

동적신경망을 이용한 이암풍화토의 전단거동에측

A Prediction of Shear Behavior of the Weathered Mudstone Soil Using Dynamic Neural Network

김 영 수 ^{*1}	Kim, Young-Su	정 성 관 ^{*2}	Jung, Sung-Gwan
김 기 영 ^{*3}	Kim, Ki-Young	김 병 탁 ^{*4}	Kim, Byung-Tak
이 상 웅 ^{*5}	Lee, Sang-Woong	정 대 웅 ^{*6}	Jung, Dae-Woong

Abstract

The purpose of this study is to predict the shear behavior of the weathered mudstone soil using dynamic neural network which mimics the biological system of human brain. SNN and RNN, which are kinds of the dynamic neural network realizing continuously a pattern recognition as time goes by, are used to predict a nonlinear behavior of soil. After analysis, parameters which have an effect on learning and predicting of neural network, the learning rate, momentum constant and the optimum neural network model are decided to be 0.5, 0.7, $8 \times 18 \times 2$ in SNN model and 0.3, 0.9, $8 \times 24 \times 2$ in RNN model. The results of applying both networks showed that both networks predicted the shear behavior of soil in normally consolidated state well, but RNN model which is effective for input data of irregular patterns predicted more efficiently than SNN model in case of the prediction in overconsolidated state.

요 지

본 연구에서는 인간의 사고과정을 근거로 개발된 동적 인공신경망을 이용하여 이암풍화토의 전단거동을 예측하였다. 흙의 비선형거동을 예측함에 있어 피드백 과정에 의해 시간경과에 따른 패턴의 특성변화를 연속적으로 예측할 수 있는 동적신경망의 종류인 SNN모델과 RNN모델을 이용하였다. 인공신경망의 학습능력과 예측능력에 영향을 미치는 여러 변수들을 분석후 SNN모델에서는 학습율, 모멘텀 상수, 신경망구조가 0.5, 0.7, $8 \times 18 \times 2$, RNN모델인 경우는 각각 0.3, 0.9, $8 \times 24 \times 2$ 의 구조가 적합한 것으로 나타났다. 예측결과는 두 네트워크 모두 정규압밀 상태의 전단거동을 잘 예측하였지만, 과압밀 상태의 전단거동 예측에서는 불규칙적인 입력패턴에 효과적인 RNN모델의 예측능력이 더욱 우수하였다.

Keywords : Dynamic neural network, Learning rate, Momentum constant, RNN, SNN

1. 서 론

지반 고유의 구성상태 및 응력경로 등에 영향을 받는

흙의 비선형적 역학거동을 표현하기 위하여 탄·소성 이론에 근거한 다양한 수학적 구성모델이 지반공학 분야에서 제안되어져 왔다. 이러한 구성모델의 적용을 위

*1 정회원, 경북대학교 공과대학 토목공학과 교수 (Member, Prof., Dept., of Civil Engrg., Kyungpook National Univ.)

*2 정회원, 경북대학교 농과대학 조경학과 교수 (Member, Prof., Dept., of Landscape Architecture, Kyungpook National Univ.)

*3 정회원, 경북대학교 공과대학 토목공학과 공학박사 (Member, Ph. D, Dept., of Civil Engrg., Kyungpook National Univ.)

*4 정회원, 한국해양연구원 선임연구원 (Member, Senior Researcher, Korea Ocean Research and Development Institute)

*5 정회원, 경북대학교 공과대학 토목공학과 박사후료 (Member, Ph. D. candidate, Dept., of Civil Engrg., Kyungpook National Univ., lsw0303@empal.com)

*6 경북대학교 공과대학 토목공학과 석사과정 (Graduate Student, Dept., of Civil Engrg., Kyungpook National Univ.)

해서는 항복과 파괴상태를 규정하기 위한 가정사항이 수반되며 수학적 표현을 위한 재료의 매개변수들을 결정하여야 한다. 구성모델은 분명한 수학적 개념을 바탕으로 쉽게 이해할 수 있다는 장점이 있지만 구성모델의 적용에 선행하여 많은 재료상수들을 결정하여야 하고, 이러한 매개변수들을 결정하기 위해서는 추가적인 실험과 최적화 기술이 요구된다. 또한 일반적으로 이러한 구성모델의 예측능력은 모델이 복잡할수록 더욱 정확한 예측결과를 기대할 수 있지만 동시에 더 많은 매개변수들을 결정하여야 하기 때문에 적용성은 감소한다고 할 수 있다. 이러한 단점을 극복하기 위하여 수리적인 수식을 풀어나가는 방식과는 반대로 학습을 도와주는 지식이나 패턴을 일치시키는 방식을 이용하는 인공 신경망(neural network) 및 퍼지이론(fuzzy theory)과 같은 인공지능기법들이 지반공학 분야의 불확실성을 감소시킬 수 있는 방법으로 최근 많이 활용되고 있다. 국내 지반공학분야에서도 인공신경망을 적용한 연구가 활발히 진행중이다. 이인모 등(1997)은 암반의 투수계수를 예측하기 위해 현장자료를 이용한 신뢰성 검증을 수행하였으며, 양현석 등(1996)은 암반의 물성추정에 대하여, 배규진 등(1998)은 도심지 터널굴착에 의한 지표침하를 예측하고 인접 구조물의 손상을 평가할 수 있는 전문가 시스템을 개발하였다. 이 윤규 등은 압밀응력비에 따른 정규압밀점토의 비배수 전단강도를 예측함에 있어 인공신경망을 적용하였으며, 김 병탁 등(2000)은 사질토 지반에서의 강관말뚝의 수평거동 예측에 대한 인공신경망의 적용성을 검토하였다. 또한, 최근에는 시간경과에 따른 패턴인식에 더욱 효과적으로 알려져 있는 동적신경망을 적용한 연구가 진행되어 Ellis 등(1995)은 동적신경망의 형태중 연속 인공신경망(Sequential Neural Network, 이하 SNN)을 이용하여 모래의 응력-변형률 거동을 예측하였으며, Jian-hua 등(1998)은 순환형 동적신경망인 RNN(Recurrent Neural Network, 이하 RNN) 모델을 적용한 잔류토의 전단거동을 예측한바 있다. 이에 본 연구에서는 기존의 정적 다층신경망 구조를 변형하여, 피드백 과정에 의해 시간경과에 따른 패턴의 특성 변화를 연속적으로 예측할 수 있는 동적신경망의 형태인 SNN모델과 RNN모델의 적용성을 비교, 분석하고자 포함지역 이암풍화토의 비배수 삼축전단시험 결과를 이용하여 학습 및 예측을 수행하였다.

