

군집신경망과 확률신경망 이론을 이용한 연약지반의 측방유동 평가 모델

Evaluation Model for Lateral Flow on Soft Ground Using Committee and Probabilistic Neural Network Theory

김 영 상¹ Kim, Young-Sang

주 노 아² Joo, No-Ah

이 중 재³ Lee, Jeong-Jae

Abstract

Recently, there have been many construction projects on soft ground with growth of industry and various construction problems concerning soft soil behavior also have been reported. Especially, foundation piles of abutments and (or) buildings which were constructed on the soft ground have been suffering from a lot of stability problems of inordinary displacement due to lateral flow of soft ground. Although many researches for this phenomena have been carried out, it is still difficult to assess the mechanism of lateral flow on soft ground quantitatively. And reliable design method for judgement of lateral flow occurrence is not established yet. In this study, PNN (probabilistic neural network) and CNN (committee neural network) theories were applied for judgment of lateral flow occurrence based on real data compiled from Korea and Japan. Predictions of PNN and CNN models for new data which were not used during model development are compared with those predicted by conventional empirical methods. It was found that the developed PNN and CNN models can predict more precise and reliable judgment of lateral flow occurrence than conventional empirical methods.

요 지

최근 급속한 경제발전과 지역산업의 성장으로 인하여 많은 물류이동 발생과 함께 연약지반에 도로를 건설하는 경우가 많아지면서 연약지반 상에 축조된 지반구조물과 관련한 제반 문제점들이 대두되고 있다. 특히 말뚝 기초 형식의 교대나 건축물을 연약지반에 시공할 경우 비정상적인 측방유동에 의한 변위가 기초지반에 발생하여 상부 구조물의 안정성과 사용성에 많은 문제를 야기하고 있다. 측방유동은 말뚝의 파손원인과 측방변위에 대한 상관관계 연구, 연약지반 상에 설치된 말뚝의 변형과 모멘트에 대한 연구, 수치해석법을 이용한 연약지반상의 성토에 따른 측방변위 특성 및 현장계측을 통한 측방변위 특성 등 많은 연구가 수행되어지고 있으나 측방유동현상은 지금까지도 그 역학적 메커니즘이 정량적으로 파악하기 어렵고, 측방유동에 대한 합리적인 설계법이 확립되어 있지 않는 실정이다. 본 연구에서는 국내 및 일본 측방유동 발생 사례를 바탕으로 효과적이고 보다 정확한 측방유동 판정을 위하여 확률신경망과 군집신경망이론을 이용한 평가모델을 구축하고 기존의 측방유동 판정식과 비교하였다. 연구결과 제안된 확률신경망과 군집신경망 모델들의 측방유동 판정 성공률이 기존의 판정식들에 비해 매우 높은 정확도를 가지며 효과적인 것으로 나타났다.

Keywords : Committee neural network, Lateral flow, Probabilistic neural network, Soft ground

1 정회원, 전남대학교 건설·환경공학부 조교수 (Member, Assistant Prof., Div. of Civil & Env. Eng., Chonnam National Univ., geoskim@chonnam.ac.kr, 교신저자)

2 전남대학교 건설·환경공학부 석사과정 (Graduate student, Div. of Civil & Env. Eng., Chonnam National Univ.)

3 한국과학기술원 스마트 사회기반시설 연구센터 연구교수 (Research Prof., Smart Infra-Structure Technology Center, KAIST)

* 본 논문에 대한 토의를 원하는 회원은 2008년 1월 31일까지 그 내용을 학회로 보내주시기 바랍니다. 저자의 검토 내용과 함께 논문집에 게재하여 드립니다.

1. 서론

우리나라는 지속적인 경제성장과 지역산업의 발달, 지역균형 발전을 위한 혁신도시건설 및 지역인프라 구축 등에 힘입어 전 국토를 연결하는 많은 도로들이 건설되고 있어 연약지반에 도로를 건설하는 경우도 많아지고 있다. 연약지반은 강도가 약하고 압축성이 커서 도로건설을 위한 성토하중을 재하하면 지반은 압밀에 의한 과도한 침하 및 수평변위가 발생한다. 특히 연약지반 상에 말뚝기초 형식의 교대나 구조물을 시공할 경우 배면지반의 뒷채움, 급속한 지반 굴착 및 성토 시 발생하는 편재하중 등에 의해서 발생된 측방유동으로 인해 상부 구조물의 안정성과 사용성에 많은 문제가 발생되어 왔다.

