

피에조콘을 이용한 선행압밀하중 결정 신경망 모델의 초기 연결강도 의존성 개선 Improvement of Initial Weight Dependency of the Neural Network Model for Determination of Preconsolidation Pressure from Piezocone Test Result

박솔지¹⁾, Sol-Ji Park, 주노아²⁾, No-Ah Joo, 박현일³⁾, Hyun-Il Park, 김영상⁴⁾, Young-Sang Kim

¹⁾ 전남대학교 건설·환경공학과 석사과정, Graduate Student, Dept. of civil & Environ. Eng., Chonnam National Univ.

²⁾ 다산이엔지, 지반사업부, Dasan ENG., Dept. of Ground Bases Business

³⁾ 삼성기술연구소, 선임연구원, Senior Researcher, Research Center, Samsung E & C

⁴⁾ 전남대학교 건설·환경공학과 조교수, Assistant Prof., Dept. of civil & Environ. Eng., Chonnam National Univ.

SYNOPSIS : The preconsolidation pressure has been commonly determined by oedometer test. However, it can also be determined by in-situ test, such as piezocone test with theoretical and(or) empirical correlations. Recently, Neural Network(NN) theory was applied and some models were proposed to estimate the preconsolidation pressure or OCR. However, since the optimization process of synaptic weights of NN model is dependent on the initial synaptic weights, NN models which are trained with different initial weights can't avoid the variability on prediction result for new database even though they have same structure and use same transfer function.

In this study, Committee Neural Network(CNN) model is proposed to improve the initial weight dependency of multi-layered neural network model on the prediction of preconsolidation pressure of soft clay from piezocone test result. It was found that even though the NN model has the optimized structure for given training data set, it still has the initial weight dependency, while the proposed CNN model can improve the initial weight dependency of the NN model and provide a consistent and precise inference result than existing NN models.

Keywords : Piezocone, Preconsolidation pressure, Artificial neural network, Committee neural network

1. 서론

선행압밀하중(σ'_p)은 지반이 과거로부터 받았던 최대 유효압력으로 정의되며 현재유효응력(σ'_{vo})과 비교하여 과압밀비(overconsolidation ratio, $OCR = \sigma'_p / \sigma'_{vo}$)를 구함으로써 흙의 응력이력 상태를 파악하는데 이용된다. 일반적으로 선행압밀하중은 원위치지반에서 채취된 불교란 시료를 이용한 실내 압밀시험을 통해 산정되지만 시료의 채취과정, 운반과정, 시료성형과정 등에서 필연적으로 시료교란이 발생되며(김태준 등, 2002) 실내시험에 많은 시간과 경비가 요구되는 단점이 있다. 따라서 시료채취 및 조성과정에서 시료교란 효과를 제거하고 현장상태 그대로의 공학적 특성을 파악하기 위하여 원위치시험을 통한 접근방법이 점차 그 중요성을 더해가고 있다. 그 중 피에조콘 관입시험은 대상지반의 특성을 반영하는 저항력들(q_T, f_s, u_2)을 연속적으로 얻을 수 있고 대상지역이 방대한 경우에도 빠른 시험과정 때문에 시간과 비용 부담이 적어 최근에는 국내 연약지반조사 시 필수 항목으로 자리 잡고 있다. 피에조콘 관입시험 관측값

을 이용한 연구 중 지반의 선행압밀하중 추정 연구들은 크게 흙의 이론적 거동모델을 도입하여 얻어진 이론적인 모델(Konrad and Law, 1987; Chen, 1994)과 피에조콘 관측값들과 선행압밀하중(또는 과압밀비)을 통계적 방법이나 회귀분석을 이용해 직접 관계식 형태로 제안한 경험적인 모델(Chen, 1994; Chen and Mayne, 1996; 장인성 등, 2002; 이강운 등, 2002), 간단한 지반의 정보와 피에조콘 관측값을 바탕으로 지반의 응력이력을 추정하는 신경망 모델(Kurup and Dudani, 2002; 김영상 등, 2002)들이 있다. 이중 신경망이론을 도입한 선행압밀하중 추정은 기존의 이론·경험적 모델과 같이 입력변수들 간의 수학적 관계를 미리 부여하는 것이 아니라 입력자료들과 출력자료들 간의 비선형적인 관계를 가장 잘 묘사할 수 있는 연결강도를 학습하므로 예측오류는 최소화하고 다양한 지반의 특성을 복합적으로 고려할 수 있어 기존 방법들의 지역 의존성 문제와 비선형성 문제를 동시에 해결할 수 있는 가능성이 높은 것으로 알려졌다. 그러나 오차역전파(back propagation) 알고리즘으로 학습된 다층인공신경망 모델(Multi-Layered Perception model, MLP)은 모델구조와 모델학습 시 각 층(layer)에 존재하는 뉴런(neuron)간의 초기 연결강도에 따라 학습과정에서 최적화된 연결강도가 다를 수 있으므로 새로운 자료에 대한 예측결과에 변동성이 항상 존재한다.

