

비선형 시스템의 신경회로망을 이용한 모델링 기법

정길도*, 노태수**, 흥동표***

Nonlinear System Modeling Using a Neural Networks

Kil To Chong*, Tae-Soo No**, Dong-Pyo Hong***

ABSTRACT

In this paper the nodes of the multilayer hidden layers have been modified for modeling the nonlinear systems. The structure of nodes in the hidden layers is built with the feedforward, the cross talk and the recurrent connections. The feedforward links are mapping the nonlinear function and the cross talks and the recurrent links memorize the dynamics of the system. The cross talks are connected between the nodes in the same hidden layers and the recurrent connection has self feedback, and these two connections receive one time delayed input signals. The simplified steam boiler and the analytic multi input multi output nonlinear system which contains process noise have been modeled using this neural networks.

Key Words: Steam Boiler(증기 보일러), Nonlinear Systems(비선형 시스템), Neural Networks(신경회로망), Modeling(모델링).

1. 서 론

과거 10년 동안 신경회로망과 관련된 이론과 여러 분야에 있어서 응용은 놀라운 발전을 가져왔다. 신경회로망은 특성상 변화하는 환경에 학습을 통하여 적응하는 능력이 있고, 복잡한 비선형 함수 관계를 규명하며, 병렬로 연결됨으로 신호 처리가 신속하고 회로망의 에러에 민감하지 않으며, 알고리즘 자체가 학문적으로 난이도를 요구하지 않아 조금만 관심을 기울이면 쉽게 적용할 수 있는 유용한 공학적인 도구이다. 이러한 이유 때문에 급격한 성장을 가져왔다고 본다. 신경회로망의 적용 분야를 살펴보면 공학이나 자연 과학에만 편중된 것이 아니고 질병을 진단하거나 심전도 그래픽을 해석하고, 여러 가지 상황을 고

려하여 예상되는 기후 변화의 예측, 주식시장의 변화 추이를 규명 예측하고, 뿐만 아니라 항공기 예약에도 이용되고 있다. 이러한 이유 때문에 신경회로망과 관련된 국제 학술 대회의 투고 논문 편수를 보면, 수천 여 편의 논문이 접수되고 여러 기관에서 학술 대회를 개최하고 있는 상황이다. 신경회로망은 다양한 분야에 이용될 수 있으며 특히 비선형 특성이 강하고 복잡한 구조를 가진 시스템의 특성을 규명하는 탁월한 장점을 지니고 있다.

시스템 규명은 관측된 시스템 데이터를 이용하여 시스템의 수학적인 모델을 세우는 문제를 다룬다. 많은 선형 시스템 이론들이 개발되어 왔고 실제적인 용용에 있어 성공적으로 수행되고 있다. 그러나, 실제 비선형성이 큰 특성을 가지고 있는 많은 응용 분야가 있다. 이런 시스템

* 전북대학교 제어계측공학과

** 전북대학교 우주항공공학과

*** 전북대학교 정밀기계공학과

의 경우에, 선형 수학 모델을 세워 시스템을 해석하는 경우에 상당한 오차가 발생하여 해석이 불가능하게 되는 경우가 있다. 또한 선형 모델로 시스템 해석이 가능하다 할 경우에도, 그 허용 범위가 한정되어 이용 범위가 줄어들게 되므로 비선형 모델링을 하게 되면 이러한 문제들로 제약을 받지 않게 된다. 그러므로 주어진 비선형 시스템에 적절한 비선형 모델을 개발하는 것이 필요하다.

비선형 시스템 규명은 전형적으로 Volterra와 Wiener series 같은 함수 시리즈 방법들이 이용되어 왔다. 이들 구조는 많은 비선형 시스템들을 묘사할 수 있는 것으로 알려졌다. 그럼에도 불구하고, 적절한 시스템 규명을 위해 필요한 계산 시간들은 제한되어 있고, 또한 이렇게 얻어진 모델들은 분석하기가 어렵다. 뿐만 아니라 함수 시리즈 방법들은 시스템의 차수가 증가함에 따라 필요한 매개변수(parameter)의 수가 기하급수로 늘어나는 단점이 있다. 비선형 블랙박스(black box) 모델들은 1980년대에 Billings⁽¹⁾ 등에 의해 폭넓게 다루어졌다. 이 모델들은 지나간 시간대의 입력들과 출력들로 이루어지는 비선형 항들을 복귀시킴으로서 비선형 시스템들을 균사화 규명하였다. 이 모델은 비선형 시스템의 규명에 있어서 가장 두드러진 구조를 제안한 것 중의 하나로 여겨진다. 하지만 이 경우에도 센서에 노이즈(Noise)가 많을 경우엔 시스템 규명이 어려운 단점이 있다.

신경회로망을 시스템 규명에 응용한 경우와 동역학적 특성을 지닌 신경회로망을 개발한 연구들을 살펴보면 다음과 같다. Chen과 Billings⁽²⁾는 복잡한 비선형 시스템을 모델링하기 위한 선택으로 피드포워드(feedforward) 단열 관념소를 이용하였다. 그들은 불연속-시간 비선형 시스템의 규명에 관해 연구하였다. 그들은 순환 예측 오차 평가 알고리즘을 단열 신경회로망에 이용하였다. 이 연구는 "신경회로망으로 비선형 시스템들을 모델링 하는 것은 효과적인 접근방법이고 이 분야에서의 지속적인 연구는 상당한 가치가 있다."라는 결론을 지었다. 또한, Chen⁽³⁾과 그의 연구팀들은 병렬 순환 예측 오차 법을 이용한 새로운 신경회로망 학습 법을 개발했다.