2. 인공신경망

인간의 생물학적 신경세포의 특성을 수학적 표현에 의해 모델링한 것을 인공신경망이라 한다. 인공신경망은 단순한 기능을 가진 무수한 처리소자들이 병렬로 연결된 연산구조를 가지고 있으며, 여러 분야에서 기존의 방법론으로는 해결하기 어려웠던 많은 부분들을 해석하는 새로운 기법으로 최근들어 급격한 연구증가와 함께 다양한 인공신경망 모델이 등장하고 있다. 이러한 인공신경망의 형태는 크게 정적신경망 및 동적신경망으로 구분할 수 있으며 각 신경망의 특징은 다음과 같다.

2.1 정적 신경망(Static Neural Network)

인공신경망은 인간의 두뇌 메커니즘을 구현하기 위한 생물학적 모델인 신경조직을 수학적으로 표현한 것으로 일반적으로 외부로부터 입력자료를 받는 입력층, 입력층으로부터 전달된 자료를 출력층으로 전달하는 은닉층, 은닉층에서의 출력값을 전달받아 최종출력하는 출력층의 구조를 가진다. 이러한 각층은 특정치의 연결강도를 갖는 링크(link)로 연결되며, 활성화함수에 의해 새로운 출력값을 생성하게 된다. 신경망에 의한 데이터의 학습알고리즘에는 여러가지 방법이 있으나 현재 가장 보편적으로 사용되고 있는 것은 역전파 학습알고리즘이다. 역전파 학습알고리즘의 기본원리는 입력층의 각 노드에 입력패턴을 주면 이 신호는 각 노드에서 변환되어 은닉층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 목표값을 비교하여 둘사이의 오차를 줄여 나가는 방향으로 연결강도를 조정하고 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나가는 것이다. 이러한 연결강도의 조정에는 출력값과 목표값의 오차의 제곱총합이 최소가 되도록 연결강도를 조정하는 일반화된 델타규칙이 적용되며, 델타규칙에 의한 연결강도의 조정을 위해서는 활성화함수의 미분과정이 필요하기 때문에 활성화함수는 연속함수이고 미분가능한 함수라야 한다. 이러한 활성화함수에는 여러 형태가 있으나, 비선형 미분가능 함수이며 미분식이 간단한 시그모이드(sigmoid)함수를 일반적으로 많이 사용한다. 이상의 역전파 학습 알고리즘에 의한 정적신경망의 구조는 그림 1과 같다.




그림 1. 정적 신경망의 구조




그림 2. SNN모델의 구조

2.2 동적 신경망(Dynamic Neural Network)

동적 신경망은 다층신경망을 확장 변형한 형태로써 피드백되는 연결강도의 값이 고정되느냐, 변화하느냐에 따라 크게 구분된다. 피드백되는 연결강도 값이 고정되는 신경망의 종류는 다시 Jordan(1987)에 의하여 제안된 SNN모델과 Elman(1990)에 의하여 제안된 RNN모델로 구분된다.

2.2.1 SNN

SNN은 출력층의 출력값을 입력층으로 피드백 시키는 신경망 모형으로 기본구조는 그림 2와 같이 입력층은 Plan Unit와 Current-State Unit로 구분되며, 학습을 통해 발생한 첫 번째 출력패턴이 피드백되어 다시 Current-State Unit로 입력되므로 연속적인 반복학습이 수행된다.

입력층 (i)에서 출력된 값(o_{pit})과 피드백된 (t-1)단계의 출력값($o_{pk(t-1)}$)은 입력층과 은닉층 사이의 연결강도(w_{jit})와 바이어스값(θ_{jt})에 의해 은닉층 (j)의 입력값(net_{pjt})으로 변환되고, 이 값에 활성화함수(f_j)가 곱해져서 식 (1)과 같은 은닉층 (j)의 출력값(o_{pjt})으로 변환된다.

$$o_{pjt} = f_j(\sum w_{jit} o_{pit} + \theta_{jt} + \sum w_{jit} o_{pk(t-1)}) \quad (1)$$

