

본 연구는 97년도 학술진흥재단(97-001-E00185)지원으로 진행되었음.

모조 시스템 형성에 기반한 2단계 뉴로 시스템 인식

배 재호*, 왕지남**

Two-Phase Neuro-System Identification Based on Artificial System Generation

Jaeho Bae*, Gi-Nam Wang**

ABSTRACT

Two-phase neuro-system identification method is presented. The 1st-phase identification uses conventional neural network mapping for modeling an input-output system. The 2nd-phase modeling is also performed sequentially using the 1st-phase modeling errors. In the 2nd-phase modeling, newly generated input signals, which are obtained by summing the 1st-phase modeling error and artificially generated uniform series, are utilized as system's I-O mapping elements. The 1st-phase identification is interpreted as a "Real Model" system identification because it uses system's real data(i.e., observations and control inputs) while the 2nd-phase identification as a "Artificial Model" identification because of using artificial data. Experimental results are given to verify that the two-phase neuro-system identification could reduce the overall modeling errors.

Key Words : Neuro-System Identification(뉴로 시스템 인식), System Modeling(시스템 모델링), Real Model(실제 모델), Artificial Model(모조 모델)

1 서 론

시스템 규명이란 자연현상을 수학적으로 나타내는 방법으로 협의의 의미로는 시스템에 존재하는 관측치와 제어 변수 그리고 입력 변수간의 사상 모델 구조(Mapping Model Structure)를 수학적으로 찾아내고 모델 구조의 변수를 추정하는 분야라 할 수 있다. 시스템 규명은 제조 현상의 상태를 감시하거나 제어하고 진단하는데 사용 될 수 있는 바 기존의 정립된 모델의 적합도를 평가하여 이

상 현상을 파악 할 수 있기 때문이다. 시스템 규명(System Identification)에 인공 신경망(ANN: Artificial Neural Network) 이론을 적용하여 전통적인 시스템 모델링 방법들에 비교하여 보다 정확한 모델 구조를 얻어내 시스템을 규명하고자 하는 많은 연구가 진행되어 왔다 (1,2,3,4,5). 그러나 이러한 모델링 방법을 적용하더라도, 실제 시스템 상황이 복잡하거나 불안정한 경우 정확한 시스템 규명에 어려움이 있다. 보다 정확한 모델링을 얻기 위하여 많은 연구가 있어왔는데, 그 중 Wang⁽¹⁾⁽⁶⁾의 연구는

* 아주대학교 기계 및 산업공학부 대학원
** 아주대학교 기계 및 산업공학부

기계 상태의 변화를 탐지하기 위하여 2단계 신경망에 의한 모델링 방법을 제안하여 1단계 모델링의 예측 오차를 2단계의 입력 벡터로 하여 모델링의 정확도를 높이고자 하였다. 이와 유사한 연구로 전 단계 신경망의 일부 출력을 다음 단계 신경망의 일부 입력 요소로 사용하는 반복적인 신경망을 제시한 Werbos⁽³⁾의 연구 등이 있는데, 이와 같이 선행된 연구에서 복잡하고 불안정한 공정을 모델링하기 위하여 2단계 또는 그 이상의 다단계 모델링을 적용하여 보다 정확한 모델링을 시도하였음을 볼 수 있다. 대체로 수학적 모델링과 인공 신경망 이론을 이용한 모델링에 있어 용어의 관계성을 다음과 같이 비교해 볼 수 있다.

Table 1. Equivalent terms in System Modeling and Neural Networks

<i>System Modeling</i>	<i>Neural Network</i>
Model Structure	Network Structure
Model parameters	(synaptic) Weights
Estimation	Learning
Off-line Estimation	Supervised learning
On-line Estimation	Unsupervised Learning (Self-organizing Learning)
Input-Output Observations	Network I-O Values

본 연구에서는 복잡하고 불안정한 공정을 규명해 내기 위하여 보다 정확한 학습을 할 수 있는 모조 시스템 (Artificial Series)을 이용한 2단계 시스템 모델링 방법을 제안한다. 즉, 시스템으로부터 얻어지는 데이터들을 1차적으로 모델링한 실제 모델(Real Model)과 시스템의 구조가 정해진 확정 모델(Deterministic Model)인 모조 모델(Artificial Model)을 통하여 생성된 모조 데이터와 1차 모델링에서 발생하는 오차들을 합성하여 새로운 데이터를 발생시킨 후 이를 다시 모델링하는 2차 모델링 방법을 제시한다. 여기서 실제 모델은 실제 존재 데이터의 관측된 변수나 제어 변수 그리고 시스템 에러 변수를 이용하여 입력과 출력간의 사상(Mapping) 관계를 찾아내는 과정에서 실제 관측 데이터를 사용하였다는 의미로 실제 모델이라는 용어를 사용하였으며, 모조 모델은 가상의

데이터를 사용한 모델로 1차 모델링의 오차를 인위적으로 입력과 출력이 잘 사상되는 가상의 시리즈에 합성하여 전체적인 모델링의 정확도 향상에 기여한다는 의미에서 모조 모델이라는 용어를 사용하였다.

본 논문은 2장에서 논문의 이론적 배경 및 근거와 제안되는 시스템에 대한 상세 설명을, 3장에서는 제안된 이론에 근거한 실험 결과를 제시하며, 마지막으로 4장에서는 본 논문의 결론과 향후 과제에 대하여 언급하도록 하겠다.