그 외에도 여러 알고리즘이 몇 가지 형태의 순환 신경회로망 즉, 피드백과 상호연결(cross-talk)이 존재하는 회로망들이 개발되었다. Williams와 Zipser⁽⁴⁾, 그리고 Williams와 Peng⁽⁵⁾은 소위 동적 역전파라 불리는 Global Feedback 회로망들에 관한 알고리즘을 개발하였다. 연결강도들은 입력과 목표 출력에 기초한 증감들을 동적으로 조절함으로써 계산된다. 여기에서 Global Feed-

back은 단지 회로망 출력이 입력으로 피드백 된다. Narendra와 Prathasarathy⁽⁶⁾는 다층 구조 신경회로망에 학습 데이터의 출력을 입력층에 피드백 함으로써 시스템의 동역학적인 요소를 습득할 수 있는 구조를 제안했다. 그렇지만 이 경우에도 학습 데이터에 상당한 센서 노이지가 존재하게 되면 시스템 모델에 큰 오차가 발생되는 단점이 있다. Werbos⁽⁷⁾와 Pineda⁽⁸⁾는 순환 회로망들을 학습하기 위한 알고리즘을 제안하였다. 다른 연구들도 순환 신경회로망에 대한 학습 알고리즘을 제안하였다. 그러나, 이들 제안된 알고리즘의 어느 것도 출력에 많은 외란이 존재하는 경우의 비선형 동적 시스템을 규명하는 좋은 연구가 없었다.

대개 신경회로망을 이용한 비선형규명 방법은 비선형 자동회귀부류 (Nonlinear AutoRegressive with eXogenous Input(NARX)) 군에 속하는 확정 시스템(deterministic system)에 적용된다.

한 개의 은닉층을 가진 신경회로망은 모든 비선형 시스템을 균사화 규명할 수 있는 Cybenko⁽⁹⁾의 이론에 따라 대부분 역전파학습 알고리즘을 변형시킨 전진과 신경회로망을 이용하여 비선형함수 $f(\cdot)$ 를 균사화 규명하고 있다. 이러한 경우 신경회로망의 입력은 $y(k), \dots, y(k-p)$, $u(k), \dots, u(k-q)$ 가 되고 목표치는 $y(k+1)$ 가 된다. 이 방법에 사용된 p 와 q 의 결과로 추정되는 시스템모형의 차수가 확정된다. 이러한 방법은 Bhat⁽¹⁰⁾, Chen⁽¹¹⁾, Narendra⁽⁶⁾에 의하여 고찰되었다. 최근에는 Qin⁽¹²⁾이 확률적 비선형 시스템 규명에 네가지 신경회로망 구조를 비교 응용한 바 있다. 다음 장에서는 본 논문에서 응용할 회귀성 신경회로망에 대해 보다 자세히 살펴보겠다.

2. 시간지연 회귀성 다층구조관념소

비선형 시스템을 모델링하기 위하여 선택한 신경회로망의 구조는 Parlos et.al.⁽¹³⁾에 의해 연구된 회귀성 신경회로망으로 전진파와 역전파 회로망으로 혼합된 것이다. 잘 알려진 다층구조관념소 은닉층(hidden layer)의 절점에 입력층과 연결된 연결고리와 절점의 출력이 본래 절점과 연결되고 또한 이웃한 절점들과도 연결되도록 구성하였다. 이때 신호 처리는 전진파 연결의 경우엔 다층구조관념소와 같고 회귀성 연결과 상호 연결은 한 스텝 지연된 값들이 연결되어 동적 시스템을 규명하는 역할을 한다. 이런 원리에 기초한 회귀성 다층구조관념소는 비선형 시스템의 특징을 추정함과 동시에 동적 특성을 구현할 수 있다. Fig. 1은 본 연구에서 사용된 일반적인 회귀 다층

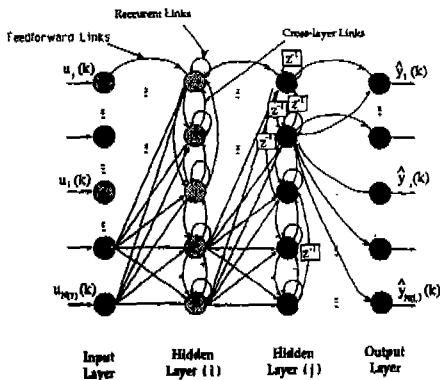


Fig. 1 Schematic Diagram of the Recurrent Multilayer Perceptron.

퍼셉트론의 모양을 묘사하고 있다.

자세한 수학적인 이론을 살펴보기 위해 L 층으로 구성된 회귀다층구조관념소를 고려해 보자.