측방유동은 오래전부터 문제점에 대한 중요성이 인식되어졌고 많은 연구가 지금도 진행되고 있다. 국외에서는 연약지반에 설치된 말뚝의 파손원인과 측방변위에 대한 상관관계 연구, 연약지반에 설치된 말뚝의 변형과 모멘트에 대한 연구, 수치해석법을 이용한 연약지반 상의 성토에 따른 측방변위특성 및 현장계측을 통한 측방변위특성 연구 등이 수행 되어졌고 국내의 경우 연약지반 상에 시공되는 성토제방 및 말뚝의 측방변위 등에 대해 많은 연구가 있다(홍원표 등 2006; 이진형 등 2003; 정하익, 1999). 하지만 측방유동현상은 예전부터 알려진 바와 같이 그 역학적 메커니즘도 정량적으로 파악하기 어렵고, 측방유동의 합리적인 설계법이나 변화양상 방지의 유효한 대책공법이 확립되어 있지 않는 실정이다(한국도로공사, 1996). 또한 측방유동은 지반의 변형과 파괴를 동시에 고려해야 하는 어려움 때문에 기존의 토질역학적 접근방식으로는 상부 구조물의 측방이동 유무를 판정하기에는 다소 무리가 따르고 근래에 전산기의 발달과 수치해석 발달로 유한요소 또는 유한차분 등의 수치해석에 의한 접근이 많이 시도되고 있으나 모델링에 많은 가정을 포함하기 때문에 정확한 지반의 거동을 추정하기는 힘들다(조상래 등, 2003). 한편 신경망이론은 인간 두뇌의 구조와 동작방식을 모사하는 단위 처리기(뉴우런)를 망구조로 연결하여 대량의 복잡한 정보를 효율적으로 병렬 처리할 수 있을 뿐만 아니라 예제를 통하여 학습하면 새로운 문제 해결 시 특정한 규칙의 개발 없이 문제를 해결할 수 있어, 최근 지반공학을 포함하여 토목분야에서 다양한 응용사례가 증가하고 있는 추세이다(김두기 등 2004; 조효남 등, 2002; Lee et al., 2004).

본 연구에서는 국내와 일본에서 보고된 측방유동 자료들을 바탕으로 패턴인식을 위하여 신경망이론에 확률적인 이론을 접목한 확률신경망(PNN, probabilistic neural network)과 전통적으로 사용되어 온 다층인공신경망(MLP, multi-layer perceptron)의 초기연결강도 의존성을 극복하여 예측결과와 신뢰성을 확보할 수 있다고 알려진 군집신경망(CNN, committee neural network)을 이용하여 연약지반의 측방유동을 평가할 수 있는 새로운 모델을 구축하고 기존의 판정식과 비교·분석하였다.

2. 측방유동 판정법

2.1 측방유동

측방유동(lateral flow)은 그림 1과 같이 연약한 점성토 지반에 시공된 건축물, 교대, 교각 등에 편재하중($\gamma_t \cdot H$)이 작용하게 되면 하부지반에서는 성토하중에 의해 지반의 침하가 발생하며 과잉간극수압이 소산되기 전에 급속히 증가된 하중에 의해 지반이 소성화되어 수평방향의 변형이 발생하는 현상을 말하고 이때 발생된 편차토압을 측방유동압이라 한다. 측방유동이 발생하면 구조물의 과도한 변형 때문에 구조물 자체가 기능상 손상을 입는 것은 물론, 인접 구조물과 지하 매설물 등에 피해를 입힐 수 있어 지반의 측방유동 현상은 구조물의 측방이동 현상과 관련지어 다루어지고 있다. 그림 2는 측방유동압의 개략적인 분포형태이며 실제로 측방유동압은 복잡한 형태를 가지나 Tschebotarioff가 제안한 이등변 삼각형 분포[그림 2. ③]를 설계 시 가장 많이 적용하고 있다.




그림 1. 교대의 측방유동




그림 2. 축방유동압 분포형태

2.2 축방유동 판정법

축방유동을 판정하는 방법에는 배면 성토하중과 연약 지반의 지반공학 특성 관계로 축방유동을 판정한 기준, 교대 구조물의 이동량이나 지표 침하량으로부터 축방유동을 판정하는 기준, 사면안전율과 관련된 축방유동 판정기준 등 크게 세 가지로 분류되며, 현재 국내 실무에서 주로 사용되는 축방유동 발생의 판정법은 표 1에 정리된 바와 같이 축방이동지수(F)법, 축방이동 판정수(I_L)법, 수정 축방이동판정수(M_U)법 등이 있다(이진형 등, 2003; 한국도로공사, 1996). 축방이동지수(F)에 의한 판정방법은 배면의 성토하중과 점성토의 비배수전단강도와 관계에 연약층의 두께(D)를 고려하였으며, 축방이동판정수(I_L)에 의한 판정법은 배면의 성토하중과 점성토의 비배수전단강도 관계에 연약층의 두께와 함께 그림 1에 정의된 바와 같이 교대 말뚝기초의 제원(교대의 교축방향 길이: A , 기초의 교축각방향의 폭: B)을 추가로 고려하고 있다. 그리고 수정 축방이동판정수(M_U)는 한국도로공사(1996)에서 국내에서 140여개의 교대거동 자료를 수집·분석하여 축방이동판정수(I_L)법을 국내 현실에 맞게

표 1. 축방유동 판정기준

판정법	판정 기준	비고
축방이동지수(F)법 (일본도로공단)	$F = \frac{c_u}{\gamma \cdot H \cdot D} < 0.04$: 교대의 축방이동 가능성 있음	안정수 [$N_b = c_u / (\gamma \cdot H)$]에 연약층의 두께의 역수를 곱한 형상으로 m^{-1} 의 차원을 갖으며, 연약층 두께(D)만을 고려
축방이동판정수(I_L)법 (일본건설성 토목연구소)	$I_L = \mu_1 \cdot \mu_2 \cdot \mu_3 \times \frac{\gamma \cdot H}{c_u} \geq 1.5$: 교대의 축방이동 가능성 있음	μ_1 은 연약층 두께에 대한 보정계수(D/L), μ_2 는 말뚝자체의 저항폭에 대한 보정계수($\Sigma b/B$), μ_3 는 교대 길이에 대한 보정계수($D/A \leq 3.0$)
수정 축방이동판정수(M_U)법 (한국도로공사)	$M_U = \alpha \cdot \frac{\gamma \cdot H}{c_u} \geq 1.5$: 축방이동 가능성 있음	c_u 는 연약지반의 평균 비배수 전단강도(t/m^2), $\gamma \cdot H$ 는 성토 하중(t/m^2), α 는 축방유동압을 받는 기초하부 면적에 대한 교대 면적비 [$\alpha = (\Sigma b \cdot D) / (B \cdot A)$]

개선하여 제안한 방법이다(정상섭, 2000). 본 연구에서도 위의 세 가지 방법을 이용하여 축방유동을 판정하고 구축된 신경망 모델들과 비교하였다.