2 이론적 배경

변화하는 공정의 상태를 규명하기 위하여 많은 통계적 접근 방법이나 인공 신경망을 이용한 연구들이 이루어져 왔지만, 아직도 실제 공정에서는 몇몇 전문가들의 경험에 의존한 휴리스틱한 방법이 주로 사용되어지고 있다. 이러한 이유는 기존의 방법들이 적용하기 어렵거나, 다양한 신호를 발생하는 공정을 효과적으로 묘사해 내지 못했기 때문이다. 일반적인 시스템 모델은 다음 식과 같이 묘사될 수 있다.

$$y_t = f_t(y_{t-1}, \dots, y_{t-n_y}, l_{t-1}, \dots, l_{t-n_l}, \dots, r_{t-1}, \dots, r_{t-n_r}, \Theta_t) + r_t \quad (1)$$

y_t 는 관측변수, l_t 는 제어변수, r_t 는 에러변수, 그리고 Θ , 는 시간 t 에서의 모델 변수를 나타낸다. 앞의 식(1)은 입력 벡터 $\bar{x}_t = (y_{t-1}, \dots, y_{t-n_y}, l_{t-1}, \dots, l_{t-n_l}, \dots, r_{t-1}, \dots, r_{t-n_r}, \Theta_t)$ 에 대한 출력 y_t 의 입력-출력의 사상관계(I-O Mapping Relation)로 서술된다.

본 연구에서는 시스템에 존재하는 모델구조 f_t 와 Θ_t 를 신경망의 특징의 하나인 일반화 능력(Generalization Capability of Universal Approximation)을 최대한 사용할 수 있도록 해주는 보상기(Compensator: 모조 시스템)를 도입하여 보다 정확하게 시스템을 규명할 수 있도록 하였고, 일반적으로 널리 사용되는 역전파 신경망(Backpropagation neural network)을 사용하여 실제 적용이 지나치게 어려워지지 않도록 하였다.

2.1 Backpropagation Neural Network with Multi-layer Perceptron

역전파 신경망은 가장 일반적으로 시스템 규명에 사용되어 왔고 이미 많은 연구를 통하여 적합성이 입증되었다^(6, 9). 근래에 가장 많이 사용되는 학습 알고리즘이며, 학습 알

고리즘이 간단한 순환적인 Gradient Search 형태나 변형 형태를 이용하기 때문에 간단하게 이용되고 있는 방법이기도 하다. 또한 이 신경망은 함수의 사상 능력이 뛰어나고, 일반화된 근사화가 뛰어난 신경망으로, 정확한 모델 구조를 알 수 없는 경우 Black Box 형태로써 모델 구축에 효율적으로 사용되어 왔다.

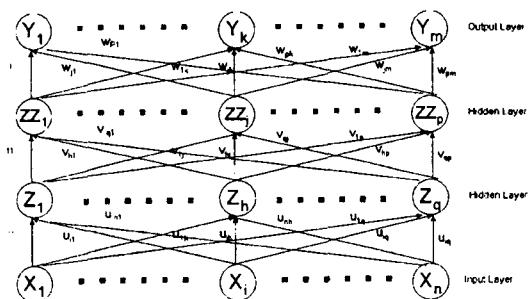


Fig. 1 Backpropagation neural network with two hidden layers

Fig. 1은 2개의 중간 층(hidden layer)을 가지는 신경망의 구조를 보인 것이다. 여기에서 u , v , w 의 값들은 전 단계의 값들을 입력 값으로 사용하여 다음 단계의 값을 얻는데 사용되는 가중치이다. Fig. 1과 같은 구조의 Backpropagation Network은 시스템의 입력과 출력을 사상하는데 효과적으로 사용되어 왔으며^(3, 4)이는 모델의 구조와 변수의 추정에 보다 쉽고 복잡한 시스템인 경우 효과적으로 사용될 수 있었다. 학습 알고리즘은 입력 패턴을 다음 계층에 전달하는 Feed-forward 단계와 발생한 오차를 다시 이전 계층으로 전달하여 오차를 반영하도록 해 주는 Backpropagation 단계, 이를 근거로 연결부를 수정하는 단계로 이루어져 있다.

2.2 제안된 방법

본 연구에서는 역전파 신경망을 2단계로 설계하여 1단계에서는 실제의 시스템에 대하여 적용하고 2단계에서 모조의 시스템을 생성하여 전체적으로 2단계 신경망 모델링을 통하여 전체적인 모델링의 정확성에 초점을 두었다. 앞에서 설명한 역전파 신경망을 사용하여 1차적인 모델링을 시도하고, 1차 모델로부터의 오차와 구조를 알고 있는 확정 모델(Deterministic Model)에서 발생된 데이터를 합성하여 새로운 데이터를 만들어내어, 이를 다시 모델링함으로써 높은 정도(精度)를 제공하는 모델을 구축할 수 있었다.

본 연구에서는 시스템 규명을 위하여 2단계 모델링 과정을 제안하였는데, 1단계는 실제 데이터를 대상으로 근사적 모델링을 통하여 Real Model을 구축하는 단계로서 Network 1로 표시한다. 2단계는 구축된 Real Model으로부터 얻어지는 모델링 에러(Innovation)와 임의의 Series(식 2)를 합성하여 신경망으로 재 모델링하는 인공 신경망을 구축하는 단계로서 Network 2로 표시된다. 2단계 모델링의 목적은 네트워크의 일반화 능력을 이용하여 1차 모델링의 에러를 2차 모델에 흡수하여 전체적인 모델의 정확도를 높이는 데 있다.

