

지역시간지연 순환형 신경회로망을 이용한 비선형 시스템 규명

정 길 도,* 흥 동 표**

System Identification of Nonlinear System using Local Time Delayed Recurrent Neural Network

K. T. Chong, * D. P. Hong**

ABSTRACT

A nonlinear empirical state-space model of the Artificial Neural Network(ANN) has been developed. The nonlinear model structure incorporates characteristic, so as to enable identification of the transient response, as well as the steady-state response of a dynamic system. A hybrid feedforward/feedback neural network, namely a Local Time Delayed Recurrent Multilayer Perception(RMLP), is the model structure developed in this paper. RMLP is used to identify nonlinear dynamic system in an input/output sense. The feedforward portion of the network architecture provides with the well-known curve fitting factor, while local recurrent and cross-talk connections provides the dynamics of the system. A dynamic learning algorithm is used to train the proposed network in a supervised manner. The derived dynamic learning algorithm exhibit a computationally desirable characteristic; both network sweep involved in the algorithm are performed forward, enhancing its parallel implementation. RMLP state-space and its associate learning algorithm is demonstrated through a simple examples. The simulation results are very encouraging.

Key Words : Nonlinear System Identification(비선형 시스템 규명), Neural Network(신경회로망), Local Time Delayed Recurrent Multilayer Perceptron(지역 시간 지연 다층구조 관념소)

1. 서 른

시스템 규명은 관측된 시스템 데이터를 기본으로 한 시스템들의 수학적인 모델을 세우는 것에 대한 문제를 다룬다. 많은 선형 시스템 이론들이 이 분야에서 개발

되어 왔고 실제적인 응용에 있어 성공적으로 수행되고 있다. 그러나, 실제 비선형성이 큰 특성들을 가지고 있는 많은 응용 분야가 있다. 이런 시스템의 경우에, 선형 수학 모델을 세워 시스템을 해석하는 경우엔 상당한 오차가 발생하여 해석이 불가능하게 되는 경우가 있다.

* 전북대학교 공과대학 제어계측공학과

** 전북대학교 공과대학 정밀기계공학과

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 대한 적당한 비선형 모델을 개발하는 것이 필요하다.

비선형 시스템 규명에 있어서 전형적으로 Volterra 와 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 parameter의 수가 기하 급수로 늘어나는 단점이 있다. 비선형 블랙박스(black box) 모델들은 1980년대에 Billings⁽¹⁾ 등에 의해 폭넓게 다루어졌다. 그들은 이전의 입력들과 출력들로 이루어지는 비선형 항들을 복귀시킴으로서 비선형 시스템들을 근사화 규명하였다. 이들은 비선형 시스템의 규명에 있어서 몇몇 가장 두드러진 구조를 제안한 것으로 여겨진다. 하지만 이 경우에도 센서에 노이지(Noise)가 많을 경우엔 시스템 규명이 어렵다는 단점이 있다.

인공 신경회로망(ANN)은 층(layer)들 안에 선형적인 열(array)들로 모여 서로 다중으로 연결된 진행 요소들을 가지고 있는 생물학적으로 고무된 위상적인 회로망이다. 회로망의 요소 중 하나인 절점은 간단한 비선형 연산자에 의해 특성화된다. 신경회로망이 비선형 시스템을 규명할 수 있는 근원은 특정한 절점의 비선형성 필터(Filter)와 회로망 위상(位相) 기하학적인 조합에 기인한다.

인공 신경회로망은 생물학적인 신경계들의 구조와 유사하게 구성되어 있다. 어떤 인공 신경회로망은 전형적으로 한 세트의 단순한 회로망 요소들로 이루어져 있다. 그리고 그것의 각각은 본질적으로 독립된 진행자이다. 생물학적 신경회로망의 세포 체들은 인공 신경회로망 안에 포함된 절점들로서 모델링되었다. 접합들을 통해 연결된 체축(體軸)들과 수상 돌기들로 이루어진 신경세포들 사이의 경로들은 인공 신경회로망 링크들로 모델링되었다. 생물학적인 신경세포의 발화율(firing rate)은 화학 물질들의 발단(threshold)에 기초한다. 이것은 인공 신경회로망의 가중치(Weight)와 바이어스(Bias)들로 모델링된다. 이러한 회로망들의 작동은 유사하다. ⁽²⁾⁽³⁾⁽⁴⁾

이들 진행 요소들과 연결 가중치들 그리고 바이어스들로 이루어진 회로망은 설계된 학습 계획들에 기초하여 사상(寫像) 특성을 배운다. 학습은 인공 신경회로망의 유일한 특성이다. 어떤 인공 신경회로망이 구성되면 입력 벡터들은 입력층들 안에서 완충된다. 이때 입력층들은 회로망 위상의 링크들을 경유하여 다음 층 절점들에 연결되어 있다.