은닉층의 출력값(o_{pjt})은 다시 은닉층과 출력층 사이의 연결강도(w_{kjt})와 바이어스값(θ_{kt})에 의해 출력층의 입력값(net_{pkt})으로 변환되어 활성화함수(f_k)에 의해 식 (2)와 같은 출력값(o_{pkt})이 산정된다. 이때 출력값은 피드백 과정에 의해 Current-State Unit로 입력되어 다음 단계 예측을 위한 입력값으로 작용한다.

$$o_{pkt} = f_k(\sum w_{kjt} o_{pjt} + \theta_{kt}) \quad (2)$$

시스템오차를 최소화하는 방법은 역전파 신경망과 유사한 형태로써, 델타 규칙에 의해 출력층에서 산출된 오차를 줄이는 방향으로 입력층까지 역전파하여 연결강도와 바이어스값을 수정한다. 식 (3), (4)에 의해 은닉층의 연결강도와 바이어스값이 조정되며, 식 (4), (5)에 의해 출력층의 연결강도와 바이어스값이 조정된다.

$$\begin{aligned} \Delta_p w_{jit} &= -\eta \frac{\partial E}{\partial w_{jit}} + w_{jit(t-1)} \\ &= \eta \sum (t_{pkt} - o_{pkt}) w_{kjt} f'_k(net_{pkt}) f'_j(net_{pjt}) o_{pit} + w_{jit(t-1)} \end{aligned} \quad (3)$$

$$\Delta_p \theta_{jt} = \theta_{k(t-1)} + \alpha \sum (t_{pkt} - o_{pkt}) w_{kjt} f'_j(net_{pjt}) \quad (4)$$

$$\begin{aligned} \Delta_p w_{kjt} &= -\eta \frac{\partial E}{\partial w_{kjt}} + w_{kjt(t-1)} \\ &= \eta \sum (t_{pkt} - o_{pkt}) o_{pjt} f'_k(net_{pkt}) + w_{kjt(t-1)} \end{aligned} \quad (5)$$

$$\Delta_p \theta_{kt} = \theta_{k(t-1)} + \alpha \sum (t_{pkt} - o_{pkt}) f'_k(net_{pkt}) \quad (6)$$

여기서, $E = \sum \frac{1}{2} (t_{pkt} - o_{pkt})^2$

η = 학습율

α = 모멘텀

f'_j, f'_k = 활성화함수 f_j, f_k 의 미분값

2.2.2 RNN

RNN은 시간경과에 따른 패턴의 특성변화를 학습할 수 있는 신경망 구조로써, 그림 3과 같이 은닉층의 출력값이 Context units로 피드백되어 이전단계 은닉층의 정보를 함축적으로 보유한 예측결과를 얻을 수 있는 신경망 구조이다. 즉 은닉층의 출력 정보를 Context layer를 통해서 입력층으로 피드백 시킴으로서 시간상 전 단계의 은닉층의 정보를 함축적으로 보유하고 있으므로 입력데이터의 연속성을 구현할 수 있다.




그림 3. RNN모델의 구조

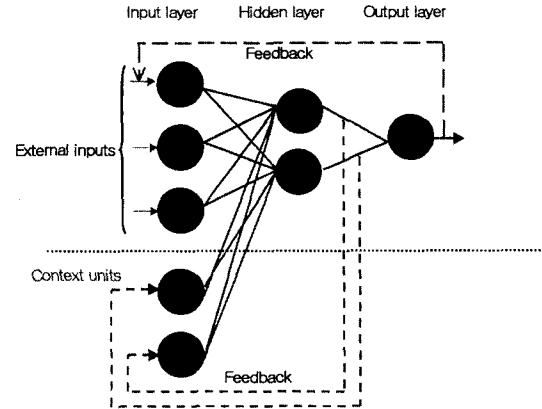


그림 4. 수정 RNN 모델의 구조

신경망 내의 뉴런들은 활성화 기억 능력의 여부에 따라 정적뉴런과 동적뉴런으로 구분된다. RNN모델에서 은닉층은 동적 뉴런으로 구성되며, 그 외의 입력층과 출력층은 정적 뉴런으로 구성된다. 현단계 은닉층의 입력값은 식 (7)과 같이 현단계 정적뉴런들의 가중치 합과 전단계 동적뉴런들의 가중치 합으로 표현되고, 이 값에 활성화함수가 곱해져서 식 (8)과 같은 은닉층 출력값이 계산된다.

$$net_{pit} = \sum w_{jit} o_{pit} + \sum r_{jit} o_{pit(t-1)} + \theta_{it} \quad (7)$$

$$o_{pit} = f_j(\text{net}_{pit}) \quad (8)$$

식 (7)에서, w_{jit} 는 정적 연결강도이며, r_{jit} 는 동적 연결강도이다. 연결강도의 변화는 역전파 신경망과 유사한 형태로 델타규칙에 의해 식 (9), (10)에 의해 산정된다.

$$\Delta_p w_{jit} = \eta \delta_{pit} o_{pit} + w_{jit(t-1)} \quad (9)$$

$$\Delta_p r_{jit} = \eta \delta_{pit} o_{pit(t-1)} + r_{jit(t-1)} \quad (10)$$

상기한 일반적 RNN모델은 출력층의 피드백 과정이 없는 형태로서 입력층과 출력층의 뉴런들은 정적뉴런 형태가 되므로, 현단계 입력값에 실험결과에 의한 목표값을 입력하여 다음 단계의 예측을 수행하여야 한다. 이에 본 연구에서는 은닉층 뿐만 아니라 출력층에서도 피드백 과정을 도입함으로써 현단계의 출력값이 다음단계의 입력값으로 작용하여 출력층 뉴런들과 피드백 되는 입력층 뉴런들 모두 동적뉴런 형태가 되도록 RNN모델을 재구성하였다. 이렇게 재구성된 RNN모델에서는 실내시험의 결과값은 훈련과정에서 단지 목표값으로만 작용하게 되며, 시간상 이전단계 은닉층 및 출력층의 정보를 함축적으로 보유한 상태에서 출력층에서 발생되

는 출력에러를 학습종료 시점까지 축적하여 평형상태에 도달시키는 연속적인 예측이 가능하다. 본 연구에서 적용한 RNN모델의 구조는 그림 4와 같다.