다음의 Fig. 2는 제안된 모델링 방법을 그림으로 표현하고 있다. 어떤 시스템으로부터 발생한 신호를 습득한 후 적당한 전처리 과정을 거쳐 1단계 모델링을 시도하여 Network 1을 얻게 된다. 여기서 발생하는 오차와 확정 모델로서의 임의의 시리즈를 합성한 데이터를 2차 모델링하여 얻어지는 모델이 Network 2이며, 본 논문에서는 모조 모델(Artificial Model)이라고 부르기로 한다.

센서에서 얻어진 신호들은 시간 영역에서 Time Series로 표시되며, 얻어진 신호들에 대한 모델링 과정은 우선 모델 구조와 정해진 구조(입, 출력의 형태 또는 중간층의 노드 수)에 해당하는 변수들을 결정하는 단계로부터 시작한다. Network 1의 Real Model 입력 벡터들은 시간 지연 신호들로 구성되어 있으며, 출력은 신호들의 미래 예측치가 된다. Network 2의 Artificial Model 입력 벡터들은 Uniform 분포를 따르는 2 종류(u_1 , u_2)의 신호들을 2단계 시간 지연 신호와 Real Model의 Innovation을 입력 벡터로 하여 그 합을 예측하는 구조로 되어 있다.(식 2)

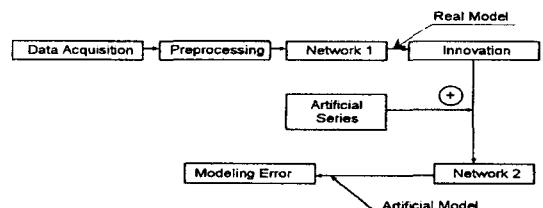


Fig. 2 Block Diagram of a Proposed Modeling Method

본 연구에서 사용한 Network 1(Real Model)은 일반적으로 사용되는 모델로 실제 시스템과 직접적으로 관련된 모델이다. 실제 시스템에서 발생되거나 관측된 데이터를 사용하여 입력과 출력의 Mapping 함수를 찾아내는 모델은 지금까지 많은 연구가 진행되어 온 방법이다. 본

연구에서는 일차적인 Network Model로 복잡하고 동적으로 변하는 비선형 모델이나 모델 구조가 불확실하게 알려지지 않은 경우 혹은 여러 개의 복합적인 모델이 합성되어 발생되는 시스템에 대한 모델링 방법으로 Network 1의 오차에 대한 보상기(Compensator) 역할을 하는 Network 2를 도입하는 방법을 제시한다. 본 논문에서 제시하는 방법은 기존의 1차적인 모델링 예러들만을 사용하여 다시 새 모델링하는 방법^(1,2,6,7)에 비하여 1차 모델링 예러들만의 특성을 다른 모조 데이터와 합성한 방법을 보이고 있다.

2.3 모조 시스템의 생성(Generation of Artificial System)

본 논문에서 모조 시스템은 신경망의 Mapping이 잘되는 인위의 데이터를 이용하여 입력과 출력의 사상 관계를 형성하는 과정이라고 정의한다. 모조 시스템은 비교적 정해진 모델 구조식을 사용하여 생성하게 된다. 아래의 식은 모조 시스템의 일반식을 보인 것이다. 모조 시스템은 그 구조가 알려져 있고, 신경망의 Mapping이 잘 되는 형태라면 다른 형태의 시리즈라도 가능하다.

Artificial Series:

$$\begin{aligned} z_t = & a_1 \cdot u_1(t-1) + a_2 \cdot u_1(t-2) + a_3 \cdot u_2(t-1) \\ & + \dots + a_n u_{n/2}(t-2) + e_t \end{aligned} \quad (2)$$

Where, $u_1, \dots, u_n \sim \text{Uniform Distn. } (-1, 1)$

$e_t = \text{Real Model의 } y_t - \hat{y}_t$

$n = \text{even number}$

Artificial Model을 결정하는 방법은 완전한 집합(Compact Set: $u_1, \dots, u_n \sim \text{Uniform Distn. } (-1, 1)$)에서 인위적인 가상의 데이터를 생성해내고, 시스템 모델의 입력과 출력의 Mapping구조를 결정한다. 즉, 출력으로는 식 (1)의 값을 사용하고 입력으로는 u_1, \dots, u_n (\sim Uniform 분포)의 Series와 1차 Real Model에서 얻은 1차 모델링 예러 데이터를 이용하여 시스템 입력과 출력 모델을 결정한다. 만약 1차 모델링 예러가 입력으로 포함되지 않는다면 Artificial Model의 정확도는 뛰어난 모델일 것이며, 여기에 1차 모델링 예러를 포함시켜 Compact Mapping구조에 1차 모델링 예러를 흡수하게 된다. 이를 단계적인 그림으로 설명하면 다음과 같다. 우선

Real Model은 아래와 같이 주어진 실제 데이터를 이용하여 모델링 예러를 계산하게 된다(Fig. 3).

