

피에조콘을 이용한 점토의 비배수전단강도 추정에의 인공신경망 이론 적용

Feasibility of Artificial Neural Network Model Application for Evaluation of Undrained Shear Strength from Piezocone Measurements

김 영 상* Kim, Young-Sang

Abstract

The feasibility of using neural networks to model the complex relationship between piezocone measurements and the undrained shear strength of clays has been investigated. A three layered back propagation neural network model was developed based on actual undrained shear strengths, which were obtained from the isotropically and anisotropically consolidated triaxial compression test(CIUC and CAUC), and piezocone measurements compiled from various locations around the world. It 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 compared with conventional empirical method, direct correlation method, and theoretical method. It was found that the neural network model is not only capable of inferring a complex relationship between piezocone measurements and the undrained shear strength of clays but also gives a more precise and reliable undrained shear strength than theoretical and empirical approaches. Furthermore, neural network model has a possibility to be a generalized relationship between piezocone measurements and undrained shear strength over the various places and countries, while the present empirical correlations present the site specific relationship.

요 지

본 논문에서는 피에조콘 관입시험 결과로부터 점토의 비배수전단강도를 예측하기 위한 인공신경망 이론의 적용과 최적 모델 구축에 대하여 기술하였다. 먼저 등방 및 비등방 삼축압축실험(CIUC and CAUC)으로 얻어진 비배수전단강도 결과를 바탕으로 오차역전파 알고리즘에 의하여 간단한 다층 구조를 갖는 최적 인공신경망 모델이 구성되었다. 구성된 인공신경망 모델은 모델 구축 시에 사용되지 않은 새로운 자료에 대해 비배수전단강도 예측을 수행하고 예측 결과와 실내시험 결과를 비교함으로써 그 타당성이 검증되었다. 또한 기존의 이론적 방법, 경험적 방법 및 direct correlation method 등으로 예측된 비배수전단강도와 제안된 모델의 예측결과를 비교하였다. 본 논문에서 제안된 인공신경망 모델링 기법은 피에조콘 관측결과들과 비배수전단강도 간의 비선형적 상관관계를 정의하는 데에 유용하며 구성된 인공신경망 모델은 기존의 이론적 및 경험적 방법들에 비하여 예측 신뢰성이 높은 것으로 나타났다. 또한, 지금까지 주로 사용되어 온 경험적 방법들이 특정 지역에 대한 상관관계에 만족하던 것과 비교해 인공신경망 모델은 다양한 지역과 국가에서 일반적으로 적용 가능한 상관관계로서 발전될 가능성이 있음을 알 수 있었다.

Keywords : Artificial neural network, Piezocone, Triaxial test, Undrained shear strength

* 정회원, 국립 여수대학교 해양시스템공학전공 전임강사 (Member, Full time lecturer, Division of Ocean System Engrg., Yosu National Univ., geoyskim@yosu.ac.kr)

1. 서 론

피에조콘(piezocene)은 관입시험(penetration test)과 간극수압의 소산시험(dissipation test)을 통해 현장지반의 공학적 분류(soil classification)와 압밀계수(coefficient of consolidation)의 추정, 지반의 응력이력(stress history)과 비배수전단강도(undrained shear strength)의 추정이 가능한 매우 유용한 원위치시험(in-situ test) 장비이다. 비배수전단강도(undrained shear strength)는 지반구조물 설계에 있어서 가장 중요한 지반정수 중 하나로 일반적으로 불교란시료를 채취하여 실내시험으로부터 결정해왔다. 그러나, 그 과정에서 시료채취 시 발생되는 교란효과(disturbance effect)를 피할 수 없으며 무엇보다 대상 지역이 방대한 경우 시료채취 및 실내시험에 많은 시간과 경비가 요구되는 단점이 있다. 피에조콘을 이용한 비배수전단강도의 추정은 실내시험에 비하여 매우 빠르고 경제적일 뿐 아니라 시료채취에 의한 교란효과와 무관하다는 장점이 있으나 피에조콘 관측값으로부터 비배수전단강도를 예측하기 위한 적절한 상관관계가 요구된다.

지금까지 국내외에서 이론적인 연구와 경험적인 연구들을 통하여 피에조콘으로부터 비배수전단강도 결정을 위한 다양한 노력들이 이루어져 왔다. 그러나, 어떠한 방법도 피에조콘 관측값으로부터 비배수전단강도를 결정하는 데에 지역적 특성을 극복하고 일반화된 방법으로 인정 받지 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 콘계수들의 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. 본 논문에서는 피에조콘 관측값으로부터 신뢰성 있는 비배수전단강도를 예측할 수 있도록 인공신경망 이론의 적용성을 검토하고 최적의 인공신경망 구조를 도출하였다. 인공신경망에서는 다양한 입력변수에 대한 검토가 가능할 뿐 아니라 부적절하거나 다른 변수들로부터 추론이

가능한 입력변수에 대해서는 매우 낮은 연결강도가 부여되므로 생략하거나 조정을 통하여 최적의 구조를 갖는 인공신경망 모델을 구축할 수 있어 통계적 회귀분석 모델에 비해 제안자의 오류를 최소화 할 수 있다. 또한 현장지반의 다양성과 함께 현장에서 채취되는 시료들이 실내로 운반되는 과정에서 불가피하게 겪게 되는 교란효과(disturbance effect)는 경험적 상관관계의 분산을 크게 하며 결과적으로 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).

본 연구에서는 국외 11개 점토지반에서 수행된 피에조콘 관입시험 결과로부터 점토의 비배수전단강도를 추정하기 위한 인공신경망 모델을 구성하였다. 구성된 인공신경망은 모델구축에 사용되지 않은 새로운 자료에 대해 비배수전단강도를 예측하고 관측값과 비교함으로써 제안된 인공신경망 모델의 적용성을 검증하였다. 또한, 기존의 이론적, 경험적 방법들의 예측결과와 비교함으로써 제안된 모델의 정확성을 기존의 모델들과 비교하였다.

2. 기존 모델에 대한 고찰

2.1 이론적 모델

이론적 방법은 다음 식 (1)로부터 흙의 비배수전단강도를 결정하며 이때 이론적인 콘 계수 N_c 는 표 1에 정리되어 있는 바와 같이 고전적인 지지력이론, 공동확장이론, 변형률경로법, 수학적인 방법 등 다양한 방법에 의하여 제시되어 왔다.

$$q_c = N_c \cdot s_u + \sigma_i \quad (1)$$

여기서, q_c =관측된 선단저항력, N_c =콘 계수, s_u =비배수전단강도, σ_i =총 응력으로 이론에 따라 다른 응력을 정의하여 사용한다.

