

인공신경망을 이용한 이력모델에 관한 연구

A Study on the Hysteretic Model using Artificial Neural Network

김 호 성* 이 승 창** 이 학 수*** 이 원 호****
Kim, Ho-Sung Lee, Seung-Chang Lee, Hak-Soo Yi, Waon-Ho

ABSTRACT

Artificial Neural Network (ANN) is a computational model inspired by the structure and operations of the brain. It is massively parallel system, consisting of a large number of highly interconnected and simple processing units. The purpose of this paper is to verify the applicability of ANN to predict experimental results through the use of measured experimental data. Although there have been accumulated data based on hysteretic characteristics of structural element with cyclic loading tests, it is difficult to directly apply them for the analysis of elastic and plastic response. Thus, simple models with mathematical formula, such as Bi-Linear Model, Ramberg-Osgood Model, Degrading Tri Model, Takeda Model, Slip type Model, and etc, have been used. To verify the practicality and capability of this study, ANN is adapted to several models with mathematical formula using numerical data. To show the efficiency of ANN in nonlinear analysis, it is important to determine the adequate input and output variables of hysteretic models and to minimize an error in ANN process. The application example is Beam-Column joint test using the ANN in modeling of the linear and nonlinear hysteretic behavior of structure.

1. 서 론

현재 국내외의 건설기술이 지속적으로 발전함에 따라, 초고층이나 대경간 구조물의 설계 및 건설이 가능해지고 있다. 이러한 구조물이 현실화되기 위해서는 충분한 내진 성능이 확보되어야 한다. 내진성능의 확보를 위해서는 부재의 응력-변형 관계로부터 복원력 특성을 이해하고, 구조물의 거동을 예측할 필요가 있다. 현재까지 구조요소의 이력 특성에 관한 많은 데이터가 반복 재하 실험 등을 통해 축적되어 왔다. 그러나 이러한 실험데이터들은 탄소성응답해석시 직접 이용할 수 없기 때문에 수식으로 표현된 모델을 사용하고 있다. 탄소성응답해석의 기존모델로는 Bi-Linear Model, Ramberg-Osgood Model, Degrading Tri Model, Takeda Model, Slip 형 모델 등이 있으며, 이는 구조물의 특성에 따라 제안되었다. 그러나 실험을 통한 복원력특성의 이해는 많은 실험을 통한 자료의 축적이 필요하고, 이는 많은 노력과 시간이 요구된다. 반복실험의 경우 기존의 실험결과를 이용한 변수의 변화에 따른 미실험의 결과에 대한 예측이 가능하다면 실험의 반복횟수의 감소 등 여러 요소의 절감이 따른다고 사료된다.

* 학생회원, 광운대학교 건축공학과 석사과정
** 정회원, (주)현대산업개발 기술연구소 연구원
*** 정회원, 한남대학교 건축·토목환경공학부 교수
**** 정회원, 광운대학교 건축공학과 교수

본 논문의 목적은 이러한 실험에서 얻어진 데이터에 의해 미실험 결과를 신경망을 이용해 예측함에 있다. 그러나 기존의 연구보고에 의하면 미실험의 예측에 대한 가능성 및 실용성이 아직 규명되어 있지 않기 때문에 우선 이것을 명확히하기 위해서 수식으로 표현된 이력모델의 데이터를 통한 기초적인 신경망 시스템의 구축을 목표로 하였다. 예제로서 구축된 신경망을 이용한 보-기동접합부 실험 이력거동의 적용성에 대하여 고찰하였다.

2. 신경망의 이론 및 구성

2.1 신경망의 개요

신경망은 인간이나 동물들이 가지고 있는 생물학적 뇌의 신경세포(neuron)를 모델화하여 인공적으로 지능을 만드는 것이다. 즉, 인간의 뇌에 존재하는 생물학적 신경세포와 이들의 연결관계를 단순화시켜 수학적으로 모델링함으로써 인간의 두뇌가 나타내는 지능적 형태를 구현하여 공학이나 기타 여러 분야에 적용하는 것을 목적으로 한다.

