

# 인공신경망을 이용한 전단보강근이 없는 철근콘크리트 보의 전단강도에 대한 예측

## Prediction of Shear Strength Using Artificial Neural Networks for Reinforced Concrete Members without Shear Reinforcement

김 강 수†                      정 성 문\*                      한 상 을\*\*  
Kim, Kang-Su                  Jung, Sung-moon                  Han, Sang-Eul  
(논문접수일 : 2005년 2월 18일 ; 심사종료일 : 2005년 6월 2일)

### 요 지

철근콘크리트 부재의 전단거동에 대한 오랜 연구에 의하여 이에 대한 다양한 이론모델들과 제안식들이 존재한다. 그러나 전단거동의 메커니즘이 복잡하고 영향을 미치는 요소들이 많아서 이론모델들은 대부분 매우 복잡한 경향이 있고, 실험에 의한 제안식들은 제한된 범위내의 실험변수에 대해서만 유효한 경우가 많다. 이러한 문제점을 해결할 수 있는 대안의 하나로써 인공신경망이 여러 연구자들에 의하여 제안되어 왔으며, 본 논문에서는 인공신경망을 이용하여 전단보강근이 없는 철근콘크리트 보의 전단강도를 예측하였다. 특히, 기존의 전단실험결과를 광범위하게 모아 구축한 데이터베이스를 활용함으로써 넓은 범위의 구조변수들을 포함한 다양한 부재들을 인공신경망의 훈련자료로 이용하였고, 인공신경망에 의한 전단강도 예측 결과를 ACI의 규준식, Zsutty, Okamura의 제안식들과도 비교 분석하였다.

ACI의 규준식은 전단보강근이 없는 철근콘크리트 부재에 대해서 매우 부정확한 전단강도를 제공하였으며, Zsutty의 제안식은 ACI의 규준식에 비해 향상된 예측 결과를 보였으나 부재의 크기효과를 반영하지 못하였다. Okamura의 제안식은 주요 변수들의 영향을 비교적 잘 반영하여 상당히 정확하면서도 안정적인 전단강도를 제공하였다. 이에 비해 인공신경망은 실험 결과에 가장 근접한 부재의 전단강도를 제공함으로써, 다양한 변수들의 영향을 매우 정확하게 반영할 수 있는 것으로 나타나서 인공신경망이 전단강도와 같이 메커니즘이 복잡하고 영향을 끼치는 변수들이 많은 다른 구조적 거동이나 강도를 예측 하는데 매우 적절한 수단을 제공할 수 있음을 보여주었다.

**핵심용어** : 인공신경망, 전단강도, 전단설계, 철근콘크리트 보, 전단 메커니즘

### Abstract

Due to the complex mechanism and various parameters that affect shear behavior of reinforced concrete (RC) members, models on shear tend to be complex and difficult to utilize for design of structural members, and empirical relationships formulated with limited test data often work for members having a specific range of influencing parameters on shear. As an alternative approach for solving this problem, artificial neural networks have been suggested by some researchers. In this paper, artificial neural networks were used to predict shear strengths of RC beams without shear reinforcement. Especially, a large database that consists of shear test results of 398 RC members without shear reinforcement was used for artificial neural network analysis. Three well known approaches for shear strength of RC members, ACI 318-02 shear provision, Zsutty's equation, and Okamura's relationship, are also evaluated with test results in the shear database and compared with neural network approach.

While ACI 318-02 provided inaccurate predictions for RC members without shear reinforcement, the empirical equations by Zsutty and Okamura provided more improved prediction of shear strength than ACI318-02. The artificial neural networks, however, provided the best prediction of shear strengths of RC beams without shear reinforcement that was closest to test results.

**keywords** : artificial neural network, shear strength, shear design, reinforced concrete beam, shear mechanism

† 책임저자, 정회원 · 일리노이 주립대학교 토목공학과 연구원  
전화 : 1-217-333-6930 ; Fax : 1-217-333-9464  
E-mail: Email: kangkim@uiuc.edu

\* 일리노이 주립대학교 토목공학과 연구원

\*\* 정회원 · 인하대학교 건축공학과 교수

• 이 논문에 대한 토론을 2005년 9월 30일까지 본 학회에 보내주시면 2005년 12월호에 그 결과를 게재하겠습니다.

### 1. 서 론

철근콘크리트 부재의 휨모멘트에 대한 거동은 그 이론과 해석이 간단 명료하면서도 매우 정확한 예측이 가능하지만 전단거동에 대한 예측은 상대적으로 정확도가 많이 부족한 편이다. 그러나, 그동안 수행된 연구에 의하여 전단 거동에 대한 이해도 많이 향상되었으며 이에 대한 설득력있는 이론모델들도 상당수 존재하게 되었다(ASCE-ACI Committee 445, 1998). 이런 모델중에는 전단설계기준에 이미 반영된 모델도 있다. 그럼에도 불구하고, 본질적으로 전단거동에 대하여 영향을 미치는 변수들이 많고, 그 메커니즘이 복잡하기 때문에 대부분의 이론모델들은 복잡한 계산과정을 요구하게 되어, 실제 전단설계에 사용하기에는 어려움이 많다. 또한, 모델들에 따라 전단강도 예측결과에 상당한 차이를 보이고 있어 연구자들 사이에서 이론적 모델에 대한 공감대가 형성될 수 있는 수준에는 아직 도달하지 못하였다. 따라서 대부분의 전단설계기준들은 실험결과를 토대로 회귀분석을 이용한 실험식을 사용하고 있으며, 이러한 접근방법은 본질적으로 몇가지 문제점을 가지고 있다. 첫째는, 비교적 제한된 개수의 실험데이터를 이용함으로써 제한된 범위의 구조변수들에 대한 영향만을 반영할 수 밖에 없다는 점이다. 둘째로, 차원이 다른 여러 변수들에 대하여 회귀분석법만 적용할 경우 각 변수의 중요도를 고려한 가중평가가 어려우며, 많은 변수들을 고려할수록 상대적으로 복잡한 실험식이 유도될 수밖에 없고, 그 실험식 또한 정확도에 상당한 한계가 있다는 점이다.