3. 신경망이론

3.1 확률신경망(Probabilistic Neural Network, PNN)

확률신경망은 어떤 개체가 어느 클래스에 속하는지를 판별하는 분류자로 두 개 이상의 훈련패턴(pattern)들에서 학습된 알고리즘으로 모형화되며, 입력 개체간의 거리행렬에 근거하여 개체가 속한 클래스(class)를 결정한다(Specht, 1990). 최근 토목분야에서도 확률신경망을 적용한 사례가 있으며 이중 액상화 발생예측(Goh, 2002), 콘크리트 압축강도 추정(김두기 등, 2004), 교량구조물의 손상평가(조효남 등, 2002) 등이 대표적인 사례들이나 지반공학 분야에서는 아직 그 적용사례가 많지 않다. 확률신경망의 장점으로는 신경망을 구성할 때 훈련패턴을 클래스 별로 은닉층에 분포시키므로 다층신경망과 달리 신경망을 학습시키기 위한 반복과정이 필요하지 않아 학습시간이 다층신경망이론에 비해 훨씬 짧고 은닉층의 수와 뉴우런 수 등의 신경망구조에 대한 불확실성 없다. 또한 훈련패턴들로부터 클래스에 속하는 누적 확률분포(PDF)를 먼저 결정하게 되므로 ‘어느 클래스에 속하는가?’ 뿐 아니라 훈련패턴들이 클래스에 속할 확률을 얻을 수 있다.

확률신경망의 구조는 그림 3과 같으며 입력층(input layer)은 모든 훈련유형에 동일한 입력유형을 입력하는 일종의 분배층이며 학습층(pattern layer)은 각 훈련패턴에 대해 가중치 벡터와 입력유형 X 의 내적을 구한 후 비선형 활성화 함수(activation function)에 앞서 구한 내적을 입력하여 비선형 연산을 수행한다. 또한, 합산층(summation layer)은 학습층에서 구한 비선형 출력결과를

합산하고 출력층은 2개의 입력 신경을 갖고 하나의 가중치를 갖고 있으며 0과 1로 구성된 2진수를 출력한다.

확률신경망의 유형 분류법은 다중범주분류문제에 적용할 수 있는 Bayesian 확률방법이며 P 차원 벡터인 $X^T = [X_1 X_2 X_3 \dots X_i \dots X_P]$ 로 나타낸 측도(거리)에 기초하여 $\theta = \theta_A$ 인지 $\theta = \theta_B$ 인지를 결정하는 Bayesian 확률방법은 식 (1)과 같이 표현된다(Specht, 1990).

$$\begin{aligned} d(X) = \theta_A & \text{ if } h_A l_A f_A(X) > h_B l_B f_B(X) \\ d(X) = \theta_B & \text{ if } h_A l_A f_A(X) < h_B l_B f_B(X) \end{aligned} \quad (1)$$

여기서 $f_A(X)$ 와 $f_B(X)$ 는 클래스 A 와 B 의 확률밀도함수(PDF: probabilistic density function)이며, l_A 와 l_B 는 잘못된 결정과 관련된 손실계수로 오류가 없는 정확한 결정이면 손실계수는 0이 된다. h_A 는 $\theta = \theta_A$ 가 될 사전 확률(prior probability)이며 $h_B = (1 - h_A)$ 는 $\theta = \theta_B$ 가 될 사전확률이다. 또한, Bayesian 확률방법을 사용할 경우




그림 3. 확률신경망(PNN)의 구조

에 $d(X) = \theta_A$ 인 영역과 $d(X) = \theta_B$ 인 영역 사이의 경계는 식 (2)와 같다.

$$f_A(X) = K f_B(X) \quad (2)$$

여기서 $K = h_B l_B / h_A l_A$ 이다. 확률신경망에서는 확률밀도함수 추정이 매우 중요하며 훈련패턴에 근거하여 식 (3)으로 표현되는 parzen windows 방법(Parzen, 1962; Cacoullos, 1966)을 이용하여 추정할 수 있다. 결국 $f_A(X)$ 는 클래스 A 에 포함된 다수의 훈련패턴을 중심으로 한 다변수의 작은 Gaussian 분포들의 단순 합으로 표현되는 것이다. 그러나 이러한 합(Sum)은 단순히 Gaussian 형태만으로 제한되지 않으며 임의의 부드러운 밀도함수를 근사화 할 수 있다.

$$f_A(X) = \frac{1}{(2\pi)^{P/2} \sigma^P} \frac{1}{m} \sum_{i=1}^m \exp\left[-\frac{(X - X_{Ai})^T (X - X_{Ai})}{2\sigma^2}\right] \quad (3)$$