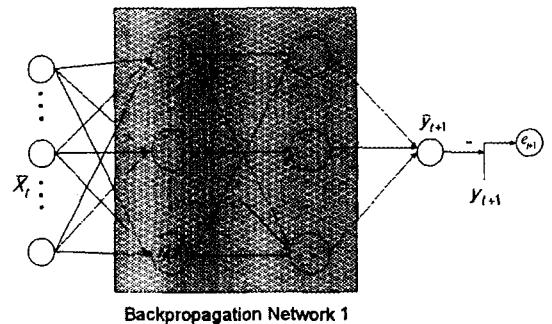


Fig. 3 Structure of Real Models

Fig. 3과 같은 시스템 관측에서 얻은 입력 벡터 \bar{X}_t 와 출력 구조를 가지는 1차적인 Real Model의 예러를 인위적으로 생성된 데이터와 함께 2차 Artificial Model을 구축한다.(Fig. 4) 아래의 그림에서 보면 1차 모델링 예러가 입력의 한 요소(e_t)를 이루고 있으며 확정 모델 식(2)에서 얻은 입력 변수벡터 $\bar{u}_{t-1} = u_1(t-1), u_1(t-2), u_2(t-1), \dots, u_{n/2}(t-2)$ 등이 입력으로 사용되고 있다. 이는 이미 생성된 Compact Mapping에 흡수 시키려는 구조로 해석 되어 진다. 즉 Uniform 분포의 입력과 모델링 예러 입력이 동시에 한 입력 형태를 이루고 있으며 이들을 합한 새로운 값을 출력으로 하여 새로운 사상 구조를 가지게 된다.

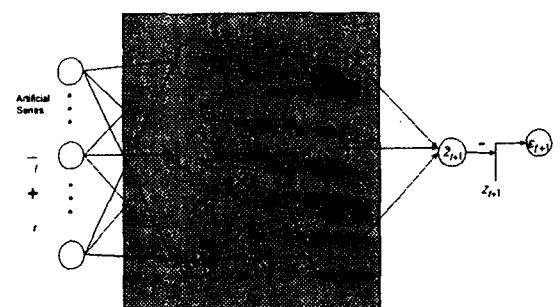


Fig. 4 Structure of Artificial Models

Uniform 분포의 입력만을 입력 벡터로 사용하게 되면 2차 네트워크에 의해 정확한 학습이 가능하겠지만, 전 단

계 네트워크의 에러가 u_i 값들에 비해 비교적 작다면 신경망의 오차를 허용하는 일반화 능력(Generalization Capability)에 의해 Uniform 분포의 입력 벡터와 전 단계 모델링 에러의 합성 입력 데이터들을 비교적 정확히 학습하여 모델을 구축 할 수 있다.

Fig.5는 Real Model과 Artificial Model을 이용한 전체적인 모델링 과정을 설명한 것이다. Network 1의 예측치와 실측치의 오차로부터 얻게 되는 오차가 임의의 생성 데이터(Artificial Series)와 합성되어 새로운 Network 2의 입력 벡터로 사용되고 Network 2에서는 Compact mapping 구조에서 전단계의 오차를 흡수하여 보다 완전한 모델링을 시도하게 된다. 본 연구에서는 추정의 정밀도를 알아보기 위하여 예측값과 실제의 값을 통하여 얻게 되는 오차의 SSE를 사용하였다.

2차 신경망(Artificial Model)의 도입은 신경망의 일반화 능력(Network Generalization Capability)에 의해 Network 1에서 발생하게 되는 오차를 흡수하게 된다. 그러나 Artificial Series의 Data의 크기에 비해 전 단계의 오차가 너무 작게 되면 오차를 흡수하는 정밀도가 떨

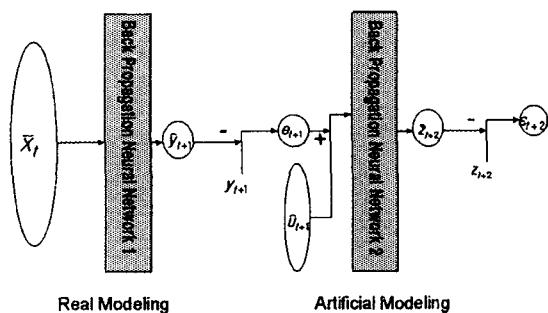


Fig. 5 Modeling Process of Real Models and Artificial Model

어지게 된다. 따라서 본 논문에서는 Artificial Series와 전 단계 네트워크의 오차가 비슷한 범위의 값을 가지도록 Artificial Series를 네트워크 오차에 기준하여 표준화(Normalization) 하였다.(식 3 과 4)

