

# 신경망과 수치 해석 알고리즘의 비교 연구

## Comparative Study on the Neural Networks versus Numerical Analysis Algorithm

이 승 창\* 박 승 권\*\* 이 병 해\*\*\*  
Lee, Seung-Chang Park, Sung - Kwon Lee, Byung-Hai

### 요 지

본 논문은 신경망 근사 해석 모델 개발을 궁극적인 목적으로 하는 기초적 연구로서, 기존의 수치 해석 알고리즘과의 성능 비교를 통하여 신경망 알고리즘의 특성과 역할을 수치 해석의 관점에서 정확히 판단하는데 목적이 있다. 신경망 알고리즘을 변형하여 선형 연립 방정식의 해를 구하는 두 가지 방법을 제안하였고, 회귀 분석, 보간법과의 비교를 통하여 광범위한 근사자(universal approximator)로서의 역할을 보였다.

### Abstract

The purpose of this paper is to develop Neural Network models for Approximate Structural Analysis (NNASA). As an initial stage, the paper classifies the characteristics and the active role of neural networks in the numerical analysis by comparing neural networks with conventional numerical analysis algorithms. The paper proposed two methods of finding solutions of linear algebraic equations by a modified neural network algorithm, and presents that multilayer feedforward networks are a class of universal approximators by comparing the neural network with regression and interpolation techniques.

**Keywords :** artificial neural networks, linear algebraic equations, universal approximators

### 1. 서 론

순차적인 컴퓨터(또는 프로그램)에 비교하여, "인공 신경 회로망(artificial neural network, 이하 '신경망'이라 함)"은 인간 뇌와 유사하게 지식 표현과 정보 처리를 병렬적으로 수행하는 거대한 병렬 연산 모델(parallel computational model)로서, 비전(vision), 지각(perception), 언

어 처리(language processing), 움직임 제어(motor control)와 같은 고도의 수행성과 복잡한 정보 처리 업무에 이상적으로 적합하다<sup>1)</sup>. 초기의 공학적인 응용에서 나타난 인간 뇌와의 하드웨어적인 구조의 유사성은 더 이상 주요한 관심사가 아니며, 현재는 공학적인 문제에서 신경망의 강력한 특성을 이용하는 방법을 찾고 있다<sup>1)</sup>. 공학적인 응용으로서 신경망의 가장 큰 특징

\* 한양대학교 건축공학과, 박사과정

\*\* 한양대학교 전자통신공학과, 교수

\*\*\* 정희원·한양대학교 건축공학과, 교수

· 이 논문에 대한 토론을 1997년 9월 30일까지 본 학회에 보내주시면 1997년 12월호에 그 결과를 게재하겠습니다.

은 학습능력이며, 구체적으로 열거하면 다음과 같다<sup>1)</sup>.

- ① 불완전하거나 부분적으로 부정확한 자극(입력)에도 적절한 결과를 출력할 수 있다.
- ② 새로운 경우(데이터)를 학습하여 일반화할 수 있다.
- ③ 잡음(noise)이 섞인 데이터로부터 정보를 추출할 수 있다.
- ④ 인공 뉴우런의 연결을 일부 제거하더라도 신경망의 수행성이 일부 감소할 뿐이며, 필수적인 인공 뉴우런은 없으므로 매우 강력한 연산 모델이다.

이러한 배경하에, 국내외적으로 구조 공학에의 신경망 적용 연구가 다음과 같은 분야를 중심으로 활발히 진행되고 있다.