3. 이암풍화토의 비배수 전단시험

본 연구에서는 경상북도 포항시 양덕지구(이하 A시료)와 두호동일대(이하 B시료)에 산재하고 있는 이암풍화토를 대상으로 동적 인공신경망을 이용한 비배수 전단거동을 모델링하였다. 두 시료에 대한 물리적 특성은 표 1과 같다.

본 연구에서는 No. 40번체를 통과한 자연 건조시료를 예비압밀 토조(가로30cm, 세로 20cm, 높이 30cm)에서 액성한계의 약 2배에 해당하는 함수비로 교반 및 탈기하여 하중증가비 1로 60kPa까지 최종 압밀하였다. 예비압밀된 시료에 대하여 정규압밀 시험인 경우 100, 200, 300, 400, 600kPa의 유효 압밀응력으로 등방압밀 시킨 후 비배수 전단시험을 실시하였으며, 과압밀 시험은 600kPa의 유효 압밀응력으로 등방압밀된 시료에 대하여 구속응력을 300, 150, 75, 60, 50kPa로 제하하여 과압밀비가 2, 4, 8, 10, 12상태에서 비배수 전단시험을 실시하였다. 전단시 0.1%/min의 변형률 제어방식으로 총 20회의 시험을 실시하였으며, 각 시험결과는 대략 500개 이상의 정보를 포함하고 있다. 시험 조건별 압밀종료시 유효수

표 1. 이암 풍화토의 물리적 특성

Sample No.	Gs	LL (%)	PL (%)	PI	#200통과율 (%)	USCS
A	2.53	56	20	36	80	CH
B	2.59	48	25	23	84	CL

표 2. 정규압밀 시료의 비배수 전단시험 결과

시료	압밀			전단			
	압밀 유형	σ'_{vo} (kPa)	σ'_{ho} (kPa)	ϵ_f (%)	$(\sigma_1 - \sigma_3)_{max}$ (kPa)	U_f (kPa)	U_{max} (kPa)
A	정규 압밀	100	100	14.39	79.79	42.93	43.53
		200	200	13.41	153.02	99.39	100.48
		300	300	12.42	218.89	160.71	164.64
		400	400	15.35	276.49	220.35	220.35
		600	600	12.43	416.30	315.37	312.37
B	정규 압밀	100	100	15.12	97.98	68.38	68.38
		200	200	15.36	179.43	133.41	133.41
		300	300	14.40	255.08	193.07	195.65
		400	400	15.35	343.88	265.05	265.05
		600	600	14.34	523.06	393.94	394.09

표 3. 과압밀 시료의 비배수 전단시험 결과

시료	압밀				전단				
	압밀 유형	OCR	σ'_{vo} (kPa)	σ'_{ho} (kPa)	ϵ_f (%)	$(\sigma_1 - \sigma_3)_{max}$ (kPa)	U_f (kPa)	U_{max} (kPa)	U_{min} (kPa)
A	과압밀	2	300	300	15.54	330.13	35.11	38.06	0
		4	150	150	14.42	266.55	-22.73	10.99	-22.93
		8	75	75	14.36	199.10	-36.57	8.74	-36.57
		10	60	60	15.31	130.15	-45.68	6.76	-45.68
		12	50	50	15.35	110.54	-55.46	4.19	-55.46
B	과압밀	2	300	300	11.33	412.33	131.76	137.77	0
		4	150	150	14.39	369.61	18.33	32.64	0
		8	75	75	12.33	296.60	-22.99	26.47	-26.77
		10	60	60	14.15	264.69	-32.35	18.08	-33.80
		12	50	50	15.38	251.81	-39.44	10.01	-39.44

직응력(σ'_{vo}), 유효수평응력(σ'_{ho})과 전단시 발생한 최대 축차응력($(\sigma_1 - \sigma_3)_{max}$) 및 최대간극수압(U_{max}) 등의 시험 결과는 다음 표 2, 3과 같다. 정규압밀 시료인 경우, 유효 압밀응력이 증가함에 따라 최대 축차응력의 크기가 거의 규칙적으로 증가하여 전단시의 축차응력을 유효 압밀응력으로 나누면 하나의 곡선군으로 정규화되는 전형적인 정규압밀 상태의 거동양상을 나타내었다. 과압밀 시료의 경우, 본 실험에서는 하중을 제하하여 과압밀 상태를 재현하였기 때문에 과압밀비가 증가함에 따라 최대 축차응력은 감소하였으며 과압밀비가 10이상인 조건에서는 과압밀비에 따른 최대 축차응력의 차이가 크게 발생하지 않았다. 이는 정규압밀 상태와는 달리 과압밀 상태의 거동양상은 과압밀비에 크게 영향을 받기 때문으로 사료된다.

