

항타말뚝의 지지력 예측을 위한 최적의 인공신경망모델에 관한 연구

A Study on Optimized Artificial Neural Network Model for the Prediction of Bearing Capacity of Driven Piles

박 현 일¹ Park, Hyun-Il

석 정 우² Seok, Jeong-Woo

황 대 진³ Hwang, DaeJin

조 천 환⁴ Cho, Chun-Whan

Abstract

Although numerous investigations have been performed over the years to predict the behavior and bearing capacity of piles, the mechanisms are not yet entirely understood. The prediction of bearing capacity is a difficult task, because large numbers of factors affect the capacity and also have complex relationship one another. Therefore, it is extremely difficult to search the essential factors among many factors, which are related with ground condition, pile type, driving condition and others, and then appropriately consider complicated relationship among the searched factors. The present paper describes the application of Artificial Neural Network (ANN) in predicting the capacity including its components at the tip and along the shaft from dynamic load test of the driven piles. Firstly, the effect of each factor on the value of bearing capacity is investigated on the basis of sensitivity analysis using ANN modeling. Secondly, the authors use the design methodology composed of ANN and genetic algorithm (GA) to find optimal neural network model to predict the bearing capacity. The authors allow this methodology to find the appropriate combination of input parameters, the number of hidden units and the transfer structure among the input, the hidden and the out layers. The results of this study indicate that the neural network model serves as a reliable and simple predictive tool for the bearing capacity of driven piles.

요 지

말뚝의 지지력과 거동을 예측하기 위하여 다양한 연구들이 수행되었음에도 불구하고, 메커니즘에 대한 전반적인 이해가 아직까지 미흡한 실정이다. 이는 많은 인자들이 서로 복잡한 연관성을 맺으며 말뚝의 거동에 영향을 미치기 때문이다. 따라서 지반조건과 말뚝조건 및 항타조건 등 과 관련된 많은 인자들 가운데 지지력에 중요한 영향을 미치는 인자들을 도출하기 어려우며, 또한 인자들 간의 복잡한 연관성을 지지력 공식에 적합하게 고려하기란 매우 어렵다. 본 연구에서는 항타말뚝들에 대한 동재하시험으로부터 선단 및 주면 지지력을 포함한 지지력을 예측하기 위하여 인공신경망이 적용되었다. 첫째로, 신경망 모델링에 근거한 민감도 분석을 통하여 지지력에 대한 각 영향인자들의 영향이 검토되었다. 둘째로, 지지력 예측을 위한 최적의 인공신경망 모델을 도출하기 위하여 인공신경망과 유전자 알고리즘으로 구성된 설계기법이 적용되었다. 이를 통해 토사지반에 관입된 항타말뚝의 지지력을 산정할 수 있는 최적의 인공신경망 모델을 제안하고자 하였다. 사용된 설계기법을 통하여 적합한 입력층 조합, 은닉층 노드수와 각 층 사이의 연결구조를 도출하였다. 도출된 인공신경망 모델을 적용함으로써 항타말뚝의 지지력을 간단하며 신뢰성 있게 예측할 수 있음을 알 수 있다.

Keywords : Artificial neural network, Bearing capacity, Driven pile, Genetic algorithm

1 정희원, 삼성물산㈜ 건설부문 기술연구소, 선임연구원 (Member, Senior Researcher, R & D Team, Samsung Corporation, gomdori7@empal.com, 교신저자)

2 정희원, 삼성물산㈜ 건설부문 기술연구소, 선임연구원 (Member, Senior Researcher, R & D Team, Samsung Corporation)

3 정희원, 삼성물산㈜ 건설부문 기술연구소, 수석연구원 (Member, Principal Researcher, R & D Team, Samsung Corporation)

4 정희원, 삼성물산㈜ 건설부문 기술본부, 전문위원 (Member, Expert Engineer, T.A. Team, Samsung Corporation)

* 본 논문에 대한 토의를 원하는 회원은 2006년 12월 31일까지 그 내용을 학회로 보내주시기 바랍니다. 저자의 검토 내용과 함께 논문집에 게재하여 드립니다.

1. 서론

말뚝 지지력 및 거동에 대하여 다양한 실험 및 이론적인 연구들이 수행되었음에도 불구하고 말뚝거동에 대한 전반적인 이해는 현재까지 미흡한 실정이다. 이는 지반조건(흙의 종류와 지반의 응력상태 및 상대밀도 등)과 말뚝조건(말뚝의 직경과 벽면마찰각과 관입깊이 및 말뚝 선단부의 개폐단 여부 등)과 말뚝의 항타조건(항타방법 혹은 항타에너지)과 시간경과효과(set-up 및 relaxation 현상) 등과 같은 많은 인자들이 말뚝 거동에 영향을 미치며, 이러한 영향인자들 간의 복잡한 상호작용을 적절하게 정량화하기가 매우 어렵기 때문이다(Kraft 1991, Bruzy, etc 1991, 백규호 2002, 조천환 2003).

선단 지지력과 주면 마찰력의 합으로써 나타나는 정역학적 극한지지력 공식들은 영향인자들의 선별과 고려 방식에 따라 형태를 크게 달리한다. 현재까지 많은 말뚝 지지력 공식들이 제안되었으나, 앞에서 언급한 말뚝 지지력에 영향을 미치는 많은 인자들을 적절하게 고려한 공식은 제안되지 않은 실정이다. 이는 말뚝 지지력에 미치는 중요인자들을 도출함과 동시에 그 영향을 정량적으로 평가하는 것이 매우 힘들기 때문이다. 또한, 공식의 지나친 복잡화를 피하는 과정에서 일부 영향인자가 제외되거나 영향인자간의 상관성이 결여되기도 한다. 시공과정에서 재하시험을 통해 말뚝의 지지력을 확인할 수는 있지만, 설계 시점에서 적절한 물량 산출 및 공기 예측을 위해서는 말뚝 지지력에 대한 신뢰성 있는 예측이 반드시 필요하다. 따라서 말뚝 지지력에 대한 여러 영향인자들 사이에 이루어지는 복합적인 상호작용을 고려하여 수식화할 수 있는 새로운 지지력 공식에 대한 개발이 필요하다고 할 수 있다.