$$\text{Max}|a_i u_j| \leq \text{Max}|e_i| \quad (3)$$

$$\text{Min}|a_i u_j| \geq \text{Min}|e_i| \quad (4)$$

where, $a_i u_j$ = 임의의 시점에서 Uniform 분포를 따르는 Random Number와 계수의 곱 e_i = t시점에서

Network 1의 에러

2.4 Hybrid 모형의 뉴로 시스템 사상능력(Mapping Capability)

본 논문의 주요 핵심 내용은 1차 모델링 에러를 줄이기 위하여 2차 모델링 방법을 제시하고 있는데 2차 모델링을 통하여 모델링 에러의 감소 여부가 초점이다. 2차 모델을 분석하면 임의로 생성한 잘 알려진 Uniform Distribution내의 모형과 불확실한 모형인 1차 모델링 에러의 합성으로 이루어져 있다. 즉 완전한 모형내의 데이터와 불확실한 모형이 혼합된 하이브리드 모형이라 할 수 있다. 염밀히 분석하면 하이브리드 모형에서 보다 잘 알려진 모형의 다수의 Input의 수가 불확실한 모형의 단일 Input의 수보다 많아 모형상으로 보다 알려진 모형에 초점이 되어 실제적으로 1차 모델링의 에러를 흡수시키는 모형으로 해석된다. 이를 수식으로 표현하면 다음과 같은 식 (2)인 $z_t = a_1 \cdot u_1(t-1) + a_2 \cdot u_1(t-2) + a_3 \cdot u_2(t-1) + \dots + a_n u_{n/2}(t-2) + e_t$ 를 식(5)로 변환되는 과정으로 여기서 $N_2(u_1(t-1), u_1(t-2), u_2(t-1) \dots u_{n/2}(t-2), e_{t-1})$ 는 입력 벡터를 $(u_1(t-1), u_1(t-2), u_2(t-1) \dots u_{n/2}(t-2), e_{t-1})$ 로 하고 출력을 로하는 신경망의 모델링을 나타난다.

$$e_t = N_2(u_1(t-1), u_1(t-2), u_2(t-1) \dots u_{n/2}(t-2), e_{t-1}) + w_t \quad (5)$$

w_t 는 2차 모델의 모델링 에러로 식 (5)로 나타내어지는 전체적인 모델링 에러이다.

$$\begin{aligned} y_t &= f_t(y_{t-1}, \dots, y_{t-n_y}, l_{t-1}, \dots, l_{t-n_y}, \dots, r_{t-1}, \dots, r_{t-n_r}, \Theta_t) + r_t \\ &= f_t(\bar{X}_{t-1}) + r_t \\ &= N_1(\bar{X}_{t-1}) + e_t = N_1(\bar{X}_{t-1}) + N_2(U_1(t-1), U_2(t-1), \dots, U_{t-n}(t-1), e_{t-1}) + w_t \end{aligned} \quad (6)$$

식(6)의 수학적인 의미는 원래의 시스템 I-O Mapping을 1차 신경망에 모델링과 모조 시스템을 통한 2차 모델링 과정으로 서술하는 접근이다.

3 시뮬레이션 결과

시뮬레이션은 1) 임의로 생성한 Time Series 데이터의 합성, 2) 시뮬레이션을 위해 특별히 제작된 설비로부터 얻은 실제 데이터와 3) 보다 복잡한 구조의 실제 데이터에 대하여 Real Model의 Training과 Test Result,

Artificial Model의 Training과 Test Result에 대하여 SSE(Sum of Squared Error)를 구하고 Plotting을 하는 방법으로 진행되었으며, Artificial Model의 입력 벡터로 사용되는 Artificial Series의 생성은 식 (2)에 따라 생성되었으며, 계수(식 2에서 a_i)는 식(3,4)를 만족하도록 적당히 조절하였다.

3.1 임의로 생성된 Time Series의 합성

실제 공정이나 실생활에서 발생하는 데이터는 단일 Series로는 Modeling 할 수 없는 경우가 많다. 따라서 본 논문에서는 여러 개의 독립된 AR(Auto-regressive) Model로부터 얻어낸 데이터를 임의로 합성하여 시뮬레이션에 사용하였다.

$$AR(2) : y_t = 1.49y_{t-1} - 0.653y_{t-2} + \theta_t \quad (7)$$

$$AR(3) : y_t = 2.146y_{t-1} - 1.598y_{t-2} + 0.409y_{t-3} + e_t \quad (8)$$

$$AR(4) : y_t = 1.876y_{t-1} - 1.781y_{t-2} + 1.201y_{t-3} + 1.373y_{t-4} + e_t \quad (9)$$

$$AR(4) : y_t = 1.840y_{t-1} - 0.893y_{t-2} - 0.613y_{t-3} + 0.879y_{t-4} + 0.350y_{t-5} + e_t \quad (10)$$

Where, $e_t \sim N(0,1)$

편의상 AR(2) Model과 AR(3) Model의 데이터를 임의로 합성한 경우 “AR(2) + AR(3)”로 나타내었으며 3개의 서로 다른 모델 구조식으로부터 얻어진 데이터를 합한 경우 (AR(3) + AR(4) + AR(5))와, 모든 모델 구조식으로부터 얻어진 데이터를 합한 경우(AR(2) + AR(3) + AR(4) + AR(5))에 대하여 시뮬레이션을 진행하였다. 각각의 복합 데이터에 대하여 Network 1의 Input Node의 수는 가장 마지막 AR 모델의 구조에 따랐다.(즉, AR(3) Model과 AR(4), AR(5) Model로부터 얻어진 데이터의 합으로 만들어 낸 데이터, AR(3)+AR(4)+AR(5), 의 경우 Input Node의 수는 5, Output Node의 수는 1로 결정하였다.)

모델의 차수를 알 수 없는 경우는 충분한 차수로 선정하여 근사화 할 수 있으므로 일반화에 제약이 없다고 할 수 있다. 이와 같이 복합 데이터를 학습하며 모델링하게 되는 Real Model의 실측 치와 예측 치의 차(오차)로부터 보다 상세한 모델링을 하게 되는 Artificial Model은 식 (2)에 따라 생성되었으며, 사용된 변수는 Table 2와 같다.