4. 신경망의 구조선정 및 적용 결과

4.1 신경망 구조선정

인공신경망의 예측능력은 출력값에 영향을 미치는 적합한 입력값의 선택에 가장 큰 영향을 받으며, 이외에도 은닉층 구조와 뉴런의 수, 학습율과 모멘텀상수 등과 같은 인자들에 의해서도 학습효율과 예측능력이 크게 달라진다. 변형율제어 전단시험에서 비종속적인 축변형률 및 변형률속도는 종속적인 응력값을 알아내기 위한 요소로 작용하므로 현단계(i)의 축변형률($\epsilon_{1,i}$)과 변형율 증분량($\Delta\epsilon_{1,i}$)은 입력변수로 고려되어야 한다. 또한, 흙의 전단거동은 압밀조건, 간극비 및 전단시 응력경로 등에 의해서도 큰 영향을 받기 때문에 현단계(i)의 유효 구속응력(σ'_{3i}), 간극비(e_i), 축차응력(σ_i) 및 간극수압(u_i) 등도 입력자료로 고려되어야 한다. 또한 압밀이력

상태에 따른 과압밀비와 점토에 있어 물리적 특성을 대표하는 소성지수(PI)등도 고려되어야 한다. 이와 같은 영향을 고려하여 본 연구에서는 다음과 같이 8개의 입력변수값을 선정하였으며, 다음단계의 축차응력(σ_{i+1})과 간극수압(u_{i+1})을 출력값으로 결정하였다.

$$[\text{Inputs/Targets}] = [\sigma_i, \epsilon_{1,i}, \Delta\epsilon_{1,i}, PI, \sigma'_3, OCR, e_i, u_i / \sigma_{i+1}, u_{i+1}]$$

최적화된 신경망을 구성하기 위하여 상기한 입력변수 8개와 출력변수 2개의 기본구조를 가지며, 은닉층이 단층인 신경망에 대하여 은닉층 뉴런의 수, 학습을 및 모멘텀 상수의 변화에 따른 학습능력의 영향을 검토하였다. 검토시 은닉층 뉴런의 수는 12, 18, 24개로 변화시켰으며, 연결강도와 바이어스값의 조정시 조정량 반영 비율을 결정하는 학습율은 0.1, 0.3, 0.5의 값을 적용하였고, 학습시간에 영향을 미치는 모멘텀 상수는 0.5, 0.7, 0.9의 값을 적용하였다. 이상의 변수를 고려하여 학습에 의한 최적 신경망 선정을 위해 사용된 SNN, RNN 모델의 구조는 각각 27종류이다. 학습시 활성화함수는 단극성 시그모이드 함수를 사용하였으며, 학습자료의 패턴오차를 합한 시스템오차가 10^{-3} 에 수렴했을 경우와 학습 횟수가 60만회 이상이 될 때를 학습의 종료 시점으로 선정하였다. 학습결과 SNN은 학습율 0.1인 경우에서 제한 학습횟수내에 시스템오차에 수렴하지 못하였으며, 대부분의 경우에서 RNN이 적은 학습횟수에서 시스템 오차에 수렴을 하였다. 이는 RNN에서의 이전단계 은닉

층의 정보를 보유하고 있는 Context layer가 수렴속도에 영향을 미친 것으로 사료된다. 하지만, SNN과 RNN 두 모델의 학습결과와 실제 실내시험 결과와의 상관계수는 모두 0.998이상으로 학습결과에서는 변수에 따른 영향이 크게 나타나지 않았다. 이에 본 연구에서는 신경망의 예측능력을 나타내는 예측 상관계수와 시스템오차의 수렴여부에 중점을 두어 최적 신경망을 선정하였다.

인공신경망의 예측능력을 검토하기 위해 학습자료를 이용하여 학습이 완료된 54개의 신경망 시험모델로부터 학습시 제외되었던 데이터를 이용하여 인공신경망의 예측능력을 검증하였다. A, B 두 시료에 대하여 정규압밀 시료의 경우 연직압밀응력이 100, 200, 400, 600kPa일 때의 실내시험의 데이터를 이용하여 학습을 실시한 후 연직압밀응력이 300kPa일때의 시험자료를 예측하였으며, 과압밀비가 각각 2, 4, 10, 12인 실내시험 자료를 학습자료로 이용하고 과압밀비가 8인 자료를 이용하여 예측능력을 검증하였다.

최적화된 인공신경망의 선정은 출력변수의 예측상관계수가 상호 가장 높은 경우를 최적 신경망으로 선정하였다. SNN은 은닉층 뉴런의 수가 18, 학습율 0.5, 모멘텀 상수 0.7인 구조에서 상관계수가 가장 높게 나타났으며, RNN은 은닉층 뉴런의 수가 24, 학습율 0.3, 모멘텀 상수 0.9인 구조에서 상관계수가 가장 높게 나타났다. 이상의 결과를 종합하여 선정된 최적 신경망의 구조는 그림 5, 6과 같다.