본 연구에서는 선행압밀하중의 추정에 있어 신경망 모델이 기존의 이론적인 방법이나 경험적인 방법이 갖는 지역적 한계성의 문제를 극복하기는 하였으나, 학습과정에서 초기에 무작위로 부여되는 연결강도에 따라 예측결과의 변동성을 가지고 있으므로 최적화된 구조에 대한 새로운 접근을 통하여 피에조콘 시험결과로부터 연약지반의 선행압밀하중을 보다 효과적이고 일관성 있게 예측하기 위한 군집신경망 모델의 구축에 대하여 기술하였다.

2. 피에조콘을 이용한 기존의 선행압밀하중 추정 모델

2.1 이론적 방법과 경험적 방법

Konrad and Law(1987)는 콘 관입 시 선단부 아래에 존재하는 지반요소의 응력경로와 유발되는 간극수압에 대한 연구를 바탕으로 점토의 유효 연직 항복응력(effective vertical yield stress) σ'_{yc} 을 산정하는 간편한 이론식을 식 (1)과 같이 제안하였다. Chen(1994)은 간편 이론식 (2)를 제안하였다.

$$\sigma'_p = 0.5(q_T - u_2) \quad (1)$$

$$OCR = 0.32 \left(\frac{q_T - u_2}{\sigma'_{vo}} \right)^{1.33} \quad (2)$$

여기서, q_T = 수정 콘선단저항력 = $q_c + (1 - a)u_2$, q_c = 콘 선단저항력, a = 불균등면적비, u_2 = 콘 선단부 뒤에서 관측된 간극수압

한편 Chen(1994), Chen and Mayne(1996)은 기존의 경험적 상관관계들의 지역 의존성을 극복하고 보다 일반화된 관계의 도출을 위하여 세계 각 지역에서 얻어진 방대한 자료를 바탕으로 회귀분석을 수행하고 다음과 같은 제안식을 도출하였다.

$$\sigma'_p = 0.305(q_T - \sigma'_{vo}), n = 1256, R^2 = 0.82 \quad (3)$$

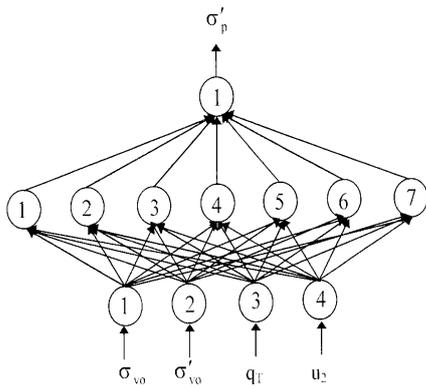
$$\sigma'_p = 0.53(u_2 - u_0), n = 811, R^2 = 0.722 \quad (4)$$

