

PC 수직 접합부의 극한 전단 내력 예측에 대한 인공 신경 회로망의 적용

Application of Artificial Neural Networks to Predict Ultimate Shear Capacity of PC Vertical Joints

김 택 완* · 이 승 창** · 이 병 해***
Kim, Taek-Wan · Lee, Seung-Chang · Lee, Byung-Hai

요 약

인공 신경 회로망은 인간의 뇌를 전산 모델로 구현한 것으로 상호 연결된 많은 정보 처리 유니트들로 구성되어 있으며, 이를 기초로 논리적인 추론을 수행할 수 있다. 특히, 신경망은 비선형 변수를 많이 포함하고 있는 복잡한 문제 해결에서 더욱 효과적이다. 신경망의 이러한 기능으로 인해 구조 분야에서는 비선형적인 각종 구조 실험의 결과 예측이나 구조 계획 그리고 최적 설계에 응용되고 있는 추세이다.

본 논문에서는 인공 신경 회로망의 기본 이론을 설명하고, 현재까지 정립되고 있지 않은 대형 콘크리트 판넬간 수직 접합부의 최대 전단 내력 예측에 기존의 제안식과 인공 신경 회로망의 예측 결과를 비교하여 신경망의 적용가능성을 검토하고자 한다.

Abstract

An artificial neural network is a computational model that mimics the biological system of the brain and it consists of a number of interconnected processing units where it can reasonably infer by them. Because the neural network is particularly useful for evaluating systems with a multitude of nonlinear variables, it can be used in experimental results predictions, in structural planning and in optimum design of structures.

This paper describes the basic theory related to the neural networks and discusses the applicability of neural networks to predict the ultimate shear capacity of the precast concrete vertical joints by comparing the neural networks with a conventional method such as regression.

Keywords : artifical neural network, experimental results predictions optimum design of structures, ultimate shear capacity, precast concrete vertical joints

* 한양대학교 건축공학석사, 현대엔지니어링 P2 토건

** 한양대학교 건축공학과 박사과정

*** 정회원 · 한양대학교 건축공학과 교수

• 이 논문에 대한 토론을 1996년 12월 31일 까지 본 학회에
보내주시면 1997년 6월호에 그 결과를 게재하겠습니다.

1. 서 론

국내에서 PC(Precast Concrete) 구조의 아파트 건설 방법은 1960년대에 처음으로 도입되어 점차 증가 추세를 보이고 있다¹⁾.

대형판 PC 구조물의 특징은 내력벽과 바닥판이 서로 연결, 조합되어 구성되는 접합부가 존재하게 되며, 이는 힘(접합부에 작용하는 풍하중 혹은 지진 하중과 같은 횡하중이나 불균등한 수직 하중의 분포, 인접 부재 간의 강성 차이, 부동 침하 등)의 불연속면을 형성하여 변형의 불연속과 응력의 집중이 일어나게 한다. 따라서 접합부의 전단에 대한 설계에서는 콘크리트의 강도, 횡보강 철근의 특성, 접합부의 형태 등을 고려하게 되는데, 실제 구조물에 적용되고 있는 전단 키의 형상과 접합부 불연속면의 횡보강 철근의 구속 조건이 다양하기 때문에 저항 능력 또한 다양하여 전단 내력을 정확히 예측하는데는 한계가 있다²⁾.

기존의 제안식들은 수정된 Mohr-Coulomb 항복 이론에 근거한 실용식이다. 즉, 수치적으로 변수에 맞는 계수들을 결정해 나가는 회귀식이기 때문에 실제 문제에서의 다양한 변수들의 영향을 고려하지 못해 복잡하고 비선형적인 실제 결과와는 상당한 차이가 생기는 경우가 많다. 그러나 본 연구에서 적용한 신경망은 패턴 인식, 자기 연관 기억과 학습 기능을 통해서 추론을 수행하기 때문에 비선형 변수를 많이 포함하고 있는 복잡한 문제 해결에 더욱 효과적이다. 신경망의 이러한 기능으로 인해 최근 구조 분야에서는 비선형적인 각종 구조 실험의 결과 예측이나 구조 계획 그리고 최적 설계에 응용되고 있는 추세이다^{3,4,5)}.

본 논문에서는 인공 신경 회로망의 기본 이론을 설명하고, 현재까지 정립되고 있지 않은 대형 콘크리트 판넬간 수직 접합부의 최대 전단 내력 예측에 기존의 제안식과 인공 신경 회로망의 예측 결과를 비교하여 신경망의 적용 가능성을 검토하고자 한다.

2. 인공 신경 회로망 이론

2.1 신경 세포의 구조

인간의 뇌는 $10^{10} \sim 10^{11}$ 개나 되는 뉴런(neuron)이 조직적으로 결합된 거대 시스템으로, 각 뉴런은 그림 1과 같이 본체인 세포체(cell body) 부분과 복잡하게 갈라져서 다른 뉴런의 전기 신호를 받아들이는 수상 돌기(dendrite) 부분, 그리고 본체에서 한줄만 뻗어나왔다가 말단에서 다수로 갈라져 정보를 전달하는 축색돌기(axon) 등 세 가지로 구성된다. 축색 돌기의 연결 부분을 시냅스(synapse)라고 하며, 각 뉴런들은 시냅스 연결을 통하여 정보를 교환한다⁶⁾.