여기서 X 는 분류되어야 할 시험벡터, m 은 클래스 θ_A 에 속한 훈련패턴의 수, X_{Ai} 는 클래스 θ_A 에서의 i 번째 훈련벡터, σ 는 너비 파라메타(smoothing parameter or spread parameter)이다. 다차원 변수를 갖는 동일한 훈련패턴에 대해 세 개의 서로 다른 σ 대한 식 (3)의 변화가 그림 4에 나타나 있다. 너비 파라메타(σ)값이 그림 4(a)나 4(c)와 같이 너무 작거나 과도하게 크면 클래스내의 훈련패턴들의 전체적인 확률분포를 표현하지 못하므로 너비 파라메타(σ)는 주어진 훈련자료들의 분류를 최대로 성공시키도록 선정되어야 하며 본 논문에서도 σ 을 다양하게 변화시키며 구축된 훈련패턴그룹에 대해 최적화하였다.

3.2 군집신경망(Committee Neural Network, CNN)

그림 5는 군집신경망의 개념을 설명한 것으로 군집신




그림 4. 확률밀도함수(PDF) 근사화에 대한 너비 파라메타(σ)의 영향

경망이란 서로 다른 초기 연결강도에 대하여 독립적으로 학습이 수행되어 최적화된 N개의 다층 신경망(Network 1, Network 2 ... Network N)들의 군집(network)으로 이루어진 신경망 집단이다. 군집신경망 네트워크를 구성하는 각 다층신경망들은 같은 구조와 전달함수로 구성될 수도 있으나 경우에 따라서는 서로 다른 구조와 전달함수를 갖는 다양한 다층신경망들의 네트워크로 구성될 수도 있고, 같은 구조와 전달함수를 갖더라도 독립적인 학습자료에 대해 학습될 수도 있으며 동일한 학습자료에 대해 학습될 수도 있다. 본 연구에서는 동일한 측방유동 학습자료에 대하여 최적 다층신경망 구조와 전달함수를 선정하고 다양한 초기 연결강도 값에 대해 20개의 다층신경망 모델을 최적화 한 뒤 그림 5와 같은 네트워크 형태의 군집신경망을 구축하였다.

군집신경망(CNN; committee neural network)을 이용한 구조전전도 평가에 대한 최근 연구결과(Lee et al., 2004)에 의하면 군집신경망을 이용함으로써 개별 다층신경망(MLP)의 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 발생할 수 있는 연결강도의 국부 해(local minima) 문제를 해결

할 수 있어 개개의 신경망 예측에 비하여 높은 정확도를 확보할 수 있는 것으로 보고되었다.

군집신경망 함수(committee mapping function)는 다음 식 (4)와 같이 표현된다.

$$f_{COM}(X) = \sum_{i=1}^N \alpha_i f_i \quad (4)$$

여기서, $X = (x_1, x_2, \dots, x_p)$, N 은 군집내의 신경망 수, α_i 는 i 번째 신경망의 가중치이며 $\sum \alpha_i = 1$ 이다. 따라서 군집신경망의 출력은 다음 식 (5)와 같이 각 신경망의 결과들의 가중평균으로 표현되며 본 연구에서는 각 다층신경망에서 출력된 결과값(발생:1, 미발생:0)들의 평균으로 측방유동 발생여부를 평가한다.

$$y_{COM} = \sum_{i=1}^N \alpha_i y_i \quad (5)$$

4. 신경망을 이용한 측방유동 판정 모델

4.1 데이터베이스(Database)

신경망모델의 구축을 위해 표 2와 같이 국내에서 조사된 측방이동 발생·미발생 교대 45개 자료와 일본 측방이동 발생·미발생 교대 66개 자료를 데이터베이스화하

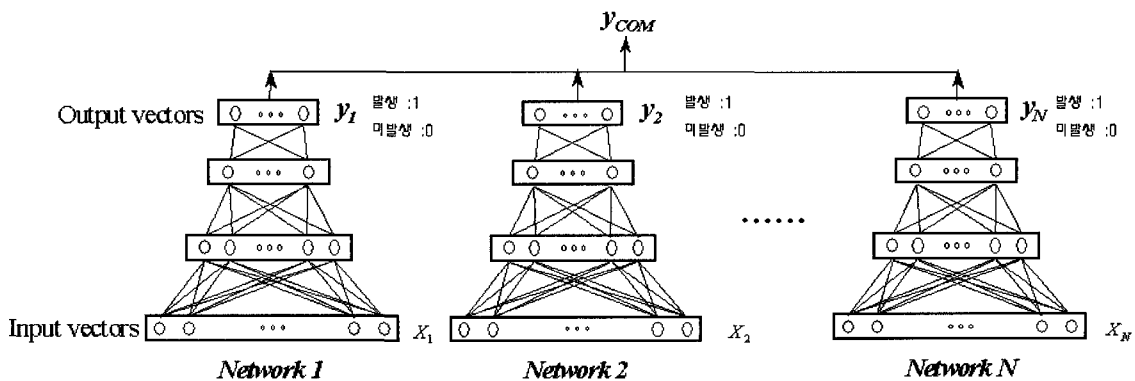


그림 5. 군집신경망의 모식도

표 2. 신경망모델을 위한 데이터베이스 구성과 입력변수

Case	지역	학습자료	검증자료	합계	입력변수	
A	a1	국내	31	14	45	γ, D, c_w, H
	a2	일본	46	20	66	
	a3	국내 + 일본	77	34	111	
B	b1	국내	31	14	45	A, B, γ, D, c_w, H
	b2	일본	46	20	66	
	b3	국내 + 일본	77	34	111	