L 개의 각 층은 $N(l)$ 절점(節點)을 갖고 있고 $l=1, \dots, L$ 이다. 버퍼(buffer) 역할을 하는 첫 번째 층에 들어가는 입력은 회로망의 입력이고, 마지막 층의 출력은 신경회로망의 출력이 된다. 신경회로망에 연결되는 입력들은 현시(Present Time)의 제어 신호들이고 이 신호들은 모델링하고자 하는 동적 시스템에 작용하는 외란에 해당된다. 지금까지 보고된 동역학적 신경회로망을 살펴보면 그 외 모두가 과거 시간대의 입력신호와 학습데이터 출력 또는 신경회로망의 출력 값을 다시 입력 층에 연결함으로 동역학적 특성을 모델링하였다. 그렇지만 이 회귀성 신경회로망은 제어 신호의 한 단계 앞의 값과 측정된 외란 혹은 출력은 입력으로 다시 연결되지 않는다.

회귀다층구조관념소의 l 번째 층에 위치한 i 번째 절점을 설명한 방정식은 다음 차분 방정식으로 나타낼 수 있다.

$$z_{[l,i]}(k) = \sum_{j=1}^{N(l)} w_{[l,j][l,i]} x_{[l,j]}(k-1) \quad (1)$$

$$+ \sum_{j=1}^{N(l-1)} w_{[l-1,j][l,i]} x_{[l-1,j]}(k) + b_{[l,i]}$$

$$x_{[l,i]}(k) = F_{[l]}(z_{[l,i]}(k)) \quad (2)$$

여기서 $z_{[l,i]}(k)$ 는 l 번째 층에서 i 번째 절점의 내부 상태 변수이고, $x_{[l,i]}(k)$ 는 신경회로망 절점의 출력이며,

$b_{[l,i],j}$ 번째 층의 i 번째 절점에 대한 바이어스를 의미한다. $w_{[l,j][l',i]}$ 는 l 번쨰 층의 j 번째 절점에서 l' 번쨰 층의 i 번째 절점으로 연결된 연결 강도이다. $F_{[l]}(\cdot)$ 는 l 번쨰 층과 관련된 식별 함수(discriminatory function)이다. 이 함수는 선형, S형만곡(sigmoid), 쌍곡탄젠트(hyperbolic tangent) 중에 하나가 될 수 있다. 본 논문에서는 은닉 층에 대해서는 쌍곡탄젠트 식별 함수를 사용했고, 반면에 출력 층에서는 선형 식별 함수 사용했다.

앞에서 언급한 것처럼 식(1)과 식(2)는 회귀다층구조관념소의 입력과 출력 사이에 전진과 경로에 시간 지연이 없음을 나타내고 있다. 그러므로 이 신경회로망에서 전진과 부분은 잘 알려진 다층구조관념소의 커브핏팅 특성과 같고, 반면에 회귀와 은닉층 상호연결 부분은 동적 특성을 갖는다. 회귀다층구조관념소의 출력들은 현재의 신경회로망의 입력에 대한 함수이고 또한 내부 상태변수에 대한 함수이기도 하다. 결국 과거 시간대의 입력과 출력들은 신경회로망에 다시 공급되지 않는다. 왜냐하면 이들의 영향은 회귀다층구조관념소의 내부 상태변수들에 의하여 소멸되기 때문이다.

위에서 제안한 회귀성 신경회로망의 동적 학습알고리즘은 Zipser와 Williams⁽⁴⁾의 전진 전파 방법(forward-propagation approach)에 기초하고 다층구조 관념소의 구조에 대한 동적 학습 알고리즘을 이용하였다.

3. 동적 학습 알고리즘

이 절에서는 회귀 다층구조관념소 신경망을 학습시키기 위하여 개발한 동적 학습 알고리즘(dynamic learning algorithm)을 설명한다. 여기서는 오차 목적 함수(error objective function)를 최소화하는 가중치와 바이어스(bias)의 세트를 결정한다. 따라서 재래식 시스템 동정 과정에서 매개변수 추정과 유사하다.

개발한 알고리즘이 감시의 진단과 복잡한 공정 시스템의 제어에 응용되기 때문에 온라인(on-line) 학습은 물론 오프라인(off-line) 학습에도 적용되어야 한다. 그러므로 가중치를 선정하는데 두 가지 학습 모드를 각각 설명한다. 오프라인 학습 모드에서 서로 연관되는 K 쌍의 입력-출력 데이터를 갖는 학습 데이터(training set)를 가정한다. 이것이 요구되는 오차 범위 내에 도달할 때까지 반복적으로 신경회로망에 작용한다. 이러한 학습기간 중에 신경회로망의 가중치는 잘 알려진 급강하법(steepest descent)을 이용하여 최적 값이 구해진다.

$$\Delta w_{[l-1,j][l,i]} = -\eta \sum_{k=1}^K \left(\frac{\partial E(k)}{\partial w_{[l-1,j][l,i]}} \right) \quad (3)$$

여기서 η 는 학습율(learning rate)이고, $E(k)$ 는 k 번째 시간에서 식(4)로 표현되는 오차의 차승이다.

$$E(k) = \sum_{i=1}^{N(L)} (x_{[L,i]}(k) - y_i(k))^2, \quad (4)$$

여기서 $x_j(k)$ 와 $\hat{y}_j(k)$ 는 각각 j 번째 신경회로망 출력과 목표치이다. 바이어스에 대해서는 물론 회귀 가중치에 대해서도 같은 생신 법칙이 적용된다. 그러나 온-라인 학습에 대해서는 미리 결정된 학습 데이터는 없고, 가중치는 측정된 정보가 접수되었을 때 생신된다. 다음 전진전파 가중치(마찬가지로 회귀 가중치와 바이어스)가 식(5)와 같이 온-라인 학습되는 동안 사용된다.