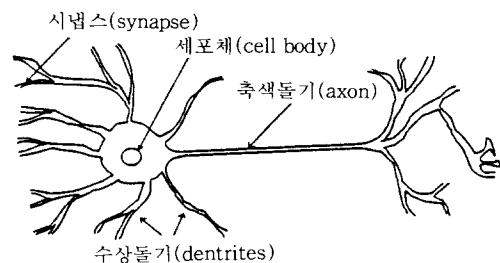


그림 1 뉴런(neuron)

2.2 신경 세포의 수학적 모델

인공 신경 회로망은 정보가 들어오는 입력층(input layer), 뉴런에 미치는 영향의 크기를 조절하는 연결 강도(weight), 입력과 연결강도를 결합하는 결합 함수(combining function), 그리고 결합 함수로부터 나온 결과를 변환하여 출력값을 결정하게 되는 활성 함수(activation function)로 구성된다. 그림 2는 뉴런의 수리 모델(일반적으로 인공적인 뉴런의 수리 모델을 유니트(unit)라 함)이며, 4개의 입력을 받아 각각의 연결 강도를 곱한 총합을 활성 함수에 의해 변형하여 출력치를 계산하는 것을 보여준다. 활성 함수에는 그림 3과 같이 계단 함수, 임계 논리 함수, 시그모이드(sigmoid) 함수* 등이 있으며, 본 논문에서는 시그모이드 함수를 사용했다. 즉, 신경망의 출력치(z)는 아래 식

* 시그모이드 함수 $[(0 \sim 1 \text{ 사이의 출력치를 가짐.})]$ 는 역치 함수와 선형 함수의 특징을 모두 가지고 있는 비선형 함수이며, 연결 강도를 구하는데 필요한 미분이 간단하다⁷⁾.

처음 입력치(X_i)와 이에 대응하는 연결강도(W_i)를 곱한 값의 총합에서 임계치(θ)를 뺀 값을 활성화함수(f)에 입력하여 구한다⁶⁾.

$$z = f \left(\sum_i W_i X_i - \theta \right)$$

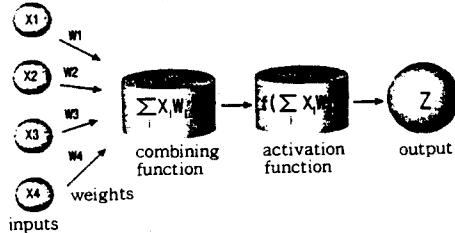


그림 2 뉴런의 수리모델(유니트)

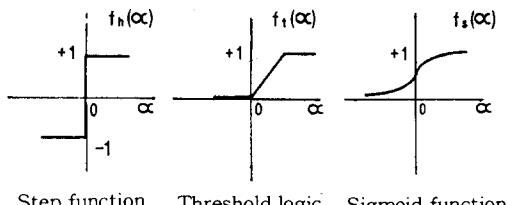


그림 3 활성화 함수의 종류

2.3 역전파(backpropagation) 학습 알고리즘
 신경망 모델의 종류에는 1943년 McCulloch와 Pitts가 최초의 수학적 모델을 제시한 이후, Perceptron, Madline, Hopfield, Kohonen, ART, BAM, Backpropagation, Counterpropagation 등의 다양한 모델이 등장했으며, Backpropagation 모델은 현재 예측을 위한 신경망 학습 알고리즘의 90 % 이상을 차지하고 있다.

역전파 신경 회로망은 그림 4와 같이 다층 퍼셉트론(multi-layered perceptron)의 구조를 갖고 있으며, 학습 단계와 산출 단계로 동작한다. 우선 학습 단계에서는 입력 패턴(input pattern)과 목적 패턴(target pattern)이 다수의 입/출력 쌍으로 주어지고, 각 입력 패턴에 대해 출력을 먼저 계산한 후, 의도하는 출력과 실제 출력과의 차이를 줄이는 방향으로 연결 강도를 조정한다. 조정 과정

이 끝나면 같은 과정으로 학습을 반복함으로써 최적의 연결 강도를 구한다. 산출 단계에서는 입력만 주어지면 연결 강도와의 계산에 의해 적절한 출력이 계산된다.

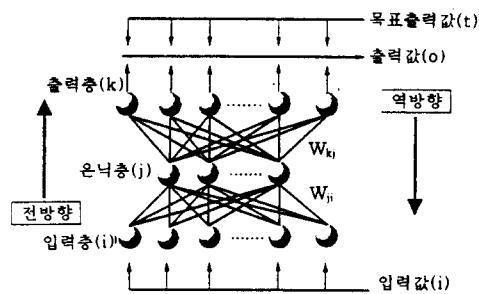


그림 4 다층 퍼셉트론의 구조

다층 역전파 신경 회로망의 학습 단계에서 사용하는 학습 알고리즘은 일반화된 델타 법칙(generalized delta rule)*이라고도 하며, 그림 4와 같이 진행 방향에 따라 전방향 진행과 역방향 진행으로 구분할 수 있다⁸⁾.