Chen and Mayne(1993)과 Chen(1994)은 이론적 접근법 중에서는 상대적으로 최근에 Hybrid theory에 의한 이론적 모델을 제안하였다. 이 모델은 식 (1)을 기본으로 구형공동확장이론(spherical cavity expansion theory)과 한계상태이론(critical state concept)을 조합하여 등방

표 1. 이론적 콘 계수들(Konrad and Law, 1987)

| $N_c(\phi = 0)$ | σ_i | 분류* | 비고 | 제안자 |
|--|-----------------|-----|--|----------------------|
| 7.41 | | 1 | | Terzaghi |
| 7.0 | | 1 | | Caquot and Kerisel |
| 9.34 | | 1 | Smooth base | Meyerhof |
| 9.74 | | 1 | Rough base | Meyerhof |
| 9.94 | | 1 | | de Beer |
| $\frac{4}{3} \left[1 + \ln \frac{E_t}{3s_u} \right] + 1$ | σ_{vo} | 2 | SCE, E_t : initial tangent modulus | Meyerhof |
| $\frac{4}{3} \left[1 + \ln \frac{E_s}{s_u} \right] + 1$ | σ_{vo} | 2 | SCE, E_s : secant modulus at 50% failure | Skempton |
| $\frac{4}{3} \left[1 + \ln \frac{E_s}{3s_u} \right] + \cot \theta$ | σ_{vo} | 2 | SCE | Gibson |
| $\frac{4}{3} \left[1 + \ln \frac{E_s}{s_u} \right] + \cot \theta$ | σ_{vo} | 2 | SCE, finite strain theory | Gibson |
| $\frac{4}{3} [1 + \ln I_R]$ | σ_{vo} | 2 | SCE | Vesic |
| $\frac{4}{3} [1 + \ln I_R] + 2.57$ | σ_{mean} | 3 | SCE | Vesic |
| $[1 + \ln I_R] + 11$ | σ_{ho} | 3 | CCE | Baligh |
| $\frac{s_a}{s_u} + \frac{4}{3} \frac{s_r}{s_u} \left[1 + \ln \frac{E_r}{3s_{ur}} \right] + \frac{4}{3}$ | σ_{vo} | 4 | Trilinear stress-strain approach | Ladanyi |
| $\left[\frac{E_u/s_u - E_r/s_{ur} \cdot s_{ur}/s_u}{E_u/s_u - E_r/s_{ur}} \right] \ln \frac{E_u}{s_u} \frac{s_{ur}}{E_r}$ | σ_{vo} | 5 | Elastic perfectly plastic strain path approach | Teh |
| (2/M)+3.9 | $-u_2$ | 6 | SCE, CCM for CIUC s_u data | Chen and Mayne, Chen |
| $a(2 + 3.9M)/[\sin \phi'(a^2 + 1)^\Lambda]$ | $-u_2$ | 6 | SCE, CCM for CAUC s_u data | |

*분류: 1.Classic bearing capacity, 2.Cavity expansion theory, 3.Conservation of energy combined with cavity expansion theory, 4.Analytical and numerical approaches using linear and non-linear stress-strain relationships, 5. Strain path method, 6. Hybrid method(Cavity expansion theory combined with Cam Clay Model).

† $I_R = G_u/s_u = E_u/3s_u$ =Rigidity index, $\sigma_{mean} = (\sigma_{vo} + 2 \cdot \sigma_{ho})/3$ =mean normal stress, θ =semiapex angle.

E_s =secant modulus, E_t =tangent modulus, SCE=Spherical Cavity Expansion theory, CCE=Cylindrical Cavity Expansion theory, CCM=Cam-Clay Model

및 비등방 삼축압축실험(CIUC and CAUC)에서 얻어지는 비배수전단강도를 결정할 수 있도록 다음 식 (2)와 같이 제안되었다.

$$s_u = \frac{q_T - u_2}{N_{qu}} \quad (2)$$

여기서, q_T =불균등면적비에 대해 수정된 콘 선단저항력= $q_c + (1-a)u_2$, q_c =관측 선단저항력, a =불균등면적비(unequal end area ratio), u_2 =콘 선단부 뒤에서 관측된 간극수압, N_{qu} =콘 계수($2/M$)+3.9 for CIUC test, $N_{qu} = (a/b)$ ($2 + 3.9M$) for CAUC test, $M = \frac{6 \sin \phi'}{3 - \sin \phi'}$, $a = \frac{3 - \sin \phi'}{6 - 4 \sin \phi'}$, $b = \sin \phi'(a^2 + 1)^\Lambda$, ϕ' =유효 내부마찰각, Λ =소성 체적

변형률 비(plastic volumetric strain ratio)= $1 - \kappa/\lambda$, κ =팽창지수(등방삼축시험 시 $e - \ln p'$ 상 팽창곡선의 기울기), λ =압축지수(등방삼축시험 시 $e - \ln p'$ 상 압축곡선의 기울기)

Mayne(1980)은 96개의 서로 다른 점토시료에 대한 삼축시험 자료들로부터 예민하지 않은 자연점토(insensitive natural clay)의 경우 유효 내부마찰각과 소성체적 변형률 비가 $18^\circ \leq \phi' \leq 41^\circ$, $0.6 \leq \Lambda \leq 0.8$ 임을 발표하였다. 그러나 ϕ' 과 Λ 만의 함수로 정의되는 콘 계수 N_{qu} 가 이 두 값에 큰 영향을 받지 않으므로 공학적인 목적을 위해서라면 평균적으로 $\phi' = 30^\circ$ 과 $\Lambda = 0.75$ 을 적용하여 다음의 관계식 (3)을 사용할 것을 제안하였다 (Chen and Mayne, 1993).

$$(s_u)_{CIUC} = (q_T - u_2) / 5.5 \quad (3a)$$

$$(s_u)_{CAUC} = (q_T - u_2) / 6.5 \quad (3b)$$

여기서, $(s_u)_{CIUC}$ = 등방 압밀 삼축압축시험(isotropically consolidated triaxial compression test), $(s_u)_{CAUC}$ = 비등방 압밀 삼축압축시험(anisotropically consolidated triaxial compression test)에 의한 비배수전단강도

2.2 경험적 모델

표 1의 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 특

정 입력변수를 얻기 위해서는 정교한 실험을 동반하는 불편함이 있어 일반적으로 경험적 방법들이 선호되어 왔다. 경험적 방법을 이용한 비배수전단강도 결정법에서는 다음 식 (4)~(6)들이 공통적으로 적용되고 있다. 식 (4)~(6)에서는 사용된 콘 관측값과 응력에 따라 순 선단저항력(net cone tip resistance) $(q_T - \sigma_{vo})$, 과잉간극수압 $(u_2 - u_o)$, 유효 선단저항력(effective cone tip resistance) $(q_T - u_2)$ 을 사용하고 있으며 이에 따라 콘 계수(cone factor) N_{kt} , N_{du} , N_{ke} 를 각각의 상관계수로 정의하여 사용하고 있다.