인공 신경회로망은 일반화(generalization), 추출(abstraction)과 보간(interpolation)의 특징들을 갖고 있다. 신경계 회로망은 병렬의 집단적인 계산을 할 수 있고, 산재한 메모리를 가지고 있다. 그것들은 데이터들에 결점이 존재할 경우에도 무리 없이 시스템을 잘 규명할 수 있는 능력이 있다. 그리고 신경계 회로망은 공학, 경제학, 의학 등 여러 분야에 일반적인 목적을 위하여 이용될 수 있다. 신경계 회로망의 단점은 회로망 학습에 있어서 긴 계산 시간을 필요로 하고 국부적인 최소 값들에 빠질 가능성이 있다는 것이다. ⁽⁴⁾⁽⁵⁾

신경계 회로망을 시스템 규명이나 동역학적 특성을 지닌 신경계 회로망을 개발한 연구들을 살펴보면 다음과 같다. Chen과 Billings⁽⁶⁾은 복잡한 비선형 시스템을 모델링하기 위한 선택으로 피드포워드(feedforward) 다열 관념소를 이용하였다. 그들은 불연속시간 비선형 시스템들의 규명에 관해 연구하였다. 그들은 순환 예측 오차 평가 알고리즘으로써 단열 신경회로망을 이용하였다. 이 연구는 “신경회로망으로 비선형 시스템들을 모델링하는 것은 효과적인 접근 방법이고 이 분야에서의 지속적인 연구는 상당한 가치가 있다.”라는 결론을 지었다. 또한, Chen⁽⁷⁾과 그의 연구팀들은 병렬 순환 예측 오차 법을 이용한 새로운 신경회로망 학습법을 개발했다.

그 외에도 여러 알고리즘이 몇몇 형태의 순환 신경회로망들 즉, 피드백과 cross-talk 연결들이 있는 회로망들이 개발되었다. Williams과 Zipser,⁽⁸⁾ 그리고 Williams과 Peng⁽⁹⁾은 소위 동적 역전파(backpropagation)라 불리는 Global Feedback 회로망들에 관한 알고리즘을 개발하였다. 가중치들은 입력들과 목표 출력들에 기초한 증감들을 동적으로 조절함으로써 계산된다. 그것은 단지 회로망 출력이 피드백 된다는 것이다. Narendra와 Prathasarathy은 다중 구조 신경회로망에 학습 데이터의 출력을 입력층에 피드백 함으로써 시스템의 동역학적인 요소를 일대일 대응하는 구조를 제안했다. 하지만 이 경우에도 학습 데이터에 센서 노

이지가 많게 되면 시스템 모델에 큰 오차가 발생되는 단점이 있다. Werbos⁽¹¹⁾과 Pineda⁽¹²⁾는 순환 회로망들을 학습하기 위한 알고리즘을 제안하였다. 다른 연구원들은 순환 신경회로망에 대한 학습 알고리즘을 묘사하였다. 그러나, 이들 제안된 알고리즘의 어떤 것도 출력에 많은 의란이 존재하는 경우의 비선형 동적 시스템을 규명하는 좋은 연구가 없었다.

2. 지역시간지연 순환형 신경회로망

2.1. 신경회로망의 모델구조

이 연구에 이용된 순환형 신경회로망(Recurrent Multilayer Perceptron (RMLP)) 구조는 동적 시스템을 규명하는 특성을 가진 혼성 피드포워드/피드백 회로망들의 부류에 속한다. 이런 순환 회로망과 순수한 피드포워드 회로망과의 주된 차이점은 전자에는 부가적인 링크들이 있다는 점이다. 그리고, 그것은 각 절점의 출력력을 직접 혹은 다른 절점들을 통하여 그 자체로 되돌린다. 이러한 링크들의 존재는 각 절점에 이전의 정보를 남아 있게 하여 새로운 입력들과 함께 처리되게 한다. 이 연구에 이용된 순환 회로망에 대하여 1번째 열에 위치한 i 번째 절점을 표현하는 방정식은 다음과 같이 주어진다.