인공신경망(Artificial Neural Network, ANN)은 인간 뇌의 처리과정을 모사하기 위해 개발된 정보처리방법으로서 입력 물성치와 출력치와의 복잡한 물리적인 관계가 규명되지 않는 공학문제에 효과적으로 적용될 수 있는 것으로 알려져 있다. 인공신경망은 최근에 지반공학 분야에서도 다양하게 적용되고 있다(김병탁 등 2001, 김영상 2003, 이성진 등 2002, 황명기 등 2003, 박현일 등 2005, Lee and Lee 1996, Rahman, etc 2001).

본 연구에서는 국내의 여러 지반조건에 타설된 항타 말뚝에 대한 동역학적 재하시험결과(조천환, 2003)로부터 도출된 주면 및 선단지지력과 영향인자들과의 관계를 나타낼 수 있는 최적의 인공신경망 모델을 제안하고

자 하였다. 이를 위해 먼저 지반조건과 말뚝조건 및 항타조건을 포함한 다양한 입력물성치들이 지지력에 미치는 영향을 검토하기 위하여 인공신경망에 근거한 민감도 분석을 수행하였다. 최종적으로 최적의 인공신경망 구조를 탐색할 수 있는 설계기법(박현일 등 2005)을 적용하여 신경망 구조의 복잡함을 피하면서, 동시에 예측에 대한 정확성을 확보할 수 있는 인공신경망에 근거한 최적의 지지력 공식을 도출하고자 하였다.

2. 인공 신경망

2.1 인공신경망의 구조

인공신경망은 뉴런(neuron) 혹은 노드(node)로 불리는 단위처리개체(simple processing unit)로 이루어져 있다. 각 노드는 입력신호에 대한 연산을 수행한 후 연결고리(connection)들을 통하여 다음 뉴런에 정보를 전달하는 처리개체이다. 여기서 연결고리는 하나의 노드로부터 다음 노드로의 정보 흐름을 의미한다. 가중치는 연결고리를 통하여 할당되며, 결과적으로 가중치가 고려된 입력신호값이 다음 뉴런에 전달된다. 일반적으로, 인공신경망은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성된다. 여기서, 입력층의 노드들은 해석에서 고려되어야 하는 입력 설계변수를 의미하고, 출력층의 노드는 목표 출력값을 의미한다. 각층의 노드들은 전이함수(transfer function) 혹은 활성화함수(activation function)을 사용하여 가중치 및 바이어스(bias)가 고려된 합의 형태로 표현된다. 가장 일반적으로 사용되는 전이함수로서 선형(linear), 시그모이드(logsig) 및 쌍곡탄젠트(tansig) 함수를 들 수 있다. 특히, 신경망 구조 설계 시에 입력층-은닉층, 은닉층-은닉층, 은닉층-출력층에 전이함수의 조합이 적합하게 적용되어야 한다.

2.2 인공신경망의 학습

인공신경망의 각 층을 연결하는 가중치 즉 연결강도값을 최적화 하는 과정을 학습(learning) 혹은 훈련(training)이라 한다. 학습의 목표는 단층 혹은 다층 네트워크에 대한 최적의 연결강도 조합을 탐색하는 것이다. 퍼셉트론 학습규칙(perceptron learning)과 LMS(least mean square)는 단일층의 퍼셉트론 네트워크를 훈련시키기 위한 학습 방법으로서 선형적인 분리구분 문제(linearly separable

classification problems)만을 풀 수 있는 단점이 있다. 따라서 다층 네트워크에 대한 최적 연결강도 조합을 찾기 위하여 역전파(back-propagation) 알고리즘이 개발되어, 지반공학의 여러 문제들에 대하여 성공적으로 적용되었다(김병탁 등 2001, 김영상 2003, 이성진 등 2002, 황명기 등 2003, 박현일 등 2005, Lee and Lee 1996, Rahman, etc 2001).

2.3 인공신경망 모델을 사용한 지지력 값의 계산 과정

훈련에 적용되는 자료의 선처리 과정으로서 입력자료(pn) 및 목표출력값(tn)이 다음 식(2)와 같이 정규화되었다(Kurup and Dudani, 2002).

$$pn = 2(p - \min p) / (\max p - \min p) - 1,$$

$$tn = 2(t - \min t) / (\max t - \min t) - 1 \quad (2)$$

여기서, p = 입력행렬, t = 목표출력값, pn = 정규화된 입력행렬, tn = 정규화된 목표출력값, $\max p$ = 입력물성치에서 최대값으로 구성된 입력행렬, $\min p$ = 입력물성치에서 최소값으로 구성된 입력행렬, $\max t$ = 목표출력값들 중에서 최대값, $\min t$ = 목표출력값들 중에서 최소값이다. 정규화된 자료들이 가중치 값들을 구하기 위해 인공신경망 모델의 학습과정에 사용된다. 따라서, 최종적으로 구해진 정규화된 출력값은 식 (3)을 통하여 실제적인 지지력값(t)으로 환산될 수 있다.

$$t = 0.5 \cdot (tn + 1) \cdot (\max t - \min t) + \min t \quad (3)$$

정규화된 출력값 tn 은 식 (4)와 같이 내부입력벡터의 전파에 의하여 구할 수 있다. 정규화된 입력물성치와 최종적인 지지력 값의 관계식은 식 (3)과 식 (4-1)로부터 (4-2)와 같이 최종적으로 정리될 수 있다.

$$tn = C \times \log \text{sig}(A \times pn + B) + D \quad (4-1)$$

$$t = 0.5 \cdot (C \times \log \text{sig}(A \times pn + B) + D + 1) \cdot (\max t - \min t) + \min t \quad (4-2)$$

여기서, A = 입력층 뉴런들과 은닉층 뉴런들과의 연결가중치 행렬, B = 은닉층 뉴런들에 대한 bias 벡터, C = 은닉층 뉴런들과 출력층 뉴런과의 가중치 행렬, D = 출력층 뉴런의 bias 값이다. 본 계산과정에서 입력층-은닉층과 은닉층-출력층 간에 적용된 전이함수는 각각 시그모이드(logsig)함수와 선형(linear) 함수이다. 여기서

시그모이드(logsig)함수는 식 (5)과 같이 나타낼 수 있다. 이러한 전체적인 계산과정에 대한 예제가 부록에 수록되어 있다.

$$\log \text{sig}(X) = 1 / [1 + \exp(-2X)] \quad (5)$$

3. 지지력 산정을 위한 인공신경망 구조의 최적화 설계

박현일 등(2005)은 최적의 인공신경망 구조 설계를 위하여 인공신경망과 유전자 알고리즘이 결합된 신경망구조 설계기법을 제안하였다. 신경망 구조설계시 신경망 구조의 복잡함을 피하며, 적합한 입력변수의 조합과 신경망구조 설계변수들을 도출하기 위하여 유전자 알고리즘에 근거한 신경망 구조 설계기법이 적용되었다. 최적의 인공신경망 구조 탐색은 그림 1과 같은 과정을 따른다.