- ① 근사화의 새로운 방법으로서의 제시<sup>2)</sup>
- ② 재료의 이력 거동(hysteretic behavior)에의 적용 연구<sup>3)</sup>
- ③ 능동 제어(active control)에의 적용 연구<sup>4)</sup>
- ④ 구조물 손상 평가에의 적용 연구<sup>5)</sup>
- ⑤ 구조 해석 및 설계 (최적화를 포함)에의 적용 연구<sup>6)</sup>

본 연구자들은 지난 2년간 PC 수치 접합부의 최대 전단 내력 예측<sup>7)</sup>과 트러스 구조물의 최적 설계<sup>8)</sup>에 대한 신경망 적용 연구를 발표한 바 있다. 그러나, 적용 방법과 결과에 주로 관심을 두어 기존 알고리즘(수치 해석)에 대한 비교로부터 구조 공학에의 신경망 적용에 대한 필연성에 대한 연구가 미흡한 실정이었다. 또한, 근사 해석을 위한 신경망 적용 연구 중에 선형 연립 방정식을 풀 수 있는 변형된 신경망 알고리즘을 유도할 수 있었으며, 이러한 알고리즘은 수치 해석 알고리즘과의 비교에 적절하다고 사료되었다.

따라서, 본 논문은 신경망 근사 해석(NNASA: Neural Network for Approximate Structural Analysis) 모델 개발을 궁극적인 목적으로 하는

기초적 연구로서, 기존의 수치 해석 알고리즘과의 성능 비교를 통하여 신경망 알고리즘의 특성과 역할을 수치 해석의 관점에서 정확히 판단하는데 목적이 있다.

## 2. 기존 연산 방법과의 비교 및 인공지능에서의 위상

### 2.1 기존 연산 방법과의 비교

#### 1) 문제 풀이

구조 공학에서는 어떠한 자연 현상을 지배 미분 방정식, 처짐 식 등으로 표현하듯이, 기존의 방법은 순차적인 알고리즘에 의한 공식화로서 문제를 해결하였다. 그러나, 신경망은 신경망 구조의 선정과 학습 예제(패턴)의 선정에 의해 문제를 해결한다.

#### 2) 지식 획득(acquisition)과 회수(retrieval)

기존의 방법은 프로그래밍에 의해 지식을 획득하고 순차적인 연산에 의해 지식을 회수하나, 신경망은 학습에 의해 지식을 획득하고 집합적인 처리에 의한 리콜(recall)에 의해 지식을 회수한다.

#### 3) 연산 업무와 데이터 저장

기존의 방법은 고 정확도의 수리 연산을 수행하고 ROM이나 RAM에 고밀도의 이진 형태로 기억되지만, 신경망은 저 정확도의 비선형 매핑을 수행하며, 뉴우런 사이의 연결 강도의 형태로 저장된다.

### 2.2 인공지능에서의 위상

새로운 상황에 부딪혔을 때에 자신이 가지고 있는 지식과 사고 기능을 통하여 주어진 문제를 해결할 수 있는 지능을 가질 수 있는 컴퓨터를 만들고자 하는 것이 인공 지능(artificial intelligence)의 목표이다. 인간의 두뇌 구조와 구조적으로 다른 폰 노이만(Von Neumann)형 컴퓨터를 가지고, 기호 처리 방법을 이용한 기존의 전문가 시스템과 같은 방식으로 인간과 같이 생각하는 컴퓨터를 만들겠다는 시도는 인공 지능의 연구가 진행됨에 따라 그 한계성을 드러내었고,

인공지능 전반에 걸친 회의를 가져왔다. 이에 따라, 인간의 사고 특징을 모델화하거나 인간의 뇌를 모델로 한 새로운 기법들이 소개 또는 재등장하면서 인공 지능에 대한 연구가 새로운 국면을 맞이하고 있다. 이러한 모델로는 인공 신경망, 퍼지 이론(fuzzy theory), 유전자 알고리즘(genetic algorithm)의 세가지 분야가 대표적이며, 단일의 모델뿐만 아니라 각 모델의 장점만을 살려 합성 또는 조합 시킴으로써 문제를 해결하고자 하는 연구<sup>9), 10)</sup>가 최근 들어 증가하고 있다.

전문가 시스템은 다음과 같은 문제점으로 인하여 구조 공학에의 적용에는 한계가 있으며, 신경망도 도입 과정에서 다음과 같은 문제점을 내포하고 있다.