그림 1 Shear transfer of cracked reinforced concrete beams without shear reinforcement

이러한 문제점을 해결할 수 있는 대안의 하나로서 인공신경망(artificial neural network, ANN or NN)이 여러 연구자들에 의하여 제안되어 왔다(Hertz 등, 1994; Reed

등, 1999). 지난 십 수년간 인공신경망분석은 이와 같이 변수가 많고 메커니즘이 복잡한 재료나 구조부재의 거동에 대하여 이미 여러차례 적용되어 그 잠재력을 확인한 바 있다(Goh, 1995; Sanad 등, 2001). 인공신경망은 훈련과정(training process)을 통하여 복잡한 메커니즘을 재현해 낼 수 있는 장점이 있다. 그러나 인공신경망의 성공적인 적용을 위해서는 신뢰할 수 있는 가능한 많은 데이터를 토대로 해야된다. 모든 변수를 고려한 광범위한 실험데이터를 이용함으로써, 앞서 언급된 것처럼 제한된 구조변수의 제한된 데이터만을 고려하여 발생하는 문제점을 극복할 수 있다. 따라서 본 연구에서는 광범위한 실험데이터를 수집하여 구축되었고, ACI Subcommittee 445(Shear and Torsion)에 의하여 그 신뢰성이 검증된 바 있는 데이터베이스(Reineck 등, 2003)를 인공신경망분석에 활용하였다. 인공신경망은 주어진 변수들 간의 복잡한 상관관계를 잘 묘사해 낼 수 있는 반면에, 회귀분석과 마찬가지로 주어진 변수의 범위 안에서만 정확한 값을 제공하기 때문에, 실험데이터 밖의 범위(예: 주어진 콘크리트강도의 밖의 범위)에는 사용하지 않아야 한다.

본 논문에서는 전단보강근이 없는 철근콘크리트 부재의 전단거동에 대하여 살펴보고, 여기서 사용된 데이터베이스에 대해서 간략히 소개한 후, 인공신경망을 이용하여 전단강도를 평가하는 방법과 그에 대한 결과를 다른 방법들과 비교하여 분석한다.

### 2. 전단보강근이 없는 철근콘크리트 부재의 전단거동

철근콘크리트 부재의 전단거동은 전단보강근의 유무에 따라 상당한 차이를 보일 수 있으며, ASCE ACI Committee 445(1973, 1998)에 의하여 잘 정리된 바 있다. 여기서는 전단보강근이 없는 철근콘크리트 부재의 전단거동을 이해하기 위하여 전단전달 메커니즘, 전단강도에 영향을 미치는 주요 변수들과 전단에 대한 이론적 모델 또는 실험적 접근 방법들에 대하여 살펴본다.

#### 2.1 전단전달 메커니즘

철근콘크리트 부재의 전단전달 메커니즘은 그림 1에 나타난 바와 같이 일반적으로 균열이 없는 휨압축 영역, 균열면에서의 전단전달(interface shear transfer), 장부작용(dowel action), 아치작용(arch action), 균열부에서의 잔류인장응력(residual tensile stresses) 등으로 알려져 있다(ASCE-ACI Committee 445, 1973, 1998). 그러나, 이러한 여러 기본 메커니즘의 역할은 부재의 특성에 따라 상대적인 다른 크기로

나타날 수 있고, 연구자들 사이에서도 이 메커니즘들의 상대적인 중요도에 대한 견해차가 있으며, 그 결과 여러 가지 다른 성격의 전단이론모델들이 발표되었다.

균열이 없는 휨압축영역에 의한 전단전달은 압축축의 중립축 깊이에 의하여 제한받게 된다. 따라서 압축력이 없는 얇은 보(slender beam)에서는 이에 의한 전단전달이 상대적으로 작다. 균열면에서의 전단전달은 균열의 폭과 균열면의 거칠기 등에 의하여 영향을 받으며, 균열의 폭이 클수록, 균열면의 거칠기가 작을수록 감소된다. 균열면의 거칠기는 보통 골재의 크기가 클수록 높아지지만 고강도 콘크리트에서는 균열이 골재를 통과하기 때문에 균열면의 거칠기가 상대적으로 낮아지게 되어, 균열면에서의 전단전달이 감소된다. 장부작용은 균열주위의 인장철근에 의하여 저항되는 전단전달을 일컬으며, 전단보강근이 없는 부재에서는 전단보강근이 있는 부재에 비하여 이에 의한 전단전달은 비교적 작지만, 주근량이 많을수록, 또한 주근 주위의 콘크리트 양이 많을수록 증가한다. 아치작용은 사인장 압축대를 통하여 지점으로 직접 전단전달이 이루어지는 것을 일컬으며 깊은 보(deep beam)에서 가장 중요한 역할을 한다. 균열부에서의 잔류인장응력은 균열폭이 비교적 작은 경우(0.05~0.15mm 정도)에 콘크리트의 미립자가 연결고리가 되어 인장응력이 균열을 넘어 전달되는 것으로 주로 작은부재에서 그 역할이 큰 것으로 알려져 있다.

## 2.2 전단 전달에 미치는 주요변수

전단전달 메커니즘과 전단강도에 영향을 미치는 주요변수들은 콘크리트강도, 부재의 크기(또는 크기효과, size effect), 전단스팬비, 주근량, 축력 등이다(ASCE-ACI Committee 445, 1973, 1998).

일반적으로 콘크리트강도가 높을수록 부재의 전단강도도 증가되나 콘크리트의 압축강도보다는 인장강도의 영향이 더 큰 것으로 알려져 있다. 그러나 콘크리트의 인장강도는 콘크리트의 압축강도에 비하여 측정결과의 편차가 큰 편이며, 보통 콘크리트의 압축강도를 이용한 함수로 표현되고 있다.