임의적으로 생성된 개체군에서 각 개체는 그림 2에 나타난 바와 같이 인공신경망 구조에 필요한 설계변수에 대한 정보를 갖고 있다. 그림 2에서는 총 8개의 설계변수 후보가 존재하며, n 번째 노드의 값이 1인 경우에는 입력층의 입력변수로 채택됨을 의미하며, 0인 경우

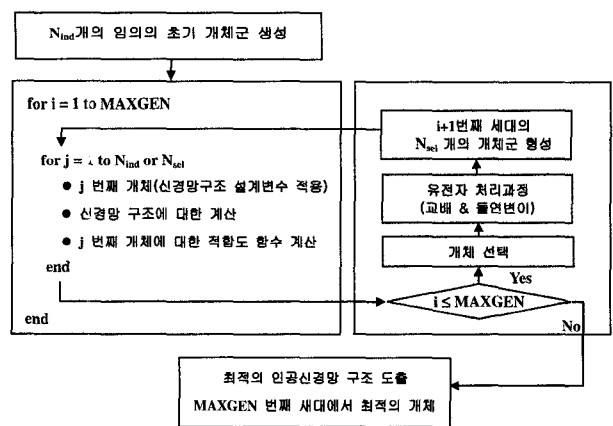


그림 1. 최적의 인공신경망 탐색 과정에 대한 흐름도(박현일 등, 2005)

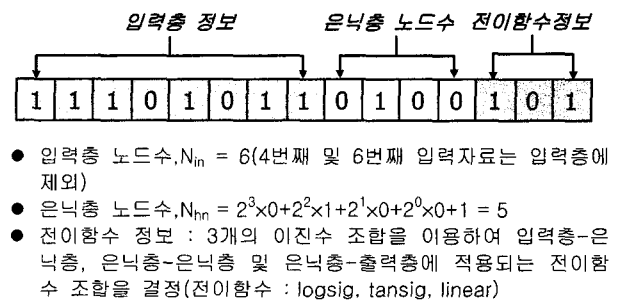


그림 2. 개체에 포함된 인공신경망 설계정보

에는 입력층에서 배제됨을 의미한다. 그림 2에서는 4번째와 6번째의 설계변수가 제외된 총 6개의 설계변수들이 입력층의 입력변수로 채택되었음을 의미한다. 이로부터 각 개체에 대한 인공신경망을 구성할 수 있으며, 각 개체의 인공신경망으로부터 얻어진 목적 함수 값에 근거한 적합도를 계산할 수 있다. 적합도에 근거하여 선별된 각 개체들은 유전자 처리과정을 거치게 되며, 다음 세대에 필요한 개체군으로 생성된다. 이러한 유전적 처리에 대한 반복과정을 거쳐서 최적의 신경망 구조를 갖는 개체를 탐색하게 된다.

최적화 과정에 필요한 목적함수 값은 식 (6)과 같이 정의되었다. i 번째 개체에 대한 목적함수, $ObjV(i)$ 는 출력값과 예측값의 차이에 근거한 오차(error)함수, E_i 와 신경망 구조의 복잡도에 근거한 벌점(penalty)함수, P_i 를 함께 적용하였다. 벌점함수, P_i 는 인공신경망 구조가 복잡해질수록 오차함수 값은 감소할 가능성이 증가하지만, 과적응(overfitting)으로 인하여 일반성이 감소하는 것을 제어하기 위하여 적용되었다.

$$ObjV(i) = E_i + P_i = \left(\sum_{k=1}^{N_{mea}} \frac{|T_k - t_k|}{T_{max}} \right) / N_{mea} + \alpha \cdot \left(\frac{N_n^i / N_{max} + CW^i / CW_{max}}{2} \right) \quad (6)$$

여기서, N_{mea} = 예측자료의 총 개수, T_{max} = 출력값 가운데 최대치, T_k = k 번째 출력값, t_k = k 번째 예측값, N_n^i = i 번째 개체에서 사용되는 총 노드 개수, N_{max} = 대상 문제에서 인공신경망 구조가 가질 수 있는 최대 노드 수, CW^i = i 번째 개체에서 사용되는 연결강도의 총 개수, CW_{max} = 대상 문제에서 인공신경망 구조가 가질 수 있는 최대 연결강도 개수이며, $\alpha = 0.1$ 로 가정되었다.

4. 입력 자료

본 연구에서는 조천환(2003)에 의해 정리된 동재하시험 결과들이 사용되었다. 국내의 6개 지역에서 실시한 77개소 말뚝에 대한 총 165회 수행된 시험결과들이 표 1에 나타나 있다. 자료들을 살펴보면 현장별로 지반조건(선단 및 주면 지반), 말뚝조건(말뚝직경과 선단부 개폐단 여부, 관입깊이), 항타조건(항타에너지 및 시간경과일수) 및 시험조건들이 정리되어 있다. 현장에 따라 다양한 직경의 말뚝이 적용되었으며, 지지력 시험은 ASTM D 4945(Crowther 1988)에 따라 미국 PDI사의 항타분석기(PDI 1995)를 이용한 동재하시험(high strain dynamic load test)에 따라 수행되었다. 항타시에는 항타시공성과 관련된 주요항목(항타에너지, 항타우렁, 저항력 등)은 관입깊이와 항타수로 관리되었다. 또한 말뚝의 set-up효