고 측방이동발생 여부에 따라 클래스를 구분(0:미발생, 1:발생)하였다. 이 데이터베이스에는 측방유동에 영향을 미치는 인자 중 교대의 형식과 관련된 변수들(A, B)과 연약지반 및 성토지반의 특성(c_u, D, γ, H)들이 조사되었으며 각 입력변수들의 통계적 특성이 표 3에 정리되어 있다. 확률신경망과 군집신경망 이론을 이용한 측방유동 판정모델의 입력변수들은 자료의 변수들에 대한 민감도 분석결과 입력 자료들을 선정한 일본도로공단의 측방이동지수(F)법에서 사용하는 입력변수[교대배면 성토재료의 단위중량(γ), 연약층의 두께(D), 교대배면의 성토고(H), 연약층의 전단강도(c_u)]들을 동일하게 이용한 Case A와 교대구조물의 특성까지 이용하는 측방이동 판정수(L_d)법, 수정 측방이동 판정수(M_{ll})법과 동일한 입력변수 [교대의 교축방향의 길이(A), 기초의 교축직각방향의 폭(B), 단위중량(γ), 연약층의 두께(D), 교대배면의 성토고(H), 연약층의 전단강도(c_u)]들을 사용한 Case B로 구분하여 모델을 구축하였다. 한편 구축된 데이터베이스를 국내데이터(Case a1, b1), 일본데이터(Case a2, b2), 국내+일본데이터(Case a3, b3)등 국내와 일본으로 구분하거나 통합한 경우 등으로 다양하게 테

이터베이스를 구성하여 총 12개(PNN - 6개, CNN - 6개)의 측방유동 신경망평가 모델을 구축하였다.


4.2 기본정보만을 이용한 신경망 측방유동 판정모델 (Case A) 구축

Case A는 교대배면 성토재료의 단위중량(γ), 연약층의 두께(D), 교대배면의 성토고(H), 연약층의 전단강도(c_u) 등 기본적인 자료들만을 입력변수로 활용하여 구축된 모델 Case로 일본도로공단의 측방이동지수(F)법과 동일한 입력변수로 이루어진 모델들이다.


확률신경망을 이용한 측방유동 판정 시 주어진 자료들의 분류를 최대 성공시키도록 그림 6과 같이 너비 파라미터(σ)를 다양하게 변화시키며 선정된 최적의 σ 값들이 표 4에 정리되어 있다. Case a1에서 학습 성공률=90.3%, 검증 성공률=71.4%의 판정성공률을 보였고 국내자료와 일본자료 모두 사용한 Case a3에 대해서는 국내 자료인 Case a1과 유사하게 학습 성공률=96.1%와 검증 성공률=73.5%의 예측 성공률을 나타냈다. 한편, 일본자료만을 사용한 Case a2에서는 학습 성공률=100%, 검증 성공률=90%로 상대적으로 높은 측방유동 판정 정

표 3. 입력변수들의 통계적 특성 범위

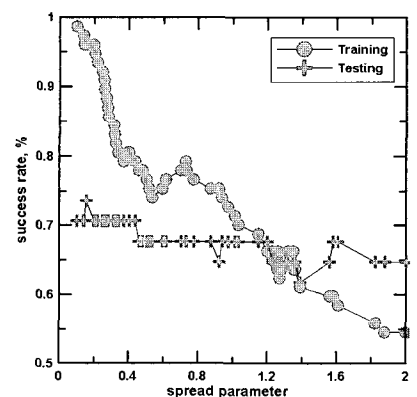
입력변수	국내자료				일본자료				국내+일본 자료			
	학습자료		검증자료		학습자료		검증자료		학습자료		검증자료	
	Min	Max	Min	Max	Min	Max	Min	Max	Min	Max	Min	Max
A (m)	2.50	12.70	3.80	10.00	2.50	16.50	4.50	14.8	2.50	16.50	3.80	14.80
B (m)	8.91	46.39	12.70	44.29	1.00	42.60	11.50	42.6	1.00	46.39	11.50	44.29
c_u (t/m^2)	0.90	11.30	1.50	4.70	1.00	10.60	1.00	6.70	0.90	11.30	1.00	6.70
D (m)	1.90	40.10	8.50	23.00	1.30	37.60	6.00	28.00	1.30	40.10	6.00	28.00
γ (t/m^3)	1.78	2.14	1.80	1.90	0.83	1.92	1.38	1.84	0.83	2.14	1.39	1.90
H (m)	2.07	14.60	5.45	9.35	2.00	21.10	5.30	11.00	2.00	21.10	5.30	11.00



(a) Case a1



(b) Case a2




(c) Case a3

그림 6. 확률신경망 Case A: 너비 파라미터 변화에 따른 판정성공률 변화


확도를 보였다. 이는 구축된 자료의 분산이 작고 유사한 입력자료에 대해 일관성있게 동일한 출력을 주는 등 일본에서 수집된 자료의 신뢰성이 높기 때문인 것으로 판단된다.

