수 있는 실질적인 모델을 개발하였다. 이를 위하여 국내 서해안 및 남해안의 대표적인 연약지반 8개 지역에서 수행된 피에조콘 관입시험 결과와 비압밀-비배수(UU) 삼축압축시험 결과를 데이터베이스로 구축하여 인공신경망 모델구축을 위한 학습과 검증에 사용하였다. 구축된 인공신경망 모델은 모델구축에 사용되지 않은 새로운 검증자료에 대해 비배수전단강도를 예측하고 관측값과 비교함으로써 검증되었으며 기존의 경험적 방법들의 예측결과와 비교함으로써 제안된 모델의 유용성과 정확성이 검토되었다.

2. 비배수전단강도 추정을 위한 피에조콘 경험모델

피에조콘 시험결과로부터 연약지반의 비배수전단강도 추정을 위한 접근법으로는 이론적 또는 경험적 접근법이 있으며 이중 이론적 접근법들은 흙의 거동모델을 바탕으로 제안되었으므로 명확한 이론적 배경을 바탕으로 하고 있으나 모델 개발 시 도입된 흙 거동의 단순화와 지반의 다양성 등의 원인으로 인해 특정 물성을 갖는 지반에 대해서만 검증되었다. 또한 제안된 식에서 요구하는 특정 입력변수를 얻기 위해서는 정교한 실험을 동반하는 불편함이 있어 일반적으로 경험적 방법들이 선호되어 왔다. 경험적 방법을 이용한 비배수전단강도 결정법에서는 다음 식 (1)~(3)들이 공통적으로 적용

되고 있다. 식 (1)~(3)에서는 사용된 콘 관측값과 응력에 따라 순 선단저항력(net cone tip resistance) ($q_T - \sigma_{vo}$), 과잉간극수압 ($u_2 - u_0$), 유효 선단저항력(effective cone tip resistance) ($q_T - u_2$)을 사용하고 있으며 콘 계수(cone factor) N_{kT} , $N_{\Delta u}$, N_{ke} 를 각각의 상관계수로 정의하여 사용하고 있다.

$$s_u = \frac{q_T - \sigma_{vo}}{N_{kT}} \quad (1)$$

$$s_u = \frac{u_2 - u_0}{N_{\Delta u}} \quad (2)$$

$$s_u = \frac{q_T - u_2}{N_{ke}} \quad (3)$$

여기서 q_T =불균등 면적비에 대해 수정된 콘 선단저항력 = $q_c + (1-a)u_2$, q_c =관측 선단저항력, a =불균등 면적비 (unequal end area ratio), u_2 =콘 선단부 뒤에서 관측된 간극수압, σ_{vo} =총 연직상재하중, u_0 =정수압

그러나 이들 상관관계의 핵심인 콘 계수(cone factor) N_{kT} , $N_{\Delta u}$, N_{ke} 값들은 국외 지반의 경우 $N_{kT}=5 \sim 30$, $N_{ke}=2 \sim 10$, $N_{\Delta u}=1 \sim 13$ 의 넓은 범위에 분포하며 국내 지반에 대해서도 $N_{kT}=10 \sim 25$, $N_{ke}=9.3 \sim 17.2$, $N_{\Delta u}=1.7 \sim 4.4$ 의 범위에 분포하여 국가 및 지역에 따라서 매우 큰 차이를 보인다. 또한, 같은 국가 내에서도 비교 대상인 비배수전단강도 결정법에 따라 그 값이 상이하여 일반화된 값으로 결정하기 어렵다.

피에조콘 관측결과로부터 비배수전단강도를 예측하는 경험적 방법에 대한 연구는 국내에서는 1990년대 후반에 와서 적극적으로 수행되고 있으며 이 중 장인성 등(2001)의 국내 10개 지역의 자료를 바탕으로 한 콘 계

수 산정에 관한 연구에서 나타난 바와 같이 콘 계수들의 분포가 그림 1과 같이 넓은 범위에 분포되어 경험적 방법에 의한 비배수전단강도 산정법의 경우 넓은 지역에서 일반화된 상관관계로 발전되기에 어려움이 있다.

