

## 뉴럴네트워크의 토목공학에의 적용



방 은 영\*



윤 정 방\*

### 1. 신경망의 배경

인간의 두뇌에 관한 탐구는 다양한 분야에서 전개된 오래된 연구과제이지만, 특히 오늘날 컴퓨터의 발달과 더불어 인간과 같이 계산하고 판단하며, 인식할 수 있는 인공지능의 구현을 위하여 많은 노력이 경주되고 있다. 그 가운데, 인공신경망(Neural Networks)은 그 목적에 따라 다양한 모델이 개발되어 왔으며, 시각적인 패턴인식, 광학, 음성타자기, 문자인식, 음성분석, 로봇공학 등의 분야에서 이용되고 있다. 신경망은 어떤 문제에 대해서는 기대 이상의 훌륭한 해결점을 제공하였으며 전통적인 인공지능 기법으로 해결할 수 없었던 문제들의 해결가능성을 보여주었다. 현재 신경망 연구의 가장 두드러진 동기는 인간 두뇌의 기능과 유사한 신경망이 실현될 것 같은 가능성이 다. 그러나 현재의 신경망 모델들은 지금까지 많은 발전이 있어 왔지만 실제 인간의 신경시스템과는 아직까지도 많은 차이가 있다. 그럼에도 불구하고 신경망 개념은 기존의 방법론으로 접근할 수

없었던 여러 문제들을 해결할 전환점을 제시하였다.

신경망 모델의 시초는 1943년 McCulloch과 Pitts에 의해서 시도되었다. 그들은 인간의 두뇌를 수많은 신경세포들로 이루어진 잘 정의된 컴퓨터라고 여겼다. 그들은 단순한 논리적 업무를 수행하는 모델을 보여주었고, 또한 패턴분류 문제가 인간의 지능적인 행위를 규명하는 이론에 매우 중요하다는 것을 인식하였다. 헬(Hebb)의 학습규칙은 두 뉴런(neuron) 사이의 연결강도(weight)를 조정할 수 있는 최초의 규칙이었다. 이 규칙은 학습에 관한 연구를 발전시켰으며 적용적인 신경망 연구에 많은 영향을 끼쳤다. Rosenblatt은 1957년 퍼셉트론(perceptron)이란 최초의 신경망 모델을 발표하였다. 퍼셉트론에 대한 관심의 주된 이유는 어떤 종류의 패턴이 입력층에 주어졌을 때 이 모델이 반응하게 하는 연결강도의 집합을 스스로 발견하는 자동적인 절차에 있다. 학습은 현재 주어진 입력 행렬에 대하여 현재의 각 연결강도를 조정함으로써 이루어질 수 있다. 이러한 퍼셉트론

\* 한국과학기술원 토목·공학과 박사과정

\*\* 정회원 · 한국과학기술원 토목·공학과 교수

모델은 그 당시 매우 가능성이 큰 것으로 여겨졌으나, 그 후 단순한 비선형 분리 문제도 풀 수 없는 것으로 밝혀졌다. Minsky 와 Papert가 'Perceptrons'란 저서에서 퍼셉트론 모델을 수학적으로 철저히 분석하여 그 모델의 단점을 밝혀내고 난 후 신경망에 관련한 연구는 약 20년간 침체의 길을 걷게 되었다. 그러던 것이 1970년대 말과 1980년 대 초반에 들어 Kohonen, Hopfield, Kirkpatrick, Hinton, Grossberg, Rumelhart 등이 신경망을 다시 활성화시켰다. 퍼셉트론과 같이 하나의 조정층으로 구성된 모델들의 한계점 때문에 한 개 이상의 은닉층을 쓰는 새로운 모델들이 1980년대 중반에 제안되었으며, 특히 Parallel Distributed Processing 그룹에 의해 폭넓은 연구가 있었다. 이 그룹에서 제안한 모델은 은닉층과 백프로퍼게이션(backpropagation) 학습 알고리즘을 사용함으로써 선형 분리 문제 뿐만 아니라 여러 가지 문제점을 해결할 수 있는 계기를 마련하였다. 이러한 중흥기를 거쳐 현재의 신경망에 대한 연구는 여러 가지 다양한 논제에 대하여 이루어지고 있다.