2.3.1 전방향 진행

그림 4의 전방향 진행에서는 우선 입력층(layer i)에 하나의 입력 패턴이 주어지면, 은닉층(layer j)에 있는 유니트로 들어가는 입력(net input)이식(1)과 같이 계산된다. 여기서 W_{ji} 는 j층과 i층을 연결하는 연결 강도이다. O_i 는 i층에서 나오는 출력을 나타내며, net_j는 활성화 함수 f_j 로 입력된 후식(2)과 같이 계산되어 j층 유니트의 출력 O_j 가 된다.

$$\text{net}_j = \sum_i W_{ji} O_i \quad (1)$$

$$O_j = f_j(\text{net}_j) \quad (\therefore O_j = \frac{1}{1+e^{-(\text{net}_j+\theta_j)}}) \quad (2)$$

여기서 θ_j 는 j층 유니트들의 임계값이다. O_j 는 다시 식(3)과 같이 출력층(layer k)으로 입력 되

* 역전파 학습 알고리즘은 목적 패턴과 출력 패턴의 차이, 즉, 델타(Delta)를 이용하여 학습을 하는 맹타 룰(단층 퍼셉트론)보다 역전파 방법이 추가된 일반화된 델타 룰(generalized delta rule, 다층 퍼셉트론)이라고 한다.

고, 활성화 함수 f_k 에 의해 식(4)와 같이 계산되어 k 층 유니트의 출력 O_k 가 된다.

$$\text{net}_k = \sum_j W_{kj} O_j \quad (3)$$

$$O_k = f_k(\text{net}_k) \quad (4)$$

일반적으로 출력패턴 O_k 는 목적패턴 t_k 와 일치하지 않으므로 하나의 패턴에 대한 패턴 오차(pattern error) E_p 를 식(5)와 같이 정의하고, E_p 가 정해지면 E_p 를 최소화하는 방향으로 연결 강도와 임계값을 조정한다. 전체 패턴에 대한 오차의 합 E_t 는 E_p 를 모두 합하여 식(6)과 같이 구한다.

$$E_p = \frac{1}{2} \sum_k (t_k - O_k)^2 \quad (5)$$

$$E_t = \sum_p E_p = \frac{1}{2} \sum_p \sum_k (t_k - O_k)^2 \quad (6)$$

2.3.2 역방향진행

역방향 진행은 최종 출력총에서 계산된 패턴 오차를 역방향으로 입력총까지 전파하여 연결 강도를 수정함으로써 오차를 최소화하는 과정을 의미한다.

1) 출력총 연결 강도의 조정

출력총에서의 연결 강도의 미소 변화량은 식(7)로 정의한다. 여기서 η 는 학습율(learning rate)*이다. 식(7)은 식(8)로 쓸 수 있으며 출력총에서 E 를 줄이는 방향으로 학습을 하기 위해서는 식(9)를 이용하여 연결 강도를 변화시키면 된다.

$$\Delta W_{kj} = \eta \frac{\partial E_p}{\partial W_{kj}} \quad (7)$$

$$\Delta W_{kj} = \eta \delta_k O_j \quad (\because \delta_k \text{를 } -\frac{\partial E_p}{\partial \text{net}_k} \text{로 정의}) \quad (8)$$

$$\Delta W_{kj} = \eta (t_k - O_k) O_k (1 - O_k) \quad (9)$$

2) 은닉층 연결 강도의 조정

은닉층 연결 강도의 미소 변화량도 식(7)~(9)와 같은 과정으로 전개하며 그 결과는 식(10)과 같다. 은닉층에서의 연결강도 미소 변화량은 식(11)과 같이 구해진다.

$$\Delta W_{ji} = -\eta \frac{\partial E}{\partial W_{ji}} = \eta \frac{\partial E}{\partial O_i} \frac{\partial O_i}{\partial \text{net}_j} \partial O_i \quad (10)$$

$$= \eta \left(\frac{\partial E}{\partial O_i} \right) f'_i(\text{net}_i) \partial O_i = \eta \delta_i O_i$$

$$\Delta W_{ji} = \eta \delta_i O_i = \eta O_i (1 - O_i) \sum_k \delta_k W_{kj} O_i \quad (11)$$

결국, 학습 과정에서 필요한 연결 강도의 변화량은 입.출력쌍의 미소 변화량을 모두 합하여 식(12)와 식(13)으로 계산하며, 위와 같은 학습 과정은 반복적으로 이루어진다.

$$\Delta W_{kj} = \sum_p \Delta_p W_{kj} \quad (12)$$

$$\Delta W_{ji} = \sum_p \Delta_p W_{ji} \quad (13)$$

마지막으로 연결 강도의 변화량에 모멘텀 항(momentum term)** α 를 추가한다. 식(14)와 식(15)은 $(n+1)$ 단계에서 출력총과 은닉총의 최종적인 연결 강도의 수정량이다.

$$\Delta W_{kj}(n+1) = \eta (\delta_k O_i) + \alpha \Delta W_{kj}(n) \quad (14)$$

$$\Delta W_{ji}(n+1) = \eta (\delta_i O_i) + \alpha \Delta W_{ji}(n) \quad (15)$$

이러한 과정이 되풀이 되면서 학습이 진행되며, 정해진 반복 횟수에 도달하거나 오차가 정해진 범위로 줄어들면 학습이 모두 끝난다⁹⁾.