표 1. 동재하 시험결과(조천환 2003)

현장 위치	말뚝직경 (m)	선단형식	관입깊이 (m)	EMX (kN·m)	경과일수 (day)	토질조건		주면지지력 (kN)	선단지지력 (kN)
						주면	선단		
포항	0.508	Closed or open	9.6~18.3	41.2~60.8	0~28	S	S	451~2502	1423~2031
	0.406	Closed or open	10.5~14	20.6~43.2	0~27			216~1030	1236~1835
광양	0.508	Closed or open	23~24.2	50.0~94.2	0~11	C/SM	SM (WR)	613~1988	2384
		Closed or open	24.2	58.9	0			1232	1867~1986
	0.406	Closed or open	24.1~24.6	54.9~95.2	0~13			636~1754	1704~2442
	0.355	Closed or open	22~23.7	41.2~60.8	0~12			725~1484	1664~1903
	0.323	Closed or open	24~24.4	51.0~78.5	0~20			785~1589	1501~1942
	0.400	Closed or open	23.3~23.6	24.5~56.9	0			42~949	1053~2228
	0.273	Closed or open	24	42.2~62.8	0~13			668~1117	1356~1617
	0.508	Closed or open	20.4~22.8	44.1~102	0~27			343~1689	1880~2741
시흥	0.406	Closed or open	20.5~21.6	30.4~77.5	0~25	SM	S	308~1350	1495~2376
	0.406	Closed or open	26.1~29.1	42.2~74.6	0~5			1031~2841	391~1617
	0.400	Closed or open	26~28.1	42.2~66.7	0~4			332~1717	1324~2075
영종도	0.610	Closed or open	31.3~42.8	59.8~99.1	0~18	C	S	736~5401	725~2256
	0.406	Closed or open	34.7~39.6	54.9~65.7	0~9	SM	SG	385~2865	394~2076
동해	0.350	Closed or open	14.7~25	15.7~33.4	0~35	S	SG	154~1372	157~500
부산	0.450	Closed or open	21.5~29	26.5~61.8	0~12	C	C	172~1398	313~1319

과를 측정하기 위하여 항타시 시험(end of initial driving, EOID)을 실시한 이후 일정시간 경과한 후에 재항타시험(restrike)을 실시하였다. EOID와 재항타시험에서 측정된 응력파에 대하여 CAPWAP(Case Pile Wave Analysis Program, GRL Associate Inc. 1996) 프로그램을 적용하여 지지력 값을 산출하였다.

5. 인공신경망에 근거한 주면, 선단 및 총지지력의 산정

5.1 인공신경망에 의한 지지력 산정

본 연구에서는 표 1에 나타난 지반조건과 말뚝 조건 및 항타조건에 관한 기본 입력자료들이 사용되었다. 여기서 주면 및 선단부 지반조건은 조천환(2003)의 지지력 증가비를 고려하기 위한 말뚝주면의 토질 분류표를 참고하여 표 2와 같이 자료화 하였으며, 말뚝 선단형식에서 개단 및 폐단 여부는 0과 1로 자료화하였다. 총 165세트의 자료 가운데 학습과 검증에 각각 148 세트 및 17 세트

표 2. 주면 및 선단부 지반조건


주면 및 선단부의 유력한 토질 종류	값
Clay	1
Silt - Clay	2
Silt	3
Sand - Clay	4
Sand - Silt	5
Fine Sand	6
Sand	7
Sand - Gravel	8

가 사용되었다. 먼저 영향인자들에 대한 민감도 분석을 수행하기 위하여 사용된 인공신경망 구조는 다음과 같다. 적용된 인공신경망의 구조는 입력 유니트 8개, 은닉 유니트 9개 및 출력 유니트 2개의 노드를 갖는 인공신경망구조(8×9×2)로 구성되어 있다. 각 층을 연결하는 전이함수의 경우, 입력층-은닉층 및 은닉층-출력층에 대하여 시그모이드 함수와 선형 함수가 각각 선택되었다.


사용된 총 8개의 입력변수들은 말뚝직경, 선단형식(개폐단 여부), 관입깊이, 시험단계(EOID 및 재항타 단계), 항타에너지(EMX), 경과일수, 주면부 및 선단부 지반조건이다. 표 1의 자료 가운데 임의로 선정된 148개의 자료가 제안된 인공신경망 모델의 훈련에 적용하였다. 얻어진 weight와 bias를 사용하여 17개의 나머지 입력자료들에 대한 검증과정을 수행하였다. 학습 및 검증과정에서 얻어진 예측결과와 목표값과의 관계가 그림 3에 나타나 있다. 주면 및 선단지지력에 대하여 학습과정에서 상관계수(R^2) 값이 각각 0.864 및 0.919이며 검증과정에서는 각각 0.817 및 0.789로 상관성이 다소 감소하였다. 주면 및 선단 지지력의 합, 즉 전체 지지력 값도 학습 및 검증에서 상관계수(R^2) 값이 각각 0.893 및 0.904로서 높은 상관성을 보였다.

5.2 지지력 산정시 입력변수들에 대한 영향성 검토

그림 4-11에서는 모델의 학습과정에서 각각의 입력변수가 모델의 출력값에 대한 영향 정도를 살펴보기 위하여 각 입력변수에 대한 민감도 분석(sensitivity analysis)을 수행하였다. 즉 민감도 분석시 입력변수들이 변함에 따라 구해진 주면과 선단 및 전체지지력 값의 경향성이



(a) 학습



(b) 검증

그림 3. 인공신경망 모델에 의한 학습 및 검증 결과

검토되었다. 대상입력변수를 제외한 나머지 7개의 입력 변수들은 각 변수들이 최소 및 최대값의 범위 안에서 임의의 값을 갖도록 하였고, 보다 일반적인 경향성을 얻기 위하여 동일한 방법의 해석을 10회씩 수행하였다. 민감도 분석결과 그림에서 나타난 10개의 그래프는 민감도 해석을 10회 반복 수행한 결과를 의미한다.