## 2. 신경망의 모델

신경망을 분류하는 기준은 다양하지만 본고에서는 특징이 뚜렷하고 기본적인 모델로 여겨지는 다층퍼셉트론, 흉필드(Hopfield) 모델, 코호넨(Kohonen) 모델을 김대수 박사의 저서 '신경망 이론과 응용'을 참고하여 간단하게 소개하고자 한다.<sup>1)</sup>

### 2.1 다층퍼셉트론

다층퍼셉트론은 입력층과 출력층사이에 하나 이상의 중간층이 존재하는 신경망으로 그림 1에 나타낸 것과 같은 계층구조를 갖는다. 이 모델은 입력층, 은닉층, 출력층 방향으로 연결되어 있으며, 각 층내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향의 신경망이다. 다층 퍼셉트론은 층의 개수가 증가할수록 퍼셉트론이 형성하는 결정 구역의 특성은 더욱 세

분화된다. 즉 단층일 경우 패턴 공간을 두 구역으로 나누어주고, 2층인 경우 오목한 개구역을 형성하며, 3층인 경우에는 이론상 어떠한 형태의 구역도 형성할 수 있다. 대부분의 다층 퍼셉트론은 백프로퍼게이션 학습 알고리즘을 사용하여 학습시킬 수 있어서 백프로퍼게이션 신경망으로도 불린다. 백프로퍼게이션 학습 알고리즘은 최소자승 알고리즘의 비선형적인 확장이다. 이 알고리즘은 지도학습의 일종으로 입력층에 입력패턴(벡터)을 제시하면, 이 신호는 각 뉴런을 거쳐 중간층에 전달되고 최후에 출력층에 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다.

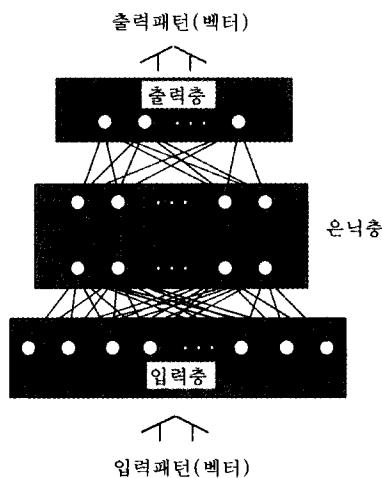


그림 1. 다층퍼셉트론

### 2.2 흉필드 모델

얼굴을 인식하거나 노란 빛깔의 유자를 보고서 신 맛을 연상하는 것들은 곱씹이나 나笏 셈과 같은 통상의 계산 범주를 뛰어넘는 것이다. 이러한 생물학적 수행 능력의 효용성으로 말미암아 신경 시스템의 원리에 의거, 이와 유사한 능력을 수행할 수 있는 모델의 개발이 시도되었다. 흉필드 모델은 1982년 미국 캘리포니아 공과대학의 물리학자인 John Hopfield에 의해 제안된 상호결합형 신

경망 모델로서 연상기억이나 최적화문제를 병렬적으로 푸는 데 많이 사용된다. 특히 연상기억에 있어서 일정한 범용 패턴들을 연결강도로 저장하였다가 미지의 입력패턴이 주어질 때 이와 가장 유사한 패턴을 찾아낸다. 흡필드 모델의 처리 유니트들은 그림 2에서 보는 바와 같이 자신을 제외한 모든 유니트들 간에 양 방향으로 상호연결되어 있으며, 정적인 입력을 다루는 다층 퍼셉트론과 다르게 시간의 함수인 입력을 취급할 수 있는 동적신경망(dynamic networks)에 속한다.