$$\Delta w_{[l-1,j][l,i]} = -\eta \sum_{k=k'-n}^k \left(\frac{\partial E(k)}{\partial w_{[l-1,j][l,i]}} \right) \quad (5)$$

여기서 $\eta > 1$, η 는 학습율이다. 매개변수 n 은 새로운 가중치가 사용되지 않는 동안 계간 시간의 수를 나타낸다. 추정되는 시스템에 따라서 n 을 0으로 고정시킬 수 있다. 단 샘플링 시간이 동적 변화를 충분히 감지할 수 있는 시스템이어야 한다. 만일 시스템 매개변수가 현저하게 변하지 않는다면 n 값을 크게 잡아도 된다.

본 연구에서는 중감(gradients)은 Zipser와 Williams⁽⁴⁾의 전진 전파 방법(forward-propagation approach)과 비슷한 방법을 이용하여 결정된다. 차이점은 개발한 알고리즘은 총을 통과하여 공간과 시간대에서 중감이 앞으로 전파되는 반면 Williams와 Zipser의 알고리즘은 단지 시간대에서만 앞으로 전파된다. 이러한 전진전파 방법이 시간역전파와 같은 방법과 비교하여 대단히 계산 상 복잡성을 갖고 있다 하더라도 온-라인 응용에는 더욱 적합하다. 왜냐하면 반복적인 성질이 있기 때문이다. 식(4)를 가중치와 바이어스에 대해서 미분하면 다음 식이 된다.

$$\left(\frac{\partial E(k)}{\partial w_{[l,j][l,i]}} \right) = 2 \sum_{n=1}^{N(L)} (x_{[L,n]}(k) - \hat{y}_n(k)) \frac{\partial x_{[L,n]}(k)}{\partial w_{[l,j][l,i]}} \quad (6)$$

$$\left(\frac{\partial E(k)}{\partial b_{[l-1,j][l,i]}} \right) = 2 \sum_{n=1}^{N(L)} (x_{[L,n]}(k) - \hat{y}_n(k)) \frac{\partial x_{[L,n]}(k)}{\partial b_{[l-1,j][l,i]}} \quad (7)$$

$$\left(\frac{\partial E(k)}{\partial b_{[l,i]}} \right) = 2 \sum_{n=1}^{N(L)} (x_{[L,n]}(k) - \hat{y}_n(k)) \frac{\partial x_{[L,n]}(k)}{\partial b_{[l,i]}} \quad (8)$$

구배항인 $\partial w_{[L,n]}(k) / \partial w_{[l,j][l,i]}$ 를 고려해 보자. 식(1)과 (2)를 $w_{[l,j][l,i]}$ 에 대해서 미분하면, 모든 m 에 대해서 $\partial x_{[L,m]}(k-1) / \partial w_{[l,j][l,i]}$ 와 $\partial w_{[L-1,m]}(k) / \partial w_{[l,j][l,i]}$ 의 항으로서 $\partial x_{[L,n]}(k) / \partial w_{[l,j][l,i]}$ 이 얻어짐을 알 수 있다.

동일하게 모든 p 에 대해서 $\partial x_{[L-1,p]}(k-1) / \partial w_{[l,j][l,i]}$ 과 $\partial w_{[L-2,p]} / \partial w_{[l,j][l,i]}$ 의 형태로 $\partial w_{[L-1,m]}(k) / \partial w_{[l,j][l,i]}$ 이 얻어진다. 그러기에 고려된 접근 방식은 둘째 층의 출력 구배인 $\partial w_{[2,m]}(k) / \partial w_{[l,j][l,i]}$ 을 먼저 계산한다. 그때, 피드포워드 전파의 알고리즘에 의해 $\partial w_{[L,n]}(k) / \partial w_{[l,j][l,i]}$ 가 얻어질 때까지 다음 층의 출력 구배를 계산하는 과정이다. 그때의 오차 구배들은 식(6)으로써 계산된다. 본 논문에서 일반화된 델타 규칙은 주어진 입력에 대한 그것의 출력을 얻기 위한 피드포워드 네트워크의 과정에 의해 행해진다. 그때 네트워크의 출력과 목표 출력 사이의 오차들을 형성하면서 네트워크의 입력에까지 마지막 층에서부터 구배들이 역전파 된다. 본 연구에서는 네트워크의 두 가지 과정이 피드포워드로 행해진다.