◆ 전문가 시스템의 문제점

- ① 실제로 전문가를 확보하기가 어렵다.
- ② 경험을 표현하기가 어렵다.
- ③ 규칙(IF-THEN rule)으로 모든 지식을 표현한다는 것은 무리가 있다.

◆ 신경망의 문제점

변수가 적을 때는 신경망의 절차 및 결과를 설명할 수 있으나, 변수가 많을 때는 정확한 설명이 어렵다.

3. 신경망과 수치 해석 알고리즘의 비교

3.1 Gauss-Seidel 방법과의 비교

유한 요소 해석에서는 선형 연립 방정식의 해를 구하기 위한 수치 해석 알고리즘으로 Gauss 소거법, Gauss-Seidel 방법 등을 사용하고 있다. 특히, Gauss-Seidel 방법은 반복법이라는 점에서 신경망 알고리즘과 유사한 점을 가지고 있다.

본 연구에서는 신경망의 구조를 바꿔가며 몇 가지 시도를 해 본 결과, Gauss-Seidel 방법과 흐름도상으로 유사하다고 판단되는 피드포워드 네트워크(feedforward network)<sup>11)</sup>로는 Single Continuous Perceptron Training Algorithm (SCPTA)<sup>11)</sup>을, 뉴런의 값이 재귀적(recurrent)

으로 변환한다는 점에서 피드백 네트워크(feedback network)<sup>11)</sup>인 Hopfield 네트워크<sup>11)</sup>를 비교 대상으로 결정하였다. 각 신경망에 의해 선형 연립 방정식의 해를 얻기 위한 다음과 같은 두 가지의 신경망 알고리즘(Modified Neural Algorithm for Solving Equations, MNASE-I, II)을 개발하였다.

3.1.1 MNASE-I의 개발

SCPTA는 선형적으로 분리 가능한 패턴 분리(linearly separable pattern)에 주로 사용되는 가장 단순한 신경망으로, SCPTA를 그대로 적용하여서는 선형 연립방정식의 해를 얻을 수 없다. 따라서, 수 십번의 반복적인 실험과 데이터의 변화를 관찰하여, Gauss-Seidel 방법의 흐름도[그림 1]와 유사하다고 판단되는 SCPTA의 알고리즘 중에서 [그림 2]와 같이 단계3과 단계4를 변경하여 MNASE-I이라는 알고리즘을 제시하였다.