Table 2 Parameters of Artificial Series

모델	계수			
	a_1	a_2	a_3	a_4
AR(3)+AR(4)+AR(5)	1/3	-1/3	1/3	-1/3
AR(2)+AR(3)+AR(4)+AR(5)	-1/3	1/3	-1/3	1/3

표 2에서 제시한 계수들의 값은 식(3,4)를 만족하기 위하여 임의로 조정한 것이며, 다른 모델과 구별된다면 어떠한 값을 사용해도 좋다.

Real Model에서 구축한 모델이 학습이 제대로 되지 않을 경우 학습하지 않은 데이터를 적용하게 되면 SSE가 증가하게 된다. 학습하지 않은 데이터를 Test 할 때 SSE가 증가하는 현상은 AR(3)모델과, AR(4), AR(5)모델로부터 얻어진 데이터들의 합인 AR(3) + AR(4) + AR(5)의 시뮬레이션의 결과에 나타나고 있다. 최초 100개의 데이터로 Real Model을 형성하며 학습한 결과를 보자.(Fig. 6) SSE가 0.6 미만으로 비교적 정확한 추정을 하고 있다. 하지만 학습하지 않은 새로운 데이터에 대하여는 SSE가 2배 가량 증가한 0.906508가 된다.(Fig. 7) 이러한 현상은 복잡한 모델 구조를 가지는 데이터일 경우 학습이 제대로 이루어지지 않아 발생하는데, Artificial Model이 완충기(Compensator) 역할을 해 줌으로써 2차 네트워크에서는 모델링이 제대로 이루어지게 된다.

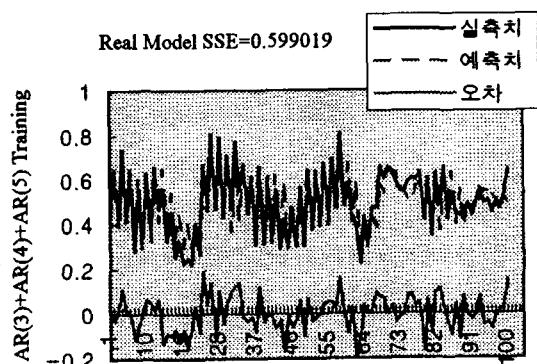


Fig. 6 Training of AR(3)+AR(4)+AR(5) Real Model

Fig. 6과 Fig. 7에서 보는 바와 같이 1차 네트워크에 의한 Real Modeling은 학습하지 않은 데이터에 대하여 좋지 않은 결과를 보이고 있다. 그러나 2차 네트워크에 의한 Artificial Modeling을 하게 되면 전 단계 오차에 대한 Artificial Model의 보상기 역할로 상당히 높은 정

도(精度)를 얻을 수 있게 된다. 아래의 Fig. 8과 9는 이러한 결과를 보이고 있다.

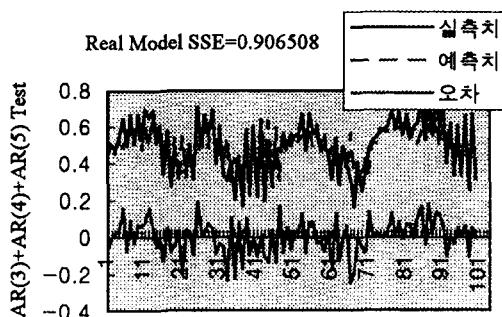


Fig. 7 Test of AR(3)+AR(4)+AR(5) Real Model

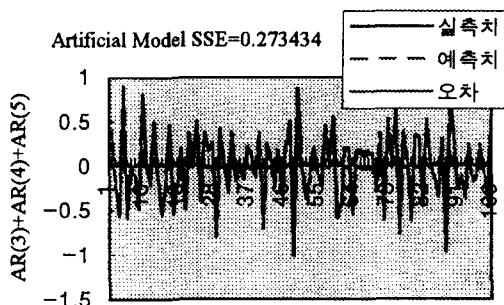


Fig. 8 Training of AR(3)+AR(4)+AR(5) Artificial Model

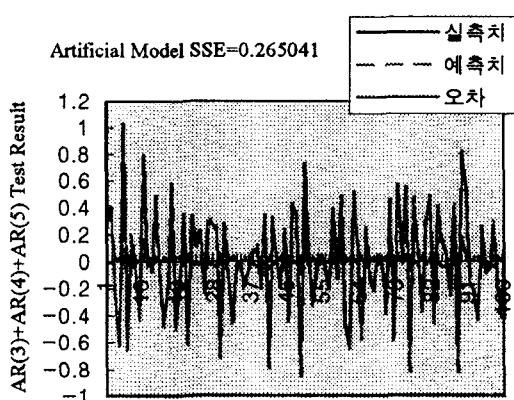


Fig. 9 Test of AR(3)+AR(4)+AR(5) Artificial Model

모델이 점차 복잡해 지게 되면 네트워크의 학습도 잘 되지 않을 뿐더러 새로운 데이터에 대한 Tracking 또한 개대로 이루어 지지 않는다. 다음의 결과는 AR(2) 모델

과, AR(3) 모델, AR(4), AR(5) 모델로부터 얻어진 데이터들의 합으로써, 모델의 구조가 점차 복잡해 지면 단일 네트워크로 모델링하기 어려운 경우도 있음을 Fig. 10 이 보이고 있다. 5개의 Input Node로 100개의 데이터 쌍을 학습 시킨 Real Model의 학습 결과는 다음 Fig. 10과 같다.