2.3.3 역전파 알고리즘의 문제점과 개선책

역전파 알고리즘의 첫번째 문제점은 전역 최소치(global minimum)가 아닌 지역 최소치(local minimum)에 빠질 가능성이 있다는 것이다. 즉, 경사 하강법(steepest descent method)은 현재의 위치에서 기울기가 가장 적은 방향으로만 움직이기 때문이다. 이러한 경우에는 은닉층의 유니트

* 학습율은 학습의 진행 속도에 관련된다. 학습율이 작을수록 학습이 성공적으로 이루어질 확률은 높아지지만 이 경우 학습이 수렴하기까지 상당히 오랜 시간이 소요되며, 값이 클수록 학습은 빨라지만 수렴하지 못하고 발산하여 네트워크가 마비되거나 최소점을 구하지 못할 수도 있다. 학습율은 대부분 네트워크의 복잡도에 따라 시행 차오를 거쳐 결정하며 일반적으로 1보다 작은 양수를 사용한다.

** 모멘텀 항은 오차값이 이전에 변화된 방향으로 조정되도록 함으로써 최소점에 도달하지 못하고 진동하는 현상을 방지하여 학습 시간을 줄이는 역할을 수행한다.

수를 증가시킴으로써 어느 정도 문제점을 해결할 수 있으나, 은닉층 증가에 따른 과적합화 문제가 발생할 때는 학습 횟수를 조절해야만 한다¹⁰⁾.

두번째 문제점은 활성 함수의 입력치가 포화 영역에 도달하게 되면 학습의 효과가 거의 나타나지 않게 된다. 즉, 식(2)와 식(10)에서 net 값이 $+\infty$ 나 $-\infty$ 에 가까워 질수록 $f'(net)$ 은 0이 되므로 연결 강도는 변하지 않게 된다. 따라서 이 문제는 난수로 주어지는 초기치와 임계치를 0에 가깝게 함으로써 해결할 수 있다^{8,11)}.

세번째 문제점으로 학습이 안될 때 그 원인을 찾기가 힘든 점이다. 입(출력쌍이 문제점이 될 수도 있고, 주어진 입(출력쌍에서 학습이 안되다 계속 반복 계산을 하면 학습이 되는 경우도 있으며, 계속 반복해서도 안되는 경우에는 초기에 정하는 연결 강도의 값을 다른 값으로 시작하면 학습이 되는 경우도 있다.

3. 수직 접합부의 실험 결과와 신경망의 학습

3.1 실험 결과와 분석

수직 접합부의 실험에서 실험체는 대형 판넬 접합 방법에 따라 A, B, C, D, E 형의 5종류로, 그림 5에서는 A type 실험체의 형상 및 접합부 상세 예를 보여 준다¹²⁾.

실험 결과로부터 접합부의 최대 전단 내력에 영향을 주는 다양한 변수를 분류하여 표 1에 정리하

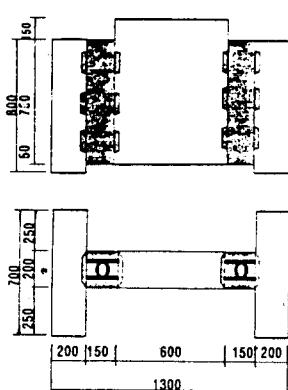


그림 5 A type 실험체

표 1 변수별 최대 전단 내력과의 관계

변수명	최대 전단 내력과의 관계
전단 키의 면적	최대 전단 내력에 가장 크게 영향을 미치는 요소로서 전단 키 면적에 비례하여 내력도 증가함. 그러나 접합부 면적에 대한 전단 키의 비가 일정 수준(실험 결과 30%)에 달하면 내력의 증가가 미흡함.
벽체 압축 강도	벽체 강도에 따른 내력의 변화는 본 실험으로 단정짓기는 어려우나, 연성도를 높이기 위해 보강근을 배근하는 경우, 벽체 강도가 클수록 부착 강도가 커짐에 따라 보강근의 구속력이 커져 전단 저항에 효과가 있는 것으로 나타남.
그라우트 콘크리트의 압축 강도	기존의 제안식들에서 전단 키의 내력(면적 × 그라우트 강도)을 변수로 사용하고 있으며 최대 전단 내력과 거의 비례함. 보강근이 없는 경우, 벽체의 강도가 그라우트보다 상대적으로 클 때, 접합부의 전단 강도가 작게 나타남. 그러나 보강근이 있고 벽체 강도가 클 때, 보강근의 부착 강도 때문에 전단 저항에 효과가 있음.
벽체와 그라우트의 압축 강도비	접합부의 면적은 벽체의 두께를 증가시킴으로써 증대시킬 수 있으며, 실험 결과 면적의 증대로 인해서 전단 저항도 증가함.
전단 키 철근 ²⁾ 의 보강 강계수 ²⁾	철근의 내력이 전단 저항에 큰 영향을 미치는 것으로 나타남.

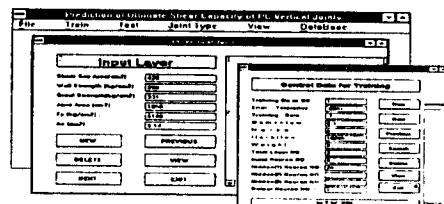


그림 6 신경망의 실행 메뉴

였다. 이 밖에도 전단 키의 경사각, 동일한 전단 키의 면적일 때 키의 수, 전단 키의 d/h (폭/높이) 등도 전단 내력에 영향을 주지만, 실험체에 사용된 값이 동일했기 때문에 고려 대상에서 제외하였다.

신경망의 학습에 사용한 실험 데이터는 표 2와 같으며, 실험에 사용된 실험 장비와 실험체의 형태 등은 참고 문헌^{12,13)}에 자세히 수록되어 있다.