크기효과는 부재의 유효깊(depth)이 클수록 전단강도가 감소되는 것을 일컫는다. 이는 Kani(1967)와 Shioya(1989) 등에 의하여 많은 연구가 이루어졌으며, 약 3000mm의 높이를 갖는 부재는 100mm 높이의 부재에 비하여 단지 1/3의 전단강도를 가지는 것으로 보고되었다. Bazant(1984)는 크기효과를 잔류인장응력(residual tensile stress)의 감소에 의한 것으로 해석하였고, Collins(1998)나 Reineck(1990) 등 다른 연구자들은 큰 부재에서 상대적으로 큰 균열폭에 의하여 균열면에서의 전단전달의 감소에 의한 것으

로 판단하고 있다. 전단스팬비가 작은 깊은 보(a/d<2.5)는 아치작용에 의하여 상대적으로 높은 전단강도를 가지게 되며, 이러한 부재는 스트럿 타이 모델(strut and tie model)로 설계하는 것이 좋다. 본 연구에서 사용된 데이터베이스에서는 전단스팬비가 2.4보다 작은 부재들(a/d<2.4)은 배제되었음을 밝혀둔다. 주근량이 감소할수록 콘크리트 부재의 전단강도도 감소되는데, 이는 같은 크기의 하중에 대하여 주근량이 감소할 경우에 휨모멘트와 전단에 의한 주인장철근의 응력과 변형율이 증가하게 되어 균열폭이 증가하기 때문이다. 또한, 주근량이 적어지면 장부작용도 감소되어 역시 전단강도의 감소를 가져온다. 철근콘크리트 부재는 인장력을 받으면 전단강도가 감소하며, 압축력이 작용하면 전단강도가 커지는 장점과 함께 파괴모드가 취성적인 경향이 되는 단점이 있다. 본 연구에서는 축력을 받는 부재는 포함되지 않았다.

## 2.3 전단전달 해석을 위한 접근방법

앞서 살펴본 바와 같이 철근콘크리트 부재의 전단전달 메커니즘은 매우 복잡하고 영향을 미치는 주요변수들도 다양하다. 전단전달의 여러 기본 메커니즘의 역할은 부재의 특성에 따라 상대적으로 다른 크기로 나타날 수 있고, 연구자들 사이에서도 이 메커니즘들의 상대적인 중요도에 대한 견해차가 있으며, 그 결과 여러가지 다른 성격의 전단 실험식과 이론모델들이 발표되었다.

전단보강근이 없는 부재에 대한 이론모델들은 구조적 거동과 파괴에 기초한 모델, 파괴역학, 비선형유한요소해석 등으로 구분될 수 있다(ASCE-ACI Committee 445, 1998). 구조적 거동과 파괴에 기초한 모델들에는 Tooth Model, STM, 콘크리트의 인장대를 고려한 트러스모델 등이 있다. 파괴역학은 균열 끝에서의 응력집중과 균열부근에서의 인장응력감소를 반영할 수 있어 전단보강근이 없는 부재에 매우 적합하다. 비선형유한요소해석은 Isenberg(1993) 등에 의하여 발전되었으며, 수정압축장이론(modified compression field theory; Vecchio 등, 1986)같은 이론모델들은 Vecchio와 Collins(1986) 등에 의하여 비선형유한요소해석이 가능하게 되었다.

지금까지 제안된 실험식이 무수히 많아서 그 내용들을 살펴보는 것은 거의 불가능하므로 여기서는 본 연구에서 인공신경망에 의한 방법과 비교 평가될 미국콘크리트학회(ACI)의 표준식 및 몇 가지 대표적인 제안식들만을 아래에 간단히 소개한다.

$$ACI\ 318(2002) : V_c = \frac{1}{6} \sqrt{f_c} b_w d \quad (1)$$

$$Zsutty(1971) : V_c = 2.2 \left( f'_c \rho_l \frac{d}{a} \right)^{1/3} b_w d \quad (2)$$

$$Okamura(1980) : V_c = 0.2 \frac{(100 \rho_l)^{1/3}}{(d/1000)^{1/4}} (f'_c)^{1/3} \left( 0.75 + \frac{1.40}{a/d} \right)^{1/3} b_w d \quad (3)$$

여기서,  $V_c(N)$ 는 콘크리트의 전단내력,  $f'_c(Mpa)$ 는 콘크리트 압축강도,  $b_w(mm)$ 는 웨브폭,  $d(mm)$ 는 부재의 유효춤(depth),  $\rho_l (= A_s / b_w d)$ 은 주인장철근비(이하 주근비),  $A_s(mm^2)$ 는 주인장철근량(이하 주근량),  $a(mm)$ 는 전단스팬길이이다.

### 3. 전단보강근이 없는 철근콘크리트 부재의 전단실험 데이터베이스

전단보강근이 없는 철근콘크리트 부재의 전단실험결과를 모아 구축한 데이터베이스(Reineck 등, 2003)는 주저자가 Kuchma의 지도아래 광범위하게 수집한 전단실험 데이터와 Reineck 등이 모은 데이터를 합하여 만들어졌으며, 본래 439개의 전단실험결과를 포함하였다. 이 데이터베이스는 후에 ACI ASCE Committee 445분과에서 마련한 부재 선정기준을 통하여 세밀히 검토한 후 41개의 데이터를 제외시켜 398개의 실험결과를 포함한 데이터베이스로 축소되었다. 부재선정기준은 이론모델과 실험식 또는 표준식 등을 검증하는데 이 데이터베이스를 활용하기 위하여 만들어졌으며, 이는 최소 콘크리트 강도, 최소 부재의 크기(넓이와 높이), 휨과피에 대한 검토 등이 포함되었다. 따라서 본 연구에서 사용되는 데이터베이스는 398개의 전단보강근이 없는 철근콘크리트 부재에 대한 전단실험결과를 가지고 있다.

데이터베이스에 포함되어있는 대부분(93%)의 부재는 장방형 단면을 가지고 있고, 나머지는 T형이다. 모든 시험

체는 전단 스패니(a/d)가 2.4이상이며, 단순지지 조건하에서 한개 또는 여러개의 집중하중으로 가력되었다. 그림 2는 데이터베이스에 포함된 철근콘크리트 부재에 대한 주요변수들의 분포를 보여준다. 각 막대그래프의 좌측에는 변수, 상단에는 변수의 범위, 중앙에는 변수의 구간에 속한 부재의 개수, 하단에는 시험체의 누적개수를 나타내었다. 275개의 시험체가 40MPa이하의 콘크리트 강도를 가지고 있으며, 123개의 부재가 40MPa이상의 강도를 가졌다. 200~300mm의 유효춤을 가진 부재가 가장 많았으며, 약 2m의 유효춤을 가진 부재도 있었다. 절반 이상의 시험체가 2.0%이상의 주근비( $\rho_l$ )을 가졌으며, 58개의 시험체는 1.0% 이하의 주근비를 보유하고 있었다. 많은 시험체가 전단스팬비(a/d) 2.4~3.0사이였고, 약간의 얇은 보는 약 6.0~8.0의 전단스팬비도 가졌다.