2.2 신경망의 구성요소와 동작

뉴런의 인공적인 모델을 처리기 혹은 유니트(unit)라고 한다. 이는 한 처리기에 연결된 다른 처리기들로부터의 입력을 연결선의 가중치를 고려하여 더한 후, 그 결과를 적당한 전이함수(transfer function)로 처리한 후 연결된 다른 처리기로 출력한다. 또한 신경망은 정보가 들어오는 입력층(input layer), 은닉층(hidden layer), 그리고 결합 함수로부터 나온 결과를 변환하여 결과 값을 결정하는 출력층(output layer)으로 구성되며, 뉴런에 미치는 영향의 크기를 조절하는 연결강도(weight), 임계치(θ)등으로 구성된다. 그림 1은 신경의 구성을 나타낸 것이고, 그림 2는 대표적인 전이함수인 시그모이드(sigmoid)함수이다.




그림 1. 신경망의 구성




그림 2. 시그모이드 함수

2.3 학습 알고리즘

본 연구에 있어서 학습(Learning)은 신호의 흐름과는 역방향으로 흐르게 되며 O층에서 I층으로 향해 재귀적으로 계산을 실행하므로 Back Propagation(BP)기법이라 부른다. 학습의 경우에 있어서 기본적인 델타룰(Delta Rule)은 출력층과 중간층간의 시냅스 가중치에 관해서만 수정해 주고 있다. 이것을 출력층 이전의 모든 층들간의 시냅스 가중치의 수정으로 확장한 것이 일반적인 델타룰(Delta Rule)이다. BP학습은 다음과 같다. k층(I층을 1층이라 함)에 속하는 i번째 뉴런의 입출력 신호를 각각 $u_i^{(k)}$, $v_i^{(k)}$ 라 하면,

$$u_i^{(k)} = \sum_{j=1}^{N_{k-1}} W_{ij}^{(k,k-1)} v_j^{(k-1)} - \theta_i^{(k)} \quad (2.1)$$

$$v_i^{(k)} = f(u_i^{(k)}) \quad (2.2)$$

으로 주어진다. 여기서 $W_{ij}^{(k,k-1)}$ 는 (k-1)층 내의 j 번째 뉴런과 k층내의 I번째 뉴런의 시냅스 가중치이고, N_{k-1} 은 (k-1)층에 포함되는 뉴런의 수이다. 또한 $\theta_i^{(k)}$ 는 k층내의 i번째 뉴런의 임계치이고, 함수 f 는 뉴런 입출력 함수이며, 일반적으로 시그모이드(Sigmoid) 함수가 이용된다. 학습은 교사신호에 대한 네트워크 출력신호의 2승 오차 (Squared Error)로서 정의되는 오차함수가 Global Minimum에 수렴하도록 실행된다. 이것을 각 층간에 적용하고 k층에 있어서는 바람직한 출력을 v_i^k ($i=1,2,3,\dots,N_k$), 실제로 얻어지는 출력을 v_i^k ($i=1,2,3,\dots,N_k$)라 하면 오차함수 E는,

$$E = \frac{1}{2} \sum (v_i^k - v_i^k)^2 \quad (2.3)$$

으로 주어진다. 이 E를 최소가 되도록 네트워크의 시냅스의 가중치를 변화시킨다. 학습의 결과를 표시하면 시냅스 가중치의 수정량 $\Delta W_{ij}^{(k,k-1)}$ 는,

$$\Delta W_{ij}^{(k,k-1)} = \eta \gamma_i^{(k)} v_j^{(k,k-1)} \quad (2.4)$$

으로 주어진다. η 는 수렴의 속도를 결정하는 학습 변수이다. $\gamma_i^{(k)}$ 는 k층이 출력층(O층)일 경우에는

$$\gamma_i^{(O)} = (d_i - v_i^{(O)}) f'(u_i^{(O)}) \quad (2.5)$$

이다. d_i ($i=1,2,3,\dots,N_{(O)}$)는 교사신호이다. 한편 k층이 O층 이내일 때는,

$$\gamma_i^k = \left(\sum_j W_{ij}^{(k+1,k)} \gamma_j^{(k+1)} \right) f'(u_i^k) \quad (2.6)$$

이다. 식 (2.4)~(2.6)로부터 임의의 k층의 수정신호 $\Delta W_{ij}^{(k,k-1)}$ 은, I층 전의 수정신호 $\Delta W_{ij}^{(k+1,k)}$ 로부터 재귀적(Recursive)으로 계산된다.