3.2 신경망의 학습

그림 6은 사용자 인터페이스를 용이하게 하기

위하여 C++과 Visual Basic으로 구현한 학습 시스템 메뉴이다.

그림 7과 같은 뉴런의 네트워크 구조는 9 - 20 - 1로써 입력층(input layer) 9개, 은닉층(hidden layer) 20개, 출력층(output layer) 1개로 구성했다.

학습 데이터로 이용될 입력층의 변수로는 전단 키의 면적(cm^2), 벽체의 압축 강도(kg/cm^2), 그라우트의 압축 강도(kg/cm^2), 벽체와 그라우트의 압축 강도비, 접합부의 면적(cm^2), 전단 키 면적과 접합부 면적의 비, 철근의 항복 강도(kg/cm^2), 철근의 단면적(cm^2), 철근과 그라우트의

표 2 수직접합부 실험결과 일람표(신경망의 학습데이터)

실험체명	① Shear Key의 면적(cm^2)	② 벽체압축 강도(kg/cm^2)	③ Grout 강도(kg/cm^2)	②/③	④ 접합부의 면적(cm^2)	①/④	⑤ f_y (kg/cm^2)	⑥ A_s (cm^2)	⑤×⑥ ①×③	R_{max} (ton)
VJA10-14-1	420.00	302.00	208.00	1.45	1050.00	0.40	0.00	0.00	0.00	14.23
VJA11-14-1	420.00	278.00	165.00	1.68	1050.00	0.40	4140.00	1.57	0.09	16.90
VJA12-14-1	420.00	256.00	152.00	1.68	1050.00	0.40	4140.00	3.14	0.20	23.65
VJA12-14-2	420.00	240.00	152.00	1.58	1050.00	0.40	4140.00	4.71	0.31	24.40
VJA13-14-2	420.00	240.00	144.00	1.67	1050.00	0.40	4140.00	4.71	0.32	20.00
VJA11-16-1	420.00	236.00	144.00	1.64	1200.00	0.35	4140.00	1.57	0.11	20.43
VJA12-16	420.00	214.00	111.00	1.93	1200.00	0.35	4140.00	3.14	0.28	19.30
VJA13-16-1	420.00	243.00	111.00	2.19	1200.00	0.35	4140.00	4.71	0.42	25.35
VJA13-16-2	420.00	243.00	198.00	1.23	1200.00	0.35	4140.00	4.71	0.23	24.20
VJA12-18	588.00	172.00	198.00	0.87	1350.00	0.43	4140.00	3.14	0.11	29.83
VJA13-18	588.00	211.00	190.00	1.11	1350.00	0.43	4140.00	4.71	0.17	27.15
VJA12-20-1	588.00	211.00	190.00	1.11	1500.00	0.39	4140.00	3.14	0.12	28.20
VJA12-20-2	588.00	202.00	157.00	1.29	1500.00	0.39	4140.00	3.14	0.14	22.00
VJA13-20	588.00	202.00	157.00	1.29	1500.00	0.39	4140.00	4.71	0.21	24.63
CVJA42-20A	585.80	320.00	281.00	1.14	1500.00	0.39	4140.00	3.14	0.08	22.50
CVJA43-20A	585.80	349.00	276.00	1.26	1500.00	0.39	4140.00	4.71	0.12	23.70
CJB42-14A	420.00	314.00	244.00	1.29	1050.00	0.40	4140.00	3.14	0.13	18.90
CJB42-14B	420.00	293.00	293.00	1.00	1050.00	0.40	4140.00	3.14	0.11	20.25
CJB43-14A	420.00	291.00	244.00	1.19	1050.00	0.40	4140.00	4.71	0.19	19.45
CJB42-20A	420.00	293.00	293.00	1.00	1050.00	0.40	4140.00	4.71	0.16	21.80
CJB43-20A	585.80	314.00	244.00	1.29	1500.00	0.39	4140.00	3.14	0.09	23.50
CJB43-20A	585.80	291.00	244.00	1.19	1500.00	0.39	4140.00	4.71	0.14	22.30
CVJB42-20A	585.80	314.00	248.00	1.27	1500.00	0.39	4140.00	3.14	0.09	21.70
CJD42-14A	307.60	291.00	257.00	1.13	1050.00	0.29	4140.00	3.14	0.16	9.65
VJD43-14B	307.60	293.00	223.00	1.31	1050.00	0.29	4140.00	31.4	0.19	8.53
VJD43-14A	307.60	262.00	257.00	1.02	1050.00	0.29	4140.00	4.71	0.25	10.03
VJD43-14B	307.60	293.00	223.00	1.31	1050.00	0.29	4140.00	4.71	0.28	13.38
VJD42-20A	440.30	314.00	257.00	1.22	1500.00	0.29	4140.00	3.14	0.11	9.53
VJD43-20A	440.30	291.00	257.00	1.13	1500.00	0.29	4140.00	4.71	0.17	15.93
CVJD42-20A	440.30	314.00	253.00	1.24	1500.00	0.29	4140.00	3.14	0.12	14.90
CVJD43-20A	440.30	262.00	253.00	1.03	1500.00	0.29	4140.00	4.71	0.18	13.95
VJE42-14A	420.00	262.00	292.00	0.90	1050.00	0.40	4140.00	3.14	0.11	13.50
VJE43-14B	420.00	293.00	176.00	1.66	1050.00	0.40	4140.00	3.14	0.18	13.60
VJE43-14A	420.00	314.00	292.00	1.08	1050.00	0.40	4140.00	4.71	0.16	16.80
VJE43-14B	420.00	293.00	176.00	1.66	1050.00	0.40	4140.00	4.71	0.26	12.80
VJE42-20A	585.80	262.00	292.00	0.90	1500.00	0.40	4140.00	3.14	0.08	12.95
VJE43-20A	585.80	314.00	292.00	1.08	1500.00	0.40	4140.00	4.71	0.11	25.15