$$s_u = \frac{q_T - \sigma_{vo}}{N_{kt}} \quad (4)$$

$$s_u = \frac{u_2 - u_o}{N_{du}} \quad (5)$$

표 2. 경험적 콘 계수들(이선재, 1997)

| 콘 계수 | 국가(위치) | 범위 | 비교 비배수전단강도 결정법 | 제안자 |
|----------|-------------------|-----------|---------------------|-------------------------------|
| N_{kt} | Norway | 13~19 | FVT | Lunne et al. |
| | Northern Sea | 17 | CIUC | Kjekstad et al. |
| | London, England | 10~30 | PLT | Marsland, Marsland and Powell |
| | England | 10~20 | TXT | Powell and Quartermann |
| | Canada | 11~18 | LVT | La Rochelle et al. |
| | 11 clays | 8~29 | CIUC, CAUC | Rad and Lunne |
| | Northern England | 12~20 | CIUC | Nash and Diffin |
| | Norway | 12~19 | FVT | Lacasse and Lunne |
| | Italy | 8~16 | FVT | Jamiolkowsky et al. |
| | | 8~10 | CKoUC | |
| | Vancouver, Canada | 8~10 | FVT | Konrad et al. |
| | | | SBPT | |
| | Brazil | 13.5~15.5 | FVT, CIUC | Rocha-Filho & Alencar |
| | Singapore | 9~12 | FVT | Dobie |
| | Australia | 13.7 | FVT | Jones |
| | Malaysia | 5~13 | FVT | Wong |
| | Korea | 10~25 | UU, CIUC, CAUC, FVT | Lee |
| N_{ke} | Japan | 8~16 | UCT | Tanaka |
| | | 9~14 | FVT | |
| | Canada | 2~10 | FVT | Campanella et al. |
| N_{du} | Canada | 6.2~7 | FVT | Konrad et al. |
| | Korea | 9.3~17.2 | UU, CIUC, CAUC, FVT | Lee |
| | Norway | 6~12 | UCT | Senneset et al. |
| | North Sea | 1~13 | CAUC | Lunne et al. |
| | Norway | 2~9 | CAUC | Karlsrud et al. |
| | Korea | 1.7~4.4 | UU, CIUC, CAUC, FVT | Lee |

LVT=Nilcone vane test, TXT=Triaxial compression test, SBPT=Self boring pressuremeter test, UCT=Unconfined compression test, PLT=Plate loading test, CIUC and CAUC=Isotropic and anisotropic consolidated undrained compression triaxial test, FVT=Field vane test

$$S_u = \frac{q_T - u_2}{N_{ke}} \quad (6)$$

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

그러나 이들 상관관계의 핵심인 콘 계수(cone factor) N_{kt} , $N_{\Delta u}$, N_{ke} 값들은 표 2에 정리된 바와 같이 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 이중 이선재

(1997), 장인성 등(2001)의 연구에서는 국내 10개 지역의 자료를 바탕으로 대표적인 콘 계수 산정에 관한 연구가 진행된 바 있다. 그러나, 전체 해석에 사용된 콘 계수들의 분포가 그림 1에 나타난 바와 같이 넓은 범위에 분포되어 경험적 방법에 의한 비배수전단강도 산정법의 신뢰성에 의문이 제기된 바 있다(장인성 등, 2001).

Rad and Lunne(1988)는 기존의 경험적 상관관계로부터 비배수전단강도를 산정할 경우 매우 특정지역의 상관관계만이 유용함을 지적하고 과압밀비(OCR)를 고려하여 피에조콘 관측값(콘 선단저항력 q_T , 마찰저항력 f_T , 콘 선단부에서 관측된 간극수압 u_1)으로부터 비배수전단강도를 직접 계산할 수 있는 direct correlation method를 그림 2와 같이 제안하였다. 이 방법에서는 지역적 상관성이 강하게 나타나는 경험적인 관계식 (4)~(6)을 사용하지 않으며 삼축압축시험으로 얻어진 비배수전단강도를 매우 합리적으로 결정하는 것으로 나타났다. 그러나, Rad and Lunne의 방법을 사용할 경우 서로 다른 관측값(즉, q_T , f_T , u_1)들로부터 결정되는 비배수

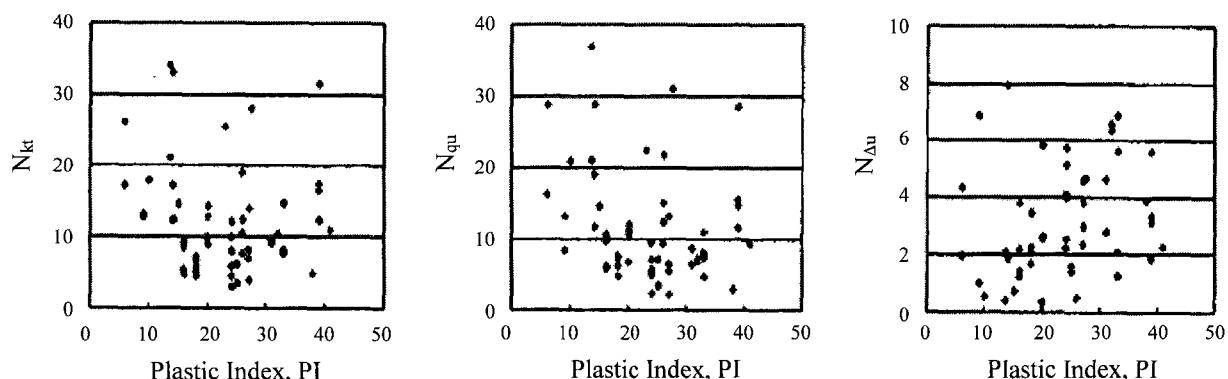


그림 1. 소성지수에 따른 콘 계수의 변화(장인성 등, 2001)

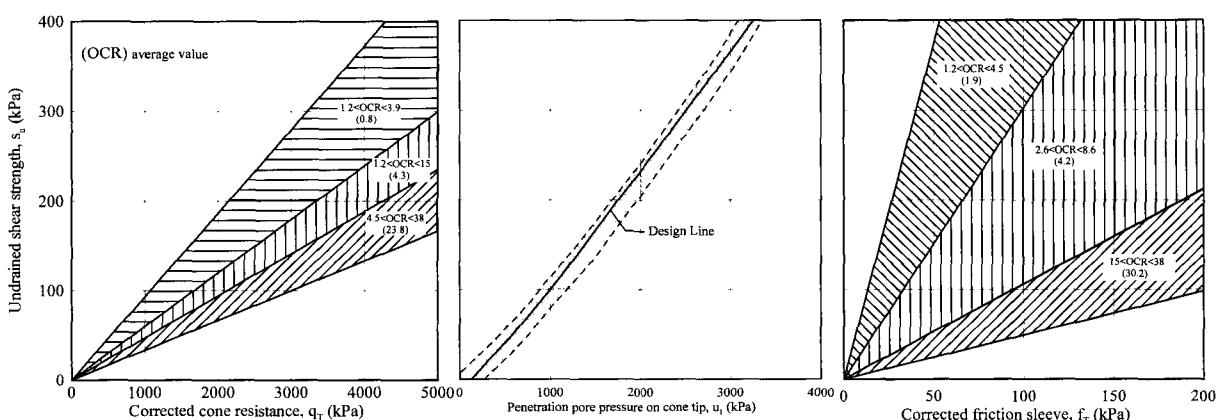


그림 2. Direct correlations method: q_T , u_1 , f_T 와 s_u 의 상관관계(Rad and Lunne, 1988)

전단강도들의 차이가 발생되고 이들의 평균값을 사용하게 될 경우 실질적으로는 설계에 어느 정도의 오차가 포함된다.