그림 5. SNN모델의 최적 신경망 구조




그림 6. RNN모델의 최적 신경망 구조

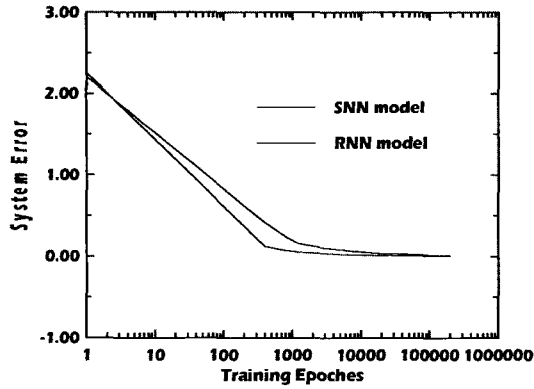


그림 7. Epoch수에 따른 시스템 오차의 변화

그림 7은 학습이 진행되는 동안 epoch수의 증가에 따른 시스템 오차의 변화를 나타낸 결과이다. 학습과정동안 두 모델 모두 epoch수가 증가함에 따라 오차의 진동 및 지역최소점에 수렴하는 경향없이 지속적 오차감소가 진행되었으며, RNN모델의 오차수렴 속도가 SNN모델보다 빠르게 나타났다.

4.2 학습 및 예측 결과


4.2.1 학습결과

선정된 최적 신경망구조를 이용하여 연직압밀응력 100, 200, 400, 600kPa의 정규압밀시료와 과압밀비가 2, 4, 10, 12인 과압밀 시료에 대하여 학습을 수행한 결과는 그림 8, 9와 같다.


변형을 증가에 따른 축차응력과 간극수압의 변화 즉 목표값과 학습된 결과인 출력값을 비교하면 SNN모델의 경우 A, B 두 시료의 상관계수는 0.9983, 0.9927로 나타났으며, RNN모델의 경우는 A, B 시료의 상관계수가 0.9994, 0.9991로 나타났다. 상관계수 값에서 알 수 있듯이 학습결과는 실측치와 거의 일치하였으며, RNN 모델의 경우가 상관계수값이 조금 높게 나타났으나 그 차이는 아주 미소하였다.

4.2.2 예측결과

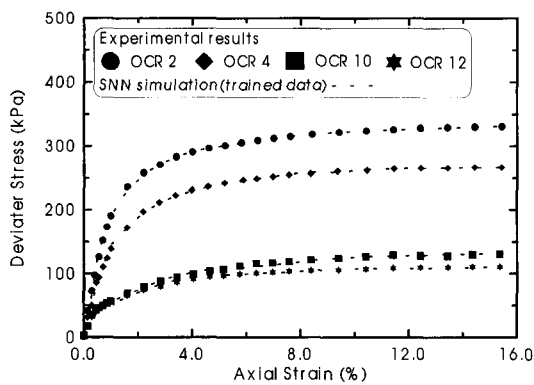
최적 신경망에 의한 예측능력을 검증하기 위하여 학습시 제외되었던 연직압밀 응력 300kPa인 정규압밀 시



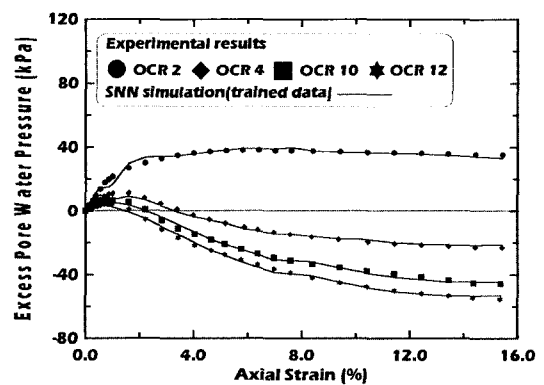
(a) 축차응력(정규압밀)



(b) 간극수압(정규압밀)




(c) 축차응력(과압밀)




(d) 간극수압(과압밀)

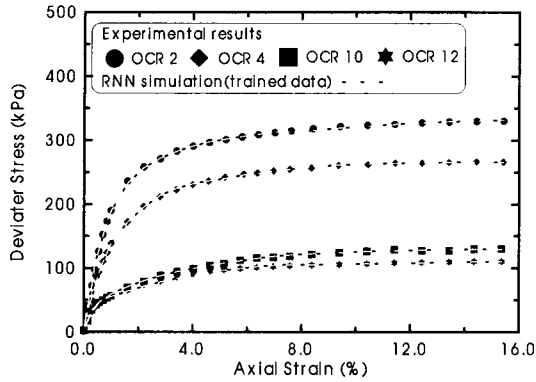
그림 8. SNN모델에 의한 A시료의 학습결과



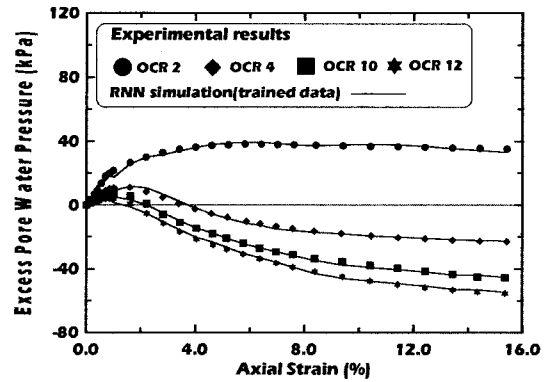
(a) 축차응력(정규압밀)



(b) 간극수압(정규압밀)

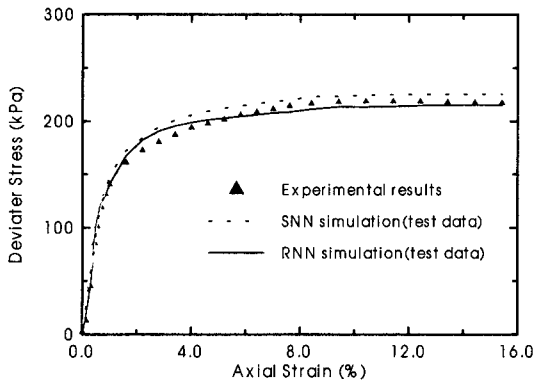


(c) 축차응력(과압밀)