내력비이며, 출력층으로는 최대 전단 내력(ton)이 들어간다. 연결 강도의 초기치로는 $-1.0 \sim 1.0$ 사이의 난수(random value)로 결정하였고, 학습율은 0.3, 모멘텀 항은 0.5로 했다. 신경망의 유니트 구조에서 사용하는 학습률과 모멘텀항은 사용하는 적정치가 있으나 그밖의 것들은 시행착오적 방법을 통해서만 결정할 수 있다¹⁴⁾.

3.3 기존의 실험 제안식

신경망의 예측 결과와의 비교를 위해서 기존의 실험 제안식인 L.V.I. 공법의 내력 산정식, CAMU의 내력 산정식, Chakrabarti, B.C.Jensen, Abdul-Wahab, Tassios의 제안식을 사용하였다. 표 3은 L.V.I 공법에 의한 제안식의 예이고, 다른 식들의 자세한 내용은 참고 문헌¹²⁾에 수록되어 있다.

표 3 제안식의 예

$$\begin{aligned} Qu &= 0.09 A_t \cdot \sigma'_b + \sum A_a \sigma_a \\ A_t / A_b &\leq 0.5, d \geq 10\text{mm}, h \leq 8d, a \leq 30, 0.02 \leq \Phi \leq 0.3 \\ A_t &= \text{Shear Key의 단면적의 합(cm}^2\text{)} \\ \sigma'_b &= \text{접합부 그라우팅 콘크리트 또는 모르터의 공시체 강도(kg/cm}^2\text{)} \\ \Sigma A^a &= \text{접합부 내의 철근 단면적의 합(cm}^2\text{)} \\ \sigma^a &= \text{철근의 항복 강도(kg/cm}^2\text{)}, \\ A^b &= \text{접합부 단면적의 합(cm}^2\text{)} \\ d &= \text{Shear Key의 깊이(cm)}, \\ a &= \text{Shear Key의 경사각} \\ \Phi &= \frac{\sum A_a \cdot \sigma_a}{A_t \cdot \sigma'_b} \end{aligned}$$

PC 486DX2-66으로 평균 40~70분 소요되었다. 각 type별 학습 반복 횟수와 오차의 관계를 그림 8에 나타냈다.

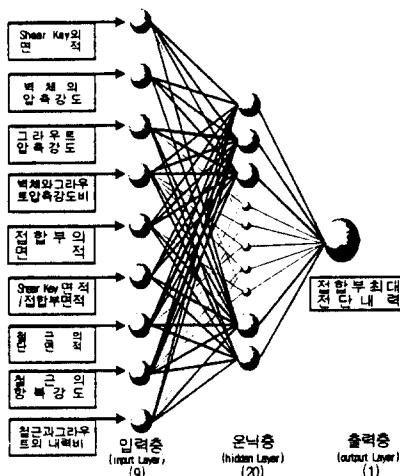


그림 7 뉴런의 네트워크

3.4 신경망과 기존 제안식의 비교

3.4.1 신경망의 학습 결과와 분석

학습은 실험체 type별로 실시되었고 C type의 실험체는 데이터 수가 두 개에 불과해 제외시켰다.

학습에 소요된 시간은 허용 시스템 오차(system error)를 0.0001로 했기 때문에 오차가 0.0001이하가 될 때까지 학습은 계속 진행되었으며

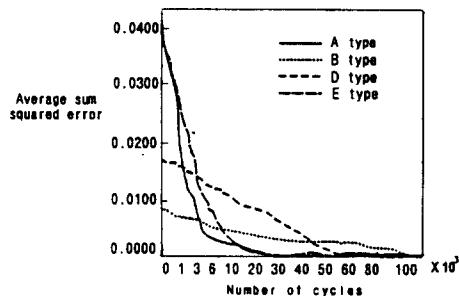


그림 8 학습 반복 횟수와 오차의 관계

A type 실험체의 경우, 학습 데이터의 수가 가장 많았고 오차도 빠르게 수렴하여 반복 횟수 6천회를 지나면서 완만한 하강 곡선을 그리기 시작해 3만 회를 지나면서 거의 0에 가까운 오차를 나타냈다. E type의 경우는 A type과 거의 비슷한 곡선을 그리면서 학습을 했고, B, D type 실험체는 각각 6만, 10만 회가 넘어서야 0에 가까운 수렴을 할 수 있었다. 이것은 다양한 값의 입력 패턴에 비해 변화의 폭이 적은 목적 패턴이 있기 때문이다.