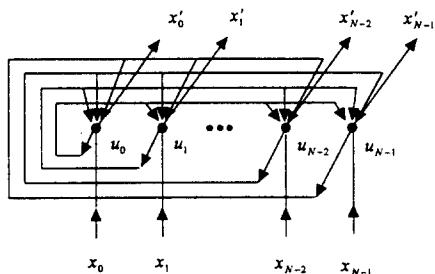


그림 2 흡필드 모델

### 2.3 코호넨 모델

태어난 지 얼마되지 않은 아기가 눈의 초점을 맞추어가는 과정을 살펴보면, 이 기능은 신생아들에게는 주어지지 않았지만 그들이 태어난 지 얼마되지 않아서 점차로 그러한 능력을 갖게됨을 알 수 있다. 즉 아기는 어떠한 교육이 없이, 눈에 보이는 자극과 물체를 서로 연관시키는 것을 자연스럽게 배우게 된다. 이러한 현상에 착안하여 핀란드의 헬싱키 공과대학의 Teuvo Kohonen에 의한 코호넨 모델이 개발되었다. 이 모델은 미국의 Grossberg 모델과 더불어 자율적인(unsupervised) 신경망 모델로서 유명하다. 이 신경망은 자기 조직화(self-organizing) 과정을 비교적 단순하면서도 매력적으로 모델링한 것이다. 이 모델은 신경망 음성타자기, 자동연상기역장치 등에 이용된다. 코호넨의 학습에서 각 뉴런은 연결강도 벡터와 입력벡터가 얼마나 가까운가를 계산한다. 그리고 각 뉴런들은 학습할 수 있는 특권을 부여받으려고 서로 경쟁하는데 거리가 가장 가까운 뉴런이

승리하게 된다. 이 승자뉴런과 이와 인접한 이웃 뉴런들만이 제시된 입력벡터에 대하여 학습이 허용된다. 이러한 학습방법을 백프로파게이션과 같은 지도학습과 구별하여 경쟁학습(competitive learning)이라 한다.

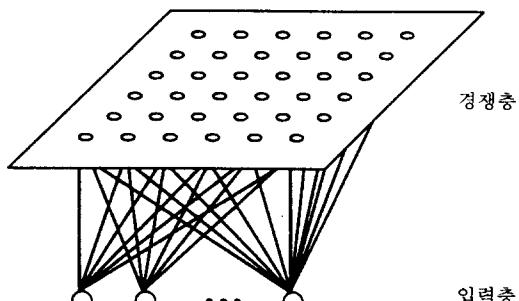
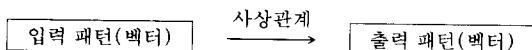


그림 3 코호넨 모델

### 3. 구조공학에의 응용

신경망을 구조공학에 응용하는 연구는 1990년대 초반부터 발표되기 시작했으며, 현재는 구조계수추정 및 손상도 추정, 진동제어, 지진공학, 지반공학, 구조해석 및 설계 등에서 다양하게 이루어지고 있다.<sup>2,7)</sup> 이와 같은 구조공학에의 적용문제들은 대부분 다층퍼셉트론의 패턴인식 기능을 이용하고 있다. 일반적으로 패턴인식 문제는 “입력패턴과 출력패턴으로 일컬어지는 두 벡터(패턴)들 사이에 사상(mapping) 관계가 성립할 때, 주어진 입력패턴에 대응하는 출력패턴을 구하는 것”으로 정의될 수 있다. 그런데, 우리가 취급해야 하는 대부분의 경우는 입력 패턴으로부터 간단한 수학적 계산으로 출력패턴을 결정할 수 없는 것이 일반적이다. 그러나, 위의 사상을 대표하는 여러 가지 입력출력패턴(훈련패턴)을 구할 수 있어서, 그들 사이의 사상관계를 신경망으로 학습시킬 수 있기 때문에 문제가 해결되는 것이다. 즉, 이러한 문제에서 가장 중요한 것은 그 문제를 대표할 수 있는 충분한 훈련패턴을 모으는 것이 중요하다. 이러한 훈련패턴은 지진관련문제인 경우와 같이 지진계측소의 계측자료를 이용할 수 있고, 문제에 따라 실

힘이 가능하고 현실적이라면, 훈련패턴을 실험으로 구할 수 있을 것이다.



### 3.1 구조계수추정(Structural Identification)

구조해석이란 구조물의 기하학적 자료와 물성치가 주어진 상황에서, 주어진 하중에 대하여 구조물의 응답을 구하는 것이고, 구조계수추정이란, 하중과 응답을 알고 있을 때 구조물의 물성치를 구하는 문제이다.<sup>7)</sup> 구조계수추정은 일종의 역문제 이므로 반복적인 과정이 요구된다. 이때 기존의 구조계수추정법은 구조시스템의 구성식과 하중 및 응답의 계측데이터로부터, 다양한 최적화 알고리즘을 사용하여 구조계수를 추정한다. 이러한 방법들은 구조시스템의 구성식이 복잡해질수록 알고리즘의 수렴성이 저하하는 경향이 뚜렷하다. 즉 구조시스템의 구성식에 대한 의존도가 크다는 단점을 가지고 있다.