3. 신경망을 이용한 이력 모델

3.1 연구목적 및 연구방법

본 논문에서는 신경망을 이용한 복원력 특성의 예측에 대한 적용성 및 가능성을 검증하기 위해서 Bi-Linear 와 Ramberg-Osgood 2종류의 모델을 사용하였다. 그림 3은 Bi-Linear 모델로 탄성역의 강성 K_y




그림 3. Bi-Linear Model




그림 4. Ramberg-Osgood Model

와 소성역의 강성 K_m 의 두 종류 직선으로 표현되며, $K_m=0$ 인 경우에는 완전탄소성모델이 된다. 그림 4는 Ramberg-Osgood Model로서 금속재료의 복원력 특성을 나타내는 모델로 제안되어 항복변위 d_y , 항복강도 p_y 및 지수 γ , η 의 4개의 변수에 의해 정의된다. 탄성 ($\gamma=1$)에서 완전탄소성 ($\gamma=\infty$)까지 각 종류의 복원력 특성이 표현될 수 있다. Ramberg-Osgood Model은 방추형의 이력 곡선을 나타내고 있으므로 철골구조나 철근 콘크리트 부재인 경우의 복원력 특성을 나타내는 모델로서 사용할 수 있다.

이력모델에 적용한 신경망의 구조는 입력층, 은닉층, 출력층을 가진 계층형 구조로 출력층의 뉴런수는 1개, 은닉층의 뉴런 수는 1~20개로 설정하였다. 학습용 입력데이터의 변수의 선정은 변위량에 대한 변수로 복잡한 재하이력에도 대응할 수 있도록 복원력특성에 일반적인 특성을 고려해 선정하였다. 학습에 사용한 입력데이터는 학습용의 복원력 특성을 이루는 점들 중에서 기본적으로는 학습가능하며 각 이력모델의 특성과 형태를 유지할 수 있는 점을 추출해 작성했으며 출력층은 하중으로 하였다. 그리고 복잡한 재하이력에도 대응할 수 있도록 복원력특성의 일반적인 특성을 고려한 입력데이터를 선정했다. 그림 5는 이력모델에 사용된 신경망의 구조도이며, 입력변수는 다음과 같다.

- 1) 변위량 δ
- 2) 최대 경험변위량 δ_{max}
- 3) 이전의 점에 있어서의 변위량 δ_r
- 4) 항복변위 δ_y
- 5) 항복하중 p_y
- 6) 지수 γ (Ramberg-Osgood Model의 경우)




그림 5. 이력모델을 위한 신경망 구조

학습 및 예측에 사용된 Bi-Linear모델, Ramberg-Osgood모델에 항복변위 δ_y 와 항복하중 p_y 를 다르게 설정한 TYPE A 와 TYPE B 두 가지의 경우를 고려하였다. 추정이력을 1, 2, 4, 5Cycle의 경우를 고려하였기 때문에 학습을 위한 TYPE A, B의 재하이력은 모두 3Cycle로 설정하였다. Bi-Linear 모델의 경우 간단히 표현되도록 항복 후 강성 K_m 을 0 (완전탄소성 모델)으로 설정하였다. 학습용 데이터의 수는 위에서 언급했듯이 이력모델의 특성과 형태를 유지할 수 있는 최적의 데이터수로 사료되는 갯수로 Bi-Linear모델의 Type A의 경우 32개, Type B의 경우로는 50개를, Ramberg-Osgood모델의 Type A의 경우 52개, Type B의 경우로는 76개의 데이터를 선정했다.