3.4.2 제안식과 신경망의 추론 과정 비교

기존의 제안식들은 수정된 Mohr-Coulomb¹²⁾의 원을 이용한 항복선 이론에 기반을 두고 수치적으로 식에 맞는 계수들을 결정해 나가는 회귀식이기 때문에 실제 문제에서의 다양한 변수들의 영향을

고려하지 못해 복잡하고 비선형적인 실제 결과와 예측 결과와는 상당한 차이가 생기는 경우가 많다. 그러나 신경망은 수학적인 모델식에 맞추어 가는 방식이 아니라 사람이 태어나면서부터 패턴을 인식하고, 경험을 통해서 추론할 수 있는 것과 같이 실제의 패턴들을 그대로 받아들여 사람의 뇌의 구조와 비슷한 수리 모델을 만들어 학습에 이용하고, 이를 바탕으로 추론을 수행하기 때문에 예측 문제에서 매우 효율적인 예측을 할 수 있다.

3.4.3 신경망과 제안식 산출 결과와의 비교·분석

표 4와 그림 9는 기존의 제안식을 실험체에 적용한 계산 결과와 신경망의 예측값을 비교하기 위해 실험값/계산값의 비로 통계 처리한 것이다.

1) L.V.I. 공법의 제안식은 실험값/계산값이 0.53~1.69의 범위로서 평균 0.92, 표준 편차 0.32로 나타났으며, 까유 공법의 제안식은 0.45~1.44의 범위로 평균 0.78, 표준 편차 0.27로 나타났다.

표 4 제안식의 계산 결과와 신경망의 예측 결과

실험체명	P_{max}	L.V.I	CAMU	Chakrabarti	Jensen	Abdul-Wahab	Tassios	Neural
VJA41-14-1	32.60	19.24	22.54	16.62	14.99	9.42	30.33	30.48
VJA42-14-1	26.70	24.87	29.84	19.19	20.91	12.20	33.82	24.47
VJA43-14-1	27.75	30.80	35.74	22.06	27.03	15.11	37.90	34.78
VJA41-16-1	32.60	17.80	21.24	15.14	14.03	8.74	27.50	26.09
VJA42-16-1	19.00	25.51	30.64	19.85	21.34	12.52	35.09	18.20
VJA43-16-1	28.40	30.54	35.32	21.79	26.86	14.98	37.38	31.79
VJA43-18-2	30.60	28.55	33.52	22.99	23.37	14.01	39.74	29.39
VJA43-18-1	35.00	35.05	40.75	26.45	29.87	17.19	44.94	35.32
VJA42-20-1	20.50	29.71	34.74	24.19	24.14	14.58	41.93	27.39
VJA43-20-1	37.00	36.21	42.24	27.65	30.64	17.76	47.13	37.77
VJB43-20-2	23.40	36.79	42.97	28.25	31.02	18.04	48.21	25.81
VJD42-20-1	15.00	26.75	32.02	21.13	22.17	13.12	37.34	19.78
VJD42-20-2	17.88	33.25	39.24	24.59	28.66	16.30	42.53	25.21
VJD43-20-1	17.80	31.43	36.55	22.71	27.45	15.41	38.97	21.98
VJE42-20-1	38.80	28.87	33.86	23.32	23.58	14.16	40.33	41.14
평균(실험/계산)	1.00	0.92	0.78	1.17	1.11	1.87	0.67	0.92
편차(실험/계산)	0.00	0.32	0.27	0.36	0.42	0.65	0.20	0.12
분산(실험/계산)	0.00	0.10	0.07	0.13	0.17	0.42	0.04	0.01

P_{max} : 실험 결과값

Neural : 신경망의 예측값

기타 : 제안식의 계산값

Chakrabarti의 제안식은 0.70~1.96의 범위로 평균 1.17, 표준 편차 0.36, Jensen의 제안식은 0.62~1.27의 범위로 평균 1.11, 표준 편차 0.42, Abdul-Wahab의 제안식은 1.09~3.46의 범위로 평균 1.87, 표준 편차 0.65, Tassios의 제안식은 40~1.07의 범위로 평균 0.67, 표준 편차 0.2, 그리고 신경망 예측 결과는 0.7~1.09의 범위로 평균 0.92, 표준편차 0.12로 나타났다. 평균값에서는 V.I 공법의 제안식과 신경망과 같았지만, 표준 편차에서는 다른 제안식들에 비해 신경망이 가장 낮게 나타났다.

2) 전체적으로 분석해 볼 때, L.V.I 공법의 제안식, Chakrabarti의 제안식과 신경망의 예측 결과가 다른 식들에 비해 비교적 실험값과 근접했으며, A type 실험체의 경우, L.V.I, Chakrabarti, Jensen의 제안식과 신경망의 예측 결과가 실험값보다 적게 나와 접합부의 최대 전단 내력을 평가하는데 안전할 것으로 사료된다. B, D, E type의 실험체에서는 신경망이 실험값에 가장 근접했으며, Abdul-Wahab의 식은 실험값보다 계산값이 작게 나타났지만 안전한 것으로 사료된다.

3) 실제 구조물에서 수직 접합부의 다양한 형상과 변수에 따라 달라질 수밖에 없는 전단 저항 능력을 고려함에 있어서 기존의 제안식들은 적용 가능한 모든 변수를 고려하는데 한계가 있지만, 신경망은 다양한 비선형 변수에 대한 적응력이 뛰어나기 때문에, 적절한 초기치와 변수들의 분류로 정확한 예측 결과를 기대할 수 있다.