$$\begin{aligned} z_{[l,i]}(n) &= \sum_{j=1}^{N(l)} w_{[l,j][l,i]} x_{[l,j]}(n-1) \\ &\quad + \sum_{j=1}^{N(l-1)} w_{[l-1,j][l,i]} x_{[l-1,j]}(n) + b_{[l,i]} \end{aligned} \quad (1)$$

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

$z(n)$ 은 n 번째의 절점 활성화 함수의 값이고, $w_{[x_i][y_j]}$ 는 x 열의 i 번째 노드에서 y 열의 j 번째 노드로 연결된 가중치이며, $b_{[l,i]}$ l 열의 i 번째 바이어스이고, $x(n)$ 은 절점의 계산된 출력을 나타낸다.

2.2 순환형 신경회로망에 대한 역전파학습

동적 시스템의 응답을 규명하기 위해 인공 신경회로망의 학습에 이용된 학습 예는 소위 역전파 학습이라는 것에 기초하였다. 표준 역전파학습의 큰 단점은 정확한 결과를 얻기 위해서는 수많은 반복 작업이 필요하며 그것의 열등한 수렴성이다.

주어진 학습 세트에 대하여 역전파학습법의 기본적인

메커니즘은 회로망에 의해 예측된 출력과 감지된 시스템 출력과의 평균 제곱근 오차(mean-squared error)가 허용 오차보다 작을 때까지 인공 신경회로망 가중치와 바이어스 항들을 조정하는 것이다. 특히, 어떤 역전파 기초 학습 알고리즘의 목적은 식(3)과 같은 함수의 모든 i, j 에 대하여 회로망 변수 w 와 b 가 최소가 되는 w 의 변화를 결정하는 것이다.

$$E(k) = \frac{1}{2} \sum_{i=1}^{N(L)} (x_{[L,i]}(k) - y_i(k))^2 \quad (3)$$

여기서 가변수 k 는 오차가 평가되는 불연속 시간이며, $y_i(k)$ 는 학습데이터의 출력값을 나타낸다.

회로망 학습은 온라인이나 오프라인 상태에서 수행되어질 수 있다. 역전파학습에 있어 $(m+1)$ 번째 회로망의 피드포워드에 있어 개신된 가중치는 이전의 개신된 가중치와 오차 기울기의 항으로써 다음과 같은 식으로 주어진다.

$$\begin{aligned} \Delta w_{[l-1,j][l,i]}(m+1) \\ = -\eta_{k-k'} \sum_{k=(m-1)+1}^{k_m} \left(\frac{\partial E(k)}{\partial x_{[l,i]}} \right) \left(\frac{\partial x_{[l,i]}(k)}{\partial w_{[l-1,j][l,i]}} \right) \end{aligned} \quad (4)$$

여기는 m 은 학습 세트를 나타내는 동안 하나 이상의 개신된 가중치를 고려하는 $1 < k' < NP \text{ (mod } NP, k = 0 \text{) }$ 에서의 개신된 가중치 색인을 나타낸다. $k=1$ 에 대하여, 위 식은 순간 평균 제곱 오차를 최소화하여 개별적인 개신(updating)의 결과를 가져온다. 반면, $k=NP$ 에 대해서는, 집단적인 개신(updating)을 얻는다. 유사하게, 피드백 가중치들에 대한 개신되는 규칙도 얻을 수가 있다. 위 식들이 의미하는 것처럼, 가중치 개신(updating)은 전체 학습 세트가 하나로 표시되는 동안에 여러 번 수행될 수 있다.

남은 일은 (4)식의 ()안에 있는 편미분식을 정확하게 풀어내는 것이다. 가중치들과 대응한 절점 출력들의 기울기는 (5)식에 표현된 것처럼 식(1)과 (2)를 이용하여 계산한 것보다 상대적으로 간단하다.

$$\frac{\partial x_{[l,i]}(k)}{\partial w_{[l-1,j][l,i]}} = F_{[l]}(z_{[l,i]}(k)) F_{[l-1]}(z_{[l-1,j]}(k)) \quad (5)$$

순환 가중치들에 대하여도 비슷한 표현이 얻어질 수 있다.