그림 4에서는 말뚝 직경이 지지력에 미치는 영향이 검토되었다. 일반적으로 말뚝 직경이 커질수록 말뚝을 설치하는데 소요되는 항타에너지는 증가되어야 한다. 따라서 말뚝 직경에 대한 민감도 분석에서는 말뚝 직경과 항타에너지 값이 최소값에서 최대값으로 함께 증가하며, 나머지 입력변수 값들은 임의의 값을 갖도록 하였다. 말뚝 직경이

증가함에 따라 전체지지력 값이 증가하는 양상을 보였다.

그림 5에서는 말뚝 선단부의 폐색여부에 따른 지지력 값의 변화를 살펴보았다. 주면 및 선단 지지력 값은 폐단 말뚝의 경우가 개단말뚝 보다 미소하게 크긴 하지만, 선단형식에 거의 영향을 받지 않는 것으로 나타났다. 실대형 현장 말뚝 시험자료들을 근거로 한 인공신경망 학습 결과로부터 선단 형식이 주면 및 지지력에 거의 영향을 미치지 않는 것으로 나타났다. 기존의 연구결과들을 살펴보면 말뚝이 직경의 10~17배 이상 관입되면 완전 폐색 상태에 도달되어 개단말뚝과 폐단말뚝의 지지력은 큰 차이를 보이지 않는다고 보고되었다(Beringen 1979, Klos and Tejchman 1981, Szechy 1959). 본 연구에서 사용된 현






그림 4. 말뚝 직경의 변화에 따른 영향






그림 5. 선단형식에 따른 민감도 평가

장 말뚝들의 경우 말뚝직경은 0.27~0.60m이며, 관입깊이는 대략 10~43m에 달하며, 관입깊이는 직경의 대략 20~88배에 이르며, 평균적으로 56배 정도의 값을 갖고 있다. 따라서, 본 연구에서 검토된 말뚝의 경우 개단 말뚝과 폐단 말뚝과 동일한 지지력을 갖는 것으로 사료된다.

그림 6에서는 관입깊이가 지지력에 미치는 영향이 검토되었다. 관입깊이가 깊어짐에 따라서 주변마찰력 값은 크게 증가하는 양상을 보였으며, 전체지지력 값도 주변마찰력의 증가양상으로 인해 크게 증가하는 경향을 보였다. 관입깊이가 대략30m보다 커짐에 따라 선단 지지력 값이 감소하는 경향성이 나타났다. 이는 본 영향검토에서 관입깊이가 깊어짐에도 불구하고 동일한

항타에너지 값이 말뚝에 적용되었기 때문이다. 이로 인해 관입깊이가 큰 경우에 항타에너지의 대부분은 주변부에 먼저 전달되며 선단부에 전달되어야 하는 항타에너지가 얇은 관입깊이에 비해서 작아지게 될 것으로 사료된다.

그림 7에서 시험단계(EOID 및 재항타 시험)의 경우 EOID에서 재항타 횟수가 증가할 때 주변지지력은 증가함에 비해서 선단지지력은 별다른 경향성이 나타나지 않았다. 즉 그림 8에서 나타난 바와 같이 재항타 횟수에 영향을 받는다고 보다는 항타 후 경과일수에 크게 영향을 받는 것으로 사료된다. 항타 후 경과일수에 대한 영향을 살펴보면, 경과일수가 증가함에 따라 주변마찰력






그림 6. 관입깊이 변화에 따른 영향



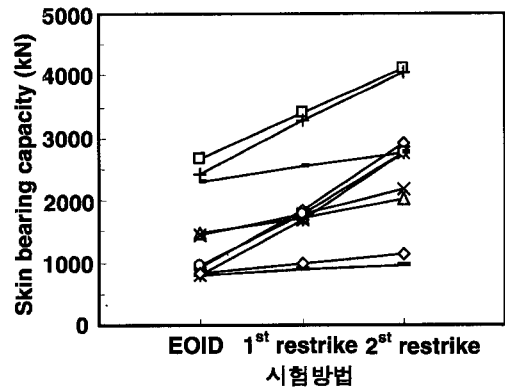


그림 7. 시험단계에 따른 영향

이 증가하는 양상을 보이는 반면에 선단지지력은 경과일수에 관계없이 큰 변동이 나타나지 않았다. 결과적으로 경과일수가 증가함에 따라 전체지지력은 주면마찰력의 증가로 인해 점차로 증가하는 양상을 보였다. 조천환(2003)의 검토내용에서도 항타후 경과일수에 따른 set-up효과는 주면마찰력의 증가에 의해 주로 발생하며, 부산현장을 제외하면 선단부의 지반조건이 대부분이 사질토인 경우에 set-up효과는 뚜렷하지 않는다고 보고한 바 있다.

그림 9에서는 항타에너지가 지지력에 미치는 영향이 검토되었다. 항타에너지가 증가할수록 주면마찰력은 증가하는 양상을 보이는 반면에 선단지지력은 별다른 경

향을 보이지 않았으며, 전체지지력은 주면마찰력의 증가로 인해 증가하는 양상을 보였다. 이와 같이 항타에너지는 말뚝의 거동에 큰 영향을 미치며, 항타에너지가 증가함에 따라 주면마찰력의 증가율이 선단지지력의 증가율을 상회하였다. 이와 같이 주면마찰력이 선단지지력에 비해 항타에너지에 크게 영향을 받는다고 보고된 바 있다(Nauroy and Le Tirant 1983, De Nicolar and Randolph 1997, 백규호 2001).