(d) 간극수압(과압밀)

그림 9. RNN 모델에 의한 A시료의 학습결과



(a) A시료




(b) B시료

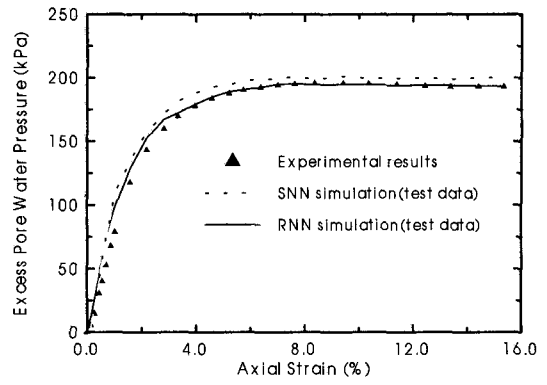
그림 10. 정규압밀 시료의 축차응력 예측 결과

료와 과압밀비가 8인 과압밀 시료의 비배수 전단거동을 예측하였다. 그림 10, 11은 정규압밀 시료의 축차응력-변형률과 간극수압-변형률 거동을 예측한 결과로서, 축차응력의 예측상관 계수는 RNN모델의 경우 0.9875, SNN모델의 경우 0.9834로 나타났으며, 간극수압의 예측상관 계수는 RNN모델의 경우 0.9819, SNN 모델의 경우 0.9726으로 나타났다. 예측상관 계수에 의해 두 모

델을 비교하면 RNN모델이 좀더 정확한 예측결과를 나타내지만 두 모델에 의한 예측능력에는 크게 차이가 없었다. 이러한 특징은 일반적으로 정규압밀 시료의 전단시 유효응력 경로는 서로다른 연직압밀 응력으로 압밀되었더라도 전단시의 축차응력을 최종압밀응력으로 나누면 하나의 곡선군으로 표현되는 정규화거동을 나타내기 때문에, 이러한 규칙적 경향을 두 모델 모두 잘 재




(a) A시료

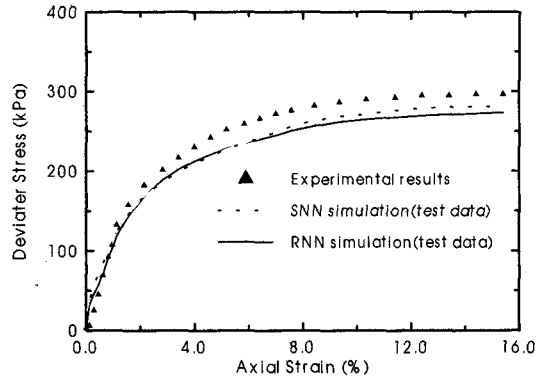


(b) B시료

그림 11. 정규압밀 시료의 간극수압 예측 결과

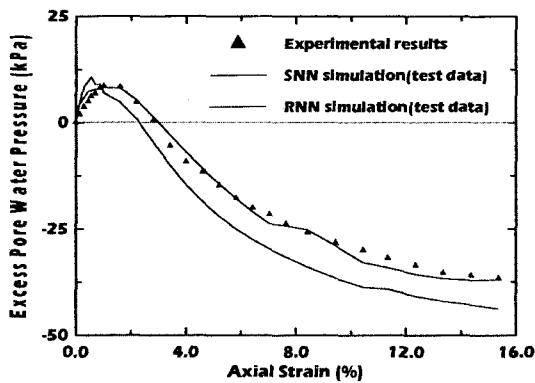


(a) A시료

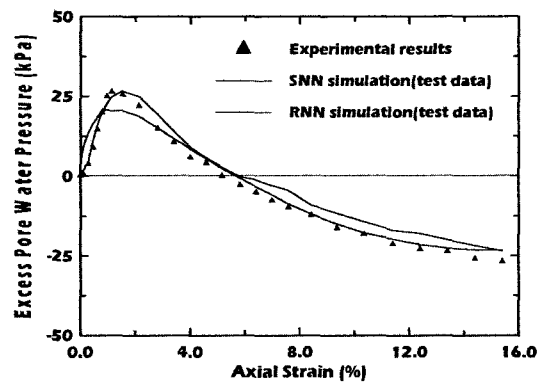


(b) B시료

그림 12. 과압밀 시료의 축차응력 예측 결과



(a) A시료



(b) B시료

그림 13. 과압밀 시료의 간극수압 예측 결과

현하였기 때문에 사료된다.

그림 12, 13은 과압밀 시료의 축차응력-변형률 거동 및 간극수압-변형률 거동을 예측한 것이다. 축차응력의 예측상관 계수는 RNN모델의 경우 0.9568, SNN모델의 경우 0.9334로 나타났으며, 간극수압의 예측상관 계수는 RNN모델의 경우 0.9711, SNN 모델의 경우 0.9133으

로 나타났다. 예측상관 계수에서 알수 있듯이 RNN모델의 예측결과가 SNN모델의 결과보다 시험결과에 더 근접하였다.