이 실행 범은 둘째 과정이 시작하기 위해서 첫째 과정이 완전히 끝나야 하는 것에 대한 시간 지연을 생략해 준다. 물론 그것의 한 네트워크 층에서의 시간 지연을 가지고서 두 가지 과정이 동시에 행해질 수 있다. 논의되었듯이 피드포워드 구배전파를 실행하는데 쓰여진 연결 식은 (1)과 (2)식을 각각 $w_{[l,j][l,i]}$ 와 $w_{[l-1,j][l,i]}$ 에 대해서 미분함으로서 유도할 수 있다. 그 결과는 다음과 같다.

$$\begin{aligned} \left(\frac{\partial x_{[l',n]}(k)}{\partial w_{[l,j][l,i]}} \right) &= \begin{cases} F'_{[l']}(z_{[l',n]}(k)) \left[\sum_{m=1}^{N(l')} w_{[l',m][l',n]} \frac{\partial x_{[l',m]}(k-1)}{\partial w_{[l,j][l,i]}} \right. \\ \left. + \sum_{m=1}^{N(l'-1)} w_{[l'-1,m][l',n]} \frac{\partial x_{[l'-1,m]}(k)}{\partial w_{[l,j][l,i]}} \right] & (\text{if } l' > l) \\ F'_{[l']}(z_{[l',n]}(k)) \left[\sum_{m=1}^{N(l'-1)} w_{[l',m][l',n]} \frac{\partial x_{[l',m]}(k-1)}{\partial w_{[l,j][l,i]}} \right. \\ \left. + \delta_{in} x_{[l',j]}(k-1) \right] & (\text{if } l' = l) \\ 0 & (\text{if } l' = l) \end{cases} \quad (9) \end{aligned}$$

$$\begin{aligned} \left(\frac{\partial x_{[l',n]}(k)}{\partial w_{[l-1,j][l,i]}} \right) = & \begin{cases} F'_{[l']}(z_{[l',n]}(k)) \left[\sum_{m=1}^{N(l')} w_{[l',m][l',n]} \frac{\partial x_{[l',m]}(k-1)}{\partial w_{[l-1,j][l,i]}} \right. \\ \left. + \sum_{m=1}^{N(l'-1)} w_{[l'-1,m][l',n]} \frac{\partial x_{[l'-1,m]}(k)}{\partial w_{[l-1,j][l,i]}} \right] & (\text{if } l' > l) \\ F'_{[l']}(z_{[l',n]}(k)) \left[\sum_{m=1}^{N(l'-1)} w_{[l-1,j][l',m]} \frac{\partial x_{[l',m]}(k-1)}{\partial w_{[l-1,j][l,i]}} \right. \\ \left. + \delta_{in} x_{[l'-1,j]}(k) \right] & (\text{if } l' = l) \\ 0 & (\text{if } l' < l) \end{cases} \quad (10) \\ \left(\frac{\partial x_{[l',n]}(k)}{\partial b_{[l,i]}} \right) = & \begin{cases} F'_{[l']}(z_{[l',n]}(k)) \left[\sum_{m=1}^{N(l')} w_{[l',m][l',n]} \frac{\partial x_{[l',m]}(k-1)}{\partial b_{[l,i]}} \right. \\ \left. + \sum_{m=1}^{N(l'-1)} w_{[l'-1,m][l',n]} \frac{\partial x_{[l'-1,m]}(k)}{\partial b_{[l,i]}} \right] & (\text{if } l' > l) \\ F'_{[l']}(z_{[l',n]}(k)) \left[\sum_{m=1}^{N(l')} w_{[l,i][l',m]} \frac{\partial x_{[l',m]}(k-1)}{\partial b_{[l,i]}} \right. \\ \left. + \delta_{in} \right] & (\text{if } l' = l) \\ 0 & (\text{if } l' < l) \end{cases} \quad (11) \end{aligned}$$

여기서, $l', l = 1 \dots, N(L)$ 그리고 $i, j = 1, \dots, N(l)$ 이다. 또한 모든 네트워크의 과정에 있어서 아래와 같은 것이 적용된다.

$$\delta_{in} = \begin{cases} 1 & \text{if } i = n, \\ 0 & \text{if otherwise} \end{cases} \quad (12)$$

$\partial x_{[l',n]}(0) / \partial w_{[l,j][l,i]}, \partial x_{[l',n]}(0) / \partial w_{[l-1,j][l,i]}, \partial x_{[l',n]}(0) / \partial b_{[l,i]}$ 의 구배함들에 대한 초기치들은 0으로 한다. 식(9)에서 (11)까지는 각각의 연결 강도들에 대해서 분리 적용되어야 한다.

그러나, $l' = l$ 층으로부터 항상 시작하고 그런 뒤 $l' = L$ 까지 피드포워드로 전파된다고 생각하면 된다. 왜냐하면 $\partial x_{[l',n]}(k) / \partial w_{[l,j][l,i]}, \partial x_{[l',n]}(k) / \partial w_{[l-1,j][l,i]}, \partial x_{[l',n]}(k) / \partial b_{[l,i]}$ 는 $l' < l$ 일 때 모두 0이기 때문이다.

4. 신경회로망을 이용한 시스템규명

4.1 단순화한 증기 보일러의 시스템규명

신경회로망을 이용한 응용으로 간단한 증기 보일러를 회성 신경회로망을 이용하여 모델링 하였다. 시스템과 관련된 방정식은 J.I. Choi의 논문을 이용하였으며 다음과 같다.⁽¹⁴⁾