3. 비배수전단강도 추정을 위한 피에조콘 인공신경망 모델(Piezocone Neural Network Model, PNNMsu)

인공신경망 이론은 인간의 뇌 구조에서 학습되고 축적되는 기존 지식의 운용체계를 모사한 컴퓨터 모델로 국내에서도 인공신경망을 이용한 말뚝의 지지력 및 수평변위의 추정, 압축지수의 추정, 화강풍화토의 토랑변화율 추정, 압밀침하량 예측, 삼축실험으로부터 비배수전단강도 예측, 굴착 시 흙막이 벽체의 최대변위 예측 등에 사용된 바 있으며 다양한 분야에서 인공신경망 이론의 응용이 증가하고 있는 추세이다. 최근에 김영상 등(2002)과 Kurup and Dudani(2002)는 피에조콘으로부터 지반의 선형압밀하중 예측을 위한 인공신경망 모델을 개발하였으며 피에조콘 해석에 있어서 인공신경망 이론의 적용이 매우 유용함을 보였다. 한편 김영상(2003)은 Rad and Lunne(1988)의 자료를 바탕으로 피에조콘으로부터 국외 11개 지역 점토지반의 비배수전단강도를 결정하는 인공신경망 모델구축에 대하여 연구하고 그림 2와 같은 인공신경망 모델을 개발하여 인공신경망 적용 가능성을 보였다. 김영상(2003)의 연구에서는 입력변수와 은닉층에 존재하는 뉴우런의 수, 전달함수, 수렴기준 등 여러 종류의 모델을 대상으로 검토하고 3개의 입력변수 - 상재하중 σ_{vo} , 수정된 콘 관입저항력 q_T , 콘 선단부 뒤에서 관측된 관입간극수압 u_2 - 만으로도




그림 1. 소성지수에 따른 콘 계수의 변화(장인성 등, 2001)




그림 2. 국외 연약지반의 비배수전단강도 결정을 위한 인공신경망 모델구조(김영상, 2003)

충분한 예측정확도를 확보한 상태로 비배수전단강도를 예측할 수 있음을 보인다. 그러나 김영상(2003)의 연구는 피에조콘으로부터 국외 점토지반의 비등방압밀-비배수(CAUC) 및 등방압밀-비배수(CIUC) 삼축실험에 의한 비배수전단강도를 예측하는 모델로 국내 점토와 지반공학적 특성이 다른 자료를 바탕으로 개발되어 국내 지반에 바로 적용하기에는 무리가 있다.

인공신경망 모델은 그림 2와 같이 입력층(I)-은닉층(H)-출력층(O)의 다층 신경망 형태로 구성되며 각 층에는 인간의 신경조직의 기본단위를 모사한 뉴우런(neuron)이 존재하고 각 층의 뉴우런 들은 다른 층의 모든 뉴우런 들과 특정 연결강도로 연결되어 있다. 각층의 각 뉴우런 에 전달된 입력값 들은 연결강도와 곱해지며 이들의 합은 전달함수(transfer function)에 의해 처리되고 출력되어 다시 다음 층에 존재하는 뉴우런 들의 입력값으로 전달된다. Hornik 등(1989)은 단일 은닉층만으로도 적절한 수의 뉴우런이 존재한다면 함수근사화(function approximation)와 패턴인식(pattern classification)이 충분한 정도(accuracy)로 가능함을 증명한 바 있다. 인공신경망 모델의 구축은 크게 두 단계로 나눌 수 있다. 먼저 기지의 입력과 결과값을 이용하여 각 층에 존재하는 뉴

우런(neuron)간의 연결강도(weight)를 조정하는 훈련단계(training phase)로, 이 과정을 통하여 신경망 모델은 주어진 자료들을 일반화할 수 있는 최적의 연결강도를 스스로 학습(learning)하게 된다. 다음은 훈련과정을 통하여 구축된 모델을 검증하는 단계(testing phase)로, 구축된 모델에 학습에 사용되지 않은 기지의 결과값을 가지는 입력값을 입력하여 얻어진 예측값과 실험값을 비교함으로써 구성된 모델을 검증한다.

3.1 데이터베이스(Database)

본 연구에서는 국내 연약지반이 발달된 8개 지역의 238개 정점의 자료들이 인공신경망 모델의 구축과 검증에 사용되었으며 자료들은 크게 남해안에서는 부산, 양산, 광양지역의 6개소, 서해안에서는 서산, 영종도 등의 2개소 총 8지역의 연약지반에서 수행된 피에조콘 관입 시험 자료와 비압밀-비배수(UU) 삼축압축시험에서 결정된 비배수전단강도 값으로 구성되어 있고 각 지역과 지반의 특성이 표 1에 정리되어 있다. 이 중 81.5%에 해당하는 194개 정점의 자료가 인공신경망 모델 구축을 위한 '학습자료'로 사용되었으며, 전체 자료 중 임의로 선