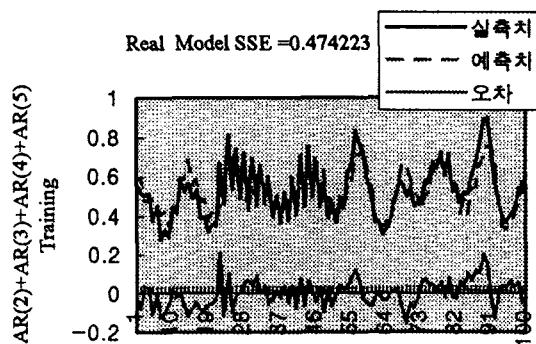


Fig. 10 Training of AR(2)+AR(3)+AR(4)+AR(5) Real Model

Fig. 11은 새로운 데이터 100쌍에 대한 Test 결과이다. 역시 SSE가 상당히 증가하였으며, Network가 제대로 구축되지 못했음을 의미한다.

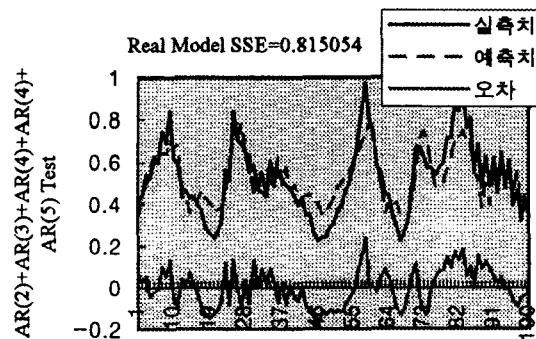


Fig. 11 Test of AR(2)+AR(3)+AR(4)+AR(5) Real Model

1차 네트워크로 Real Model을 형성한 뒤 대체적인 추정을 마치고 그 오차를 입력 벡터의 한 요소로 사용하여 학습한 Artificial Model은 보다 정밀한 추정을 보장해 준다. Fig. 12는 Artificial Model로서, 임의의 시리즈와 Real Model의 학습 결과의 오차를 학습한 결과이고, Fig. 13은 학습되지 않은 데이터를 사용한 Real Model

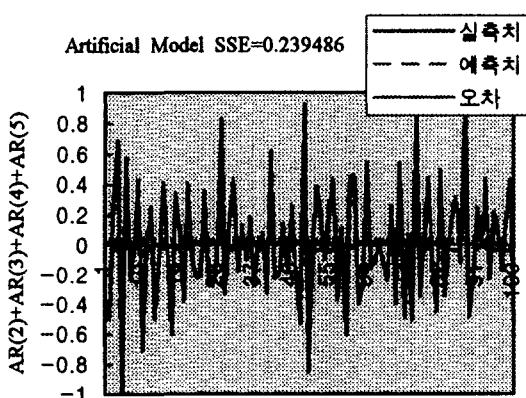


Fig. 12 Training of AR(2)+AR(3)+AR(4)+AR(5) Artificial Model

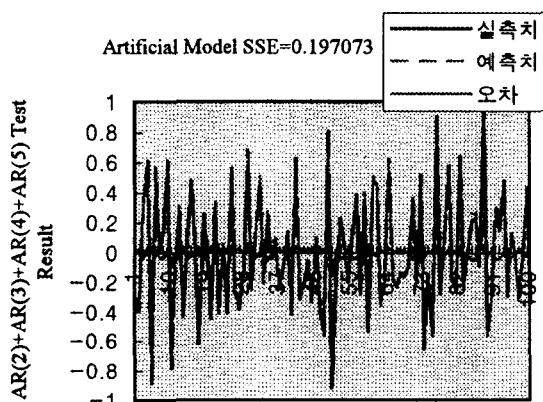


Fig. 13 Test of AR(2)+AR(3)+AR(4)+AR(5) Artificial Model

의 Test 결과에서 비롯된 오차와 임의의 시리즈를 학습한 결과이다.

3.2 시뮬레이션을 위하여 특별히 제작한 설비로부터 수집한 실제 데이터의 경우

이상의 시뮬레이션으로부터 2차 네트워크의 도입은 추정의 정도(精度)를 한층 높여주고 있음을 보았다. 그러나 실제 현장에서 발생하는 데이터는 모델의 구조를 알 수 없는 경우가 대부분인데, 입력 데이터의 모델을 알 수 없는 실제 데이터의 경우는 모델링하기가 더욱 어렵다. 단일 모델을 따른다고 하더라도 Parameter의 결정은 모두 휴리스틱한 방법에 의존할 수 밖에 없으므로, 모델링이 어렵고 정확한 모델을 구축하기도 어렵다. 이러한 경우에도 제안된 2단계 모델링을 사용하면 정확한 모델의 구축이 가능하다.

본 시뮬레이션을 위하여 다음의 그림과 같은 회전하는

모형기계를 제작하고 전동 센서를 부착한 후 얻어지는 데이터를 A/D Converter를 통해 1kHz의 샘플링 비율로 신호를 받아 분석하였다. 우선 정상 상태의 데이터(Real(03))를 수집하고, 회전하는 모형 기계의 조립 나사를 느슨하게 풀어준 후(unbalance 상태) 설비를 가동하여 데이터를 수집(Real (10))하였다. 즉, 수집된 데이터는 두 종류로써 모형기계가 정상 상태일 때 발생하는 신호(Real (03))와 Unbalanced 상태일 때 발생하는 신호(Real (10))가 그것이다.