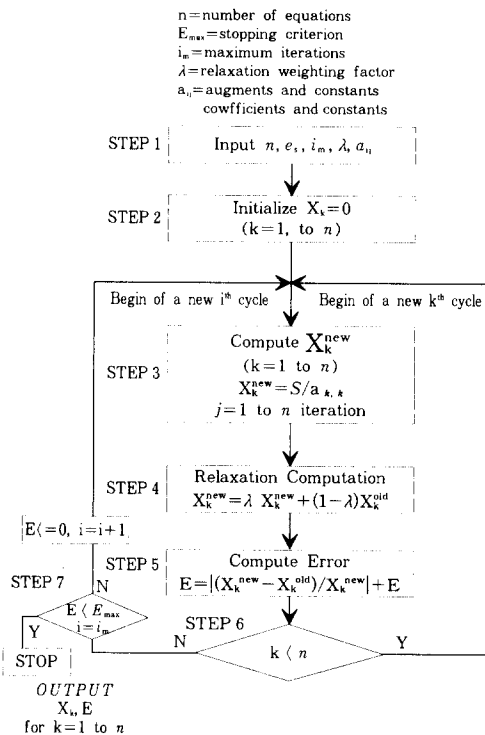


그림 1 Gauss-Seidel 방법

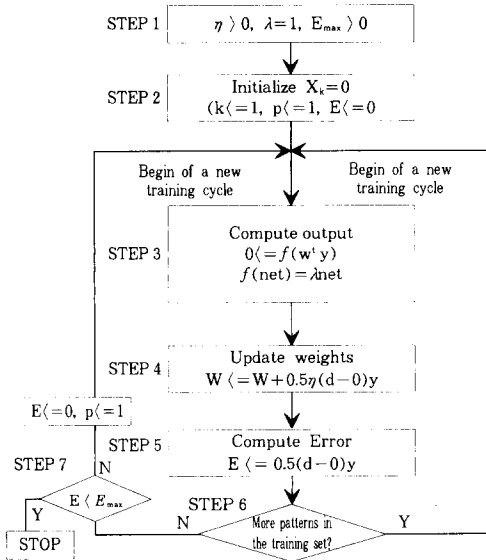


그림 2 MNASE-I의 흐름도

SCPTA는 에러 함수의 경사도  $\Delta E(w)$ 에 의해 부 최대 경사(negative gradient)의 방향으로 식(1)과 같이 연결 강도가 변경된다. ( $\eta$ 는 학습 상수)

$$w^{k+1} = w^k - \eta \Delta E(w^k) \quad (1)$$

최소화하고자 하는  $k$ 번째 학습 단계의 분류 에러(classification error)는 식(2)와 같이 표현되며,  $n+1$ 차원의 경사도 벡터는 식(3)과 같이 정의된다.

$$E_k = \frac{1}{2}(d^k - 0^k)^2, \text{ or } E_k = \frac{1}{2}[d^k - f(w^k y^k)]^2 \quad (2)$$

$(net = w^k y)$

(여기서,  $d$ 는 기대값(desired value),  $o$ 는 결과값(output value),  $f$ 는 활성화 함수,  $net$ 는 연결 강도 벡터( $w$ )와 입력 벡터( $y$ )의 스칼라 곱이다)

$$\Delta E(w) \Delta \left[ \frac{\partial E}{\partial W_1} \quad \frac{\partial E}{\partial W_2} \quad \dots \quad \frac{\partial E}{\partial W_{n+1}} \right]^T \quad (3)$$

그러므로, 분류 에러의 경사도 벡터는 식(4)와 같다.

$$\Delta E(w) = -(d - o) f'(net) \left[ \frac{\partial(net)}{\partial w_1} \quad \dots \quad \frac{\partial(net)}{\partial w_{n+1}} \right]^T$$

$$= -(d - o) f'(net) y \quad (4)$$

단계3에서 활성화 함수로 bipolar sigmoid 함수<sup>11)</sup>를 사용하면, 활성화 함수와 미분 함수를 식(5)와 같이 표현 할 수 있다. 따라서, 단계4에서의 델타 학습 규칙(delta learning rule)<sup>11)</sup>에 의한 연결 강도의 적응 규칙은 식(6)과 같다.

$$f(net) = \frac{2}{1 + \exp(-net)} - 1$$

$$f'(net) = \frac{2 \exp(-net)}{[1 + \exp(-net)]^2} = \frac{1}{2}(d - o)^2 \quad (5)$$

$$w^{k+1} = w^k + \frac{1}{2} \eta (d - 0)(d - 0^2) y^k \quad (6)$$

선형 연립 방정식의 해를 구하기 위해서 단계3에서 활성화 함수로 선형 함수(linear function)를 사용하면, 활성화 함수와 미분 함수를 식(7)과 같이 표현 할 수 있다. 그러므로, 단계4에서의 연결 강도의 적응 규칙은 식(8)과 같아진다.

$$f(net) = net, \quad f'(net) = 1 \quad (7)$$

$$w^{k+1} = w^k + \frac{1}{2} \eta (d^k - 0^k) y^k \quad (8)$$

### 3. 1. 2 MNASE-II의 개발

Hopfield 네트워크는 최적화 문제에 주로 사용되는 신경망으로, SCPTA와 비교하여 시간에 따라 변화하는 동적인 시스템으로 구현되며, 문제를 정의하는 에너지 함수의 표현에 따라 신경망의 수렴과 구성이 결정되어, 에너지 함수의 최소화 에 의해 평형점을 찾고자 하는 것이다.