$$\dot{P}_d(t) = \frac{1}{\tau_d} (W_{ar}(t) - W_d)(t), \quad (13)$$

$$\dot{P}_d(t) = \frac{1}{\tau_{sh}} (W_d(t) - W_{sh})(t), \quad (14)$$

$$\dot{P}_r(t) = \frac{1}{\tau_r} (W_{sh}(t) - P_r(t)), \quad (15)$$

$$W_d(t) = [K_{sh}(P_d(t) - P_f(t))]^{\frac{1}{2}}, \quad (16)$$

$$W_{sh}(t) = A_{cv}(t)P_t(t), \quad (17)$$

$$MW(t) = K_t W_{sh}(t) + (1 - k_t)P_{r(t)} \quad (18)$$

여기에서 $P_c(t), P_t(t)$ 와 $P_r(t)$ 는 각각 드럼(drum), 조절판(Throttle) 재가열(Reheat) 압력의 상태 변수를 의미한다. 제어 입력은 $W_{ar}(t)$ 이며, 필요한 전력 생산량에 따라 변동되는 외란 즉 제어입력은 제어 밸브의 위치 $A_{cv}(t)$ 이다. 보일러 드럼(Boiler Drum), 고전열기(Superheater), 재가열기(Reheater)의 시정수는 각각 τ_d, τ_{sh} 와 τ_r 로 표시된다.

$W_d(t)$ 와 $W_{sh}(t)$ 는 각각 보일러 드럼, 고전열기의 증기 유동량을 의미하고, $MW(T)$ 는 전체 발전량을 의미한다. 또한 고성능 터빈을 통한 전기 생산률을 K_t 로 나타낸다.

시스템 규명에 이용된 신경회로망의 구조는 입력층에 한 개의 절점과 두 개의 은닉층에 각각 8개와 6개의 절점을 그리고 한 개의 출력절점을 가진 형태를 선택하였다. 물론 이 구조는 여러 가지 경우를 고려해 본 결과 선택했다. 발전소의 증기 보일러는 개루프(Open Loop)의 경우 전체 작동 구간 안에서 안정된 시스템이다. 그러므로 입력이 $A_{cv}(t)$ 이며 출력이 $MW(T)$ 인 개루프(open loop) 시스템의 동작 상태를 모델링 하는 것이 가능하다. 발전소 운영시 대부분의 경우에 외란이 스텝과 램프로 되어 있다. 따라서 이 두 가지 신호만을 학습과 검증 과정에서 고려하였다. 이 응용 예의 학습 데이터는 9가지 스텝 즉, 정규화된 전기 발전량의 0.01에서 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9의 스텝으로 구동하도록 선택하였으며, 495개의 샘플로 되어 있다. 1-8-6-1 회귀 신경회로망은 연결 강도와 바이어스(bias)의 학습율을 0.05로 400사이클(cycle) 동안 학습되었다. 추가로 또다시 연결 강도와 바이어스의 학습율을 0.01로 하여 500사이클 동안 학습시켰다.

위에서 모델링 한 신경회로망의 모델이 증기 보일러를 정확하게 규명하였는가를 검증하기 위하여 3가지 스텝

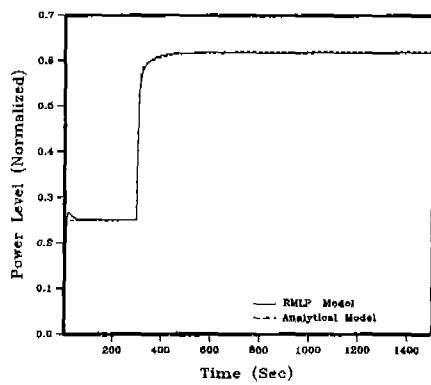


Fig. 2 Steam Boiler Power Plant Step Disturbance Response (Intermediate Power).

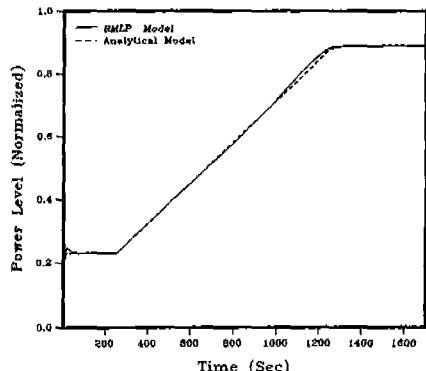


Fig. 3 Steam Boiler Power Plant Ramp Disturbance Response.

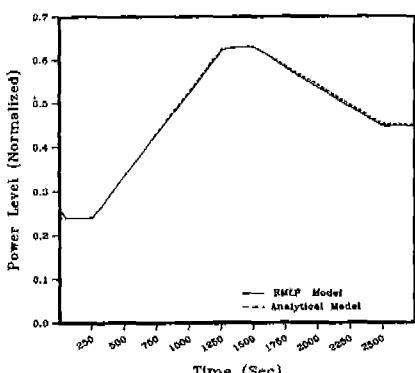


Fig. 4 Steam Boiler Power Plant Ramp-up Ramp-down Disturbance Response.