오차 기울기 항의 계산은 출력 단위들로 시작하는 순환 과정이다. 만일 단위가 출력 층에 있다면, 절점 출력에 관계한 오차 기울기는 다음 식(6)과 같이 주어진다.

$$\frac{\partial E(k)}{\partial x_{[l,i]}} = y_i(k) - \hat{y}_{[i]}(k) \quad (6)$$

은닉층의 단위들에 대한 오차 기울기는 식(1)과 (2)를 미분함으로써 다음과 같이 얻어진다.

$$\frac{\partial E(k)}{\partial x_{[l-1,j]}} = \sum_{i=1}^{N(l)} w_{[l-1,j][l,i]}(k) F'_{[l]}(z_{[l,j]}(k)) \left(\frac{\partial E(k)}{\partial x_{[l,i]}} \right) \quad (7)$$

식(7)은 은닉층의 오차 기울기는 뒤따르는 은닉층의 오차 기울기들을 이용함으로써 계산된다. 이것이 이름을 역전파(Back Propagation)라 한 정확한 이유다.

요약하면, 위의 학습 알고리즘의 적용은 다음의 4단계들을 포함한다.

(1) 첫 번째 단계 동안 세트에서의 각 입력은 각 데이터 쌍 $k=k'(m-l)+1, \dots, k'm$ 에 대하여 각 단위 $i=1, 2, \dots, N(L)$ 의 출력 $y_i(k)$ 를 계산하기 위하여 회로망 식(1)과 (2)에 이용된다. 이 출력 값은 식(6)을 이용하여 출력 층 단위들의 오차 기울기 값의 계산을 위해 이용된 출력 층 오차 기울기 신호를 생산하면서 목표 값 $y(k)$ 에 비교된다.

(2) 두 번째 단계는 (7)식을 이용하여 출력 층 오차 기울기 신호가 은닉층들의 각 절점에 대해 오차 기울기의 역전파를 위해 이용된 회로망을 통해 역전파(backward pass)를 수행한다.

(3) 세 번째 단계는 (4)식과 (5)식, 그리고 1단계와 2단계의 결과들을 이용하여 회로망 무게에 있어 적당한 새로운 정보들을 만드는 것을 포함한다.

(4) 만일 오프라인 학습이 수행되어진다면, 1단계에서 3단계는 전체 학습 세트가 회로망에 표시될 때까지 되풀이된다. 오프라인 학습 동안 1단계에서 4단계는 회로망이 요구된 값으로 수렴할 때까지 되풀이된다.

3. U자관 증기 발생기에의 응용

3. 1. U자관 증기 발전기의 물리적인 모델(Physical Model)

앞에서 제안한 신경회로망 시스템규명 모델을 만들고 검증하기 위해서 발전소 구성요소의 동력 시스템을 이용하였다. 여기에서 증기발생기를 고찰하고자 한다. 이 연구에 사용되는 증기발생기의 모델은 시스템 제어장치

설계를 위해 개발했던 것을 이용하려 한다. 이 모델은 낮은 전기 생산과 많은 전기 생산의 경우에 모두 검증된 바 있다.

이 모델이 비록 안전에 관계된 분석은 충분히 되지 않았지만 본 연구가 이루고자 하는데는 충분한 성질들을 갖고 있다. 즉, 원자력 발전소 증기발생기의 수위조절 문제는 복잡하며 비선형이다. 또한 많은 전기를 생산하기 위해 증기동 내의 수증기를 터빈으로 보내게되면 증기동 내의 압력의 하락으로 물이 수증기로 변화되며 물의 양은 적어지지만 수위를 측정하는 센서는 수위가 올라가는 현상을 나타낸다. 이러한 이유는 증기동 내의 압력 강하로 물 속에 많은 기포가 생겨 수위를 올리게 되며, 빠져나간 수증기의 양만큼 물의 공급이 필요하지만 센서의 물 증가 현상으로 반대의 명령을 전달하며, 또한 증기동 내에 물을 공급하게 되면 실제의 증기동 내의 물의 양은 증가했지만 차가운 물의 유입으로 인해 물 속의 기포들이 줄어들어 센서의 수위는 낮아짐을 보인다. 즉 증기원동소는 널 미니멈(Nonminimum) 시스템이다.