또한 선단저항력 q_T 과 관측 간극수압 u_i 으로부터 비배수전단강도를 결정할 경우 과압밀비(OCR)에 대한 정보가 필요하며, 관입저항력 q_T 의 보정을 위해서는 간극 수압이 선단부(u_1)와 선단부 뒤(u_2)에서 동시에 관측되어야 하는 불편함이 있어 보편적으로 사용되기에 어려움이 있다.

3. 인공신경망 모델(Artificial neural network model)

인공신경망 이론은 인간의 뇌 구조에서 학습되고 축적되는 기존 지식의 운용체계를 모사한 컴퓨터 모델로 최근 지반공학 분야에서도 다양한 문제에 적용되고 있다(Toll, 1996). 국내에서도 인공신경망을 이용한 말뚝의 지지력 및 수평변위의 추정, 압축지수의 추정, 화강 풍화토의 토량변화율 추정, 압밀침하량 예측, 삼축시험으로부터 비배수전단강도 예측, 굴착 시 흙막이 벽체의 최대변위 예측 등에 사용된 바 있으며 다양한 분야에서 인공신경망 이론의 응용이 증가하고 있는 추세이다. 최근에 김영상 등(2002)은 피에조콘으로부터 지반의 선행 압밀하중 예측을 위한 인공신경망 모델을 개발하였으며 Kurup and Dudani(2002)는 비슷한 시기에 유사한 기법을 이용하여 과압밀비 예측모델을 개발하여 피에조콘 해석에 있어서 인공신경망 이론의 적용이 매우 유용할 것으로 사료된다. 김영상 등(2002)과 Kurup and Dudani(2002)의 연구결과에 의하면 인공신경망 모델은 응력이력(stress history) 추정을 위한 피에조콘 해석에 사용된 기존의 이론적 접근법과 경험적 접근법의 단점을 보완하고 예측능력의 정확도를 크게 향상하는 것으로 나타났다.

인공신경망 모델의 구축과정은 크게 두 단계로 나눌

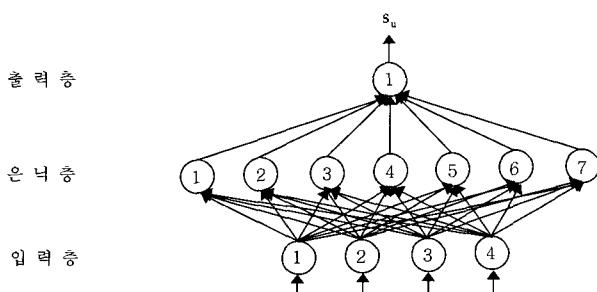


그림 3. 비배수전단강도 결정을 위한 인공신경망 구조

수 있다. 먼저 기지의 입력과 결과값을 이용하여 그림 3과 같이 각 층에 존재하는 뉴우런(neuron)간의 연결강도(weight)를 조정하는 훈련단계(training phase)로, 이 과정을 통하여 신경망 모델은 주어진 자료들을 일반화 할 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.

그림 3은 본 연구에서 피에조콘 관측값들로부터 점토의 비배수전단강도 결정을 위해 구축된 인공신경망의 구조이다. 모델은 입력층(I)-은닉층(H)-출력층(O)의 간단한 다층 신경망 형태로 구성되며 각 층에는 인간의 신경조직의 기본단위를 모사한 뉴우런(neuron)이 존재하고 각 층의 뉴우런들은 다른 층의 모든 뉴우런들과 특정 연결강도로 연결되어 있다. 각 층의 각 뉴우런에 전달된 입력값들은 연결강도와 곱해지며 이들의 합은 전달함수(transfer function)에 의해 처리되어 출력되어 다시 다음 층에 존재하는 뉴우런들의 입력값으로 전달된다. Hornik 등(1989)은 단일 은닉층만으로도 적정한 수의 뉴우런이 존재한다면 함수근사화(function approximation)와 패턴인식(pattern classification)이 충분한 정도(accuracy)로 가능함을 증명한 바 있으며, 본 연구에서도 단일 은닉층을 사용하여 좋은 결과를 얻을 수 있었다. 그러나, 은닉층에 존재하는 뉴우런의 수를 결정하는 방법에 대한 결론은 존재하지 않으며 지금까지는 반복적인 시행착오를 통해 결정하고 있다. 본 연구에서는 은닉층에 존재하는 뉴우런의 수를 2개부터 점차 증가시키면서 식 (7)과 같이 정의되는 평균제곱오차(mse)가 더 이상 감소하지 않는 경우의 최소 뉴우런 수로 결정하였다. 전달함수(transfer function)로서는 입력층과 은닉층 사이에 S형 시그모이드(sigmoid) 함수를 사용하였고 은닉층과 출력층 사이에는 선형함수를 사용하였다.

$$mse = \frac{1}{n} \sum_{k=1}^n (a(k) - t(k))^2 \quad (7)$$

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

3.1 데이터베이스(Database)

본 연구에서는 Rad and Lunne(1988)에서 발췌된 자료들이 인공신경망 모델의 구축과 검증에 사용되었으며 자료들은 노르웨이, 북해, 영국, 브라질, 캐나다 등의 11개 점토에서 수행된 41개 정점으로 구성되어 있고 각 지역과 지반의 특성이 표 3에 정리되어 있다. 이 중 73%에 해당하는 30개 정점의 자료가 인공신경망 모델 구축을 위한 ‘학습자료’로 사용되었으며, 전체 자료 중 임의로 선택된 27%에 해당하는 11개 정점의 자료는 구축된 모델의 ‘검증자료’로 사용되었다. 학습 및 검증에 사용된 입력변수들과 출력값(비배수전단강도)의 범위가 표 4에 정리되어 있으며, 각 입력값들은 인공신경망의 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 인공신경망 모델은 매트랩 툴박

스(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 급속 하강법(steepest descent method)에 비해 오차역전파 알고리즘의 학습 효율을 매우 향상 시키는 것으로 알려져 있다. 학습은 최대 훈련회수에 도달하거나 식 (7)로 정의되는 평균제곱오차(mse)가 최종 목적 제곱오차(mean squared error goal) 0.0005이하로 수렴하는 경우에 종료하도록 프로그램 되었다.