$$\sigma'_p = 0.5(q_T - u_2), n = 884, R^2 = 0.797 \quad (5)$$

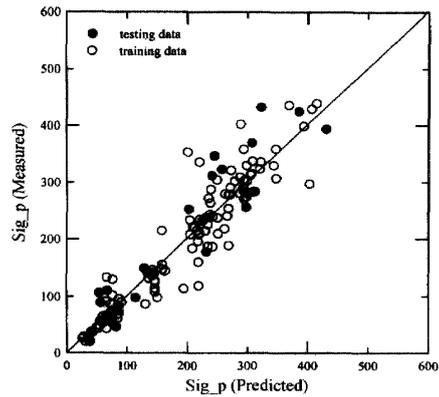
여기서, n = 회귀분석 시 사용된 자료의 개수, R^2 = 결정계수

2.2 신경망이론을 이용한 모델

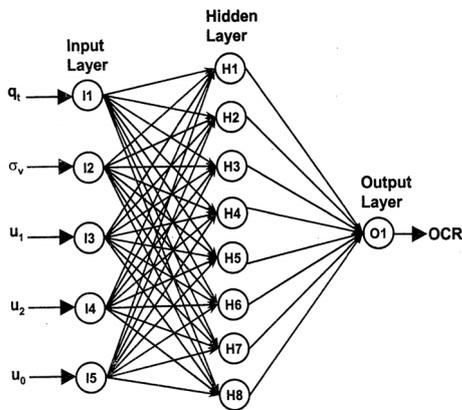
김영상 등(2002)과 Kurup and Dudani(2002)는 그림 1과 같이 Chen(1994)의 연구자료를 바탕으로 피에조콘의 관측값과 간단한 지반정보를 입력하여 선행압밀하중과 과압밀비를 예측하는 신경망모델을 각각 제안하였다. 그 결과 그림 1(b), (d)에 나타난 바와 같이 신경망에 의한 지반의 응력이력 추정은 기존의 이론적·경험적 모델과 비교하여 매우 정확한 예측이 가능하고 지역의존적인 모델이 아닌 일반적인 지역 모델로서 적용 가능함을 확인하였다.



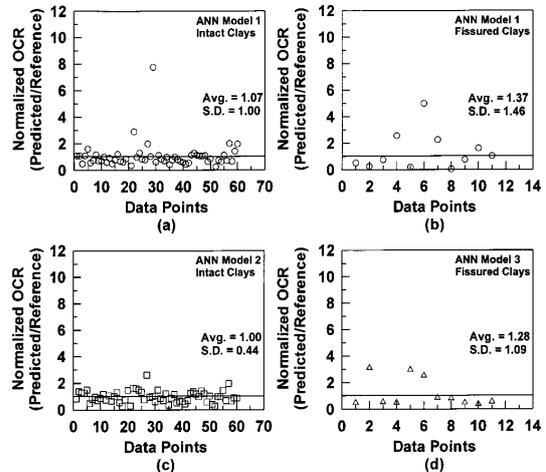
(a) 김영상 등(2002)의 모델



(b) 김영상 등(2002)의 예측결과



(c) Kurup and Dudani(2002)의 모델



(d) Kurup and Dudani(2002)의 예측 결과

그림 1. 피에조콘으로부터 응력이력 예측을 위한 신경망 모델들

그러나 김영상 등(2002)과 Kurup and Dudani(2002)의 모델이 동일한 연구자료를 바탕으로 제안되었음에도 불구하고 입력변수와 출력변수, 사용된 전달함수 등이 다른 것을 알 수 있으며 이는 특정문제에 대한 신경망의 최적 구조설계가 지금까지 어떤 공식화된 설계원칙이 존재하지 않기 때문이다. 뿐만 아니라 반복학습에 의하여 학습을 수행할 때 동일한 모델의 입력 및 출력변수, 전달함수, 학습률, 수렴기준을 가지는 경우에도 학습 최초에 무작위(random)로 부여된 연결강도에 의해 역방향 단계의 연결강도가 재조정되기 때문에 만일 최초 연결강도를 다르게 부여한다면, 학습 후에 최적화된 연결강도들이 전

역해가 아닌 국부해에 수렴하는 경우도 있어 다층신경망의 예측결과가 다르게 얻어질 수 있다. 이는 일반적인 반복과정으로 신경망을 학습할 때 발생할 수 있는 문제로 초기연결강도 의존성이 높아 때때로 새로운 자료에 대한 일관성 있는 예측을 어렵게 할 수 있다(Lee 등, 2004).

3. 다층 신경망 구조의 최적화 및 군집신경망의 구축

3.1 데이터베이스(Database)

다층신경망 모델의 구조 최적화와 초기 연결강도 의존성 개선을 위한 군집신경망 모델 구축에 사용된 데이터베이스는 세계 8개국(스웨덴, 노르웨이, 미국, 영국, 브라질, 캐나다, 이탈리아) 점토지반에서 수행된 피에조콘 관측값과 일차원 압밀실험 결과, 그리고 상재하중 및 소성지수 자료(Chen, 1994)들로 학습 데이터 119개와 검증 데이터 28개로 구성하였다. 표 1에는 사용된 입력변수들의 통계적 특성 값들이 제시되어 있다.