선형 연립 방정식의 해를 구하는 문제에 대하여 에너지 함수를 정의함으로써 다음과 같은 MNASE-II라는 알고리즘을 제시하였다.

Hopfield 네트워크에서는 점근적인 안정성 (asym-totic stability)과 국부 최적해로의 수렴성을 보장하기 위하여, 식(9)와 같은 연산상의 에너지 함수인 Liapunov 에너지 함수<sup>11)</sup>가 정의된다.

$$E(\underline{v}) \Delta - \frac{1}{2} \underline{v}' \underline{w} \underline{v} - i' \underline{v} + t' \underline{v} \quad (9)$$

(여기서,  $\underline{v}$  는 뉴런의 입력 벡터,  $\underline{w}$ 는 연결 강도의 행렬,  $i$ 는 뉴런의 외부 입력 벡터,  $t$ 는 뉴런의 임계값 벡터이다. 첨자  $t$ 는 전치(transpose)를 의미)

선형 연립 방정식의 해를 구하는 문제를 정의하는 에너지 함수는 식(10)과 같이 표현할 수 있다.

$$E(\underline{X}) = (\underline{A} \underline{X} - \underline{B})^2 \quad (10)$$

(여기서,  $\underline{A}$ 는 상수행 계수 행렬,  $\underline{X}$ 는 미지수 벡터,  $\underline{B}$ 는 상수 벡터이다.)

$\underline{B}$ ,  $\underline{B}$ 는 상수항으로 에너지 함수를 최소화하는 데는 무관하므로 식(11)과 같이 표현할 수 있다.

$$\text{Min} \cdot E(\underline{X}) = \underline{X}' \underline{A}' \underline{A} \underline{X} - 2 \underline{X}' \underline{A}' \underline{B} \quad (11)$$

또한, 활성화함수로 선형 함수를 사용하면 Liapunov 함수에서 임계값 항은 무시할 수 있으므로, 식(9)와 식(11)의 비교로부터 연결 강도 행렬과 뉴런의 외부 입력 벡터를 식(12)와 같이 결정할 수 있다.

$$\underline{w} = -2 \underline{A}' \underline{A}, \quad i' = 2 \underline{B}' \underline{A} \quad (12)$$

전기적인 요소를 사용한 신경망 모델에서는 상태 방정식과 출력 방정식을 (13.a)와 (13.b)로 나타내며, 이를 Hopfield gradient-type dynamic 방정식<sup>11)</sup>이라 한다.

$$\underline{C} \frac{d\underline{u}(t)}{dt} = \underline{W} \underline{V} - \underline{G} \underline{u}(t) + i \quad (13.a)$$

$$\underline{v}(t) = f[\underline{u}(t)] \quad (13.b)$$

(여기서,  $\underline{u}(t)$ 와  $\underline{v}(t)$ 는 뉴런의 입력 벡터 및 출력 벡터이고,  $\underline{C}$ 와  $\underline{G}$ 는 입력 커패시턴스(input capacitance)와 입력 컨덕턴스(input conductance)이다.)

본 문제는 단위 시간에 대한 변화를 나타내고, 활성 함수로 선형 함수를 사용하므로 뉴런 값의 변화는 식(13)과 같은 Hopfield gradient-type dynamic 방정식<sup>11)</sup>으로부터 식(14)과 같이 정의할 수 있다.

$$\underline{u}(k+1) = \underline{u}(k) + \underline{w} \underline{u}(k) + i \quad (14)$$

(여기서,  $\underline{u}(k)$ 와  $\underline{u}(k+1)$ 는  $k$ 번째 뉴런의 입력 벡터 및 출력 벡터이다.)



### 3. 1. 3 4원 일차 방정식의 시뮬레이션 결과 비교

개발된 알고리즘을 이용하여 [그림3]과 같이 4원 일차 연립 방정식을 표현하고 해를 구하였다. Gauss-Seidel 방법과의 비교 목적으로, MNASE-I에서는 초기 연결 강도 값을, MNASE-II에서는 초기 뉴런 값을 모두 0.0으로 초기화 하였다. 결과를 [표1]에 나타내고 분석하여 보면 다음과 같다.