표 1. 신경망 구성 상세표

Network Parameters	Bi-Linear		Ramberg-Osgood	
	TYPE A	TYPE B	TYPE A	TYPE B
No. of INPUT units	5	5	6	6
No. of OUTPUT units	1	1	1	1
No. of HIDDEN units	10	10	11	11
Learning Rate	0.9	0.9	0.9	0.9
Activation Function	Sigmoidal Function		Sigmoidal Function	
No. of Training cycles	1983	2273	2321	2547

기준오차로는 반복된 시뮬레이션의 경험을 바탕으로 적절한 수렴값을 나타낼 수 있는 평균 오차값인 2.0×10^{-3} 으로 설정하였고, 은닉층의 뉴런수는 이전의 시뮬레이션에 있어 적은 오차를 보인 뉴런수를 바탕으로, Bi-Linear모델은 10개, Ramberg-Osgood모델은 11개로 설정하였다. 예측을 위한 이력모델에 대해서는 1, 2, 4, 5Cycle의 재하이력과 각각 다른 재하방법을 통해 다양한 재하이력에 대한 신경망의 예측을 평가하고자 했다. 구체적인 신경망 구성요소는 표 1에, 학습에 사용된 신경망변수와 수치는 표 2에 나타내었다.

표 2. TYPE별 변수의 설정

Parameters	Bi-Linear		Ramberg-Osgood	
	TYPE A	TYPE B	TYPE A	TYPE B
δ_y	1.0	0.5	1.0	0.5
b_y	1.5	1.0	1.5	1.0
γ	—	—	6.0	3.0

3.2 시뮬레이션 결과

학습이 완료된 TYPE A와 TYPE B의 경우 모두 학습횟수가 2,000~2,500회 이내에 오차가 2.0×10^{-3} 의 경우로 감소했으며, 학습에 사용한 은닉층의 뉴런수의 타당성을 검증하기 위해서 은닉층의 뉴런수를 1~20개로 변화시켜 가며 동일한 학습횟수(1000회)에 대해 비교했다. 그림 6은 Bi-Linear Model의 은닉층 변화에 따른 오차를, 그림 7은 Ramberg-Osgood Model의 은닉층 변화에 따른 오차를 나타내었다. 그림 6와 그림 7에서 알 수 있듯이 학습에 사용한 은닉층의 수를 10~11개로 설정한 것은 타당함을 알 수 있다.




그림 6. Bi-Linear Model의 오차변화




그림 7. Ramberg-Osgood Model의 오차변화

Cycle의 수를 1, 2, 4, 5의 경우에 대해서 재하이력을 시뮬레이션한 결과는 다음과 같다. Cycle 1과 Cycle 2의 경우 그림 8과 그림 9에서 알 수 있듯이 예측될 수 있는 데이터에 대한 학습 데이터의 수가 풍부함에 따




그림 8. Bi-Linear Model의 Cycle별 추정값

라 목표치와 거의 일치하는 좋은 추정결과를 나타내었다. Cycle 4의 경우는 Bi-Linear 모델과 Ramberg-Osgood 모델 모두 원하는 목표값 보다는 다소 차이가 나는 결과를 나타내었다. 이는 3Cycle로 학습이 완료된 신경망이 4Cycle의 구간에 있어, 학습 데이터의 부족과 다양한 학습패턴의 부족에도 관계가 있는 것으로 사료된다. 그러나, 충분히 학습된 구간에 있어서는 비교적 높은 예측성을 보임을 알 수 있다.




그림 9. Ramberg-Osgood Model의 Cycle별 추정값

4. 적용예제

4.1 예제실험체

제안된 신경망을 이용한 이력모델의 적용성을 위해 기존 실험을 행했던 보-기둥접합부의 하중-변위의 데이터를 통해 검증해 보고자 했다. 본 예제의 모델링은 중층(약 50층 정도) 규모의 철근콘크리트 모멘트 연성 골조의 전형적인 외부접합부를 나타내도록 계획하며, 강진시 가장 손상을 입기 쉬운 저층부를 선택하였고, 실험체의 형상은 저층부의 보-기둥 외부접합부를 보와 기둥의 반곡점 위치에서 잘라낸 평면 T자형으로 실제 건물의 부재크기를 약 1/2의 축척으로 줄여서 제작한 것이다. 실험의 진행은 하중 작용점에 부착된 변위계(LVDT)의 변위를 연속적으로 측정하면서 의도된 변위이력에 따라 가력한 경우를 고려하였다.