표 1. 입력변수들의 통계적 특성 범위

입력변수	학습자료		검증자료	
	max	min	max	min
$\sigma_{vo} (kPa)$	566.4	13.2	521.2	39.5
$\sigma'_{vo} (kPa)$	255	3.4	238.3	10.1
$q_T (kPa)$	1885	58	1885	148
$u_1 (kPa)$	1210	53	1128	108
$u_2 (kPa)$	1089	41	1013	82
PI	85	5	85	5

3.2 경험적 반복법에 의한 단일 다층신경망 구조의 최적화

군집신경망 모델을 구축을 위해 먼저 네트워크 내의 단일 다층신경망(Multi-Layer Perceptron, MLP)의 구조 최적화를 수행하였다. 이는 일반적인 경험적 반복법에 의한 신경망구조의 최적화를 수행하였으며, 적은 수의 은닉층과 뉴런 수를 갖는 가장 간단한 구조부터 검토하기 시작하여 이후에 입력변수와 출력의 관련성을 탐색하면서 점차 각층의 뉴런 수를 증가시켰다. 또한 네트워크의 입력변수와 출력변수 사이에 비선형성을 제공하는 전달함수로는 선형(Linear), 로그 시그모이드(Log Sigmoid), 탄젠트 시그모이드(Tansig Sigmoid)의 조합을 검토하였고 은닉층의 뉴런 수는 입력변수 개수의 최대 2배까지 검토하였다. 표 2와 같이 입력변수에 따라 총 6개의 모델이 검토되었으며, 입력변수로는 지반의 응력상태를 반영할 수 있도록 상재하중(σ_{vo})과 유효상재하중(σ'_{vo})을 선택하였고 피에조콘 관측값으로는 불균등 면적비에 대해 보정된 선단저항력(q_T)과 콘 선단부와 선단부 바로 뒤에서 관측된 간극수압 u_1 과 u_2 를 입력변수로 선정하였다. 그 외에도 지반의 소성지수를 이용할 경우 콘 관측결과와 선행압밀하중 간의 통계적 상관성을 높일 수 있다는 Chen and Mayne(1996), Lunne 등(1997)의 보고를 반영하여 소성지수 PI 를 입력변수로 선정한 모델에 대해서도 검토를 수행하였다. 학습 시 각각 다른 스케일(scale)로 분포하고 있는 모든 입력변수들을 0과 1사이의 값의 분포를 가지도록 정규화 하였고, 학습의 종료 조건은 최종 목표오차(ϵ)가 0.005이하로 수렴하거나, 최대 반복회수(maximum epoch)가 10,000번에 도달하는 경우 종료되도록 하였다.

표 2. 모델변수 및 전달함수에 따른 모델 예측능력 비교

모델명	입력변수	뉴런수	전달함수	결정계수 (R^2)		
				학습	검증	최적구조
모델A	σ_{vo}, q_T, u_2	8	Logsig - Logsig	0.930	0.905	
모델B	$\sigma_{vo}, q_T, u_1, u_2$	9	Logsig - Linear	0.929	0.889	
모델C	$\sigma_{vo}, \sigma_{vo}, q_T, u_2$	7	Logsig - Logsig	0.929	0.922	○
모델D	$\sigma_{vo}, \sigma_{vo}, q_T, u_1, u_2$	7	Tansig - Logsig	0.929	0.903	
모델E	$\sigma_{vo}, \sigma_{vo}, q_T, u_2, PI$	10	Tansig - Tansig	0.931	0.914	
모델F	$\sigma_{vo}, \sigma_{vo}, q_T, u_1, u_2, PI$	7	Tansig - Linear	0.930	0.909	