첫째, 신경망의 연결 강도는 연립 방정식의 미지수와 유사한 의미를 가질 수 있으므로 선형 연립 방정식은 신경망의 연산 모델로 모델화될 수 있다.

둘째, 정확해를 구할 수 있었으나, MNASE-I은 Gauss-Seidel 방법에 비해서 수렴 속도가 매우 떨어지고, MNASE-II는 반복 회수가 일치하였으나 매트릭스(A)의 원소 값을 1이하로 스케일링(scaling)하여야 하기 때문에 원소 값의 차이가 10배 이상인 경우 수 만번의 반복 회수가 필요하여, 유한 요소 해석과 같은 일반적인 선형 연립 방정식 문제에서는 수렴 속도가 현저히 저하됨을 확인하였다.

$$\begin{bmatrix} 4 & 2 & 0 & 0 \\ 2 & 8 & 2 & 0 \\ 0 & 2 & 8 & 2 \\ 0 & 0 & 2 & 4 \end{bmatrix} \begin{bmatrix} X1 \\ X2 \\ X3 \\ X4 \end{bmatrix} = \begin{bmatrix} 4.0 \\ 0.0 \\ 0.0 \\ 0.0 \end{bmatrix}$$



MNASE-II

그림 3 4원 일차 연립 방정식의 표현

표 1 4원 일차 연립 방정식의 시뮬레이션 결과

	결 과 값				반 횟	복 수
	x 1	x 2	x 3	x 4		
정확해	1.155	-0.311	0.089	-0.044		
MNASE-I	1.155	-0.311	0.089	-0.044		616
MNASE-II	1.155	-0.311	0.089	-0.044		10
Gauss-Sediel	1.155	-0.311	0.089	-0.044		10

### 3.2 회귀 분석, 보간법과의 비교

실험 결과를 적합 시킬 때는 경향 분석과 가상 검증을 접하게 된다. 경향 분석의 첫번째 방법은 회귀 분석(regression analysis)<sup>12)</sup>이며, 데이터가 오차나 잡음을 어느 정도 포함하는 경우로서, 데

이터의 일반적인 흐름을 표현하는 단일 곡선으로부터 경향을 파악하는 것으로 모든 점을 지날 필요는 없다. 두 번째 방법은 데이터가 정확하게 알려진 경우로서, 각 점을 지나는 곡선을 찾고자 하는 보간법(interpolation)<sup>12)</sup>이다. 데이터로부터 경향 분석을 할 경우, 선택한 방법에 따라 결과가 다르므로 어떠한 방법을 선정할 것인가는 매우 중요한 문제이다.

#### 3.2.1 신경망 구조와 학습(시뮬레이션)

신경망은 패턴 인식뿐만 아니라 광범위한 근사자(universal approximator)<sup>13)</sup>로서의 역할을 수행한다. 이를 위한 신경망 알고리즘으로는 다층 피이드포워드 네트워크(multilayer feedforward network)이며, 다변수의 비선형 문제에 가장 적합한 대표적인 신경망인 Error Back-Propagation Training Algorithm (EBPTA)<sup>11)</sup>을 이용한 신경망을 선택하였고, 이 알고리즘의 유도 과정에 대해서는 기존 연구<sup>7)</sup>에서 충분히 다루었으므로 생략하고, 시뮬레이션 결과에 중점을 두고자 한다.