외란, 즉, 낮은 발전량, 높은 발전량 그리고 중간 발전량으로 시험하였다. 이러한 시험 외란에 대한 신경회로망과 증기 보일러의 RMS(Root-Mean-Square) 모델링 에러는 각각 1.1%, 1.5%, 2.2%로 나타났으며 완전 가동 상태의 40~60%의 중간 발전량에 대한 응답이 Fig. 2에 나타나 있다. 또한, 스텝 테스트의 경우에 비해 넓은 발전량 영역의 변화를 램프 입력으로 구동한 검증의 경우를 시험해 보았으며 이 경우에 응답이 Fig. 3에 나타나 있다. 마지막으로, 상승 램프와 하강 램프를 결합한 구동을 검증 신호로 고려하였으며, 이때 응답은 Fig. 4에 나타나 있고, RMS 모델링 에러는 각각 1.3%, 1.4%이다.

$$\text{Error} = \frac{\sqrt{\sum_{k=1}^K \sum_{i=1}^{N(L)} (x_{L,i}(k) - y_i(k))^2}}{\sqrt{\sum_{k=1}^K \sum_{i=1}^{N(L)} (y_i^2(k))}} \quad (19)$$

4.2 외란이 존재하는 다중 입력 다중 출력 비선형 시스템 규명

외란이 존재하는 다음과 같은 다중 입력 다중 출력 (MIMO) 시스템에 대해 신경회로망을 이용하여 모델링 해보았다.

$$x_1(k) = 0.5(x_1^2(k-1))^{\frac{1}{3}} + 0.3x_2(k-1)x_3(k-1) + 0.2u_1(k-1) + n_{x1}^{pr}(k), \quad (20)$$

$$x_2(k) = 0.5(x_2^2(k-1))^{\frac{1}{3}} + 0.3x_3(k-1)x_1(k-1) + 0.2u_2(k-1) + n_{x2}^{pr}(k), \quad (21)$$

$$x_3(k) = 0.5(x_3^2(k-1))^{\frac{1}{3}} + 0.3x_1(k-1)x_2(k-1) + 0.2u_3(k-1) + n_{x3}^{pr}(k), \quad (22)$$

$$x_1(k) = 0.5(x_1(k) + x_2(k) + x_3(k)), \quad (23)$$

$$y_2(k) = 2(x_1^2(k))^2 \quad (24)$$

여기에서 $n_{x_j}^{pr}(k)$ 는 $j=1,2,3$ 에 대하여 각각 시스템의 공정 과정의 외란을 의미한다. 본 예제에서 사용된 회귀성 신경회로망은 2개의 입력노드, 2개의 은닉층(각각 12개와 10개의 노드를 지님), 2개의 출력 노드로 이루어졌다.

(2-12-10-2). 학습 데이터는 크기가 0.125, 0.25, 0.375, 0.5인 모든 가능한 25개의 스텝의 조합(입력 채널에서 0입력도 포함)으로 이루어져 있고 각 스텝의 경우에 15개씩 샘플링 하여 375개의 데이터를 선택하고 추가적으로 5개의 폴스를 각각 40개씩 샘플링 하여 전체 575개의 샘플을 학습 데이터로 설정했다. 외란은 평균이 0이며, 표준편차가 0.02인 백색 잡음을 사용하였다. 연결 강도와 바이어스 학습율이 0.01이고 3600번을 학습시켰다.

첫 번째 검증의 입력 신호는 $u_1(k) = 0.3 + 0.2\sin(\pi k/8)$, $u_2(k) = 0.2$ 이다. 여기서 두 번째 채널의 스텝 입력은 첫 번째 채널에서의 입력과 비교하여 5 단계 시간 지연된다. 두 번째의 검증 신호는 폴스이며, 마지막 검증 신호는 0.1의 표준편차를 가지고 백색 가우스 잡음의 평균값이 0인 신호가 가미된 스텝으로 이루어져 있다. y_1 의 응답은 Fig. 5에 나타나 있고 RMS오차는 사인, 폴스, 외란이 존재한 스텝의 경우에 각각 7.67×10^{-2} , 5.66×10^{-2} ,

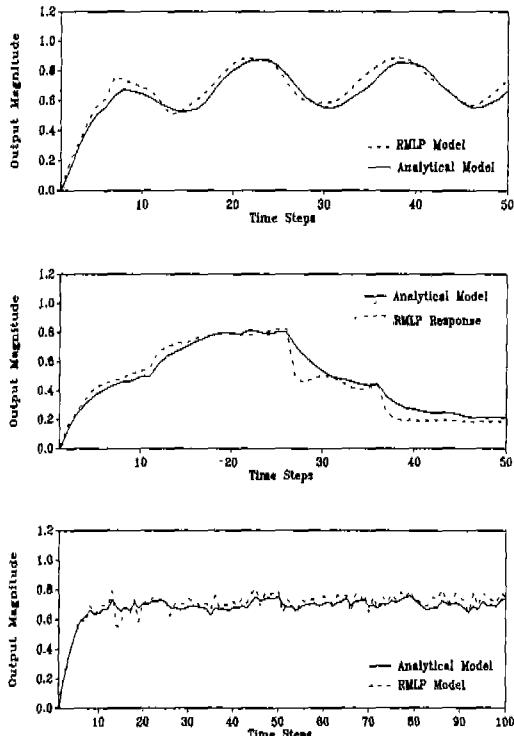


Fig. 5 Response for High Noise Environment RMLP Model First Output: Top: Sinusoidal Input; Middle: Ramp Input; Bottom: Step Input