표 2에 나타난 바와 같이 각 모델에 대하여 은닉층과 출력층에 사용되는 전달함수를 기준으로 각 모델에서도 9개의 조합이 검토되었으며, 각 조합에서도 은닉층 내의 뉴런 수를 늘리면서 많은 수의 모델에 대하여 검토하였다. 검토된 모델 중에서 모델 C의 경우가 학습자료와 검증자료에 대하여 가장 높은 예측 결정계수를 보였다. 그림 2에 전달함수와 은닉층 내의 뉴런 수에 따른 모델 C의 학습자료에 대한 예측결과를 나타내었다. 전달함수 및 은닉층 수에 관계없이 모든 모델이 은닉층 내의 뉴런의 수가 6개 이후로 수렴된 예측이 가능하였다. 그러나 검증자료에 대해서는 수렴의 경향성이 이지 않아 상대적으로 가장 높은 결정계수(R^2)를 갖는 경우를 최적 구조로 선정하였다. 경험적 반복법에 의하여 선정된 단일 다층신경망의 최적 구조는 입력변수가 전응력(σ_{vo}), 유효응력(σ'_{vo}), 보정된 선단저항력(q_T), 콘선단부 바로 뒤에서 관측되는 간극수압(u_2)이고 은닉층 내의 뉴런 수가 7개, Logsig-Logsig의 전달함수를 가지는 조합이 최적의 모델구조인 것으로 나타났다.

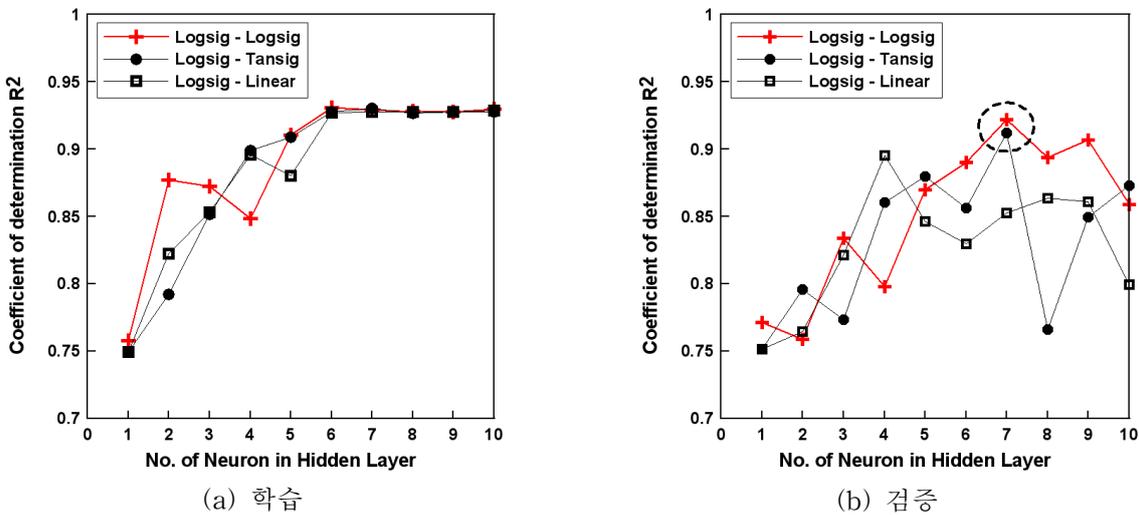


그림 2. 전달함수와 뉴런 수에 따른 모델 C의 예측 결정계수 비교

3.3 군집신경망(Committee Neural Network, CNN) 모델 구축

군집신경망은 서로 다른 초기 연결강도에 대하여 독립적으로 학습이 수행되어 최적화된 N개의 인공신경망(Network1, Network2, ... Network N)들이 그림 5와 같이 군집(network)을 이룬 신경망 집단이다. 군집신경망을 이용한 구조건진도 평가에 대한 연구결과(Lee 등, 2004)에 의하면 군집신경망을 이용

함으로써 단일 다층신경망의 경우에 나타나는 무작위로 선정되는 연결강도의 초기값에 의한 예측결과의 오차를 현저히 감소시킬 수 있는 것으로 알려졌다. 또한 군집신경망은 개개의 신경망 구조의 훈련 시 훈련자료에 포함된 노이즈(noise)와 제한된 수의 훈련자료 등으로 인하여 발생될 수 있는 연결강도의 국부해 문제까지 해결할 수 있어 개개의 신경망 예측에 비하여 높은 정확도를 확보할 수 있는 것으로 보고되었다.