한편 그림 7은 군집신경망 네트워크를 구성하는 20개의 다층신경망의 독립적인 예측 성공률과 군집신경망 네트워크 내의 다층신경망 개수를 늘려가면서 예측한 경우가 비교되어 있다. Case a1[그림 7(b)]에 명확히 나타난 바와 같이 20개의 다층신경망들은 각각의 성공률이 초기 연결강도에 따라 매우 좋은 결과(100%)를 줄 수도 있고 좋지 않을 결과(50%)를 주는 경우도 있으나 이들이 네트워크 형태로 구성되어 판정할 경우 네트워크 내의 신경망


의 수가 증가함에 따라 성공률이 수렴(80%)이상 하는 경향을 보여 Lee et al.(2004)의 연구결과와 유사하게 각각의 다층신경망이 가질 수 있는 예측 오류를 최소화하고 상대적으로 높은 수준의 예측성공률을 보장하는 것을 알 수 있다. 군집신경망을 이용한 측방유동 판정결과 Case a1에서는 Logsig-Tansig 함수를 사용하고 은닉층에서 뉴런수 3일 때, Case a2와 Case a3은 Logsig-Tansig 함수를 사용하고 뉴런수 10일 때 최상의 판정성공률을 보였으며, 확률신경망과 비슷한 정도의 성공률을 보였다. 한편 군집신경망에서도 일본자료인 Case a2는 학습 및 검증자료에 대해 각각 100%, 88.3%의 높은 판정성공률을 나타내 확률신경망과 같은 경향을 나타냈다.



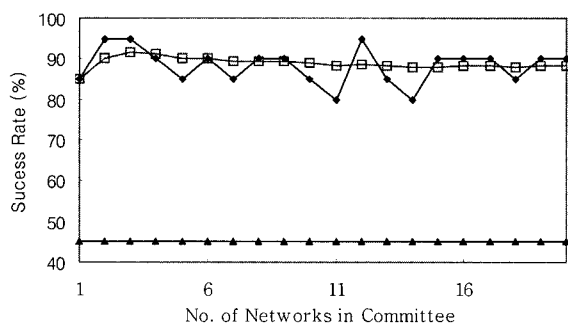
(a) Case a1 (Training)




(b) Case a1 (Testing)




(c) Case a2 (Training)



(d) Case a2 (Testing)



(e) Case a3 (Training)



(f) Case a3 (Testing)

▲ : 측방이동지수(F) ◆ : 독립학습이 수행된 신경망 □ : 군집신경망

그림 7. Case A: 신경망 수에 따른 군집신경망 판정성공률 변화

표 4. Case A 확률신경망 및 군집신경망 판정성공률 비교

Case A	확률신경망			군집신경망		
	학습	검증	σ	학습	검증	전달 함수
Case a1	90.3%	71.4%	0.207	80.8%	77.5%	Logsig(3)-Tansig
Case a2	100%	90.0%	0.171	100%	88.3%	Logsig(10)-Tansig
Case a3	96.1%	73.5%	0.155	99.3%	87.5%	Logsig(10)-Tansig

4.3 기본정보와 교대제원을 함께 이용한 신경망 측방유동 판정모델(Case B) 구축

Case B는 Case A의 입력자료들에 교대의 교측방향의 길이(A)와 기초 교측직각방향의 폭(B)을 추가로 고려하여 신경망모델을 구축한 경우로, 측방이동판정수(I_L) 법 및 수정측방이동 판정수법(M_{LL})과 동일한 입력변수를 이용한 신경망 모델들이다.

Case B에서 확률신경망 모델의 최적 너비파라메타(σ) 선정이 그림 8에 나타나 있으며, 군집신경망 내의 개별 다층신경망의 예측성공률과 군집신경망의 예측성공률은 그림 9와 같다. 각 모델의 데이터베이스에 대한 성공률이 표 5에 정리되어 있으며 Case B의 모든 경우(b1, b2, b3)가 Case A의 (a1, a2, a3)경우에 비해 군집신경망과 확률신경망모델 모두에서 예측정확도가 향상된 것으로 나타나 교대 제원을 고려함으로써 신경망모델의 예측정확도를 향상 시킬 수 있는 것으로 판단된다.

4.4 기존 측방유동 판정식과 제안된 신경망모델들과의 비교 및 분석

4.4.1 확률신경망 모델과 기존 측방유동 판정식 비교 및 분석

본 절에서는 확률신경망 모델과 동일한 입력변수를 갖는 측방유동 판정식에 의한 판정결과를 구축된 신경망 모델들의 판정결과와 비교하였다.

그림 10에 기존의 측방이동지수 (F)법에 의한 측방유동 판정결과가 정리되어 있다. Case a1의 경우 측방이동지수법이 학습(41.9%)과 검증(50.0%)에서 50% 이하의 낮은 판정성공률을 보이는 반면 확률신경망 모델은 학습자료에 대해 90.3%, 검증자료에 대해 71.4%로 기존의 판정식에 비해 상당히 높은 판정성공률을 보였다. 또한 그림 10(b, c)에서 Case a2, a3에 대해 측방이동지수(F)에 의한 예측성공률 결과가 평균 58.4%, 53.5%로 50%를 약간 넘는 정도에 그친 반면 확률신경망에 의한 측방