그림 10과 11에서는 주면 및 선단부의 지반조건에 따른 지지력의 변화양상이 검토되었다. 주면 지반조건의 경우 점토에서 모래자갈층으로 변화함에 따라 주면마찰력이 상당히 감소하였으며, 선단지지력은 증가하






그림 8. 경과일수의 변화에 따른 민감도 평가



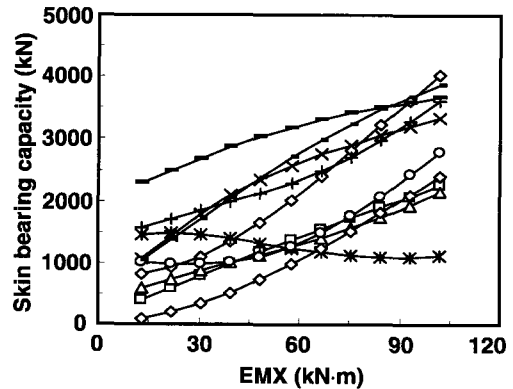
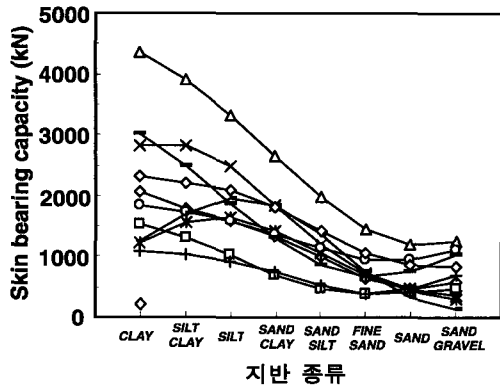




그림 9. EMX의 변화에 따른 민감도 평가




지반 종류




지반 종류




지반 종류



지반 종류



지반 종류



지반 종류

그림 10. 주면 지반조건의 변화에 따른 영향

그림 11. 선단 지반조건의 변화에 따른 영향

다가 수렴하는 경향성을 보였다(그림 10 참고). 반면에 선단 지반조건이 점토에서 모래자갈층으로 변화함에 따라 주면마찰력과 선단지지력은 별다른 경향성을 보이지 않았다(그림 11 참고). 그러나, 모래자갈층의 선단 지지력이 점토지반의 선단지지력에 비해 반드시 크다고 할 수 없다. 본 연구에서 분석자료에 포함되지는 않았지만, 지지력 값은 점토지반의 OCR이나 사질토 및 모래지반에서의 상대밀도에 의해 크게 영향을 받기 때문에 주면과 선단의 흙의 종류만을 근거로 하여 지지력 값의 변동을 살펴보는 것은 다소 무리가 있는 것으로 사료된다.

5.3 지지력 산정을 위한 최적의 인공신경망 모델

박현일 등(2005)이 제안한 인공신경망(Artificial Neural Network, ANN)과 유전자 알고리즘(Genetic Algorithm, GA)의 특성이 조합된 신경망구조 설계기법(GA/NN)을 사용하여 지지력 산정을 위한 최적의 인공신경망 모델을 도출하고자 하였다. 표 3에는 GA/NN 기법을 적용하기 위한 설계변수들이 정리되어 있다. 인공신경망의 구조에서 최적화되어야 하는 설계변수들은 입력변수 조합과 은닉층 갯수 및 각 은닉층의 노드수와 전이함수의 조합이며, 은닉층 개수는 최대 2개이며, 각 은닉층의 노드수는 최대 15이다. GA/NN 기법을 적용하기 위해 유전자 알고리즘에 관련된 초기 설계조건도 표 3에 정리되어 있다.

그림 12에는 인공신경망 모델 설계변수들의 최적화 과정이 나타나 있다. 그림 2에 설명된 바와 같이 입력변수에 해당하는 값이 1인 경우에는 입력변수로 선정되는 것을 의미하며, 0인 경우에는 입력변수에서 제외됨을 의미한다. 세대수가 15보다 커짐에 따라 입력변수 조합은 총 6개로서 시험단계와 선단지반조건이 제외되었다. 은닉층 노드수는 12개로 수렴되었으며, 입력층-은닉층과 은닉층-출력층을 각각 연결하는 전이함수의 조합은 시그모이드(logsig) 함수와 선형(linear) 함수로 수렴되었다. GA/NN 기법을 사용하여 구해진 신경망 구조의 최적화된 설계변수값들이 표 4에 정리되어 있다. 인공신경망 모델에서 사용된 2개의 입력변수가 GA/NN 기법에 근거한 최적화 과정을 거쳐서 제외되었다. 은닉층 갯수는 1개로 인공신경망 모델과 동일하며, 은닉층 노드수는 8개로 인공신경망 모델보다 1정도 크게 구해졌다. 입력층-은닉층 및 은닉층-출력층에 적용된 전이함수는 각각 쌍곡탄젠트 함수와 선형함수로 구해졌다. 신경망에서 사용되는 weight와 bias 값들은 표 5에 나타나 있다. 계산에 필요한 입력 및 출력값들의 최대 및 최소치들이 표 6에 정리되어 있다.

표 3. GA/NN 기법의 적용을 위한 설계조건

		변수	값
GA 관련변수		개체군 개수, N_{ind}	400
		총 세대 수, $MAXGEN$	40
		돌연변이 확률, P_{mut}	0.05
NN 관련변수		최대 입력변수 개수, IL_{max}	8
		은닉층 최대 개수, HL_{max}	2
		은닉층 최대 노드 수, NH_{max}	15

표 4. GA/NN 방법에 의해 선택된 입력변수

	입력자료							전이함수		은닉층 노드수	
	말뚝직경	선단형식	관입깊이	항타방식	경과일수	EMX	주면지반조건	선단지반조건	I-H		H-O
GA/NN	0	0	0	x	0	0	x	0	tansig	linear	8

표 5. 최적화된 인공신경망 모델의 weight 및 bias 값들

A	0.388	-0.658	-0.108	-0.321	-0.509	1.127	B	-0.866		
	-0.143	-0.158	0.943	-0.184	0.770	0.048		-0.167		
	0.166	-0.003	-2.016	0.287	0.800	1.067		1.977		
	-1.392	0.107	3.777	-0.152	0.670	-2.235		-1.417		
	-0.888	-0.377	0.644	-0.824	0.098	0.619		1.786		
	-0.409	-0.178	0.241	0.135	0.424	1.548		-1.455		
	-0.403	-0.308	0.961	0.445	-1.746	0.567		-0.567		
	0.135	-0.238	0.110	-0.895	0.689	-0.191		0.501		
C	-0.223	0.371	1.258	0.832	-0.947	0.031	0.2311	0.0632	D	-0.106
	0.984	1.134	-1.543	-1.403	1.214	-1.962	-0.7874	-1.4537		-1.008

최적화된 인공신경망 모델의 구체적인 사용을 위하여 부록에서 실제적인 계산 예가 정리되어 있다.