군집신경망의 출력은 다음 식 (6)과 같이 각 신경망의 결과들의 가중평균으로 표현된다.

$$y_{com} = \sum_{i=1}^N \alpha_i y_i \quad (6)$$

여기서, N =군집내의 신경망 수, $\alpha_i = i$ 번째 신경망의 가중치이며 $\sum \alpha_i = 1$

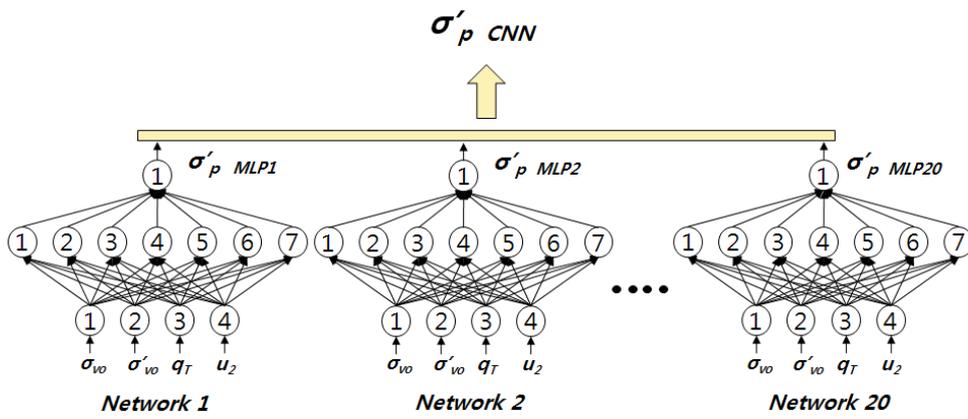
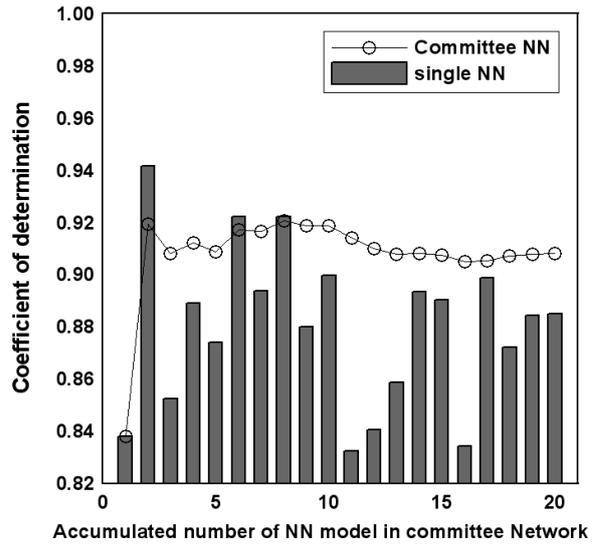
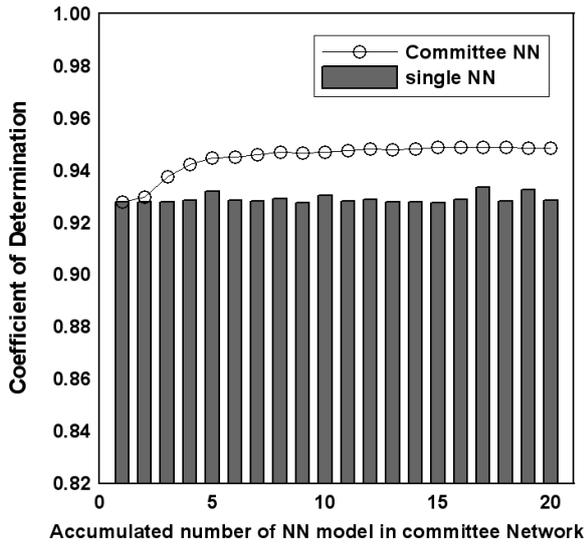