회귀 분석과 보간법과의 비교를 위해서 최소 제곱법<sup>12)</sup>에 의한 선형 회귀 분석에 적절한 7개의 데이터 점[(1,0.5) (2,2.5) (3,2.0) (4,4.0) (5,3.5) (6,6.0) (7,5.5)]에 대하여, 6차 다항식 곡선, 3차 spline곡선을 적합시키고, 신경망을 3가지 랜덤한 초기 연결 강도 값으로 수행한 결과와 비교하였다. X 값을 나타내는 입력 층의 1개의 뉴런, Y값을 나타내는 출력 층의 1개의 뉴런과 5개의 뉴런을 가진 1개층의 은닉 층으로 신경망을 생성하였다. 학습 패턴은 10으로 나누어, 1 이하의 값으로 스케일링하였고, 신경망 구조의 다른 변수는 다음과 같이 가정하여 각 패턴에 대하여 학습하였다.

[최대 에러 (maximum error)=0.00001, 활성화 함수(activation function)=Uni-polar sigmoid function( $\lambda=1.0$ ), 학습 상수( $\eta$ )=0.5, 모멘텀 항 (momentum term, ( $\alpha$ )=적응적(adaptive)인 방법으로 결정]. 학습에는 3652회의 반복 회수 (epoch)가 소요되었으며, 학습이 완료된 후에는

학습에 사용된 7개의 학습 패턴을 포함하여, 총 40개의 패턴으로 리콜하였다.

### 3. 2. 2 시뮬레이션 결과 분석

시뮬레이션 결과는 [그림4]와 같으며, 6차 다항식은 거친 진동을 보이고 있고, 3차 spline곡선은 부드러운 곡선을 보이고 있다. 또한, 신경망은 초기 연결 강도 값에 따라 CASE 1, CASE 2, CASE 3의 다른 결과를 보이지만 학습 데이터 점은 정확하게 지나고 있으며, 3차 spline곡선과 유사한 경향을 보인다. 초기 연결 강도 값에 따라 정도의 차이는 있지만, 신경망은 적절한 신경망 구조와 학습 패턴의 선정에 따라 다변수 함수에 대한 근사화에 있어 매우 좋은 일반화(generalization)를 보이고 있음을 알 수 있다.

## 4. 결 론

신경망과 수치 해석 알고리즘의 성능 비교를 통하여 얻은 결론은 다음과 같다.

1) 신경망 알고리즘은 근사해(선형 연립 방정식의 해)를 반복적인 방법으로 구하는 알고리즘을 내포하고 있으며, 제시한 두가지 변형된 신경망 알고리즘(MNASE-I,II)은 적용된 예제에 한

정하여 기존의 공식화된 연산 알고리즘(Gauss-Seidel 방법)에 비교해서는 속도가 느리고 정확도가 떨어졌다. 신경망은 하드웨어로 구현될 경우, 병렬성을 충분히 사용할 수 있으므로 계산 속도가 현저히 개선될 것으로 보이나, 소프트웨어를 통한 수치 해석적인 방법에서는 계산상의 효율을 개선할 수 없었다.

2) 신경망에 의한 근사자(approximator)<sup>13)</sup>로서의 역할은 회귀 분석이라기 보다는 보간법에 가까우며, 보간법 중에서도 다항식 근사보다는 3차 spline과 유사하고, 학습 데이터 점을 정확하게 통과하며, 그 사이의 값을 부드러운 곡선으로 보간함을 알 수 있다.

3) 신경망의 구조 공학에의 적용 연구는 기존의 수치 해석 알고리즘에 대한 대안이긴 보다는 기존의 방법으로 해결하기 어려운 복잡한 비선형 문제나 인간만이 판단할 수 있는 문제에 적용되어야 한다고 사료된다.

## 감사의 글

본 논문은 한양대학교 초대형구조시스템연구센터의 학위 논문 연구비 지원으로 수행되었으며, 이에 감사 드립니다.