데이터베이스에 포함되어있는 부재들의 주요변수분포를 살펴보면, 대부분 연구를 위한 시험체들이기 때문에 현장에서 실제로 건설되는 부재와는 상당히 차이가 있는 부분도 있으나, 주요변수들의 범위가 상당히 포괄적이어서 다양한 성격의 부재를 포함하고 있음을 알 수 있다.

### 4. 인공신경망을 이용한 전단강도의 예측

#### 4.1 인공신경망의 개요

인공신경망은 신경과학의 원리를 응용하여 개발된 기법으로, 간단한 인공신경들의 조합으로 복잡한 시스템이나 함수를 표현한다. 그림 3은 인공신경망중 본 연구에 사용된 다층신경망(Multilayer Neural Networks)을 도식적으로 나타낸 것이다. 왼쪽의 세 절점으로 구성된 층은 입력층(input layer), 가운데의 두 층은 은닉층(hidden layer), 오른쪽의 한 절점으로 구성된 층은 출력층(output layer)

<b>f<sub>c</sub> (MPa) :</b>	10	20			30				40	50	60	70	80	100	120	
<b>N of Tests :</b>	20			151				104		15	16	29	17	42	4	
<b>sum :</b>	20			171				275	290	306	335	352		398		
<b>d (mm) :</b>	10		200						300	400		600	900	2000		
<b>N of Tests :</b>		68			209					37		43	13	25		
<b>sum :</b>		68			277				314			357	370	398		
<b>ρ<sub>l</sub> (%) :</b>	0.1	0.75	1.0	1.25	1.5		2.0			3.0			4.0	7.0		
<b>N of Tests :</b>	30	28	30	24		67		120			67			32		
<b>sum :</b>	30	58	88	112		179		299			366			398		
<b>a/d :</b>	2.4					3.0		3.5				4.0		5.0	6.0	8.0
<b>N of Tests :</b>					155			70			98		45	20	10	
<b>sum :</b>					155			225			323		368	388	398	

그림 2 Distribution of parameters of 398 reinforced concrete members without shear reinforcement in sher database

이라 부른다. 그림의 다층신경망의 구조를 3-5-5-1로 요약해서 나타내기도 한다. 다층신경망 전체는 입력과 출력의 관계를 정의하기 때문에 하나의 함수로 간주할 수도 있지만, 일반적인 함수와 비교해서 학습의 유무라는 큰 차이 점이 있다. 다층신경망은 주어진 입력과 출력의 관계를 개개의 연결강도(weight, 그림 3에서 실선)들을 점진적으로 바꾸어서 묘사하게 된다. 이 학습 과정이 끝나면, 얻어진 인공신경망은 학습에 사용되지 않은 새로운 입력치에 대해서 적절한 출력치를 제공할 수 있게 된다.




그림 3 Illustration of multilayer neural networks

다층신경망의 학습에는 경사강하법(Gradient Descent Method)을 사용한다.

하나의 절점(node, 그림 3에서 원)은 주어진 신호를 더해서 다른 절점으로 보낸다.

$$O_i = \tanh\left(\sum_j w_{ij} \xi_j\right) \quad (4)$$

여기서,

$\xi_j$ : 다른 노드로 부터의 신호치

$w_{ij}$ : 연결강도

$O_i$ : 현재 노드에서의 출력 신호

다층신경망 전체의 오차는 다층신경망 출력치와 주어진 출력치의 차이로 정의된다.

$$E(\mathbf{w}) = \frac{1}{2} \sum_i [\zeta_i - O_i]^2 \quad (5)$$

여기서,

$O_i$ : 다층신경망으로 계산한 출력치

$\zeta_i$ : 주어진 출력치

오차는 경사강하법을 이용하여 줄이게 된다.

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (6)$$

여기서,

$\eta$ : 학습률(learning rate)

학습의 보다 자세한 과정은 Hertz 등(1991)의 저서에서 찾아볼 수 있다. 본 논문에서는 보다 빠른 학습을 위하여 RPROP(Riedmiller 등, 1993)을 사용하였다.

RPROP(resilient propagation)은 보다 효율적인 학습을 위해 전통적인 경사강하법을 개량한 것으로, 국소경사정보(local gradient information)를 이용하여 연결강도를 수정한다. 이를 위해서 모든 연결강도에 대해서 새로운 변수인 연결강도 수정치  $\Delta_{ij}$ 를 도입한다.

$$\begin{aligned} \Delta w_{ij} &= -\Delta_{ij} & \text{if } \partial E / \partial w_{ij} > 0 \\ \Delta w_{ij} &= +\Delta_{ij} & \text{if } \partial E / \partial w_{ij} < 0 \end{aligned} \quad (7)$$

즉, 전통적인 경사강하법이 모든 연결강도들에 대해서 똑같은 학습률을 사용하는 반면에, RPROP에서는 각각의 연결강도에 대해서 독립적인 강도 수정치  $\Delta_{ij}$ 를 사용한다. 이는 경사강하법의 느린 학습속도의 주요 원인이 수많은 연결강도들의 서로 다른 수렴 속도를 고려하지 않았기 때문이라는 가설에 근거한 것이다. 연결강도 수정치는 진행이 국소오차의 최소치를 향해 가고 있을 경우는 더 빠른 수렴을 위해 조금 증가시켜주고, 국소오차의 최소치를 막 벗어났을 경우는 감소시켜 준다.

$$\begin{aligned} \Delta_{ij}^{(t)} &= \eta^+ \times \Delta_{ij}^{(t-1)} & \text{if } \partial E^{(t-1)} / \partial w_{ij} \times \partial E^{(t)} / \partial w_{ij} > 0 \\ \Delta_{ij}^{(t)} &= \eta^- \times \Delta_{ij}^{(t-1)} & \text{if } \partial E^{(t-1)} / \partial w_{ij} \times \partial E^{(t)} / \partial w_{ij} < 0 \end{aligned} \quad (8)$$

여기서, 편미분의 부호가 바뀌었다는 건 이전의 변화치가 너무 커서 국소오차의 최소치를 지나쳤다는 것이고, 따라서  $\Delta_{ij}$ 를 감소시키고 연결강도의 변화치도 무효화한다.  $\eta^+$ 는 증가,  $\eta^-$ 는 감소를 위한 것으로  $0 < \eta^- < 1 < \eta^+$ 이다. 본 연구에서는  $\eta^+ = 1.2$ ,  $\eta^- = 0.5$ 를 사용하였다.