4. 결 론

본 연구에서는 최근 인공지능의 한 분야로 많은 연구가 진행되고 있는 신경망의 역전파 학습 알고리즘을 이용해 프리캐스트 콘크리트 수직 접합부의 최대 전단 내력을 예측함에 있어서, 기존의 제안식에 의한 계산 결과와 신경망의 예측 결과를 비교하여 신경망의 적용 가능성을 연구해 보았다. 결과는 다음과 같다.

1) 신경망은 수직 접합부의 변수간 비선형 관계와 입(출력 패턴들을 신경망의 자기조직화(self-organizing) 기능을 통해서 학습할 수 있었기 때-

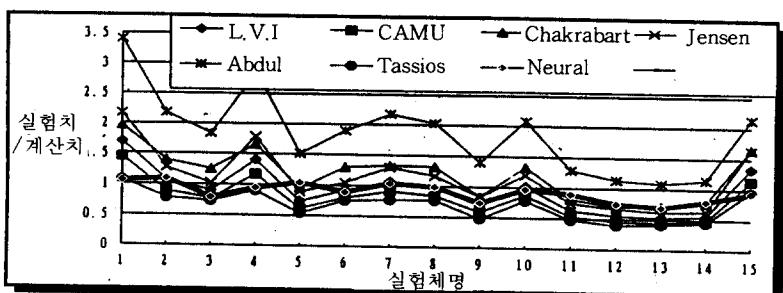


그림 9 기존 제안식의 계산 결과와 신경망의 예측 결과 비교
 1:VJA41-14-1 2:VJA42-14-1 3:VJA43-14-1 4:VJA41-16-1 5:VJA42-16-1 6:VJA43-16-1
 7:VJA43-18-2 8:VJA43-18-1 9:VJA42-20-1 10:VJA43-20-1 11:VJB43-20-2 12:VJD42-20-1
 13:VJD42-20-2 14:VJD43-20-1 15:VJE42-20-1

그림 9 기존 제안식의 계산 결과와 신경망의 예측 결과 비교

문에, 전단 내력 예측에 다른 기존 제안식들에 비해 만족스러운 결과를 얻을 수 있었으며, 결과적으로 신경망은 많은 비선형 문제를 갖고 있는 구조 실험 결과 예측에 도입될 수 있다.

2) 비록 신경망의 예측 가능성은 입증되었지만, 수직 접합부의 거동에 수반되는 변수가 매우 다양한 것에 의해 신경망의 학습에 적용한 데이터의 종류는 매우 제한적이었다. 따라서 실무에 직접 적용을 하기 위해서는 보다 다양한 시공 현장의 자료와 지식들이 필요하며, 이것들을 데이터베이스화할 수 있는 지식 기반 시스템(knowlege based expert system)과의 인터페이스¹⁵⁾를 통해서 수직 접합부의 실용 설계 시스템(인공 신경 회로망 지식 기반 시스템)을 구현하는 것이 향후 연구 과제이다.

참 고 문 헌

1. 이리형외 14인, 한양대학교 산업과학연구소, 고층아파트 대형 콘크리트 판넬구조 시스템 개발에 관한 연구, 1992.2
2. 윤재진, 남정수, “프리캐스트 콘크리트 전단키 접합부의 극한강도 예측방법”, 콘크리트 학회논문집, 4권 4호, 1992.12, pp141
3. I. Flood, N. Kartam, “Neural networks in civil engineering. I : Principles and Understanding”, *J.Comp. In Civ.Engng.*, ASCE, 1994, 8(2), pp131-147
4. J. Ghaboussi, J. H. Jr. Garret, and X. Wu, “Knowledge-based modeling of material beh-
- avior with neural networks”, *J.Engng.Mech.*, ASCE, 1991, 117(1), pp132-153
5. M. F. Elkordy, K. C. Chang, and G. C. Lee, “Application of neural networks in vibration signature analysis”, *J.Engng.Mech.*, ASCE, 1994, 120(2), pp250-265
6. 김대수, 신경망의 이론과 응용(I), 하이테크 정보, 1994.
7. J. M. Zurada, *Artificial neural Systems*, Info Access Distribution Pte Ltd, 1992
8. 이정학, 이인모, “인공 신경망 이론을 이용한 말뚝의 극한지지력 해석(I)-이론”, 한국 지반 공학회지, 10권 4호 1994.12.
9. 이철욱, 문현구, “암반터널 예비설계를 위한 인공 신경회로망 전문가시스템의 개발”, 한양 대학교 대학원 석사학위 논문, 1993.6.
10. Y. H. Pao, *Adaptive pattern recognition and neural networks*, Addison-Wesley, 1989
11. J. K. Wu, *Neural networks and simulation methods*, Dekker, 1994.
12. 서수연, 이리형, 대형 콘크리트 판구조의 접합부 거동에 대한 연구, 한양대학교 대학원 박사학위 논문, 1994.12
13. 이리형외 14인, 한양대학교 산업과학연구소, 고층아파트 대형 콘크리트 판넬구조의 접합부에 관한 연구, 1990. 7.
14. J. L. Rogers, “Simulating structural analysis with neural network”, *J.Comp. in Civ.Engng.*, ASCE, 1994, 8(2), pp252-265
15. 이승창, 이병해, “통합 구조 설계 시스템을 위한 엔지니어링 데이터베이스 구축”, 대한건축학회 논문집, 10권 11호, 1994.11, pp279~289

(접수일자 : 1996. 1. 15)