GA/NN 기법으로부터 얻어진 신경망 구조를 적용할 경우 두 개의 입력변수, 시험단계와 주면부 지반조건이 입력변수에서 제외음에도 불구하고 그림 13에 나타나 바와 같이 훈련 및 검증과정에서 상관성이 매우 양호하게 나타났다. 또한, 모든 입력변수가 적용된 인공신경망 모델의 상관관계가 나타나 있는 그림 3의 결과와 비교해도 거의 유사한 정도의 상관성이 나타남을 알 수 있다. 즉 시험단계와 주면부 지반조건은 지지력 값에 별다른 영향성을 미치지 않는 것으로 나타났다. 특히 선단형

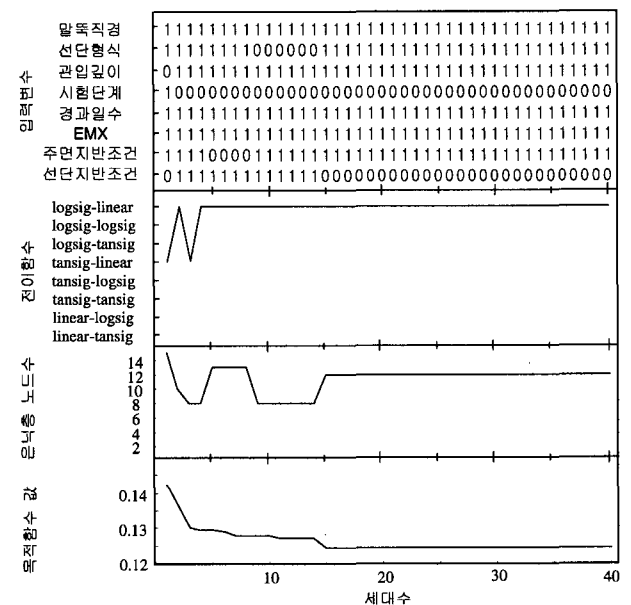




그림 12. 인공신경망 최적화 과정



(a) 학습



(b) 검증

그림 13. 최적화된 인공신경망 모델에 의한 학습 및 검증 결과

표 6. 인공 신경망모델 입력 및 출력값의 최대 및 최소값

	min p	max p	min t	max t
말뚝직경 (m)	0.273	0.6096	-	-
선단종류	0(폐단)	1(개단)	-	-
관입깊이 (m)	9.6	42.8	-	-
EMX (kN·m)	12.8	102.0	-	-
경과일수 (day)	0	35.0	-	-
선단지반조건	1	8	-	-
주면마찰력 (kN)	-	-	154.0	5401.1
선단지지력 (kN)	-	-	157.9	2741.7

식의 경우 그림 5의 민감도 분석에서 별다른 경향성이 나타나지 않았으나, 신경망 구조 최적화에서는 제외되지 않았다. 즉 선단형식에 따라 관입성이 상당한 영향을 받으며, 주어진 관입깊이까지 도달되는데 요구되는 항타에너지값에 상당한 영향을 미치기 때문으로 사료된다. 즉 선단형식은 지반조건과 항타에너지와 같은 영향인자들과 상당한 연관성이 있는 것으로 사료된다.

6. 결론

본 연구에서는 실제 국내 현장에서 설치된 항타말뚝들에 대한 동재하시험으로부터 얻어진 주면과 선단 및 전체지지력을 예측하기 위하여 인공신경망 모델이 적용되었다. 영향인자들이 지지력에 미치는 영향을 검토하기 위하여 지반조건과 말뚝조건 및 항타조건을 포함한 총 8개의 영향인자들에 대한 인공신경망 모델에 근거한 민감도 분석을 수행하였다. 여러 영향인자들에 대한 민감도 분석결과를 정리하면 다음과 같다. 말뚝 직경이 증가함에 따라 주면 및 선단지지력이 증가하는 양상

을 보였다. 개단 및 폐단 말뚝의 지지력 값은 서로 유사한 경향을 보였는데, 이는 본 연구에서 분석된 말뚝 자료들의 관입깊이가 크기 때문에 개단말뚝과 폐단말뚝이 유사한 지지력을 갖는 것으로 사료된다. 관입깊이가 증가함에 따라서 전체지지력 값이 상당히 증가하는 양상을 보였다. 항타조건인 경우 시험단계에 따라서 별다른 변동을 보이지 않은 반면에, 경과일수가 증가함에 따라 주면 지지력은 크게 증가함에 따라 전체지지력값이 증가하는 경향을 보였다. 지반조건인 경우 주면부 토질층이 점토층에서 모래자갈층으로 변화함에 따라 주면 및 선단지지력이 점차적으로 감소하는 경향을 보였다. 선단부 토질층이 점토층에서 모래자갈층으로 변화함에 따라 주면 지지력은 크게 감소한 반면에 선단지지력은 크게 증가하였고, 전체지지력 값은 큰 변동이 없는 것으로 나타났다.

관입된 항타말뚝의 지지력을 산정할 수 있는 최적의 인공신경망 모델을 제안하기 위하여 유전자 알고리즘에 근거한 신경망 구조 최적화 기법을 적용하였다. 최적화된 인공신경망 구조는 다음과 같다. 총 8개의 입력변수들 가운데, 시험단계 및 선단부 지반조건이 입력층에서 제외되었으며, 은닉층 개수 및 각 은닉층의 노드수는 각각 1개와 6개이다. 구해진 전이함수 조합은 쌍곡탄젠트함수 및 선형함수이다. 최적화된 인공신경망 모델은 복잡한 신경망 구조를 피하면서 주어진 자료들에 대하여 도출될 수 있는 입력물성치들과 출력값과의 관계를 가장 적합하게 표현할 수 있음을 알 수 있다.

참고 문헌

1. 김병탁, 김영수, 배상근 (2001), "압축지수의 추정을 위한 인공신경망

적용과 경험식 제안”, *한국지반공학학회논문집*, 제 17권, 6호, pp.25-36.