#### 4.2 인공신경망과 진단강도 예측

인공신경망은 학습을 통해 복잡한 입출력 관계를 묘사할 수 있고, 많은 뉴런들의 조합을 사용하여 오차에 덜 민감하기 때문에 다음과 같은 경우에 유리하게 적용될 수 있는 기법이다. 첫째, 입출력의 관계가 복잡하여 일반적인 함수로 표현하기 힘들 때 사용할 수 있다. 둘째, 입출력치가 한번에 모두 주어지는 것이 아니라, 이전에 주어진 입출력치들을 보완하는 새로운 입출력치가 지속적으로 주어질 때 유리하다. 기존의 함수를 사용한 방법은 새로운 입출력치에 대해 이미 결정한 함수를 바꾸기가 쉽지 않으나, 인공신경망은 이러한 경우를 포함하는 일반적인 학습기법이 확립되어 있

기 때문에 새로운 입출력치가 주어졌을 때 기존의 인공신경망을 쉽게 향상시킬 수 있다. 세째, 입출력치가 어느 정도의 오차를 포함하고 있을 경우, 함수를 사용한 방법은 오차에 민감할 수 있으나, 인공신경망 기법은 오차에 보다 덜 민감하게 사용될 수 있다(Ghaboussi, 2001). 전단강도 예측은 이 모두에 해당하기 때문에 인공신경망을 적용하기에 이상적인 문제라고 할 수 있다.

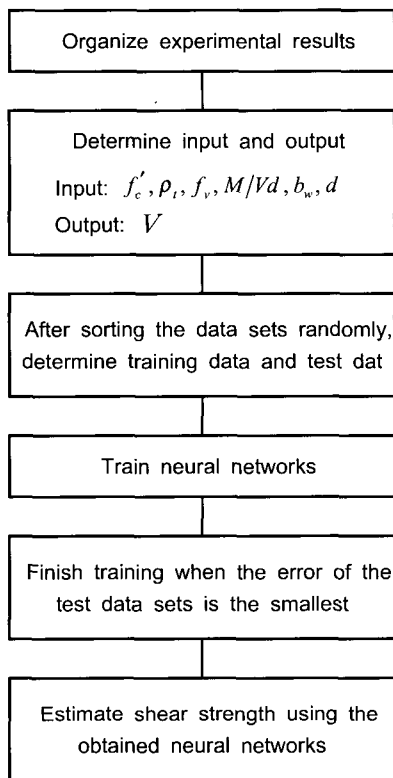


그림 4 Flowchart of prediction of shear strength of reinforced concrete members using neural networks

그림 4는 인공신경망을 이용한 전단강도 예측 과정을 요약한 것이다. 입력치와 출력치의 결정은 인공신경망 기법의 성공을 위해 가장 중요한 과정으로, 출력치를 얻기 위해 꼭 필요한 값들을 입력치로 구성하여야 한다. 자료 전체를 학습에 사용하지 않고, 훈련자료(training data)와 시험자료(test data)로 나누어 훈련자료만을 사용하는 이유는 과대적합(over-fitting)을 방지하기 위해서이다. 과대적합이란 반복(iteration) 회수가 늘어남에 따라 주어진 자료는 잘 근사하면서 새로운 자료에 대해서는 큰 오차를 보이는 현상을 말한다. 이를 방지하기 위해서는 무작위로 추출해 놓은 시험자료의 오차를 최소화할 때까지 학습을 시키는 기법이 주로 사용된다. 이렇게 얻어진 인공신경망은 훈련치에 포함되지 않은 새로운 입력치에 대해서도 매우 정확한 출력치를 제공한다.

#### 4.3 전단강도 예측을 위한 인공신경망 구성

본 연구에서는 콘크리트강도( $f'_c$ ), 휨 철근비( $\rho_t$ ), 철근의 인장강도( $f_y$ ), 전단스팬비(a/d or M/Vd), 웨브의 넓이( $b_w$ ), 부재의 유효춤( $d$ )을 인공신경망의 입력치로, 전단강도를 인공신경망의 출력치로 사용하였고, 6-8-8-1구조의 다층신경망을 사용하여 전단실험 데이터베이스로부터 얻어진 자료로 학습을 수행하였으며, 전단실험 데이터베이스의 398개 자료를 무작위로 섞어 그 중 350개를 훈련자료로, 48개를 시험자료로 사용하였다. 그림 5는 학습의 진행에 따른 평균오차의 증감을 나타낸 것이다. 학습자료의 평균오차는 계속해서 감소하는 반면에, 시험자료의 평균오차는 대략 20,000 반복회수까지 감소하다가 증가하는 추이를 보인다. 전단강도 데이터베이스에 포함되지 않은 새로운 경우에 대한 전단강도 예측 효과를 극대화하기 위해서는 시험자료의 오차가 최소일때의 인공신경망을 사용하여야 한다. 따라서, 반복회수 2,000일 때의 인공신경망을 전단강도 예측용 모델로 선택하였으며, 본 연구에서는 이 선택된 모델로 구성된 인공신경망을 이용하여 전단강도를 산출한다.

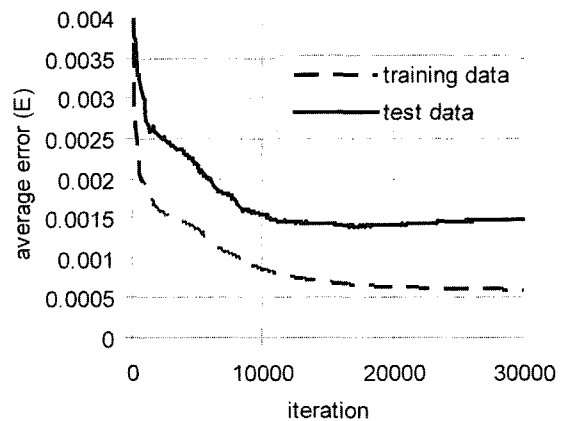


그림 5 Changes in average error for different number of iteration process

#### 5. 인공신경망을 이용한 전단강도 예측과 기존식들에 의한 예측의 비교

본 연구에서는 식 (1), (2), (3)에 표현되어 있는 ACI 318 02규준식, Zsutty와 Okamura의 제안식들과 인공신경망에 의하여 398개의 전단보강근이 없는 철근콘크리트 부재의 전단강도를 구하였으며, 이를 실험치와 비교하였다. ACI규준에 의하여 산출한 전단강도는 강도저감계수와 하중계수를 고려하지 않았으며, 콘크리트의 압축강도에 대한 제한도 무시하였다.