그러나, 앞에서 설명한 다층퍼셉트론을 이용하면 다른 방향으로 이 문제에 접근할 수 있다.<sup>2,3)</sup> 구조계수추정에 사용되는 데이터는 다양하지만 일반적으로 동적데이터를 사용할 때에는 자유진동데이터(고유진동수 및 진동모우드)를 많이 사용하므로 본고에서는 이 데이터를 사용하는 경우로 설명하고자 한다. 미지 구조계수추정이란, 자유진동데이터가 계측되었을 때, 이 데이터에 대응하는 구조계수를 구하는 것을 의미한다. 다층퍼셉트론을 이용하여 이러한 목적을 달성하려면 해당구조물의 구조계수와 이에 관련되는 자유진동 데이터와의 관계를 나타내는 패턴을 충분한 조합에 대하여 구하고, 이 패턴을 사용하여 자유진동데이터가 신경망에 입력되었을 때, 대응하는 구조계수가 출력되도록 신경망을 학습시키는 것이다. 이러한 방법의 주된 과정은 훈련패턴을 구하고 이를 학습시키는 두 가지 과정이다. 신경망에 의한 구조계수추정의 성능은 “훈련패턴이 그 문제를 얼마나 잘 대표하는냐?”에 의해 결정되므로 신경망의 입력인 자유진동데이터와 출력인 구조계수와의 관계를

묘사하기에 충분한 훈련패턴집합을 구하는 것이 중요하다. 이때 구조계수를 관심구역에 따라 변화시켜가면서 구조해석을 수행하여 각 경우에 대한 자유진동데이터를 구하여 훈련패턴으로 사용할 수 있다. 즉, 입력패턴(자유진동데이터)으로부터 출력패턴(구조계수)을 구하는 것은 복잡하지만, 입력패턴은 출력패턴으로부터 구조해석으로 쉽게 구할 수 있으므로, 필요한 훈련패턴을 구할 수 있다.

이해를 돋기 위해 그림 4에 보이는 것과 같은 트러스 구조에서 표시된 11개 부재의 축강성계수를 추정하는 예제를 들고자 한다. 이때 각 상대 축강성계수가 0.3과 1.7 사이에 존재한다고 가정하자. 여기서 0.3은 축강성계수가 기준치에서 70%감소한 상태, 1.0은 기준치와 같은 상태, 1.7은 70% 증가한 상태를 의미한다.

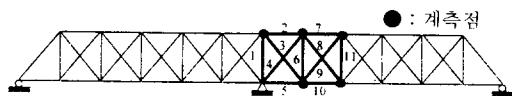


그림 4 예제 트러스 구조

위의 구조에서 각 부재의 상태 축강성계수를 0.3과 1.7 사이에서 변화시켜가며, 각 경우에 대하여 구조해석을 하면 자유진동데이터를 구할 수 있다. 이 때, 경우의 수를 효율적으로 줄이기 위해 Latin Hypercube Sampling 기법을 사용할 수 있다. 이 예제의 경우 총 957개의 훈련패턴과 학습된 신경망의 시험을 위해 580개의 시험패턴을 구하였다. 시험패턴의 한 예를 표 1에 실었다. 표 1에서 입력패턴은 저차의 4개 고유진동수와 그림 4의 5개 계

표 1 시험패턴과 출력결과의 예

입력패턴	5.92	0.34	0.30	0.05	0.25	0.09	0.00	0.30	0.31	0.52	-0.49
	7.70	0.04	0.06	0.09	0.05	0.09	0.18	0.37	0.36	0.56	0.59
	11.36	0.38	0.37	0.37	0.43	0.50	0.06	0.07	0.14	0.19	0.24
	13.34	-0.02	0.30	0.41	0.59	0.56	-0.21	0.08	0.03	-0.01	0.09
출력패턴	0.40	0.75	0.65	0.55	0.75	0.75	1.30	1.15	1.55	0.85	
신경망출력	0.38	0.80	0.62	0.57	0.80	0.75	0.95	1.45	1.22	1.54	1.00
상대오차(%)	5.0	6.4	4.6	4.0	6.4	0.1	26.5	11.5	6.4	0.5	18.0

표 2 추정된 축강성계수의 상대오차

부 재											
1	2	3	4	5	6	7	8	9	10	11	평균
평균상대오차(%)	11.2	7.3	7.7	7.8	6.2	11.9	6.3	11.0	10.9	4.9	15.0

축점에서의 모우드벡터로 총 44개의 항으로 구성된다. 출력은 11개 부재의 상대 축강성 계수이다. 위에서 구한 훈련패턴으로 10,000회의 학습을 수행한 후에 시험한 결과를 표2에 나타내었다. 결과에서 보듯이 평균상대오차가 9.1%로서 충분히 의미있는 결과를 얻을 수 있음을 알 수 있다.