그림 8. 확률신경망 Case B: 너비 파라메타 변화에 따른 판정성공률 변화

표 5. Case B 확률신경망 및 군집신경망 판정성공률 비교


Case B	확률신경망			군집신경망		
	학습	검증	σ	학습	검증	전달 함수
Case b1	90.3%	85.7%	0.53	96.5%	86.8%	Tansig(3)-Linear
Case b2	100%	95.0%	0.388	100%	89.0%	Logsig(5)-Tansig
Case b3	98.7%	79.4%	0.168	99.6%	86.8%	Tansig(7)-Tansig




(a) Case b1 (Training)




(b) Case b1 (Testing)




(c) Case b2 (Training)



(d) Case b2 (Testing)



(e) Case b3 (Training)



(f) Case b3 (Testing)

△ : 교대축방이동 판정지수(I_L) - 일본건설성 토목연구소 ◆ : 독립학습이 수행된 신경망
 ● : 수정축방이동 판정지수(M_L) - 한국도로공사 □ : 군집신경망

그림 9. 군집신경망의 Case B: 신경망 수에 따른 군집신경망의 판정성공률 변화




그림 10. Case A에 대한 축방이동지수(F)법과 확률신경망 판정성공률 비교

유동 판정성공률은 평균 95%, 84.8%로 기존의 판정식보다 높은 판정성공률을 나타내 본 연구에서 구축된 확률신경망 이론에 의한 측방유동 평가모델이 기존의 평가모델에 비해 매우 효과적인 것으로 나타났다.

그림 11에는 교대 측방이동판정수(I_L)법, 수정 측방이동판정수(M_L)법에 의한 측방유동 판정결과가 Case B에 대한 확률신경망의 예측결과와 비교되어 있으며 Case b1에서 평균적으로 54.1%, 47.6%의 판정성공률을 보이는 반면 확률신경망 측방유동 판정모델은 학습, 검증자료에서 각각 90.3%, 85.7%의 성공률로 평균 88%의 성공률을 보여 Case A와 동일하게 기존의 판정식에 비해 월등히 높은 판정성공률을 보였다. 또한 그림 11(b)의 Case b2 경우에는 기존의 판정식, 확률신경망 모델 모두 대체적으로 높은 판정성공률을 보이나 확률신경망 모델이 학습 및 검증자료에 대하여 평균 97.5%로 기존의 판정식 보다 정확한 예측성공률 보이고 있다. 그림 11(c)의 Case b3에서도 확률신경망에 의한 판정성공률은 89.5%로 기존의 판정식(I_L , M_L)들이 평균 73.6%, 62.4%의 성공률을 보이는 것과 비교해 매우 높은 판정성공률을 보였다.

이상에서 Case A, B에 대해 구축된 확률신경망 이론에 의한 측방유동 판정모델이 기존의 측방유동 판정방법과 비교해서 훨씬 향상된 판정성공률을 보여 매우 효과적으로 적용될 수 있음을 알 수 있다. 또한 교대 구조물의 정보를 함께 이용한 Case B의 확률신경망모델이 기본정보만을 사용한 Case A의 확률신경망모델에 비해 높은 성공률을 보여 입력되는 정보(교대길이와 폭)가

많을수록 학습 시 보다 정확한 패턴학습이 가능한 것으로 판단된다.

4.4.2 군집신경망 모델과 기존 측방유동 판정식 비교 및 분석

본 절에서는 군집신경망이론을 이용하여 구축된 측방유동 판정모델과 기존 측방유동 판정식의 판정 정확도를 비교하였다.

그림 12(a)는 Case A에 대한 비교 결과로 기존의 측방이동지수(F)법을 이용한 측방유동 판정결과가 학습(41.9%)와 검증(50.0%)에서 50% 이하의 낮은 판정성공률을 보이는 반면 서로 다른 초기 연결강도에 대하여 독립적으로 학습이 수행된 20개의 다층신경망의 결과들의 평균으로 얻어진 군집신경망의 판정성공률은 학습에 대해 80.8%, 검증에 대해 70.5%로 기존의 판정식에 비해 높은 판정성공률을 보였다. 또한 그림 12(b, c)에서 Case a2 와 Case a3의 군집신경망 모델에 의한 측방유동 판정성공률도 기존의 판정식보다 현저히 높은 판정성공률을 보여 군집신경망모델에 의한 측방유동 평가모델 역시 확률신경망과 같이 매우 효과적임을 알 수 있다.

그림 13은 Case B에 대한 비교결과로 그림 13(a)에서 보는 바와 같이 교대 측방이동판정수(I_L)법, 수정측방이동판정수(M_L)법에 의한 측방유동 판정성공률은 학습 및 검증에서 평균적으로 약 50%의 판정성공률을 보이는 반면 군집신경망 모델은 평균적으로 학습에 대해 96.5%, 검증에 대해 86.8%로 기존의 판정식에 비해 높




그림 11. Case B에 대한 측방이동판정수(I_L)법, 수정 측방이동판정수(M_L)법과 확률신경망의 판정성공률 비교




그림 12. Case A에 대한 측방이동지수(F)법과 군집신경망 판정성공률 비교




그림 13. Case B에 대한 측방이동판정수(I_L)법, 수정 측방이동판정수(M_L)법과 군집신경망의 판정성공률 비교

은 판정성공률을 보였다. 또한 그림 13(b, c)에서 Case b2와 Case b3의 군집신경망 모델에 의한 측방유동 판정 성공률 비교에서도 기존의 판정식에 비해 높은 판정 성공률이 나타나 군집신경망모델에 의한 측방유동 평가 모델이 Case A와 동일하게 효과적임을 알 수 있다.