3.3 모델의 구성 및 최적모델의 선정

본 연구에서는 5개의 변수들을 - 상재하중 σ_{vo} , 피에조콘 선단저항력 q_T , 콘 선단부에서 관측된 간극수압 u_1 과 u_2 그리고 과압밀비(OCR) - 조합하여 최적의 인공신

표 3. 인공신경망 모델의 학습 및 검증에 사용된 현장자료의 위치와 지반특성

| Site | Location | Soil description |
|----------------|---------------|--|
| Onsoy | Norway | Plastic clay with shells or Homogeneous clay |
| Haga | Norway | Lean OC clay or Plastic OC clay |
| Troll 2 | North Sea | Plastic clay or Lean sandy clay |
| Brage 2 | North Sea | Silty clay |
| Haltenbanken 2 | Norwegian Sea | Silty sandy clay with gravel |
| Cowden | England | Weathered Stony clay(till) or Unweathered stony clay |
| Brent X | England | Weathered clay or Unweathered clay |
| Rio | Brazil | Highly plastic clay |
| Vancouver | Canada | Clayey silt |
| Emmerstad | Norway | Silty quick clay |
| Drammen | Norway | Plastic drammen clay or Lean drammen clay |

표 4. 입력 및 출력변수들의 범위

| 구분 | 변수 | 학습자료 | | 검증자료 | |
|------|--------------------------|---------|---------|---------|---------|
| | | 최소(Min) | 최대(Max) | 최소(Min) | 최대(Max) |
| 입력변수 | 상재응력 σ_{vo} (kPa) | 30 | 820 | 44 | 682 |
| | 선단저항력 q_T (kPa) | 134 | 4320 | 245 | 2890 |
| | 콘선단부 간극수압 u_1 (kPa) | 112 | 1350 | 210 | 2380 |
| | 콘 선단부 뒤 간극수압 u_2 (kPa) | 82 | 2360 | 158 | 1790 |
| | 과압밀비(OCR) | 1.2 | 38 | 1.2 | 35 |
| 출력변수 | 비배수전단강도 s_u (kPa) | 7.1 | 380 | 11.8 | 270 |

표 5. 검토된 인공신경망 구조와 입력변수들의 상대 중요도(relative importance)

| 모델 | 은닉층의 뉴우런 수 | 입력변수와 상대 중요도(%) | | | | | 상관계수 R(%) | |
|--------|------------|-----------------|----------------|----------------|----------------|-------|-----------|------|
| | | σ_{v_0} | q _T | u ₁ | u ₂ | OCR | 학습단계 | 검증단계 |
| SuM3 | 7 | 31.71 | 28.39 | — | 39.91 | — | 99.8 | 99.6 |
| SuM4 | 4 | 13.08 | 36.13 | 36.21 | — | 14.58 | 98.9 | 98.8 |
| SuM4-1 | 4 | 26.06 | 23.21 | — | 33.15 | 17.58 | 99.3 | 99.1 |
| SuM5 | 4 | 44.21 | 10.79 | 27.91 | 11.24 | 5.85 | 99.8 | 99.3 |

경망 모델의 선정을 위한 후보로 4개의 서로 다른 구조를 갖는 모델이 검토되었으며 표 5에 각 모델의 입력변수들이 정리되어 있다. 모든 모델은 동일하게 단일 은닉층을 가지며 은닉층 내의 뉴우런 수는 앞에 설명된 바와 같이 최소의 평균 제곱 오차를 갖는 최소 뉴우런 수로 결정되었다. 출력층은 삼축압축시험(CIUC and CAUC)에서 얻어지는 비배수전단강도를 표현할 수 있도록 한 개의 뉴우런(neuron)으로 구성되었다. 일반적으로 등방 삼축시험과 비등방 삼축시험으로 얻어진 비배수전단강도에는 5~10%의 차이가 있으나 Rad and Luunne(1988)의 Direct correlation method로 얻어진 결과와 비교하기 위해서 두 실험에서 얻어진 비배수전단강도를 구분하지 않고 사용하였다.

각 모델에서 예측된 비배수전단강도 예측값과 실험값으로 계산된 상관계수(Correlation coefficient, R)를 살펴보면, 본 연구에서 검토된 네 개의 모델들이 훈련단계와 검증단계에서 모두 비교적 양호한 예측정도를 가진 것으로 평가되었으며 그 중에서 입력 변수의 수가 가장 적은 SuM3 모델이 학습단계와 검증단계에서 모두 가장 높은 상관계수를 보였다. 또한 SuM3 모델은 과압밀비(OCR)를 입력자료로 이용하지 않아 이 값을 결정하기 위하여 별도의 실내시험을 수행할 필요가 없으며, 콘 선단부에서 관측된 간극수압(u_1)값을 이용하지 않고 콘 선단부 뒤에서 관측된 간극수압(u_2)을 이용하기 때문에 이 두 위치(u_1 , u_2)에서 동시에 간극수압을 관측해야 하는 어려움을 동반하지 않아 실용성 면에서도 가장 돋보이는 것으로 평가되어 최적의 모델로 선정되었다.

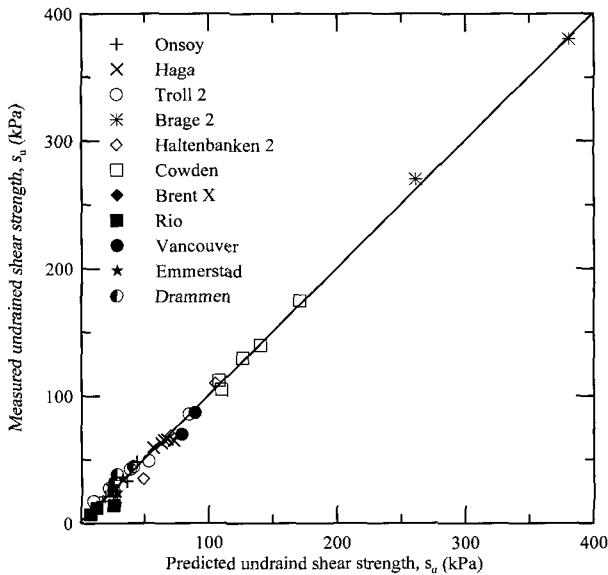
표 5에는 각 모델의 훈련단계와 검증단계의 상관계수(correlation coefficient)와 함께 각 모델의 입력변수들의 상대적인 중요도(relative importance)가 계산되어 있다. 상대 중요도(relative importance)는 Garson(1991)에 의하여 제안되었으며 각 모델에서 최종 출력값 예측에 기여하는 입력변수의 상대적인 중요도(relative importance)를 의미하고 모든 변수들의 상대 중요도의 합은 100%

이다. 각 입력변수들과 연결되어 있는 은닉층-출력층의 연결강도(connection weight)들을 분리함으로써 계산할 수 있으며 간단한 계산과정의 예는 Goh(1994)를 참고하라. 각 모델의 입력변수의 상대중요도를 살펴보면, 과압밀비는 SuM4, SuM4-1, SuM5 모델들에서 다른 입력변수와 비교하여 상대적으로 낮은 중요도를 갖는 것으로 평가되어 SuM3 모델에서와 같이 생략될 수 있음을 시사하였다. 이는 과압밀비를 사용함으로써 점토의 비배수전단강도 산정의 예측정도를 높였던 Rad and Lunne(1988)의 결과와 상반되는 결과이나 SuM3 모델은 사용된 3개의 입력변수들과 각 뉴우런간의 연결강도를 조절함으로써 과압밀비와 u_1 의 영향을 충분히 고려할 수 있음을 의미하는 것이어서 인공신경망 모델의 장점을 나타내는 것으로 사료된다.