### 3.2 지진 피해도 / 위험도 예측

어떤 지역에 지진이 발생하였을 때, 진앙부근의 광범위한 각 지역의 지진 피해도 / 위험도를 나타내는 Modified Mercalli Intensity(MMI)를 예측하는 문제를 신경망을 사용하여 해결할 수 있다.<sup>4)</sup> Tung등은 MMI를 결정하는 요소로 네 가지를 선택하여 이것을 입력패턴으로 사용하였다. 이들은 ‘발생한 지진규모’, ‘해당 위치와 단층파단면사이의 최단거리’, ‘파단면과 최단거리에 의해 결정되는 azimuth 각’ 및 ‘그 지역의 지질조건’이다. 즉, 위의 4가지를 알고 있을 때, 해당지역의 지진위험도인 MMI를 구하는 문제이다. 이들은 미국의 캘리포니아 지역을 대상지역으로 삼았고, 그 지역의 최근 3개의 지진기록을 훈련패턴으로 사용하였다. 그 지진들은 1989년의 규모 7.2의 Loma Prieta 지진, 1987년의 규모 6.7의 Coalinga 지진, 1984년의

규모 6.2의 Morgan Hill 지진이다. 위의 지진의 진앙지에서 150km 주변의 133개의 강진계측소의 실제지진기록으로부터 위의 4가지 입력패턴 사항 및 MMI 데이터를 추출하여 훈련패턴으로 사용하였다. 최종적으로 앞의 그림 5와 같은 지진위험도를 공간적으로 나타내는 그림을 구할 수 있다. 그들은 이 예제를 통하여 신경망을 사용한 방법이 기존의 다른 방법들보다 효과적임을 보이었다.

### 참 고 문 헌

1. 김대수, 신경망의 이론과 응용(I), 하이테크정보, 1992
2. Wu, X., Ghaboussi, J., and Garrett, J. H. Jr., “Use of Neural Networks in Detection of Structural Damage”, Comput. Struct., 42(4), 1992, pp. 649-659.
3. Tsou, Poyu and Shen M.-H. Herman, “Structural Damage Detection and Identification Using Neural Networks”, AIAA Journal, Vol. 32, No. 1, 1994, pp. 176-183.
4. Tung, Albert T. Y. and Wong, F. S. and Dong, Weimin, “Prediction of the Spatial Disribution of the Modified Mercalli Intensity Using Neurall Networks”, Earthquake Engineering and Structural Dynamics, Vol. 23, pp. 49-62. 1994.
5. Cheng, M. and Popplewell, N. “Neural Network for Earthquake Selection in Structural Time History Analysis”, Earthquake Engineering and Structural Dynamics, Vol. 23, pp. 303-319, 1994.
6. Molas, G. L. and Yamazaki, F. “Neural Networks for Quick Earthquake Damage Estimation”, Earthquake Engineering and Structural Dynamics, Vol. 24, pp. 505-516. 1995.
7. Yun, Chung-Bang and Bahng, Eun-Young, “Substructural Identification of Bridge Structures Using Neural Networks”, NSF Workshop on Structural Reliability in Bridge Engineering, October 1996, Colorado, USA. ■

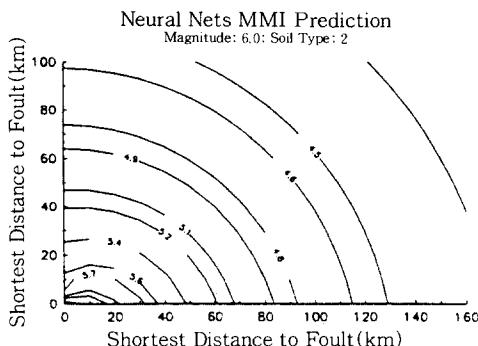


그림 5 MMI 공간분포도