그림 3. 군집신경망의 모식도

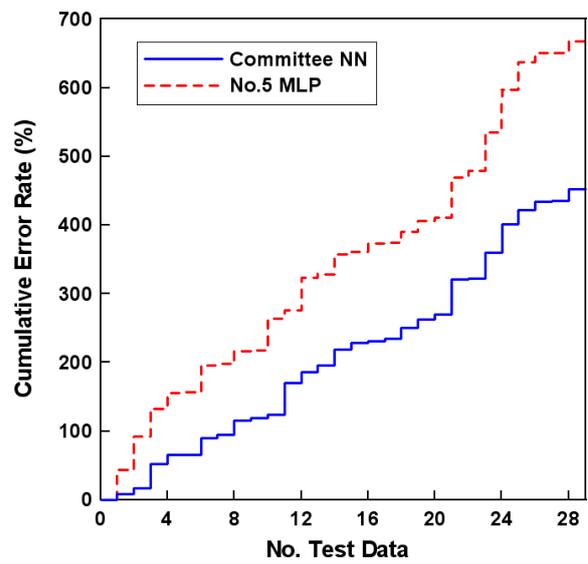
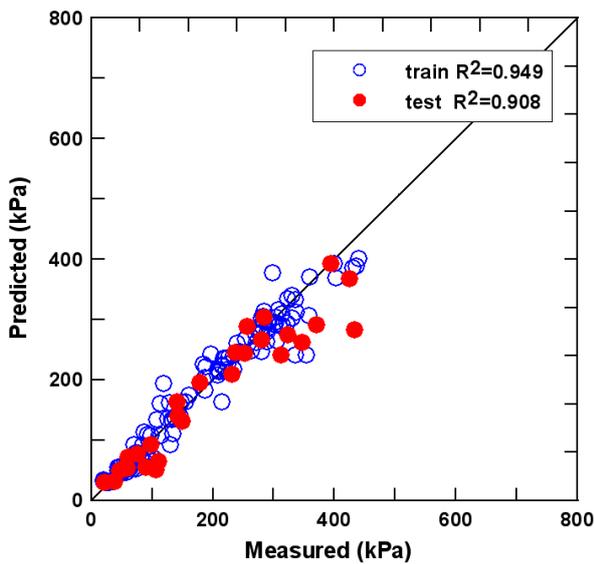
4. 군집신경망을 이용한 선행압밀하중 예측결과

이 연구에서는 군집신경망 구성 시 네트워크 내 단일신경망의 개수에 따른 군집신경망의 예측능력 변화를 검토하기 위하여, 네트워크 내 단일신경망의 수를 늘려가면서 학습 및 검증자료에 대한 예측을 수행하였으며 그 결과가 그림 4에 나타나 있다. 군집신경망 모델(Committee Neural Network)은 그림 4에 나타난 바와 같이 단일 신경망에 비해 신경망 수가 증가 할수록 학습자료에 대한 결정계수가 증가하고 군집 내 다층신경망이 12개 이상이 되면 수렴하는 경향을 보였다. 또한 새로운 검증자료에 대한 예측결과도 신경망의 수가 증가 할수록 개별 신경망의 예측결과의 변동에 무관하게 예측 정확도가 높고 최종적으로는 12개 이상의 다층신경망들로 군집을 형성한다면 예측결과가 안정적으로 수렴하는 것을 알 수 있다. 그림 5(a)에는 군집신경망 모델의 예측결과가 나타나 있으며, 학습과 검증 모두에서 뛰어나 예측능력을 보이고 있다. 또한 그림 5(b)에는 군집신경망 모델과 단일 신경망 중 검증에 대한 예측결과가 가장 낮은 모델(No. 5)의 누적오차율이 나타나 있다. 그림 5(b)에 나타난 바와 같이 단일 신경망은 동일한 구조를 갖는 모델일지라도 초기연결강도에 따라서는 그 오차가 군집신경망에 비하여 0.5배 정도 크게 나타나는 것을 알 수 있다.

이 결과로부터 군집신경망은 20개의 다층신경망들이 다양한 초기 연결강도에 대해 학습되어 서로 다르게 예측하는 결과들을 평균적으로 제공하기 때문에 다층신경망의 초기 연결강도에 따른 변동성과 오차의 최소화가 가능하며 보다 신뢰성 있고 일관성 있는 예측이 가능함을 알 수 있다.