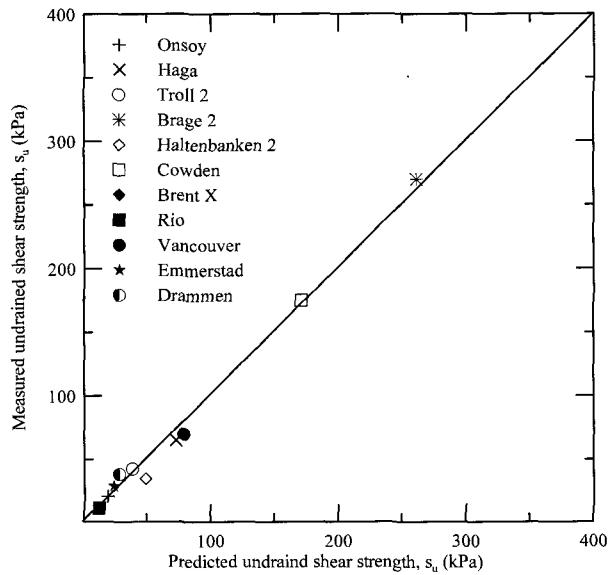
4. 제안된 모델의 검증 및 적용

4.1 학습자료와 검증자료에 대한 SuM3 모델 예측결과

최적 인공신경망 모델로 선정된 SuM3를 이용한 전체 자료들에 대한 비배수전단강도 예측 결과가 그림 4에 나타나 있다. 그림 4(a)에는 학습 및 검증자료 전체에 대한 예측결과가 실내 삼축시험으로부터 결정된 비배수전단강도 값과 비교되어 있다. 전체 자료에 대한 비배수전단강도 예측결과는 실험결과와 전체적으로 고르게 일치하는 것으로 나타났다. 그림 4(b)에는 학습단계에 이용되지 않는 자료들 만에 대해서 비배수전단강도 예측을 실시한 결과로 SuM3 모델이 전혀 경험해 보지 않은 자료에 대해서도 매우 정확한 예측을 하는 것으로 나타났다. 이상의 결과로부터 인공신경망 모델이 다양한 지역에서 수행된 피에조콘 관입시험 결과와 비배수전단강도 간의 복잡한 상관관계를 성공적으로 모델 할 수 있음을 알 수 있다.



(a) 전체자료에 대한 예측결과 비교



(b) 검증자료만에 대한 예측결과 비교

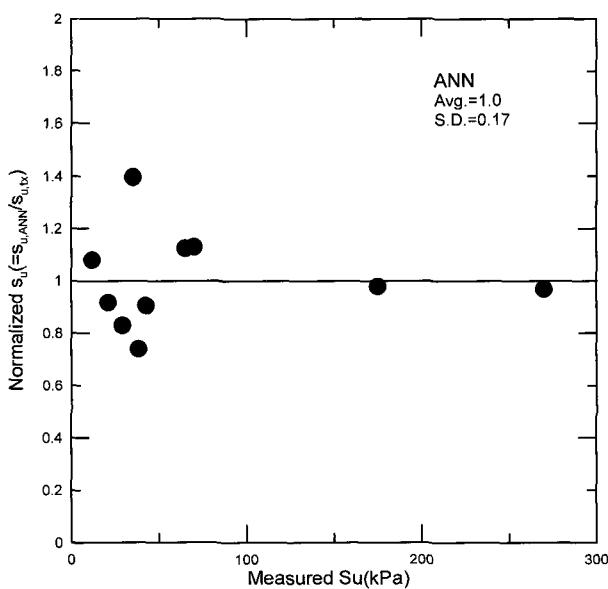
그림 4. 실험값과 SuM3 모델의 비배수전단강도 예측결과 비교

4.2 경험적 방법들과의 비교

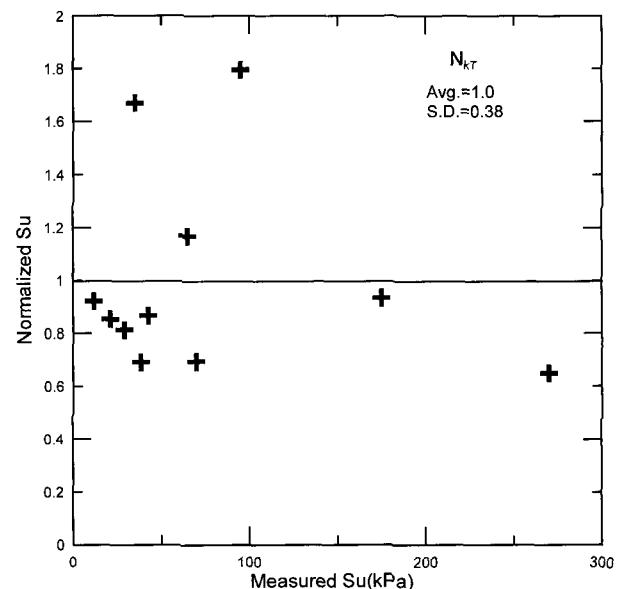
본 절에서는 제안된 인공신경망 모델의 예측결과를 기존의 경험적 방법(식 (4)~(6))을 이용한 비배수전단 강도 예측결과와 비교하였다. 기존의 경험식을 사용하기 위하여 학습 자료들로부터 콘 계수(cone factor)들이 $N_{kT}=12.6$, $N_{\Delta u}=4.78$, $N_{ke}=9.42$ 로 결정되었다. 결정된 콘 계수와 식 (4)~(6)을 이용하여 검증자료에 대한 비배수 전단강도 예측을 수행하였으며 모든 예측 비배수전단

강도들은 삼축압축시험으로 결정된 실측값($s_{u,tx}$)으로 정 규화된 비배수전단강도 $s_u (= s_u / s_{u,tx})$ 로 표현되어 그림 5에 비교되어 있다.