표 1. 인공신경망 모델의 학습 및 검증에 사용된 현장자료의 지반특성

Site	Location	자연함수비(%)	소성지수	#200 통과율	과압밀비	USCS
인천	영종도	19.6~46.2	2.6~23.9	83~99.4	0.7~3.4	CL, ML
서산		29.2~40.0	6~14	58.1~86.9	4.2	CL, ML
양산		31.5~78.7	6~38	15.0~99.8	0.3~15.2	CL, CH, SM
광양	항만	57.7~106.7	36~63	85.5~100	0.6~2.2	CH, MH
	발전소	31.7~58.7	5.3~38.4	33.4~98.9	0.6~1.1	CH, CL, SC
부산	투기장	21.9~81.3	8.3~55.6	7.9~99.6	0.2~8.6	CH, CL
	도로	20~72.3	2.4~56.5	-	0.4~1.4	CH, SM
	소각장	41.8~55.7	33.6~53	95.5~98.5	1.4~1.9	CH

표 2. 학습자료와 검증자료의 통계특성

변수 및 자료 분류		평균(mean)	표준편차(S.D)	최대(Maximum)	최소(Minimum)
σ_{vo} (kPa)	training	211.9	132.7	644.7	20.5
	testing	247.6	119.7	640.6	62.0
q_T (kPa)	training	665.6	426.7	3092.6	53.9
	testing	765.3	419.7	2365.2	171.5
u_2 (kPa)	training	312.5	217.0	1027.9	-48.4
	testing	351.4	198.3	798.1	-6.2
s_u (kPa)	training	25.1	14.0	75.5	2.9
	testing	30.2	13.4	58.8	7.8

택된 18.5%에 해당하는 44개 정점의 자료는 구축된 모델의 ‘검증자료’로 사용되었다. 학습 및 검증에 사용된 입력변수들과 출력값(비배수전단강도)의 범위가 표 2에 정리되어 있으며 학습자료와 검증자료의 통계특성(평균과 표준편차)을 살펴보면 임의로 추출된 검증자료의 통계적 특성이 모집단인 학습자료의 통계적 특성과 크게 다르지 않아 모델구축 및 검증에 사용되어도 무리가 없을 것으로 판단된다. 한편 각 입력값들은 인공지능망의 학습을 효율적으로 수행하기 위하여 최대값과 최소값을 기준으로 [-1, 1]범위의 값들로 정규화(normalized) 되었다.

3.2 학습규칙 및 최적화기법(Learning rule and optimization technique)

본 연구에서 구축된 인공지능망 모델은 매트랩 툴박스(Matlab neural network toolbox)를 이용하여 프로그램 되었으며 학습규칙으로는 오차역전파 알고리즘이 사용되었다. 다층 신경망의 학습에 이용되는 오차역전파 알고리즘(error back-propagation algorithm)은 입력값과 결과값의 비선형적인 관계를 구축하는 함수근사화(function approximation)에 매우 효율적인 것으로 알려져 있다. 또한 연결강도와 바이어스(bias)를 최적화하는 기법으로는 매트랩 툴박스에서 제공하는 Levenberg-Marquardt 기법을 이용하였으며 이 기법은 기존의 급속하강법(steepest descent method)에 비해 오차역전파 알고리즘의 학습 효율을 매우 향상 시키는 것으로 알려져 있다. 학습은 최대 훈련회수(max. epoch)에 도달하거나 식 (4)로 정의되는 평균제곱오차(mse)가 최종 목적 제곱오차(mean squared error goal)인 0.005 이하로 수렴하는 경우에 종료하도록 프로그램 되었다.

$$mse = \frac{1}{n} \sum_{k=1}^n (a(k) - t(k))^2 \quad (4)$$

여기서, $a(k)$ =인공지능망의 비배수전단강도 예측값, $t(k)$ =실험으로 얻어진 비배수전단강도 실측값, n =학습에 사용된 전체 자료의 수