(a) 학습자료 (b) 검증자료
 그림 4. 군집신경망 내 다층신경망 누적 수에 따른 예측결과 비교



(a) 군집신경망 모델 (b) 누적오차율 그래프
 그림 5. 다층 신경망과 군집신경망 모델의 예측 결과 비교

5. 결론

본 연구에서는 피에조콘으로부터 연약지반의 선행압밀하중을 예측하기 위해 기존에 제안되었던 신경망 모델이 초기 연결강도에 큰 영향을 받는다는 것을 설명하였다. 이를 극복하기 위한 방법으로 다수의 초기 연결강도에 대해 독립적으로 학습된 신경망들을 네트워크로 연결한 군집신경망 모델을 구축하고 이를 이용하여 수행된 예측결과를 비교·검증하였다.

1. 인공신경망 이론에 근거한 다층신경망 모델은 기존의 피에조콘을 이용한 이론적·경험적 모델이 갖는 지역의존성의 문제를 비교적 효과적으로 처리할 수 있고 선형적인 상관관계의 제한으로 인한 예

측 정확도를 크게 개선할 수 있으나, 동일한 구조를 갖는 모델일지라도 초기에 무작위로 부여되는 연결강도에 따라 학습에 이용되지 않은 새로운 자료에 대해서는 예측의 변동성을 갖는 한계를 나타내었다.

2. 최적화된 구조 도출을 위하여 경험적 반복(trial-and-error)법에 의해 최적 구조를 도출하였다. 이 경우에 대해서는 경험적 반복법이 σ_{vo} , σ'_{vo} , q_p , u_2 를 입력변수로 사용하며 단일 은닉층 내의 뉴런 수가 7개이고 logsig-logsig 전달함수 조합을 갖는 최적의 단일 다층신경망 구조를 도출하였다.
3. 최적 구조를 갖는 단일 다층신경망들을 이용한 선행압밀하중 예측은 학습자료에 대해서는 대부분 비교적 좋은 예측능력을 보였지만 검증자료에 대해서는 동일한 구조를 가진 모델일지라도 초기에 부여되는 연결강도에 따라 예측능력이 매우 큰 차이를 나타내었다. 그러나 다층신경망을 네트워크로 연결한 군집신경망은 학습자료와 검증자료에 대해 군집신경망 네트워크 내의 다층신경망의 수가 증가함에 따라 예측 결정계수가 개선되며 일정 개수 이상의 단일 신경망이 조합될 경우에는 예측결과의 수렴 경향이 뚜렷이 보이며 매우 안정되게 예측하는 것으로 나타나 단일 신경망의 초기 연결강도 의존성을 크게 개선하는 것으로 나타났다.

참고문헌

1. 김영상, 이승래, 김종수(2002), “피에조콘을 이용한 연약지반 선행압밀하중 결정의 인공신경망 이론 적용 연구”, *대한토목학회논문집*, 제22권, 제6-C호, pp.623-633.
2. 김영상, 주노아, 이종재(2007), “군집신경망과 확률신경망 이론을 이용한 연약지반의 측방유동 평가 모델”, *한국지반공학학회논문집*, 제23권, 제7호, pp.65-76.
3. 김태준, 박봉기, 이재성, 전일수, 이충원, 정충열, 변영기, 윤현진, 이우진(2002), “선행압밀하중 결정방법의 비교분석”, *한국지반공학학회 연약지반기술위원회 2002 학술세미나*
4. Chen, B.S.Y., Mayne, P.W.(1996), “Statistical relation ships between piezocone measurements and stress history of clays”, *Canadian Geotechnical Journal*, vol.33, pp.488-498.
5. 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.
6. Konard, J-M., Law, K.T.(1987), “Preconsolidation pressure from piezocone tests in marine clays”, *Geotechnique*, vol.32, No.2, pp.177-190.
7. Mayen, P.W.(1991), “Determination of OCR in clay by piezocone tests using cavity expansion and critical state concepts”, *Soils and Foundations*, Vol.31, pp.65-76.
8. Kurup, P.U., Dudani, N. K.(2002), “Neural networks for profiling stress history of clays from PCPT data”, *Journal of Geotechnical and Geoenvironmental Engineering*, Vol.128, No.7, July, pp.569-579.
9. Lee, J.W., Yi, j.H., Kim, J.D., and Yun, C.B.(2004), “Health Monitoring Method Using Committee of Neural Networks”, *Key Engineering Materials*, Vol.270-273, pp.1983-1988.
10. Lunne, T., Robertson, P.K., and Powell, J.J.M. (1997), “Cone penetration testing in geotechnical practice”, *Taylor & Fancis*