그림 5에 나타난 바와 같이 기존의 경험적 모델들 중에서는 순 선단저항력($q_T - \sigma_{vo}$)을 이용하는 N_{kT} 방법(그림 6(b))이 평균(average) 1.0, 표준편차(standard deviation) 0.38로 가장 신뢰할 만 한 것으로 나타났다. 그러나, 이 방법의 예측결과도 인공신경망 모델의 예측결과(그림 6(a))와 비교하면 평균값은 동일하게 1이나 표준편차가

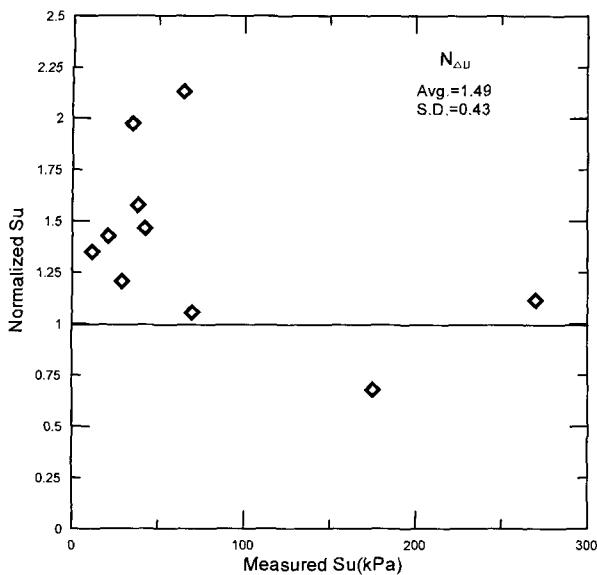


(a) 인공신경망 모델

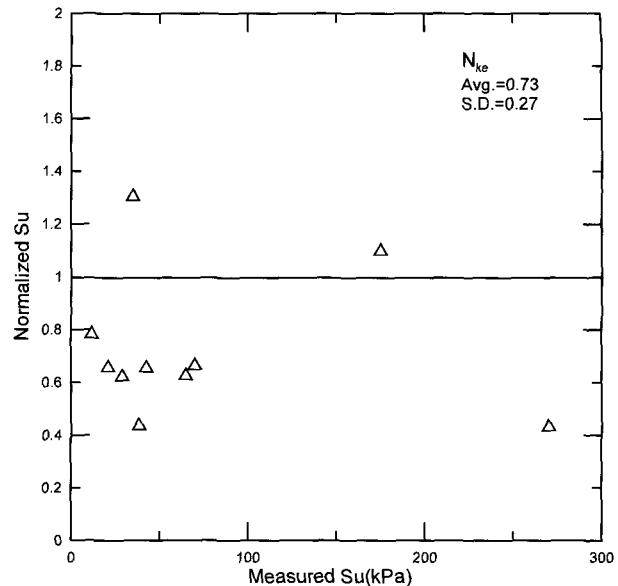


(b) N_{kT} 경험식

그림 5. 경험적 방법들과 인공신경망 모델의 정규화된 비배수전단강도 예측결과 비교



(c) N_{du} 경험식



(d) N_{ke} 경험식

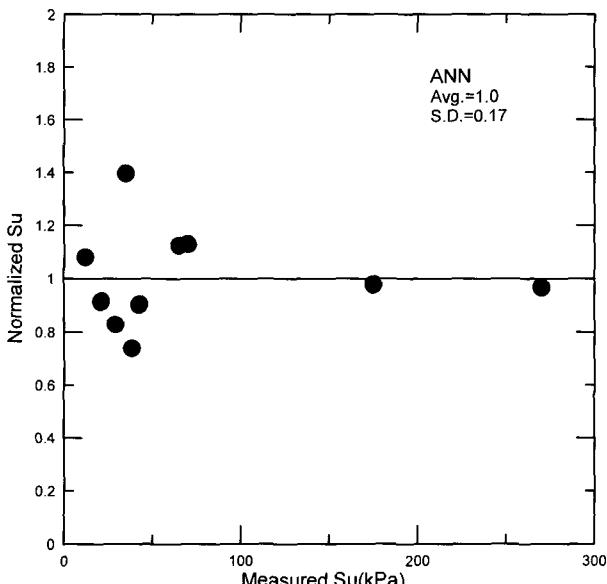
그림 5(계속). 경험적 방법들과 인공신경망 모델의 정규화된 비배수전단강도 예측결과 비교

2배 가량 큰 값을 주고 있어 인공신경망 모델이 기존의 경험적 방법보다 예측 정도(accuracy)가 높고 신뢰성이 큰 것으로 판단된다. 이 결과는 기존의 경험법들이 본 예제의 경우와 같이 다양한 지반에 대한 예측능력이 높은 신뢰성을 갖지 못하는 반면, 인공신경망은 다양한 특성을 갖는 지반에서도 예측 신뢰도가 높아 일반적인 지역에서의 예측방법으로서 사용 가능성이 있음을 의미하는 것으로 판단된다.

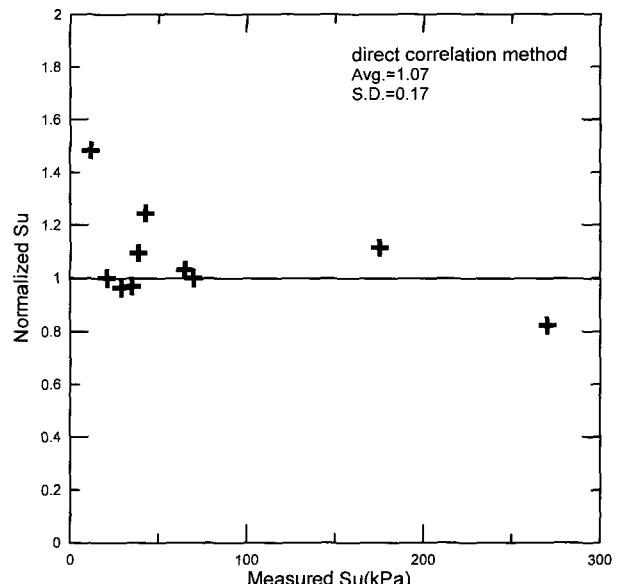
4.3 Direct correlation method 및 Hybrid theory와의 비교

기존의 경험적 모델의 단점을 극복하기 위하여 과압밀비(OCR)를 고려한 비배수전단강도 예측법인 direct correlation method(Rad and Lunne, 1988)와 이론적 방법인 hybrid theory(Chen and Mayne, 1993)에 의하여 제안된 식 (3)의 예측결과와 비교하였다.