여기에서 이용되는 증기발생기 모델은 일차분야(primary side)에 3개의 검사체적(control volume), 이차분야(secondary side)에 4개의 검사체적이 있다. 일차분야 지역(region)엔 입력 Plenum과 관통치(tube bundle) 유체 체적과 출력 Plenum이 있다. 네 개의 이차분야 지역엔 관통치, 오름부위(riser) 포화체적(saturated volume)과 과냉체적(subcooled volume)으로 된 증기 하향기(downcomer)가 있다. 포화체적과 과냉체적은 가변경계가 있고, 그 위치는 미지 변수다. 일차분야(primary side) 모델은 3개의 미분방정식과 3개의 미지변수가 존재한다. 행렬형으로 나타내면

$$\begin{aligned} \underline{C} \dot{\underline{T}} &= \underline{g} \\ \underline{C} &= \text{diag} [C_1 \ C_2 \ C_3] \\ \underline{T} &= \text{col} [T_1 \ T_2 \ T_3] \\ \underline{g} &= \text{col} [g_1 \ g_2 \ -Q_B \ g_3] \end{aligned} \quad (8)$$

여기에서 T_1, T_2, T_3 은 세 일차분야의 검사체적 온도들이다. 이차분야에서는 질량과 에너지법칙이 이용되고 유체들의 모멘텀(momentum) 방정식을 사용하여 다음의 식을 구했다.

$$A \dot{x} = f \quad (9)$$

$$A \frac{d}{dt} \begin{bmatrix} u_0 \\ V_v \\ <\alpha_r> \\ <\alpha_r> \\ p \\ \bar{W} \end{bmatrix} = \begin{bmatrix} f_1 + Q_B \\ f_2 \\ f_3 \\ f_4 \\ f_5 \\ f_6 \end{bmatrix}$$

여기에서 상태(state)들은 하향기 출구의 내부에너지, 증기돔(steam dome) 속의 증기 체적, 오름기(riser) 입구와 출구에서의 Void fraction, 증기압과 유체 이동률 등을 각각 나타낸다. 방정식의 오른쪽 행렬에 있는 것들은 외부 힘들의 함수와 열 이동 Q_B 와 관련된 사항들을 나타낸다. 식(1)과 식(2)에서 구한 9개의 비선형 미분방정식을 이용하여 전체적으로 과도해(transient solution)의 해들을 얻게 된다. 위의 증기 발생기에 사용된 제어기의 구조는 논문집(13)에 나타나 있다.

3.2 인공 신경회로망들을 이용한 경험적인 증기 발생기의 모델링

이 단원에서는 전 단원들의 이론적인 개발들을 U자관 증기 발생기에 적용시킨다. 이 연구에서 제시된 시뮬레이션에 있어, 선형 판별 함수를 가지고 있는 입력 층, S자 모양 판별 함수를 가지고 있는 많은 은닉층들, 그리고 선형 판별 함수를 가지고 있는 출력 층으로 된 혼성 피드포워드/피드백 다렬 관념소가 이용된다. 비록 증기 발생기가 하나의 조작된 입력, 5개의 교란 입력들과 3개의 출력들(6입력, 3출력 시스템)을 가질지라도, 이 연구에서는 단지 단일입력 단일출력 모델이라고 간주한다. 특히, 규명된 폐루프 경험 모델은 증기 흐름률(교란)로부터 하강 파이프 물 수위(출력)까지이다. 간소화된 경험 모델을 이용한 시스템 규명의 배후 동기는 다중입력 다중출력(MIMO) 시스템 학습으로는 원리 증명이 복잡하기 때문이다. 그럼에도 불구하고, 이렇게 개발된 이론은 몇 개의 입력들과 출력들이 있는 시스템에 더 이용될 수가 있다. 최근 결과들이 이 이론을 증명하였다.