3.3 모델의 구성 및 최적모델의 선정

본 연구에서는 선행연구결과를 바탕으로 기본 입력 변수들 - 상재하중 σ_{vo} , 피에조콘 선단저항력 q_T , 콘 선단부 뒤에서 관측된 간극수압 u_2 - 만으로 점토지반의 비배수전단강도를 예측하도록 하는 인공지능망 모델을 구성하였다. 은닉층의 수는 단일 은닉층만으로도 적절한 수의 뉴우런이 존재한다면 함수근사화(function approximation)와 패턴인식(pattern classification)이 충분한 정도(accuracy)로 가능하다는 Hornik 등(1989)의 연구결과를 바탕으로 본 연구에서도 단일 은닉층을 사용하였으며 효과적인 것으로 나타났다. 그러나 은닉층에 존재하는 뉴우런의 수와 전달함수의 종류에 따라 구성된 인공지능망 모델의 정확도(Accuracy)가 달라질 수 있으므로 일반적으로 오차역전파 알고리즘에 적용되는 3개의 전달함수들(Log-sigmoid, Tan-sigmoid, Linear)의 조합들을 표 3과 같이 적용하고 은닉층에 존재하는 뉴우런의 수를 2에서 10개 까지 증가시키면서 학습자료와 검증자료에 대한 모델의 예측 정확도를 근거로 최적 피에조콘 인공지능망 모델을 구축하도록 하였다. 출력층은 삼축압축시험(UU)에서 얻어지는 비배수전단강도를 표현할 수 있도록 한 개의 뉴우런(neuron)으로 구성되었다. 알려진 바(Ladd와 Foott, 1974)와 같이 비배수전단강도는 실험방법에 따라 그 크기가 달라지는 강도 이방성(strength anisotropy)을 가지므로 인공지능망 모델의 구축을 위해 출력층에 사용되는 비배수전단강도는 동일한 실험과정을 통하여 얻어진 값으로 활용하여야 한다. 본 연구에서는 국내에서 연약지반 설계 시에 실내실험

중 가장 일반적으로 수행되는 비압밀-비배수(UU) 삼축 실험에 의한 비배수전단강도 값을 학습을 위한 출력목표 값으로 선정하였으며 따라서 구축된 모델은 다른 실험법(예, FVT 또는 일축압축실험)으로 산정된 비배수전단강도를 예측하기 위해서는 각 실험법에 의한 비배수전단강도에 대해 재학습될 필요가 있다.

그림 3(a), (c), (e)는 전달함수가 조합된 각 인공신경망 모델 내에서 뉴우런 수의 증가에 따른 학습자료와 검증자료에 대한 예측값과 실험값의 결정계수(coefficient of determination) R^2 의 변화를 나타낸 것으로 뉴우런의 수가 증가할수록 학습자료에 대한 결정계수가 높아지는 반면 학습에 사용되지 않은 검증자료에 대한 결정계수는 지속적으로 증가하기 보다는 특정 뉴우런 수를 지나면 오히려 감소하는 현상을 보이게 된다. 이와 같이 학습자료에 대한 결정계수가 증가하는 것은 뉴우런 수의 증가로 인해 학습효과가 증가되는 것이 아니라 자료를 기억(remember)하는 현상으로, 이러한 현상이 발생되면 오히려 학습에 사용되지 않은 검증자료에 대한 예측 정확도는 현저히 떨어지게 된다. 따라서 이러한 현상을 막기 위해서는 ‘early stopping’ 또는 ‘regularization’ 기법을 적용하여 일반화하거나 검증자료에 대한 결정계수를 함께 관찰하여 뉴우런 수의 증가에도 더 이상

결정계수가 증가하지 않는 최소의 뉴우런 수로 모델을 결정하는 것이 바람직하다. 본 연구에서는 그림 3의 결과에 나타난 바와 같이 검증자료의 결정계수가 크게 감소하지 않은 범위 내에서 학습자료의 결정계수가 최대한 뉴우런 수를 최적 뉴우런 수로 결정하였으며 표 3에 정리된 바와 같다. 한편 그림 3(b), (d), (f)에는 각 모델의 최적 뉴우런 수를 적용한 경우의 학습 및 검증자료에 대한 각 모델의 예측결과를 실험결과와 비교한 것이며 이때 결정계수가 표 3에 정리되어 있다. 세 개의 모델 중에서는 Tan-sigmoid와 Linear 전달함수의 조합을 사용하며 6개의 은닉층을 갖는 모델이 가장 예측 경향이 좋은 것으로 판단되며 나타난 바와 같이 다른 전달함수의 조합을 갖는 모델의 결정계수들도 최적모델과 비교할 때 큰 차이를 보이지 않아 인공신경망 모델링 기법 자체의 적용이 매우 효과적인 것으로 판단된다. 한편 표 4에는 최적모델인 Tansig-Linear 모델의 입력층-은닉층 간의 연결강도 행렬(IW)과 은닉층-출력층의 연결강도 행렬(LW)이 정리되어 있다. 표 4의 IW행렬[(1)~(3)열]은 입력층의 입력변수 들(σ_{vo} , q_T , u_2)과 은닉층의 6개의 뉴우런 간의 연결강도로서 입력변수들이 입력층에 주어지면 입력된 값들과 곱해져 그 합이 Tan-sigmoid 전달함수에 의해 처리되어 은닉층에 입력값으로 전달된다.