본 연구의 목적이 신경망을 이용한 이력모델의 예측이기 때문에, 재료적 성질보다는 실험체의 이력거동을 주된 변수로 채택하였다.

4.2 데이터의 습득 및 측정방법

실험의 진행은 하중 작용점에 부착된 변위계(LVDT)의 변위를 연속적으로 측정하면서 의도된 변위이력에 따라 가력하였다. 보 단부에 작용한 하중은 액츄에이터(actuator)의 헤드(head) 부분에 부착되어 있는 로드셀(load cell)로 측정하였으며, 작용하중에 대한 보 단부에서의 변위는 작용 하중점에 부착된 변위계로써 측정하였다. 그림 10은 실험체의 설치상황을 보여준다.

4.3 변위 이력




그림 10. 실험체 설치




그림 11. 하중 이력

첫 번째 사이클에서는 보-기둥 접합부의 보 주근에 부착한 wire strain gage(WSG)의 변형도가 철근의

재료시험에 의해 구한 항복변형도에 이를 때까지 가력하여 초기 항복변위(δ_y)로 설정하였고, 그림 11의 하중-이력 곡선과 같이 $2\delta_y$, $4\delta_y$, $6\delta_y$ 으로 가력하여 점증변위법과 일정변위법을 병행하여 가력하였다. 각 싸이클에서의 일정변위 가력시에는 3회의 싸이클로 가력하여 일정변위시의 강성 및 강도저하 특성을 파악하고자 하며 각 싸이클에서의 최대하중이 실험체 항복하중의 75%이하로 떨어졌을 때 실험을 종료하였다.

4.4 신경망의 구조 및 적용

신경망의 적용에 있어서의 입력변수는 변위량에 관한 변수로 현재변위, 변위증분량, 최대경험변위, 이전의 변위, 항복변위를 사용하였으며, 최대변위는 실험과 같이 100mm로 설정하였으며, 출력변수는 하중(ton)으로 하였다. 학습은 80CM-STAN의 δ_y 를 10mm으로 했을 경우로 점증가력법 및 순차 가력법에 의해서 얻어지는 총 3500개 이상의 데이터에 대하여 순차적 샘플링기법을 사용했다. 효율적인 데이터의 선정을 위해서 변곡점에 있어서의 데이터를 포함해 총 150개의 학습패턴을 선정하였다. 학습 패턴의 선정에 있어 탄성구간의 학습을 통해 비탄성구간의 영역을 예측해 보고자 1~5 Cycle의 구간의 학습 데이터의 수를 증가시켰다. 입력데이터값은 신경망의 추정가능 구간인 -1.0~1.0 구간으로 Scale down을 한 후 학습을 행하였다. 하중-변위에 따른 실험값에 의해서만 신경망을 구성하기 위해서 재료적 성질 등은 학습변수로부터 제외하였다. 해석에 있어서는 80CM-STAN의 δ_y 를 16mm으로 했을 경우로 실험에 있어서 각 싸이클에서의 최대하중이 실험체 항복하중의 75%이하로 떨어졌을 때 실험을 종료하였으므로, 이 경우의 변위와 하중의 해석에 있어 예측을 고려 하지 않았다. 은닉층의 결정에 있어서는 이력모델의 이력거동의 해석에 있어서 은닉층의 뉴런수는 같은 학습횟수에 대해서 비교적 작은 오차를 보인 뉴런수가 11개일 때로 설정하였다. 학습을 및 모멘텀항은 이전의 시뮬레이션을 통해 비교적 좋은 추정을 보인 결과에 따라, 학습을 α 로는 0.9 모멘텀항 m 은 0.3으로 설정하였다. 학습제한오차는 이력 모델의 학습시와 같은 2.0×10^{-3} 으로 설정하였으며, 연결강도의 초기치는 -0.1~0.1사이의 난수를 사용하였다. 시뮬레이션에 사용된 컴퓨터의 기종으로는 팬티엄 MMX 300으로 3분 정도의 평균 학습시간이 소요되었다. 학습의 종료시점까지의 반복횟수는 2,000~3,000회 사이였으며, 오차의 감소는 그림 12에서 알 수 있듯이 50~100회 이후 급격히 감소함을 보였고, 그 이후는 완만한 곡선을 이루며 0에 가까워졌다. 그림 13은 Visual Basic으로 구현한 신경망 프로그램을 나타낸다.