3.3 경험적인 인공 신경회로망 모델의 학습과 시험

이 연구에서 인공 신경회로망 학습은 온라인 학습과 오프라인 학습으로 나누어진다. 인공 신경회로망의 오프라인 학습에 있어 학습이 끝날 때를 결정하기 위해

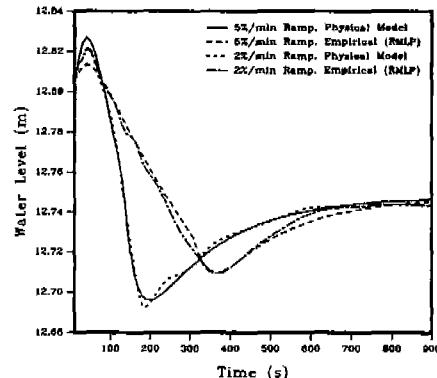


Fig. 1 Water Level Response for High Power Level Operation(70% of Full Power);Training Set Response

이용되는 오차 기준을 똑같이 하는 것이 필요하다. 비록 이전 단원들에서 제시된 학습 알고리즘들이 식(3)의 절대 평균 제곱 오차에 기초하였을지라도 변형된 오차는 오프라인 학습 과정의 수렴성을 결정하기 위해 이용된다. 다음의 오차 정의 식은 오프라인 학습을 마치기 위하여 이 연구에서 이용되어졌다.

$$\text{Relative Error} = \frac{\frac{1}{NP} \sum_{k=1}^{NP} \sum_{i=1}^{N(L)} |(x_{[x,i]}(k) - y_i(k))|}{\sqrt{\frac{1}{NP} \sum_{k=1}^{NP} \sum_{i=1}^{N(L)} (y_i(k) - y_{0i})^2}} \quad (10)$$

분자부분은 절대오차의 평균값이며, 분모는 평형으로 부터의 RMS(Root Mean Square) 편차를 의미한다. 또한, $y_i(k)$ 는 k 번째 학습데이터 출력벡터이며, $y_{0i}(k)$ 는 학습데이터의 평형(Equilibrium) 값을 의미한다.

두 오프라인 학습 기간이 낮거나 높은 동력에서 증기 발생기의 경험적인 인공 신경회로망 모델을 규명하기 위해 수행되어졌다. 첫 번째 학습 기간에서 증기 발생기의 어떤 변화된 부하가 들어오기 전에 높은 동력(전동력의 70%)으로 작동하는 경우로 가정하였다. (Fig. 1 참고) 발전량의 변화는 1분에 5%증가하는 램프와 1분에 2%증가하는 램프 입력에 대한 증기원동소의 반응을 고려하였다. 각각의 경우를 물리적인 모델과 신경회로망의 반응을 비교해 보았다. 반면, 두 번째 학습 기간에서는 70%의 동력상태에서와 같은 방법으로 낮은 동력 작동(전 동력의 15%)이 가정되었다. (Fig. 2 참고) 이전 단원들에서 서술된 시스템 규명 과정은 전체

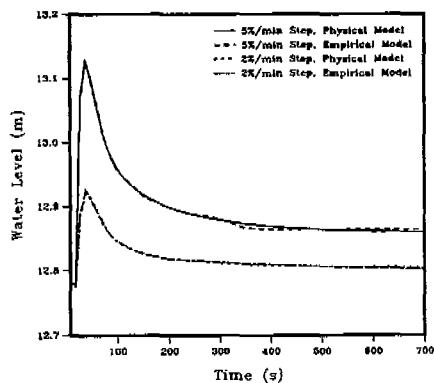


Fig. 2 Water Level Response for Low Power Level Operation(15% of Full Power);Training Set Response

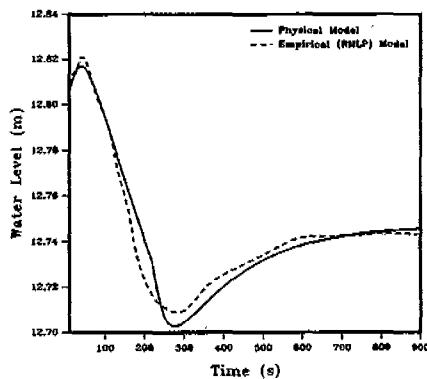


Fig. 3 Water Level Response for High Power Level Operation(70% of Full Power);Testing Set Response

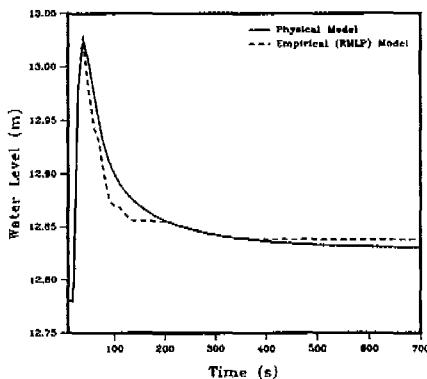


Fig. 4 Water Level Response for Low Power Level Operation(15% of Full Power);Testing Set Response