2. 김영상 (2003), “피에조콘을 이용한 점토의 비배수전단강도 추정 에의 인공신경망 이론”, *한국지반공학학회논문집*, 제19권, 제4호, pp.287-298.
3. 박현일, 권기철, 오세봉 (2005), “인공 신경망 모델에 근거한 노 상토 및 보조기층의 탄성계수값 추정”, *대한토목학회논문집*, 제 25권, 제2-C호, pp.61-72.
4. 박현일, 권기철, 황대진, 이승래 (2005), “최적의 인공신경망 구 조 설계를 통한 지반 물성치 추정”, *한국지반공학학회논문집*, 제21 권, 제9호, pp.35-44.
5. 백규호 (2001), “모래지반에서 말뚝의 항타에너지가 강관말뚝의 지지 력에 미치는 영향”, *한국지반공학학회논문집*, 제 17권, 6호, pp.99-110.
6. 백규호 (2002), “모래 지반에서 강관말뚝의 최적항타 시공법”, *대한토목학회논문집*, 제22권, 제1-C호, pp.45-55.
7. 이성진, 이승래, 장범수 (2002), “인공신경망 모델을 이용한 불포 화 결빙기점착력 추정에 관한 연구”, *대한토목학회논문집*, 제22 권, 제3-C호, pp.331-344.
8. 조철환 (2003), “타입 말뚝의 지지력 증가효과 특성”, *한국지반 공학회논문집*, 제 19권, 4호, pp.235-246.
9. 황명기, 김지형, 김영욱 (2003), “초음파-토양수세법을 이용한 오 염지반 복원률증대에 인공신경망의 적용”, *한국지반공학학회논 문집*, 제 19권, 6호, pp.343-350.
10. Beringen, F. L. (1979), “Results of Loading Tests on Driven Piles in Sand”, *Recent Developments in the Design and Construction of Piles*, London, pp.213-225.
11. Brucy, F., Meunier, J., and Nauroy, J. F. (1991), “Behavior of Pile Plug in Sandy Soils during and after Driving”, *Proc. 23rd Annual Offshore Technology Conf.*, Vol.1, pp.145-154.
12. Crowther, C.L. (1988), *Load Testing of Deep Foundations. The Planning Design and Conduct of Pile Load Tests*, John Wiley & Sons.
13. De Nioclar, A. and Randolph , M. F. (1977), “The Plugging Behavior of Driven and Jacked Piles in Sand”, *Geotechnique*, London, UK, Vol.47, No.4, pp.841-859.
14. GRL Associates, Inc. (1996), *CAPWAP User Manual*.
15. Klos, J. and Tejchman, A. (1981), “Bearing Capacity Calculation for Pipe Piles”, *International Conference on Soil Mechanics and Foundation Engineering, Stockholm*, Vol.2, pp.751-753.
16. Kraft, L. M., Jr. (1991), “Performance of Axially Loaded Pipe Piles in Sand”, *J. Geotech. Engrg.*, Vol.117, No.2, pp.272-296.
17. Kurup, P. U. and Dudani, N. K. (2002), “Neural Networks for Profiling Stress History of Clays from PCPT Data”, *J. of Geotechnical and Geoenvironmental Engineering*, Vol.128, No.7, pp.569-578.
18. Lee, I. M and Lee, J. H. (1996), “Prediction of Pile Bearing Capacity Using Artificial Neural Networks”, *Computers and Geotechnics*, Vol.18, No.3, pp.189-200.
19. Nauroy, J.F. and Le Tirant, P. (1983), “Model Tests on Piles in calcareous Sands”, *Proc. Conf. on Geotech. Practice in Offshore Engrg.*, Austine, pp.356-369.
20. Pile Dynamics, Inc. (1995), *PDA User Manual*.
21. Rahman, M.S., Wang, J., Deng, W. and Carter, J.P. (2001), “A Neural Network Model for the Uplift Capacity of Suction Caissions”, *Computers and Geotechnics*, Vol.28, pp.269-287.
22. Szechy, C.H. (1959), “Tests with Tubular Piles”, *AcTa Technica of the Hungarian Academy of Science*, Vol.24, pp.181-219.

(접수일자 2005. 11. 25, 심사완료일 2006. 5. 30)

Appendix

인공신경망모델을 이용한 말뚝 지지력 계산에

입력벡터 p 다음과 같이 주어져 있다.

$$p = \begin{bmatrix} \text{말뚝직경} \\ \text{선단종류} \\ \text{관입깊이} \\ \text{EMX} \\ \text{경과일수} \\ \text{선단지반조건} \end{bmatrix} = \begin{bmatrix} 0.508 \\ 0 \\ 10.3 \\ 55.9 \\ 28 \\ 3 \end{bmatrix}$$

정규화된 입력벡터 pn 은 다음 식을 사용하여 구해지 며, $\min p$ 와 $\max p$ 값은 표 6에 주어져 있다.

$$pn = 2 (p - \min p) / (\max p - \min p) - 1$$

$$pn = \begin{bmatrix} 0.3963 \\ -1.0000 \\ -0.9578 \\ -0.0330 \\ 0.6000 \\ -0.4286 \end{bmatrix}$$

정규화된 출력값은 다음과 같이 정규화된 입력벡터 pn 의 전파로 구해질 수 있다.

$$tn = C \times \text{logsig} (A \times pn + B) + D$$

$$A \times pn + B = \begin{bmatrix} -0.7283 \\ -0.5204 \\ 3.9898 \\ -4.3281 \\ 1.0153 \\ -2.0831 \\ -2.6444 \\ 1.2122 \end{bmatrix}$$

$$\text{tansig}(A \times pn + B) = \begin{bmatrix} -0.6220 \\ -0.4780 \\ 0.9993 \\ -0.9997 \\ 0.7679 \\ -0.9695 \\ -0.9900 \\ 0.8373 \end{bmatrix}$$

$$C \times \text{logsig} (A \times pn + B) + D = \begin{bmatrix} -0.6519 \\ 0.0961 \end{bmatrix}$$

정규화된 tn 값은 다음과 같이 실제적인 주면 및 선단 지지력값으로 환산될 수 있다.

$$t = 0.5 \cdot (tn + 1) \cdot (\max t - \min t) + \min t = \begin{bmatrix} 1067.3 \\ 1574.0 \end{bmatrix}$$

시험결과로부터 도출된 결과는 주면마찰력과 선단지 력값은 각각 882.8kN과 2030.5kN이며, 인공신경망 모델을 통하여 도출된 값은 1067.3kN과 1574.0kN이다.