표 3. PNNMsu 전달함수와 최적 뉴우런 수에 따른 결정계수(coeff. of determination) R^2 비교

전달함수	최적 뉴우런 수	training data R^2	testing data R^2
Logsig - Linear	4	0.71	0.70
Tansig - Linear	6	0.72	0.71
Logsig - Tansig	4	0.72	0.69


표 4. PNNMsu(tansig(6)-linear) 모델의 연결강도

은닉층 뉴우런	입력 및 출력 연결강도(Weight matrix, $IW_{1,1}$ & $LW_{2,1}$) [†]			
	입력 1 - σ_{vo} (1)	입력 2 - q_T (2)	입력 3 - u_2 (3)	출력 (4)
1	7.7337	16.1236	142.6362	0.13
2	-586.066	114.8168	-197.305	0.1529
3	2.0053	0.439	0.4991	0.6124
4	17.7467	-31.6702	-11.1864	98.5856
5	64.2132	-60.6498	-58.2467	0.0739
6	17.645	-31.4907	-11.1136	-98.6974


† IW : 입력층과 은닉층 간의 연결강도, LW : 은닉층과 출력층 간의 연결강도

표 5. 피에조콘 인공신경망 모델 입력변수의 상대중요도(relative importance) 비교


Model	입력 1 - σ_{vo}	입력 2 - q_T	입력 3 - u_2	reference
PNNMsu	38.61%	29.17%	32.22%	본 연구
SuM3	31.71%	28.39%	39.91%	김영상(2003)




(a) 은닉층의 뉴우런 수에 따른 결정계수(R^2)




(b) Logsig(4)-Linear 모델




(c) 은닉층의 뉴우런 수에 따른 결정계수(R^2)



(d) Tansig(6)-Linear 모델



(e) 은닉층의 뉴우런 수에 따른 결정계수(R^2)



(f) Logsig(4)-Tansig 모델

그림 3. 최적모델 구성을 위한 뉴우런 수와 전달함수 조합에 따른 예측정도(R^2) 비교

또한 은닉층에서 출력된 값들은 다시 LW행렬[(4)열]과 곱해지고 그 합이 Linear전달함수에 의해 처리되어 최종적으로 출력층에 전달되는 과정을 거친다. 표 5에는 Garson(1991)의 제안을 바탕으로 산정된 각 입력변수의 상대중요도(relative importance)가 정리되어 있으며 상대중요도란 출력결과에 미치는 입력변수들의 각각의 기여도를 의미하며 모든 입력변수들의 상대중요도의 합은 100%이다. 표 5에 정리된 바와 같이 국외 11개 점토지반의 데이터를 바탕으로 제안된 김영상(2003)의 연구결과와 국내 연약지반의 점토지반의 데이터를 바탕으로 구성된 모델의 입력변수의 상대중요도가 거의 유사한 것으로 나타나 3개의 입력변수만으로 최적모델을 구성한 김영상(2003)과 본 연구의 연구결과가 일관성 있는 것으로 나타났다.

4. 제안된 모델의 검증 및 적용


4.1 학습자료와 검증자료에 대한 PNNMSu 모델들의 예측결과

표 3에 정리된 바와 같이 최적화된 뉴우런 수를 갖는 인공신경망 모델들을 이용한 학습자료와 검증자료에 대한 비배수전단강도 예측 결과가 그림 4에 나타나 있다. 그림 4(a)에는 학습자료에 대한 전체 모델들의 예측 결과가 비압밀 비배수(UU) 삼축실험으로부터 결정된