동력 레벨들의 70%와 15%근처에서 증기 발생기의 거동을 모방한 경험적인 모델을 규명하기 위해 두 가지 경우로 적용되었다. 높은 동력 학습 기간에 이용된 인공 신경회로망은 하나의 입력, 각각 10개와 6개의 절점들이 있는 두 온너층들, 그리고 하나의 출력 절점으로 구성되어 있다. 낮은 동력 학습 기간에 대한 인공 신경회로망은 상대적으로 두 온너층에 13개와 8개의 절점들이 이용된 것을 제외하면 위와 유사하다. 일찍이 언급된 것처럼, 두 회로망들의 입력과 출력 절점들은 선형 판별 함수들을 가졌다. 높은 동력 학습 세트는 전 동력의 70%로부터 초기화된 5분 동안 분당 2%와 2분 동안 분당 5%인 두 증기 흐름률 램프(ramp)와 이에 대응하는 하강 파이프 수위 응답들로 구성되어 있다. 유사하게, 낮은 동력 학습 세트는 전 동력의 15%로부터 초기화된 전동력의 2%와 5%인 두 증기 흐름률 단위 관계들과 이에 대응하는 하강 파이프 수위 응답들로 이루어졌다. 두 인공 신경회로망은 상대적으로 52,500회와 70,000회 반복에 대해 0.001과 0.0005의 학습율로 학습된다. 그리고 한 반복은 상대적으로 회로망에 대해 두 램프와 단계들의 한 표현으로 이루어진다. 학습을 통해 얻은 시스템의 모델의 타당성을 보기 위해 학습 데이터에 들어 있지 않는 데이터를 가지고 위의 두 모델에 대해 검증하였다. (Fig. 3과 Fig. 4 참고) 높거나 낮은 동력 오프라인 학습 기간들로 인한 정상화된 평균 절대 오차들의 최종 값들은 상대적으로 대략 7.5%와 5%였다.

인공 신경회로망 온라인 학습 가능성을 논증하기 위한 것뿐만 아니라 요란한 입력 신호들에 대하여 경험적인 모델의 민감성을 조사하기 위하여, 3%편차를 가진 화이트 노이지(white noise)가 알려지지 않은 회로망 시험 신호들에 첨가되고 이에 따른 물리적이고 경험적인 모델의 수위 응답을 예측한다. (Fig. 5 참고) 시험 신호는 전 동력의 80%에서 증기 흐름률 램프업(ramp-up)이 분당 3.5%로 뒤따르면서 10초 동안 전 동력의 70%에서 정상 상태 동작을 한다. 이것은 한 주기의 정상 상태 동작으로 뒤따르고 그 후에 2분 동안 1% 증기 흐름률 램프다운(ramp-down)이 뒤이어온다. 경험적인 모델 시뮬레이션의 처음 900초 동안에는 온라인 학습이 “오프(off)”한다. 그리고 이것은 오프라인 학습된 인공 신경회로망 가중치들이 어떤 변형 없이 이용되어지고 있음을 의미한다. 900초 후의 경험적인 모델 시뮬레이션에 대하여는, 두 가지 응답이 나타난

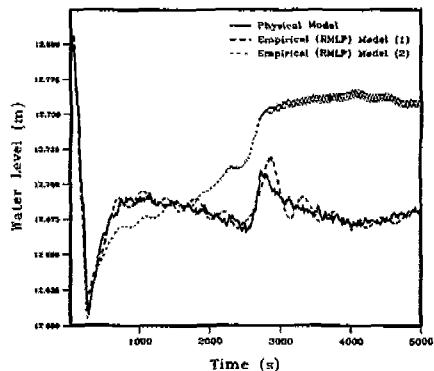


Fig. 5 Water Level Response for High Power Level Operation(70% of Full Power);Testing Set with On-Line Learning;Model (1) is with On-Line Learning, Model (2) is without On-Line Learning

다. 한 도면은 “오프”가 계속된 온라인 학습에 대한 예측된 응답을 그린다. 반면, 다른 도면은 “온(on)”된 온라인 학습에 대한 예측된 수위 응답을 그린다. 온라인 선택은 $k' = 1$ 과 0.005의 학습률로 성취된다. 이것은 가중치 갱신이 뒤따르는 모든 입력 표본으로 수행되어짐을 의미한다. 이것은 온라인 회로망 학습은 인공 신경 회로망 가중치들과 일시적인 오차를 계속적으로 갱신함으로써 경험적인 모델의 예측된 가능성을 더욱 개선한다는 것을 입증한다.