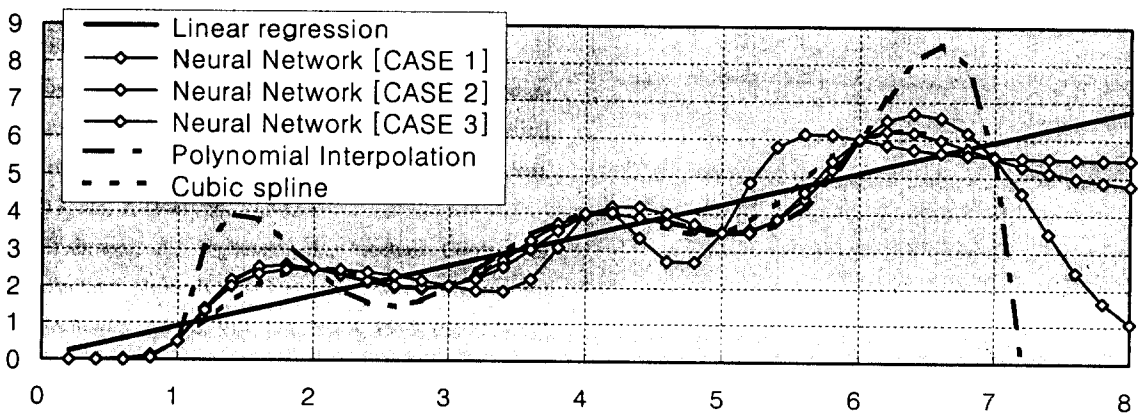


그림 4 회귀 분석, 보간법과의 비교

## 참 고 문 헌

1. Ghaboussi, J., "Some Applications of Neural Networks in Structural Engineering," *Proceedings, Structures Congress*, ASCE, Atlanta, GA, 1994.
2. Carpenter, W. C. and Barthelemy, J. F., "Common Misconceptions about Neural Networks as Approximators," *J. of Computing in Civil Engineering*, ASCE, Vol. 8, No. 3, 1994, pp. 345-358.
3. Ghaboussi, J., Garrett, J. H. and Wu, X., "Knowledge-Based Modeling of Material Behavior with Neural Networks," *J. of Engineering Mechanics*, ASCE, Vol. 117, No. 1, 1991, pp. 132-153.
4. Ghaboussi, J., Joghataie, A., "Active Control of Structures Using Neural Networks," *J. of Engineering Mechanics*, ASCE, Vol. 121, No. 4, 1995, pp. 555-567.
5. Ghaboussi, J., Garrett, J. H. and Wu, X., "Use of Neural Networks in Detection of Structural Damage," *Computers & Structures*, Vol. 42, No. 4, 1992, pp. 649-659.
6. Rogers, J. L., "Simulating Structural Analysis with Neural Network," *J. of Computing in Civil Engineering*, ASCE, Vol. 8, No. 2, 1994, pp. 252-265.
7. 김택완, 이승창, 이병해, "PC 수직 접합부의 극한 전단 내력 예측에 대한 인공 신경 회로망의 적용", *전산구조공학회논문집*, 제9권 제2호, 1996. 6, pp 93~101.
8. 백기현, 이승창, 이병해, "인공 신경 회로망을 이용한 트러스 구조물의 최적화", *대한건축학회학술발표회논문집*, 제16권 제2호, 1996. 10, pp 565~570.
9. S. Rajasekaran, M. F. Febin and J. V. Ramasamy, "Artificial Fuzzy Neural Networks in Civil Engineering," *Computers & Structures*, Vol. 61, No. 2, 1996, pp. 291-302.
10. Lu Jingui, Ding Yunliang, Wu Bin and Xiao Shide, "An Improved Strategy for GAs in Structural Optimization," *Computers & Structures*, Vol. 61, No. 6, 1996, pp. 1185-1191.
11. Zurada, J. M., *Introduction to Artificial Neural Systems*, Info Access Distribution Pte Ltd., 1992.
12. Hostetter, G. H., *Analytical, Numerical, and Computational Methods for Science and Engineering*, Prentice-Hall International, Inc., 1991.
13. Hornik, K., M. Stinchcombe, and H. White, "Multilayer Feedforward Networks Are Universal Approximators," *Neural Networks*, Vol. 2, 1989, pp. 359-366.

(접수일자 : 1997. 5. 2)