Table 1 Summary of evaluation on shear strength predictions by four different approaches

Method	ACI318 ( $V_{test}/V_{ACI}$ )	Zsutty ( $V_{test}/V_{Zsutty}$ )	Okamura ( $V_{test}/V_{Okamura}$ )	Nural networks ( $V_{test}/V_{NN}$ )
average	1.414	1.069	1.159	1.005
stdev	0.482	0.252	0.234	0.145
cov	0.341	0.236	0.202	0.144
Range	Distribution of $V_{test}/V_{prediction}$ (%)			
>2	11.6	0.3	0.5	0.0
1.3~2.0	47.0	15.1	18.8	3.8
0.85~1.3	30.7	69.8	77.6	87.4
0.65~0.85	6.3	11.8	3.0	8.3
0.5~0.65	2.3	1.5	0.0	0.5
<0.5	2.3	1.5	0.0	0.0
Level	Fractile values			
max	3.216	2.066	2.453	1.715
99.9%	2.910	1.851	1.883	1.455
99%	2.538	1.657	1.703	1.343
95%	2.208	1.484	1.543	1.244
75%	1.740	1.239	1.316	1.103
50%	1.414	1.069	1.159	1.005
25%	1.089	0.898	1.001	0.907
5%	0.621	0.654	0.775	0.766
1%	0.291	0.481	0.615	0.667
0.1%	0.081	0.286	0.435	0.555
min	0.366	0.432	0.656	0.561

Table 1에서는 이들 네가지 방법에 의하여 산출한 전단 강도 예측치들의 정확도를 몇가지로 요약하여 나타내었다. Table 1의 윗부분은 실험치/계산치( $V_{test}/V_{prediction}$ )의 평균, 표준편차와 분산계수를 나타내었다. 네가지 방법중 ACI는  $V_{test}/V_{ACI}$ 의 평균 1.414, 분산계수 0.341로서 가장 좋지 못한 결과를 보였으며, Zsutty의 제안식은 이에 비해 매우 향상된 결과를 나타내었다. 또한, 더 많은 변수를 고려한 Okamura의 제안식은 이 두 방법보다 훨씬 더 정확한 예측치를 제공하였다. 그러나, 인공신경망에 의한 전단강도는 평균 1.005, 분산계수 0.144로서 다른 방법들보다 월등히 정확한 예측치를 주었다.

Table 1의 가운데 부분에는 실험값/계산치( $V_{test}/V_{prediction}$ )의 분포를 나타내었다. ACI규준식에 대하여  $V_{test}/V_{ACI}$ 의 값들이 상당히 넓게 분포되어 있음을 알 수 있다.  $V_{test}/V_{ACI}$ 의 값들이 1.3~2.0사이에 47%로 가장 많이 분포되어 있었지만 0.85이하인 값들이 10%를 초과했으며, 특히 0.65이하인 값들도 거의 5%에 달했다. Zsutty의 제안식은  $V_{test}/V_{Zsutty}$ 의 값들이 대부분(69.8%) 0.85~1.3사이에 분포되어 있어 ACI규준식에 비하여 매우 향상된 전단강도 예측치를 보여

주었다. 그러나 Zsutty의 제안식 역시 0.65~0.85사이의 값들이 11.8%나 되었고, 0.65이하인 값들도 3%에 육박했다. 이들 두 방법에 비해 Okamura의 제안식은 더욱 정확한 예측치를 제공하였는데 0.85~1.3 사이에  $V_{test}/V_{Okamura}$ 의 대부분(77.6%)이 분포되었으며, 약간의 데이터만이 그외의 구간에 분포되었다. 인공신경망에 의한 예측치는  $V_{test}/V_{NN}$ 의 87.4%가 0.85~1.3사이에 분포되어 가장 많은 예측치가 실험결과에 가까운 결과를 보여주었으며, 분산계수도 0.144로서 가장 낮은 산포도를 나타내었다.

Table 1의 맨 아래 부분에는 실험값/계산치( $V_{test}/V_{prediction}$ )의 분위수(Fractile value)값들을 나타내었다. 분위수값들은 규준식이나 제안식들의 안정성을 평가할 수 있다. 예를 들어, 전단보강근이 없는 철근콘크리트 부재를 ACI규준식을 사용하여 설계하였을 경우 5%의 부재들이 필요한 설계강도의 약 62%의 전단강도만을 가질 수 있음을 나타낸다. 이에 비해 Zsutty, Okamura의 제안식들은 부재의 5%가 필요한 설계강도의 약 65%와 78%를 각각 가질 수 있음을 보여준다. 인공신경망에 의하여 전단설계를 하였을 경우에는 부재의 5%가 필요한 설계강도의 약 77%를 가질 수 있음을 알 수 있어 매우 적합한 편으로 사료된다.

식 (1)~(3) 및 인공신경망에 의한 전단강도 예측치들이 각 변수에 대한 영향을 어떻게 반영하고 있는지를 구체적으로 살펴보기 위하여 그림 6~9에서는 실험값/계산치( $V_{test}/V_{prediction}$ )를 각 주요변수에 대하여 나타내었다.