이는 RNN모델에서는 은닉층에서 입력층으로 피드백되는 과정이 있기 때문에 학습시 더 많은 자료를 보유한 상태에서 데이터의 변화추세를 효과적으로 반영할

수 있기 때문에 사료된다. 정규압밀 상태의 예측결과와 비교하면 과압밀 시료의 예측결과가 다소 신뢰성이 감소하였다. 이는 학습시 사용된 시험결과의 경향이 과압밀비가 증가함에 따른 거동양상의 규칙성을 나타내지 않았고 특히, 과압밀비가 10 이상에서는 축차응력의 차이가 크게 발생하지 않았다. 이러한 학습결과를 바탕으로 과압밀비가 8인 경우를 예측함에 있어 과압밀비가 2에서 4로 변함에 따른 영향보다는 10에서 12로 변함에 따른 영향이 크게 반영되었기 때문에 사료된다.

5. 결론

포항지역 이암풍화토의 비배수 전단거동을 예측함에 있어 출력값을 입력층으로 피드백하는 SNN모델과 은닉층 및 출력층의 값이 입력층으로 피드백되는 RNN모델을 적용하여 등적신경망의 예측능력을 비교한 결과는 다음과 같다.

- (1) SNN모델과 RNN모델의 최적 신경망 구조를 선정하기 위하여 은닉층 뉴런의 수, 학습율, 모멘텀등을 변화시켜 예측능력을 비교한 결과 SNN모델의 경우는 학습율 0.5, 모멘텀 상수 0.7, $8 \times 18 \times 2$ 구조, RNN 모델은 각각 0.3, 0.9, $8 \times 24 \times 2$ 의 구조에서 최고의 예측능력을 나타내었다.
- (2) 압밀이력 상태에 따른 예측결과를 비교하면 정규압밀점토의 전단거동은 시험결과에 거의 근접하였지만, 과압밀 점토의 축차응력은 다소 과소평가 되었다. 이러한 결과는 학습시 사용된 시험결과가 정규압밀 점토의 경우 전단시의 축차응력을 유효압밀응력으로 나누면 하나의 곡선군으로 정규화되는 거동특성이 나타나지만, 과압밀 점토는 과압밀비에 따라 매우 상이한 거동을 나타내었기 때문에 사료된다.
- (3) SNN모델과 RNN모델의 적용성 분석결과 학습상관계수 및 예측상관계수가 SNN모델의 경우 0.91 이상, RNN모델의 경우 0.95이상으로, 두 모델 모두 비교적 높게 나타났다. 정규압밀 시료의 예측결과는 모델에 의한 차이가 크게 나타나지 않았으나, 과압밀

시료의 예측결과는 예측능력과 수렴속도 모두 은닉층과 입력층사이에 피드백 과정이 있는 RNN모델이 SNN모델보다 더욱 효과적이었다. 이러한 결과에서 알 수 있듯이 RNN모델이 불규칙한 패턴의 입력값에 의한 예측능력이 더욱 우수한 것으로 사료된다.

(4) 본 연구에서는 등방압밀된 포항이암 풍화토를 대상으로 흙의 초기간극비와 소성지수만으로 시료를 구분하여 전단거동을 예측하였지만, 향후 보다 많은 물리적 특성 및 이방성을 고려할수 있는 신경망의 적용연구가 필요하다고 사료된다.

참 고 문 헌

1. 김병탁, 김영수, 이우진(2000), "인공 신경망을 이용한 모형말뚝의 수평변위와 최대 휨모멘트 예측", 한국지반공학회지, 제16권, 제5호, pp.169-178.
2. 배규진, 김창용, 신휴성, 문현구(1998), "터널 굴착 현장에 인접한 지상구조물의 안전성 평가용 전문가 시스템의 개발(1)", 한국지반공학회지, 제14권, 제12호, pp.107-123.
3. 양형석, 김남수(1996), "가속신경망에 의한 암반물성의 추정", 한국암반공학회 논문집, 제6권, pp.316-325.
4. 이윤규, 윤여원, 강병희(2000), "인공신경회로망을 이용한 압밀응력비에 따른 정규압밀점토의 비배수전단강도 예측", 한국지반공학회지, 제16권, 제1호, pp.75-81.
5. 이인모, 조계춘, 이정학(1997), "인공신경망을 이용한 암반의 투수계수 예측", 한국지반공학회지, 제13권, 제2호, pp.77-89.
6. C.L. Giles, G.M.Kuhn, and R.J. Williams(1994), "Dynamic recurrent neural networks:theory and application", *IEEE Trans. Neural Network*, 5(2), pp.153-160.
7. Ellis,G.W., Yao, C., and Zhao, R.(1992). "Neural Network modeling of the mechanical behavior of sand," *Proc., 9th Conf., ASCE Engrg. Mech., ASCE, New York, N.Y.*, pp.421-424.
8. G.W. Ellis, C. Yao, R. Zhao, and D. Penumadu(1995), "Stress-strain modeling of sands using artificial neural networks", *J. Geotech. Engrg. Div. ASCE*, 121(5), pp.429-435.
9. Jian-hua Z. and Musharraf M., Scott A.(1998), "Modeling of shearing behaviour of a residual soil with recurrent neural network", *Int. J. Numer. Anal. Meth. Geomech.*, 22, pp.671-687.
10. Peumadu, D., Zhao R., Yao, C., and Ellis, G. W.(1995), "Stress-strain modeling of sands using artificial neural network", *J. Geotech. Engrg., ASCE*, 121(5), pp.429-435.
11. R.Penumadu(1996), "Discussion of stress-strain modeling of sands using artificial neural networks", *J. Geotech. Engrg. ASCE*, 122(11), pp.950-952.

(접수일자 2002. 6. 18, 심사완료일 2002. 9. 10)