Hybrid theory에 의한 이론적 예측결과는 Chen and

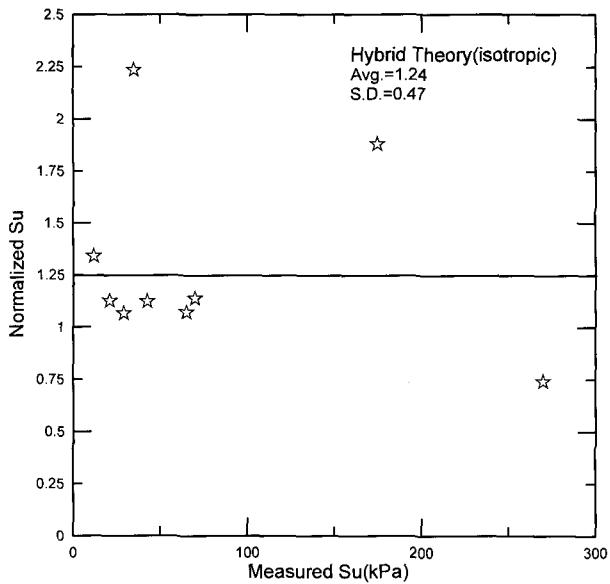


(a) 인공신경망 모델

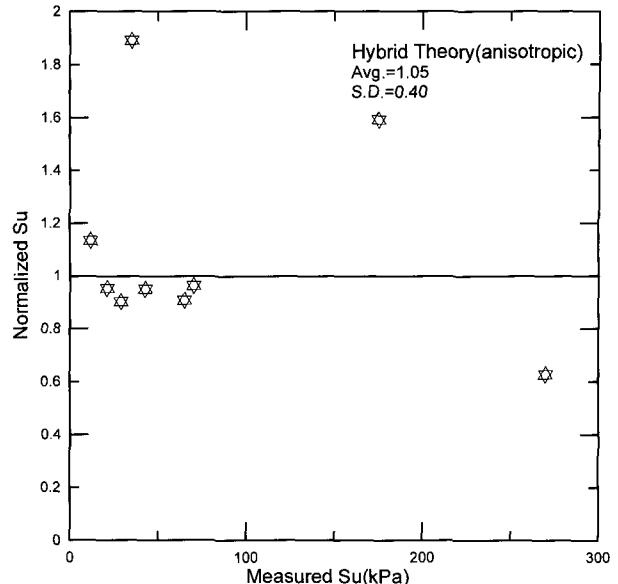


(b) direct correlation method

그림 6. direct correlation method 및 Hybrid theory와의 정규화된 비배수전단강도 비교



(c) Hybrid theory(CIUC)



(d) Hybrid theory(CAUC)

그림 6(계속). direct correlation method 및 Hybrid theory와의 정규화된 비배수전단강도 비교

Mayne(1993)의 주장과 같이 현장지반과 유사하게 비등 방성을 고려한 그림 6(d)의 경우가 등방의 경우인 그림 6(c)보다 평균값과 표준편차를 기준으로 볼 때 상대적으로 정확한 것으로 나타났다. 그러나 전반적으로는 두 경우 모두 경험적 방법들과 유사하게 표준편차가 크고 예측결과의 정확도가 높지 않은 것을 나타났다. 한편 direct correlation method는 기존의 경험법들과 이론적 방법(Hybrid theory)에 비해 표준편차가 작고 비교적 향상된 예측결과를 주고 있으며 제안된 인공신경망 모델과 매우 유사한 정확도를 갖는 것으로 나타났다. 그러나, 최적 모델 선정 시 언급한 바와 같이 direct correlation method를 사용하기 위해서는 지반의 과압밀비가 요구되며 콘 선단부에서의 간극수압 u_1 과 u_2 를 동시에 관측할 수 있는 장비가 필요한 반면, 본 연구에서 제안된 인공신경망 모델이 특별한 장비를 요구하지 않으면서도 간편하고 신뢰성 있게 비배수전단강도를 예측하여 실용적인 면에서 보다 우수한 것으로 사료된다.

5. 결 론

본 논문에서는 피에조콘 관측값으로부터 국외 11개 점토의 비배수전단강도 추정이 가능한 간단한 구조를 갖는 다층 인공신경망 모델링 기법을 제안하였다. 구성된 다층 인공신경망 모델은 삼축압축시험(CIUC and CAUC)으로 얻어지는 비배수전단강도를 예측할 수 있

도록 오차 역전파 알고리즘을 이용하여 학습되었으며 학습에 사용되지 않은 자료에 대한 예측 결과를 바탕으로 검증되었다. 제안된 기법과 모델에 대한 연구결과를 정리하면 다음과 같다.

- (1) 인공신경망 이론은 피에조콘 관측값들과 점토의 비배수전단강도 간의 복잡한 비선형 상관관계를 성공적으로 모델 할 수 있는 것으로 나타났으며 기존의 이론적 모델이나 경험적 모델과 비교할 때 훨씬 높은 예측정도를 가지는 것으로 나타났다.
- (2) 또한, 구축된 인공신경망 모델은 학습 및 검증에 사용된 다양한 특성을 갖는 11개의 점토의 비배수전단강도를 일관성 있고 정확하게 예측하는 것으로 나타나 기존의 경험적 모델이 특정 지역에만 적용 가능하던 지역성을 극복하고 일반적인 상관관계로 발전할 가능성을 충분히 갖추고 있는 것으로 평가된다.
- (3) 그러면서도 인공신경망 모델은 기존의 모델(direct correlation method 또는 Hybrid theory)에서 요구되는 추가적인 정보(과압밀비 OCR, 소성 체적 변형률 비 Λ)를 요구하지 않으며 일반적인 피에조콘 장비에서 관측되는 관측값(q_T , u_2)만을 이용하여 좋은 결과를 예측해 실용적인 면에서도 뛰어난 것으로 나타났다.
- (4) 본 연구에서 제안된 인공신경망 모델은 추후 국내자료에 대한 데이터베이스가 추가될 경우, 국내 지반

에의 적용성에 대한 평가도 이루어질 수 있으며 간단한 재 학습을 통해 모델을 수정하거나 국내지반에 적용 가능한 모델의 변화도 가능하다는 점이 가장 큰 장점이다.

감사의 글

본 연구는 한국과학재단 목적기초연구(과제번호 R05-2003-000-11073-0) 지원으로 수행되었으며 이에 감사드립니다.

참 고 문 헌

1. 김영상, 이승래, 김종수(2002), “피에조콘을 이용한 연약지반 선형암밀하중 결정의 인공신경망 이론 적용 연구”, 대한토목학회 논문집, 제22권, 제6-C호, pp.623~633.
2. 이선재(1997), 피에조콘을 이용한 국내지반의 공학적 특성 연구, 박사학위논문, 서울대학교, p.157.
3. 장인성, 이선재, 정충기, 김명보(2001), “국내 점성토 지반의 피에조콘 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. Mayne, P. W.(1980), “Cam Clay predictions of undrained strength”, *ASCE Journal of Geotechnical Engineering*, Vol.106, No.11, pp.1219~1242.
12. 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.
13. Toll, D.(1996), “Artificial Intelligence Applications in Geotechnical Engineering”, *Electronic Journal of Geotechnical Engineering*, Premiere Issue.

(접수일자 2003. 5. 31, 심사완료일 2003. 7. 22)