그림 6에서는 각각의 방법에 의한  $V_{test}/V_{prediction}$ 를 콘크리트 압축강도에 대하여 나타내었다. 앞서 언급하였듯이 전단강도는 콘크리트의 강도가 증가할수록 증가하며, 콘크리트의 인장강도에 의하여 크게 영향을 받는 것으로 알려져있다. 그러나, 고강도 콘크리트 부재는 균열이 골재를 가로질러 형성되므로 전단균열면이 상대적으로 매끈하기 때문에 전단균열면에서의 전단력 전달의 감소가 우려된다. 철근콘크리트의 전단강도는 식 (1)에서 보여지는 ACI규준식의 경우 ( $f_c$ )<sup>1/2</sup>에 비례하는 것으로 반영되었으며, 식 (2)와 (3)에서 보여지는 Zsutty와 Okamura에 의한 제안식들은 ( $f_c$ )<sup>1/3</sup>에 비례하도록 콘크리트의 강도가 고려되었다. ACI규준식은 전 범위의 콘크리트 압축강도( $f_c$ )에 대하여 큰 산포도를 보여주고 있다. 이러한 큰 산포도는 콘크리트의 강도에 대한 잘못된 반영이라기보다는 다른 변수들(부재의 크기, 주철근비, 전단스팬비 등)의 영향을 반영하지 않은 것이 더욱 큰 요인으로 판단된다. Zsutty의 제안식은 ACI규준식에 비해 매우 향상된 예측치를 보여주고 있으며, Okamura의 제안식은 정확하면서도 더욱 안정된 예측치를

가져다 주었다. 그러나 이들 세가지 방법은 콘크리트 강도가 증가할수록  $V_{test}/V_{prediction}$ 의 값들이 다소 낮아지는 경향을 보이고 있다. 이에 비해 인공신경망에 의한 예측치는 모든 콘크리트 강도의 영역에서 매우 정확하였으며, 콘크리트 강도의 증감에 상관없이 거의 일정한 수준의 평균예측치를 보여주었다.

그림 7에서는  $V_{test}/V_{prediction}$ 의 값들을 부재의 유효층(depth)에 대하여 나타내었다. 전단보강근이 없는 철근콘크리트 부재의 전단강도는 크기효과(size effect)에 의하여 부재의 크기(depth)가 클수록 전단강도가 감소된다. 그러나 ACI의 규준식과 Zsutty의 제안식은 이러한 크기효과를 고려하지

않아서 그림 7에서 보여지는 바와 같이 크기가 작은 부재에 대해서는 대단히 보수적인 예측결과를 가져다주는 반면 크기가 큰 부재에 대해서는 매우 불안정한 예측치를 보여주었다. 특히, ACI규준식에 의한 전단강도는 보의 춤이 약 700mm이상일 때 매우 안정하지 못한 예측결과를 나타내었다. 이에 비하여 Okamura의 제안식에서는 전단강도가  $d^{1/4}$ 에 반비례하도록 고려되었으며, 다양한 부재의 크기에 대하여 비교적 정확하고 안정적인 예측치를 제공하였다. 연구자들에 따라 전단강도에 대한 크기효과를 반영하는데 많은 견해 차이를 보이고 있는데, 예를들어, Bazant(1984)는 크기효과에 의하여 전단강도가  $d^{1/2}$ 에 반비례한다고 판단하




그림 6 Strength ratios versus concrete compressive strength,  $f_c$




그림 7 Strength ratios versus effective depth,  $d$






그림 8 Strength ratios versus longitudinal reinforcement ratio,  $\rho_l$




그림 9 Strength ratios versus shear span to depth ratio,  $a/d$

고 있다. 인공신경망에 의한 전단강도는 전 범위의 부재 유효춤에 대하여 실험치와 가장 가까운 평균값과 일정한 안전율을 제공하였다.

그림 8에서는 전단강도에 대한 주근비의 영향이 각 방법들에서 어떻게 고려되었는지를 알아볼 수 있다. 보통 주근비가 증가할수록 철근콘크리트 부재의 전단강도도 높아진다. 식 (1)에 나타나있는 ACI규준식은 주근비에 대한 영향을 전혀 고려하지 않았기 때문에 적은 주근량을 가진 부재에 대해서는 매우 낮은  $V_{test}/V_{ACI}$  값을, 많은 주근량을 가진 부재에 대해서는 매우 높은  $V_{test}/V_{ACI}$  값을 제공하였다. 특히 주근

비  $\rho_l < 1.0\%$ 인 부재에 대하여 ACI규준식이 매우 불안정한 전단강도 예측을 제공함을 알 수 있다. Zsutty와 Okamura에 의한 제안식들에서는 부재의 전단강도가  $(\rho_l)^{1/3}$ 에 비례한다. 이 제안식들은 ACI규준식에 비해 매우 향상된 결과를 보여주고 있으나, Zsutty의 제안식의 경우 주근비가  $\rho_l < 1.0\%$ 인 부재에 대하여 역시 불안정한 예측치를 보여주고 있다. 이는 주근비에 의한 영향보다 부재의 크기효과에 대한 고려가 없는 것이 더욱 큰 요인으로 판단된다. ACI규준식, Zsutty와 Okamura의 제안식들은 그 정확성의 차이에도 불구하고 주근비가 증가할수록  $V_{test}/V_{prediction}$ 도 다소 높아

지는 것을 알 수 있다. 반면에 인공신경망을 이용하는 경우에는 전 영역의 주근비에 대해서  $V_{test}/V_w$ 의 값들이 증감되는 경향이 없이 거의 대부분 정확하게 반영되는 것을 볼 수 있다.

그림 9에서는  $V_{test}/V_{prediction}$  값들을 전단스팬비에 대하여 나타내었다. 전단 스패비가 낮을수록 콘크리트 보의 전단강도는 일반적으로 높아지게 된다. 특히, 전단스팬비가 약 2.5 이하인 경우에 아치작용에 의하여 보의 전단강도는 현저하게 높아지게 된다. 본 연구에서는 앞서 언급된 바와 같이 전단 스패비가 2.4이상인 경우에 대하여만 다루고 있다. ACI규준식은 전단강도에 대한 전단스팬비의 영향을 반영하지 않았기 때문에 낮은 전단스팬비를 가진 부재에 대하여  $V_{test}/V_{ACI}$  값들이 매우 높은 것을 볼 수 있으나,  $V_{test}/V_{ACI}$ 의 상당수가 실험치에 비해 매우 낮은 것도 보여진다. 이것은 대체적으로 다른 변수(주근비, 유효출 등)들의 영향 때문인 것으로 사료된다. Zsutty의 제안식은 ACI규준식에 비해 상당히 양호한 산포도를 나타내었다. Okamura의 제안식은 전단스팬비가 약 3.0이하인 부재들에 대해 다소 보수적인 예측치를 보여주었으나 전반적으로 매우 정확한 전단강도를 제공하였다. 인공신경망에 의한 전단강도는 다양한 전단스팬비의 범위에서 매우 정확하고 일정한 수준의 예측 평균값을 보여주었다.