비배수전단강도 값과 비교되어 있다. 학습자료에 대한 비배수전단강도 예측결과는 실험결과와 전체적으로 고르게 일치하는 것으로 나타났으며 각 모델 간에는 큰 차이는 보이지 않는 것으로 나타났다. 그림 4(b)에는 학습단계에 이용되지 않는 검증자료들 만에 대해서 각 모델로 예측된 비배수전단강도와 UU실험에 의해 관측된 비배수전단강도가 비교되어 있으며 40kPa 이상에서는 약간 과소평가하는 경향이 있으나 전체적으로는 비교적 좋은 예측결과를 주는 것으로 판단할 수 있다. 40kPa 이상에서 나타나는 과소평가 현상은 본 연구에서 대상으로 한 국내 연약지반의 비배수전단강도 범위가 그림 4(a)에 나타난 바와 같이 40kPa 이상의 자료 수가 40kPa 미만의 자료 수에 비하여 상대적으로 현저히 적기 때문에 판단되며 추후 자료축적 등을 통하여 데이터베이스를 확장할 경우 충분히 극복될 것으로 판단된다. 이상에서 국내 8개 지역의 연약지반의 데이터베이스를 바탕으로 구축된 피에조콘 인공신경망 모델은 국외 점토지반에 대한 김영상(2003)의 연구와 마찬가지로 매우 성공적으로 적용될 수 있음을 확인하였다.

4.2 경험적 방법들과의 비교

본 절에서는 기존의 경험적 방법(식 (1)~(3))을 이용한 비배수전단강도 예측결과를 실험에서 얻어진 비배수전단강도와 비교하고 개발된 인공신경망 모델 중



(a) 학습자료




(b) 검증자료


그림 4. PNNMSu 모델들의 비배수전단강도 예측결과 비교

Tansig(6)-linear모델의 예측결과를 함께 비교함으로써 인공지능망 모델의 유용성과 국내 전 지역에서 적용할 수 있는 일반화된 모델로의 적용성에 대하여 검토하였다. 기존의 경험식을 사용하기 위하여 학습 자료들로부터 콘 계수(cone factor) 들이 $N_{kT}=16.5$, $N_{\Delta u}=7.33$, $N_{ke}=12.54$ 로 결정되었으며 콘 계수 중 N_{kT} 와 $N_{\Delta u}$ 는 기존의 연구결과 범위에 부합되나, N_{ke} 의 범위는 다소 크게 나타났다. 기존의 연구결과를 적용하는데 있어서 각 지역의 콘 계수를 결정하여 지역별로 적용할 수도 있으나 본 절에서는 전체 지역에 대하여 학습된 인공지능망과의 비교를 위


하여 전체 학습자료에 대한 콘 계수를 적용하였다. 결정된 콘 계수와 식 (1)~(3)을 이용하여 학습자료와 검증 자료에 대한 비배수전단강도 예측을 수행하고 모든 예측 비배수전단강도들을 관측된 UU 삼축압축실험에서 결정된 실측값으로 정규화하여 그림 5와 6에 도시하였다. 또한 정규화된 비배수전단강도의 통계특성 값(평균과 표준편차)을 표 6에 정리하였는데 평균이 1에 가깝고 표준편차 값이 작을수록 예측된 비배수전단강도 값이 실제 비배수전단강도와 일치하고 예측정확도가 높은 것을 의미한다.



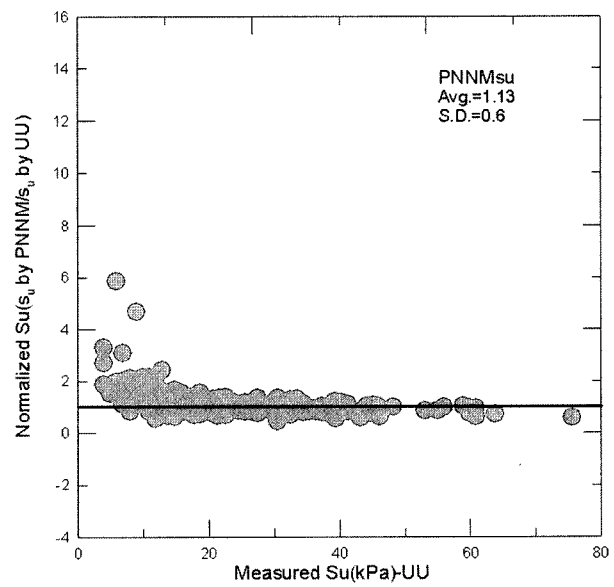
(a) N_{kT} 방법



(b) $N_{\Delta u}$ 방법



(c) N_{ke} 방법




(d) 인공지능망 모델


그림 5. 경험적 방법들과 인공지능망 모델로 예측된 정규화 된 비배수전단강도 비교(학습자료)