그림 12. 학습횟수에 따른 오차의 변화




그림 13. 신경망 Simulation

4.5 해석결과

그림 14에서 나타나듯이 1~4Cycle의 구간에 있어 실험값과 추정값의 오차의 합은 8.34%로 양호한 추정 결과를 보였다. 이는 학습시 탄성구간에 있어 다양한 입력패턴과 충분한 학습데이터로 학습된 결과에 따른 것으로 사료된다. 그림 15에서 보여주듯이 비탄성 구간에 있어서의 실험값과 추정치의 오차의 합은 29.28%로 탄성구간의 추정값에 비해 추정능력이 떨어짐을 알 수 있었다.




그림 14. 1~4Cycle의 실험값과 신경망의 해석값




그림 15. 1~8Cycle의 실험값과 신경망의 해석값

5. 결론

본 연구는 최근 인공지능의 한 분야로 연구되고 있는 신경망을 이용하여 기존 이력모델의 적용가능성과 이를 위한 신경망변수의 설정, 예제 등에 관해 연구한 결과 다음과 같은 결론을 얻었다.

- 1) 신경망을 이용한 이력모델의 예측에 있어서 학습된 범위내에서의 예측은 만족스러운 결과를 나타냈다. 그 이외의 범위에 있어서는 Bi-Linear Model, Ramberg-Osgood Model 모두에서 다소 오차를 보이긴 하였으나 두 모델의 결과를 통해, 본 연구에서 제안된 신경망변수가 이력모델의 예측에 있어 타당함을 알 수 있었다.
- 2) 보-기둥 접합부 실험예제를 통한 신경망의 적용에 있어서는 탄성구간의 경우는 충분한 학습 데이터와 입력패턴을 통한 학습으로 양호한 추정값을 보였다. 그러나 소성구간에서는 신경망의 추정능력이 다소 떨어지는 것으로 나타났다. 따라서 이력특성의 추정능력을 향상시키기 위해서는 최적의 변수설정과 학습 데이터의 추가 등을 통해 신경망을 구성하는 것이 바람직하다고 사료된다. 이러한 결과를 통해 알 수 있듯이 적절한 변수를 사용한다면 보-기둥접합부의 이력거동에 대한 보다 정확한 예측이 가능하다고 사료되며, 보-기둥접합부의 이력거동의 추정을 위해 본 연구에서 제안된 변위를 통한 입력변수의 설정이 유효함을 알 수 있었다.

이상의 연구결과 신경망을 이용한 이력거동의 예측 및 다른 재하실험의 하중-변위 등의 해석에 대한 적용도 가능할 것으로 사료된다. 향후의 과제로 연성비, 변위이력, 항복하중과 항복변위 등을 다양하게 변화시켜 신경망에 적용하고, 상당량의 데이터에 대한 적절한 샘플링기법과 최적의 변수를 설정하고자 한다.

참고문헌

1. 이승창, "신경망을 이용한 스티브거더 시스템의 근사 해석 모델의 원형개발", 한국전산구조공학회 논문집, 제10권, 제2호, 1997.6.
2. 이정환, 조중현, 유영찬, 이원호, 정현수, "고강도 철근 및 고강도 콘크리트를 사용한 보-기둥접합부의 비선형거동", 한국콘크리트학회 학술발표 논문집, 제11권, 제1호 1999. 5.
3. 이상원, 학습하는 기계 신경망, Ohm사 1995.
4. Zurada, J. M., *Introduction to artificial Neural Systems*, Info Access Distribution Pte Ltd., 1992.
5. Ghaboussi, J., "Some Applications of Neural Networks in structural Engineering," *Proceedings of Structures Congress, ASCE, Atlanta, GA*, 1994.