4. 요약 및 결론

입력/출력 의미에 있어 공정 과정 시스템들의 비선형 경험 모델을 규명하기 위한 과정이 제시되었다. 시스템 규명에 이용된 비선형 구조는 다열 관념소 신경회로망이다. 인공 신경회로망의 파라미터들은 동적 회로망들로 이용하기 위해 변형된 BP학습 알고리즘을 이용함으로써 결정된다. 제안된 규명 과정의 적용과 수행은 U자 관 증기 발생기의 실례 연구를 통해 입증되었다.

단지 입력/출력 측정을 이용하여 경험적인 모델을 규명하기 위한 많은 가능한 응용들이 있을지도, 이 연구에서의 특별한 이용은 페루프 과도 응답 예측에 대해 행해졌다. 시뮬레이션 결과들에서 비선형 공정 과정 모델들은 경험적으로 규칙적인 오프라인과 온라인 과정들에 의해 규명될 수 있고 이들 모델들은 효과적으로 과도 응답을 예측하기 위해 이용될 수 있다는 것을 입증

하였다. 기대한 것처럼, 낮은 동력에서 작동되는 경험적인 증기 발생기 모델의 규명은 높은 동력에서 작동되는 것보다 더 힘들다는 것을 나타낸다. 전자는 오프라인 학습 단계에 있어 더 많은 절점들과 더 많은 반복이 필요하다. 비록 폭넓은 오프라인 학습이 수행될지라도 온라인 학습에 대한 학습 단계의 증가는 인공 신경회로망들의 예측 가능성을 더욱 개선한다. 이것은 컴퓨터 시뮬레이션으로 증명된다. 그리고 이것은 두 높고 낮은 동력 작동 동안 온라인 학습은 확실히 예측 오차를 줄인다는 것을 의미한다. 더욱이, 만일 전 동력 작동 점들로부터 상대적으로 전 동력의 +15%나 -15%에서 대부분 교란된다면 두(높고 낮은 동력) 규명된 증기 발생기 모델은 정확하다. 이 제한된 학습 능력은 이용된 인공 신경회로망 구조보다 오히려 동적 학습 알고리즘들의 연구를 증진시킴으로써 BP 범례의 정적 본질에 더 공헌되어진다.

참고문헌

1. S. A. Billings, "Identification of Nonlinear Systems-A Survey", IEEE Proc. D, Control Theory and Applications, 127, (6) pp. 272-285, 1980.
2. DARPA Neural Networks Study, Fairfax, VA:AFCEA International Press, 1988.
3. D. Rumelhart, Hinton G. and Williams R., "Learning Internal Representation by Error Propagation", in Parallel Distributed Processing, Vol. 1, MIT Press, Cambridge, MA, 1989.
4. P. D. Wasserman, Neural Computing: Theory and Practice, Van Nostrand Reinhold, New York, NY, 1989.
5. Pabon, J. A., "A Neural Network Model of Adaptation in Motor Coordination", Phd. Dissertation, Mechanical Engineering Dept., MIT, Cambridge, MA, 1988.
6. S. S. Billings, S. Chen and Korenberg, "Identification of MIMO Nonlinear Systems Using a Forward-regression Orthogonal Estimator", Int. Journal of Control, Vol. 49, pp. 2157-2189, 1989.

7. 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.
8. R. J. Williams, and D. Zipser, "A Learning Algorithm for Continually Running fully Recurrent Neural Networks", Neural Computation, Vol. 1, pp. 270-280, 1989.
9. 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.
10. K. S. Narendra and K. Parthasarathy, "Identification and Control of Dynamic System Using Neural Networks", IEEE Transactions on Neural Networks, Vol. 1, No. 1, pp. 4-27, 1990.
11. 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.
12. F. J. Pineda, "Generalization of Backpropagation of Recurrent Neural Networks", Vol. 589, No. 19, pp. 2229-2232, 1987.
13. J. I. Choi, "Nonlinear Digital Computer Control for the Steam Generator System in a Pressurized Water Reactor Plant", PhD Dissertation, Nuclear Engr Department, MIT, Cambridge, MA. Aug. 1987.