## 6. 결 론

본 연구에서는 인공신경망을 이용하여 전단보강근이 없는 철근콘크리트 보의 전단강도를 예측하였다. 전단보강근이 없는 철근콘크리트 보의 전단거동 메커니즘과 주요변수들에 대한 고찰을 수행하였으며, 전단실험결과를 모아 구축한 데이터베이스를 이용하여 ACI규준식 및 대표적인 제안식들과 인공신경망에 의한 전단강도 예측의 정확도를 비교 분석하였다. 본 논문에서 수행한 연구를 토대로 다음과 같은 결론을 얻을 수 있다.

- 1) 전단보강근이 없는 철근콘크리트 부재의 전단실험결과를 모아 구축한 데이터베이스는 전단설계기준 및 제안식들의 정확도를 평가하는데 매우 중요한 자료를 제공하였다.
- 2) 전단보강근이 없는 철근콘크리트 부재의 전단강도에 대한 경험식들은 사용자들에게 고려되는 변수들의 영향을 알기 쉽게 전달해 줄 수 있으나, 전단강도 예측의 정확도에 비교적 한계가 있고 정확도를 높이기 위해서는 많은 주요 변수들을 고려해야 되기 때문에 매우 복잡한 형태로 나타내어야 되는 반면, 인공신경망은 이러

한 많은 변수들을 단지 입력함으로써 매우 정확한 결과를 간편하게 얻을 수 있는 장점이 있다.

- 3) ACI 규준은 전단보강근이 없는 철근콘크리트 부재의 전단강도에 대하여 매우 낮은 정확도를 보였으며, 주철근비가 낮은 부재( $\rho_l < 1.0\%$ ), 춤이 높은 보( $d > 700mm$ ) 등에 대하여 매우 안정적이지 못한 전단강도를 제공하였다.
- 4) Zsutty의 제안식은 ACI규준식에 비해 상당히 향상적인 전단강도 예측치를 주었으며, Okamura의 제안식은 더욱 정확하면서도 안정적인 전단강도를 제공하였다.
- 5) 인공신경망은 전단보강근이 없는 철근콘크리트 부재의 전단강도에 대하여 매우 정확한 예측치를 제공하였다.
- 6) 인공신경망은(전단강도와 같이) 메커니즘이 복잡하고 영향을 끼치는 변수들이 많은 다른 구조적 거동이나 강도를 예측하는데 매우 적절한 수단을 제공할 수 있음을 보여주었다.

## 참 고 문 헌

- ASCE-ACI Committee 426(1973) The Shear Strength of Reinforced Concrete Members, *Journal of Structural Division, ASCE*, 99 (6), pp.1091~1187
- ASCE-ACI Committee 445 on Shear and Torsion(1998) Recent Approaches to Shear Design of Structural Concrete, *Journal of Structural Engineering*, 124(12), pp.1375~1417
- ACI Committee 318(2002) *Building Code Requirements for Structural Concrete (ACI 318-02) and Commentary (ACI 318 R-02)*, American Concrete Institute, Farmington Hills, p.443
- Bazant, Z.P., Kim, J.K.(1984) Size Effect in Shear Failure of Longitudinally Reinforced Beams, *ACI Structural Journal*, 81(5), pp.456~468
- Collins, M.P., Kuchma, D.A.(1998) Advances in Understanding Shear Performance of Concrete Structures, *Progress in Structural Engineering and Materials*, 1(4), pp.1~10
- Ghaboussi, J.(2001) Biologically inspired soft computing methods in structural mechanics and engineering, *Structural Engineering and Mechanics*, 11(5), pp.485~502
- Goh, A.T.C.(1995) Prediction of Ultimate Shear

- Strength of Deep Beams Using Neural Networks, *ACI Structural Journal*, 92(1), pp.28~32
- Hertz, J.A., Krogh, A., Palmer, R.G.**(1991) *Introduction to the Theory of Neural Computation*, Perseus Publishing
- Isenberg, J.**(1993) *Finite Element Analysis of Reinforced Concrete Structures II*, Proc., Int. Workshop, New York
- Kani, G.N.J.**(1967) How Safe Are Our Large Reinforced Concrete Beams, *ACI Journal Proceedings*, 64, pp.128~141
- Okamura, H., Higai, T.**(1980) Proposed Design Equation for Shear Strength of R.C. Beams without Web Reinforcement, *Proc. of Japan Soc. Civ. Engrg.*, 300, pp.131~141
- Reed, R.D., Marks, R.J.**(1999) *Neural Smoothing: Supervised Learning in Feedforward Artificial Neural Networks*, MIT Press
- Reineck, K.H.**(1990) Mechanical Model for the Behaviour of Reinforced Concrete Members in Shear, Ph.D. Thesis, University of Stuttgart
- Reineck, K.H., Kuchma, D.A., Kim, K.S., Marx, S.**(2003) Shear Database for Reinforced Concrete Members without Shear Reinforcement, *ACI Structural Journal*, 100(2), pp.240~249
- Riedmiller, M., Braun, H.**(1993) A direct adaptive method for faster backpropagation learning: the RPROP algorithm, IEEE International Conference on Neural Networks, San Francisco, IEEE
- Sanad, A., Saka, M.P.**(2001) Prediction of Ultimate Shear Strength of Reinforced Concrete Deep Beams Using Neural Networks, *Journal of Structural Engineering*, 127(7), pp.818~828
- Shioya, T.**(1989) Shear Properties of large reinforced concrete member, Special Report of Institute of Technology, Shimizu Corporation, 25
- Vecchio, F.J., Collins, M.P.**(1986) The Modified Compression Field Theory for Reinforced Concrete Elements Subjected to Shear, *Journal of the American Concrete Institute*, 83(2), pp.219~231
- Vecchio, F.J., Collins, M.P.**(1986) Predicting the Resopnse of Reinforced Concrete Beams Subjected to Shear Using the Modified Compression Field Theory, *ACI Structural Journal*, 85(4), pp.258~268
- Zsutty, T.C.**(1971) Shear Strength Prediction for Separate Categories of Simple Beams Tests, *ACI Structural Journal*, 68(2), pp.138~143