한편 구축된 Case A와 B의 군집신경망 모델 예측성 공률을 비교하면 기본정보만을 이용한 Case A의 모델 에 비해 지반 및 교대구조물의 정보를 함께 이용한 Case B의 군집신경망이 같은 전달함수와 은닉층내의 적은 뉴런수에서도 Case A에 비해 비교적 높은 측방유동 판 정성공률을 보이는 것으로 나타나 군집신경망 이론을 이용한 측방유동 판정모델에서도 교대 제원의 입력정 보가 판정에 도움이 되는 것으로 나타났다. 따라서 추후

국내에서 적용될 수 있는 신경망모델의 개량을 위해서 는 가능한 많은 자료들을 확보하고 모델 개선에 사용하 는 것이 바람직할 것으로 판단된다.

5. 결론

본 논문에서는 국내 및 일본에서 발생한 측방유동 사 례를 바탕으로 연약한 점토지반에 설치된 교대구조물 에서 발생하는 측방유동 발생여부를 판정하기 위하여 확률신경망 이론 및 군집신경망 이론을 적용한 새로운 측방유동평가 모델을 구축하고 기존 평가식들과 비교 하였다. 연구결과 다음과 같은 결론을 얻었다.

- (1) 입력변수의 수에 따라 구분된 Case A와 Case B의 자료들에 대해 확률신경망 모델과 군집신경망 모델이 모두 기존의 측방유동 판정법에 비해 높은 예측 성공률 보여 신경망 이론을 이용한 모델이 매우 효과적으로 적용될 수 있음을 보였다. 그러나 확률신경망과 군집신경망 모두 큰 차이 없이 좋은 결과를 보여, 모델 간의 적용상 우열을 판단하기는 어렵다.
- (2) 측방유동 판정을 위한 기본정보(c_u, γ, H, D)에 교대의 교축방향의 길이(A)와 기초의 교축직각방향의 폭(B)을 추가적으로 고려한 Case B의 모델들이 보다 높은 성공률을 보여 측방유동 예측 시 교대구조에 대한 입력정보가 도움이 되는 것으로 나타났다.
- (3) 군집신경망의 경우 개별 다층신경망들은 예측성공률이 높고 낮은 경우가 매우 임의적으로 분포하였으나 20개 다층신경망의 네트워크로 이루어진 군집신경망은 네트워크 내의 신경망 수가 증가할수록 예측성공률이 수렴하여 평균적으로 높은 예측성공률을 보장하는 것으로 나타났다.

감사의 글

이 논문은 2004년도 학국학술진흥재단의 지원(과제번호 KRF-2004-042-D00196)에 의하여 연구 되었으며 저자들은 이에 감사드립니다.

참고 문헌

1. 김두기, 이종재, 장성규 (2004), “콘크리트 압축강도 추정을 위한 확률 신경망”, *한국구조물진단학회논문집*, 제8권, 제2호, pp.159-167.
2. 서정주, 서동희, 정상섭, 김유석 (2003), “측방유동을 받는 교대 말뚝기초의 거동분석(I) -원심모형실험 연구-”, *한국지반공학회 논문집*, 제19권, 제1호, pp.5-19.
3. 이진형, 서정주, 정상섭, 장범수 (2003), “측방유동을 받는 교대 말뚝기초의 거동분석(II)-측방유동 판정기준”, *한국지반공학회 논문집*, 19권, 1호, pp.21-29.
4. 이현엽, 문경일 (1999), MATLAB을 이용한 퍼지-뉴로, 아진, pp.245-309.
5. 정상섭 (2000), “연약점성토에 설치된 말뚝기초의 측방이동 판단 기준과 대책”, *한국지반공학회소식지 Q&A*, pp.50-52.
6. 정하익 (1999), “해안공간 개발을 위한 연약지반 처리기술-연약 지반의 측방유동 특성”, *한국건설기술연구원*, pp.9-45.
7. 조상래, 최기봉, 임경수, 지병환 (2003), “연약지반상의 측방유동 특성”, *한국지반환경 공학회 학술발표대회 논문집*, pp.159-164.
8. 조효남, 강경구, 이성철, 허춘근 (2002), “확률신경망에 기초한 교량 구조물의 손상평가”, *한국구조물진단학회*, 제6권, 제4호, pp.169-179.
9. 한국도로공사 (1996), 교대변위 억제대책에 관한 연구(II), *연구 보고서*, 도로연 96-46-12.
10. 홍원표, 송영석 (2006), “측방유동 연약지반상 파일슬래브로 보강된 교대의 안정”, *한국지반공학회지*, 제22권, 8호, pp.13-24.
11. Cacoullos, T. (1966), “Estimation of a multivariate density”, *Annals of the Institute of Statistical Mathematics (Tokyo)*, 18(2), 179-189.
12. Goh, T. C. (2002), “Probabilistic neural network for evaluationg seismic liquefaction potential”, *Canadian Geotechnical Journal*, Vol.39, pp.219-231.
13. 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.
14. Parzen, E. (1962), “On estimation of a probability density function and mode”, *Annals of Mathematical Statistics*, 33, 1065-1076.
15. Specht D. F. (1990), “Probabilistic Neural Networks”, *Neural Networks*, 3, pp.109-118.

(접수일자 2007. 5. 11, 심사완료일 2007. 7. 26)