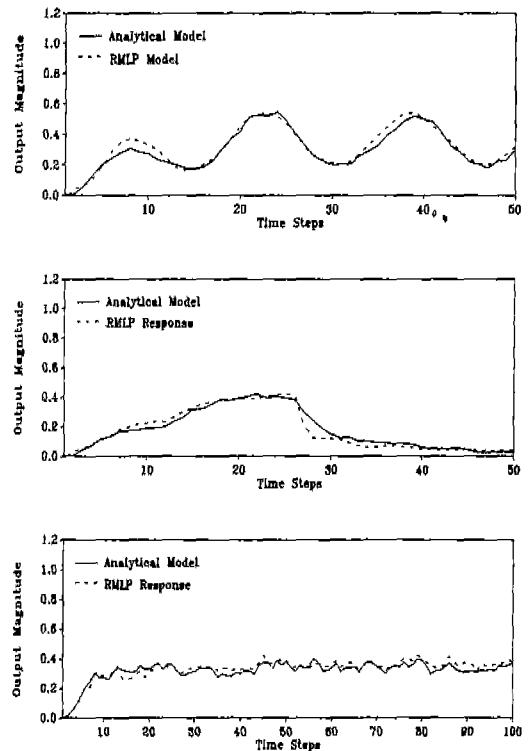


Fig. 6 Response for High Noise Environment RMLP Model Second Output: Top: Sinusoidal Input; Middle: Ramp Input; Bottom: Step Input.

0.16이다. 또한 y_2 의 응답은 Fig. 6에 나타나 있으며, RMS오차는 사인, 폴스, 외란의 스텝의 경우에 각각 6.74×10^{-2} , 3.42×10^{-2} , 0.22이다.

5. 결 론

비선형시스템의 규명의 기초적인 이론과 종류에 관해 살펴보았으며, 동적 변화 상태의 모델링이 가능한 회귀성 신경회로망을 살펴보았다. 회귀성 신경회로망의 피드포워드 부분은 다층구조관념소의 형태이고, 피드백 부분은 회귀 연결과 각 층들의 혼성 연결로 이루어졌다. 신경회로망의 응용으로 단순화한 종기 보일러의 시스템 모델링과 외란이 존재하는 다중 입력 다중 출력의 복잡한 비선형 시스템을 규명해 보았다. 결과적으로 회귀성 신경회로망은 시스템의 동특성을 전혀 모르는 구조적인 비선형성을 지닌 시스템의 동역학적인 상태 변화를 규명하는데 매우 효과적임을 알 수 있었다. 시스템 규명을 통해 구한 모

델의 겸중 시 나타난 RMS 모델링 오차는 이 결론을 확
인해 주며 회귀 신경회로망이 더 복잡한 비선형시스템에
의 규명에도 효과적으로 쓰일 수 있음을 시사한다.

참 고 문 헌

1. S.A. Billings, "Identification of Nonlinear Systems-A Survey," IEEE Proc. D; Control Theory and Applications, Vol. 127, (6).pp. 272-285, 1980.
2. S. Chen, S.S. Billings and P.M. Grant, "Nonlinear System Identification Using Neural Networks," Int. J. Control, Vol. 51, No.6, pp. 1191-1214, 1990.
3. S. Chen, F.N. Cowan and S.S. Billings, "Parallel Recursive Prediction Error Algorithm for Training Layered Neural Networks," Int. J. Control, Vol. 51, No. 6. pp. 1215-1228, 1990.
4. R.J. Williams, and D. Zipser, "A Learning Algorithm for Continually Running fully Recurrent Neural Networks," Neural Computation, Vol. 1 pp. 270-280, 1989.
5. R.J. Williams and J. Peng, "An Efficient Gradient-Based Algorithm for On-line Training of Recurrent Network Trajectories," Neural Computation, Vol. 2, pp. 490-501, 1990.
6. K.S.Narendra and K. Paratharathy, "Identification and Control of Dynamic System Using Neural Networks," IEEE Transactions on Neural Networks, Vol. 1, No. 1. pp. 4-27, 1990.
7. P.J. Werbos, "Backpropagation Through Time: What it Does and How to Do It," Proceedings of the IEEE, Vol. 78, No. 10, pp. 1550-1560, 1990.
8. F.J. Pineda, "Recurrent Backpropagation and the Dynamical Approach to Adaptive Neural Computation," Neural Computation, Vol. 1, pp. 161-172, 1989.
9. Cybenko,G., "Approximation by Superposition of a Sigmoidal Function" Mathematics of Control, Signal, and Systems, 2:303-314, 1989.
10. Bhat, N. and McAvoy, T.J., "Use of neural Nets for Dynamic Modeling and Control of Chemical Process Systems," Computers and Chemical Engineering, Vol. 14, No. 4/5, pp. 573-583, 1990.
11. S.Chen,C.F.N.Cowan,S.A.Billings and P.M.Grant,"A Parallel Recursive Prediction-Error Algorithm for Training Layered Neural Networks," Int. Journal of Control,Vol. 51, pp. 1215-1228, 1990.
12. Qin,S.-Z,H._t.Su, and t.J.McAvoy, "Comparison of Four Neural Net Learning Methods for Dynamic System Identification," IEEE Transactions on Neural Networks, Vol. 3, No. 1, pp. 122-130, 1992.
13. Parlos, Chong. Atiya, "Application of the Recurrent Multilayer Perceptron in Modeling Complex Process Dynamics," IEEE Trans. Neural Network, Vol. 5, No. 2, pp.255-266, Mar. 1994.
14. J.I. Choi, "Nonlinear Digital Computer Control for the Steam Generator System in a Pressurized Water Reactor Plant," PhD Dissertation, Dep. Nuclear Engineering, Mass. Inst. Tech., Cambridge, MA, 1987.