그림 5와 6 및 표 6에 나타난 바와 같이 기존의 경험적 모델들 중에서는 관입 과잉간극수압($u_2 - u_o$)을 바탕으로 한 $N_{\Delta u}$ 방법의 정규화 된 비배수전단강도 평균이 학습자료와 검증자료에 대해 각각 0.96과 0.86, 표준편차 1.06, 0.8로 순 선단저항력($q_T - \sigma_{vo}$)을 사용하는 N_{kT} 방법(평균 1.25와 1.06, 표준편차 1.0과 0.66)과 함께 좋은 결과를 주는 것으로 나타났다. 그러나 $N_{\Delta u}$ 방법은 그림 5(b)와 6(b)에 나타난 바와 같이 관입 과잉간극수압 값이 음($u_2 - u_o < 0$)인 경우에 비배수전단강도 값도 음(negative)을 주는 비현실적인 현상을 보여 실용적으로


는 N_{kT} 방법이 적절할 것으로 판단된다. 또한 유효 선단저항 값($q_T - u_2$)을 사용하는 N_{ke} 방법에 의한 예측결과는 앞의 두 방법보다 상대적으로 예측 정확도가 떨어지는 것으로 나타났으며 $N_{\Delta u}$ 방법과 같이 음의 비배수전단강도를 주는 경우가 발생되었다[그림 5(c) 및 6(c)]. 인공신경망 모델의 정규화 된 비배수전단강도 예측결과는 학습자료와 검증자료에 대해 평균 1.13과 0.97, 표준편차 0.6과 0.29로 기존의 방법들과 비교할 때 평균이 1에 가깝고 표준편차가 현저히 작아 예측 정확도가 높고 신뢰성이 큰 것으로 판단된다. 특히 이 결과는 기존의 경




(a) N_{kT} 방법



(b) $N_{\Delta u}$ 방법



(c) N_{ke} 방법



(d) 인공신경망 모델

그림 6. 경험적 방법들과 인공신경망 모델로 예측된 정규화 된 비배수전단강도 비교(검증자료)

표 6. 기존 경험법과 인공신경망 모델에 의한 정규화 비배수전단강도 예측 평균 및 표준편차

	학습자료		검증자료	
	평균	표준편차	평균	표준편차
PNNMSu	1.13	0.6	0.97	0.29
N_{kT} 방법	1.25	1.0	1.06	0.66
$N_{\Delta u}$ 방법	0.96	1.06	0.86	0.8
N_{ke} 방법	1.31	1.51	1.12	1.03

험법 들이 국내 8개 지역에서 얻어진 다양한 지반에 대한 전체적인 콘 계수를 활용할 경우 그 예측능력이 상대적으로 떨어지는 반면, 인공신경망은 다양한 특성을 갖는 지반에서도 고르게 예측 신뢰도가 높아 학습과정을 통하여 데이터베이스에 포함된 지역에서의 일반화된 예측방법으로서 사용 가능성을 알 수 있다.

5. 결론

본 논문에서는 국내 8개 연약지반에서 수행된 피에조콘 관입실험결과와 비배수-비압밀(UU) 삼축압축실험으로 얻어진 비배수전단강도를 데이터베이스로 하여 국내 연약지반의 비배수전단강도 추정이 가능한 다층 구조를 갖는 피에조콘 인공신경망 모델(PNNMSu)의 구축에 대하여 기술하였다. 구성된 피에조콘 인공신경망 모델은 상재하중 σ_{vo} , 수정된 관입저항력 q_T , 관입 간극수압 u_2 를 입력값으로 사용하며 단일 은닉층으로 구성되어 있고 출력층에서는 비배수전단강도 하나만을 출력하도록 구성되어 있다. 제안된 기법과 모델에 대한 연구 결과를 정리하면 다음과 같다.

- (1) 피에조콘 인공신경망 모델은 단일 은닉층으로 구성되어 있으며 은닉층에 존재하는 뉴우런의 최적 개수는 사용된 전달함수에 따라 다르나 Logsig-linear 전달함수 모델, Tansig-Linear 모델, Logsig-Tansig 모델에 대해 각각 4, 6, 4의 뉴우런 수가 가장 최적인 것으로 나타났다. 그러나 세 개의 모델 모두 학습 자료에 대해 0.71~0.72의 결정계수를, 검증자료에 대해서는 0.69~0.71의 결정계수를 보여 모델 간의 큰 차이 없이 입력변수와 출력변수(비배수전단강도) 사이의 비선형적 상관관계를 성공적으로 모델하고 실용적으로도 적용 가능한 예측 정확도가 확보되는 것으로 판단된다.
- (2) 피에조 콘으로부터 비배수전단강도를 예측하는 기존의 경험적 모델들 중에서는 순 선단저항력($q_T - \sigma_{vo}$)

을 사용하는 N_{kT} 방법이 가장 실용적인 것으로 평가되었으며 $N_{\Delta u}$ 방법과 N_{ke} 방법은 음(negative)의 비배수전단강도를 예측하는 비현실적인 결과를 도출하기도 하였다.

- (3) 피에조콘 인공신경망 모델은 기존의 경험적 모델에 비하여 훨씬 높은 예측정도를 가지는 것으로 나타났다. 학습 및 검증에 사용된 다양한 특성을 갖는 8개의 국내 연약지반에 대한 예측결과가 일관성 있고 정확한 것으로 나타나 기존의 경험적 모델이 특정 지역에만 적용 가능하던 지역성을 극복하고 국내 연약지반에서 일반적인 상관관계로 발전될 가능성이 있음을 재확인 하였다.
- (4) 본 연구에서 제안된 인공신경망 모델은 추후 국내 연약지반 자료들이 지속적으로 추가될 경우 간단한 재 학습을 통해 모델을 수정할 수 있어 다양한 지역의 지반특성을 고려하면서도 예측정확도가 높은 모델의 구축이 가능하므로 국내 관련 업계와 연구자 등 지반공학자 들의 지속적인 자료축적과 상호협조를 통하여 국내 전 지반에 활용 가능한 모델로 발전될 것을 기대한다.

감사의 글

본 연구는 과학기술부가 선정한 스마트 사회기반시설연구센터(SISTEC:생산기반분야/ERC)의 연구비 지원으로 수행된 것으로 이에 감사드립니다.

참고 문헌

1. 김영상 (2003), "피에조콘을 이용한 점토의 비배수전단강도 추정에서의 인공신경망 이론 적용", *한국지반공학회는논문집*, 제19권 4호, pp.287-298.
2. 김영상, 이승래, 김종수 (2002), "피에조콘을 이용한 연약지반 선형압밀하중 결정의 인공신경망 이론 적용 연구", *대한토목학회 논문집*, 제22권, 제6-C호, pp.623-633.
3. 장인성, 이선재, 정충기, 김명모 (2001), "국내 점성토 지반의 피

- 에조콘 계수”, *한국지반공학회논문집*, 제17권 6호, pp.15-24.
4. Chen, B. S. Y. (1994), *Profiling stress history of clays using piezocone with dual pore pressure measurements*, Ph.D thesis, Georgia Institute of Technology, p.350.
 5. Chen, B. S. Y. and Mayne, P. W. (1993), “Piezocone Evaluation of Undrained Shear Strength in Clays”, *11th Southeast Asian Geotechnical Conference*, 4-8 May, Singapore, pp.91-98.
 6. Garson, G. D.(1991), “Interpreting neural-network connection weights”, *AI expert*, 6(7), pp.47-51.
 7. Goh, A. T. C. (1994), “Seismic liquefaction potential assessed by neural-networks”, *ASCE Journal of Geotechnical Engineering*, Vol.120, No.9, pp.1467-1480.
 8. Hornik, K., Stinchcombe, M., and White, H. (1989), “Multilayer feed-forward networks are universal approximators”, *Neural Networks*, 2(5), pp.359-366.
 9. Konard, J. -M. and Law, K. T. (1987), “Undrained Strength from piezocone tests”, *Canadian Geotechnical Journal*, Vol.24, pp.392-405.
 10. Kurup, P. U. and Dudani, N. (2002), “Neural networks for profiling stress history of clays from PCPT data”, *ASCE Journal of Geotechnical and Geoenvironmental Engineering*, Vol.128, No.7, pp.569-579.
 11. Ladd, C. C. and Foott, R. (1974), “New Design Procedure for Stability of Soft Clays”, *ASCE Journal of Geotechnical Engineering*, 100, No.GT.7, pp.763-786.
 12. Mayne, P. W. (1980), “Cam Clay predictions of undrained strength”, *ASCE Journal of Geotechnical Engineering*, 106, 11, pp.1219-1242.
 13. Rad, N.R. and Lunne, T. (1988), “Direct Correlations between Piezocone Test Results and Undrained Shear Strength of Clay”, *ISOPT-1*, Vol.2, pp.911-917.

(접수일자 2005. 7. 5, 심사완료일 2005. 10. 10)