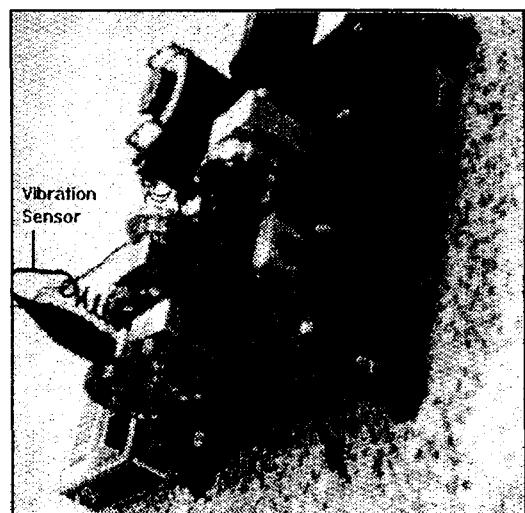


Fig. 14 The Prototype Rolling Machine used in Experimental Analysis

수집된 신호의 모델 구조를 전혀 알지 못하기 때문에 Real Model의 Input Node의 수를 10으로 가정하였다. Artificial Model을 위해 생성한 Artificial Series는 (식 2)과 같으며 사용된 계수는 다음의 표 3과 같다.

Table 3 Parameters of Artificial Modeling (For Real Data)

모델	변수			
	a ₁	a ₂	a ₃	a ₄
Real(03); 정상 상태	-1/3	1/3	1/3	-1/3
Real(10); Unbalanced	1/3	-1/3	-1/3	1/3

정상 상태의 Real Data에 대한 Real Model은 현재 학습이 제대로 이루어 지고 있지 않다.(Fig. 15) 실측 데이터에 대한 추세 반영이 전혀 이루어 지고 있지 않고 있

으며, 예측 값은 0.5 근처에서 같은 값을 반복하고 있다. 그러나 추정 오차에 대한 SSE는 2.2 정도로 그리 나쁘지 않다. 이는 입력 벡터의 값이 그리 크지 않기 때문인 것으로 분석되는데, 당연히 Real Model의 테스트 결과에서도 0.5가량의 값만을 추정할 뿐이다.(Fig. 16) 이와 같은 결과는 입력 노드의 수나 히든 노드의 수 및 learning rate등 결과에 영향을 줄 수 있는 인자들을 변환하며 실험해 보아도 비슷한 결과를 보였다. 이과 같은 결과는 얻어지는 데이터는 1단계의 모델링으로는 한계가 있음을 보이고 있다.

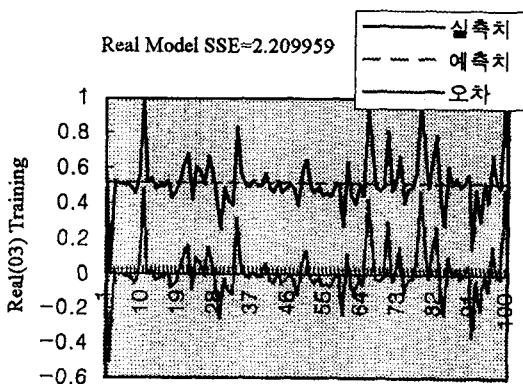


Fig. 15 Training of Real Data Real Model

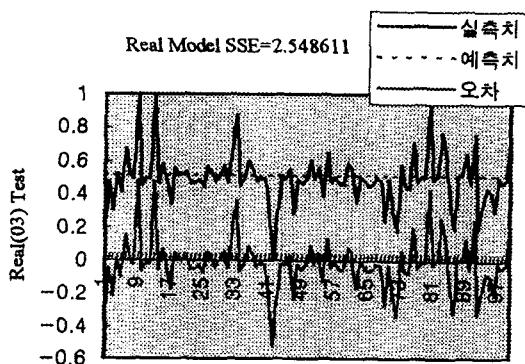


Fig. 16 Test of Real Data Real Model

1단계 모델링으로는 대체적인 추세만 파악하게 되지만, Fig. 17에서 보는 바와 같이 2단계 모델링으로써 Artificial Model을 구축하게 되면 정확한 시스템을 규명할 수 있게 된다. 이처럼 제안된 2단계 모델링으로써 모델 구조를 모르더라도 정확한 시스템 모델링을 할 수 있다.

다음 Fig. 18은 위에서 구축한 Artificial Model의 Test 결과이다.

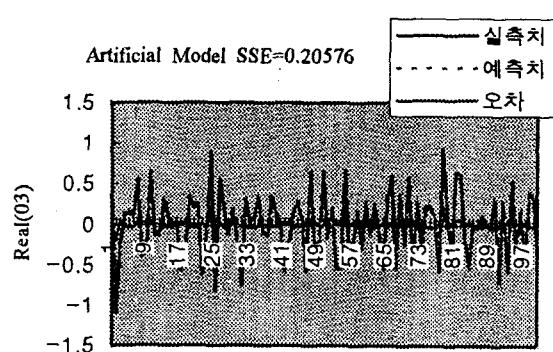


Fig. 17 Training of Real Data Artificial Model

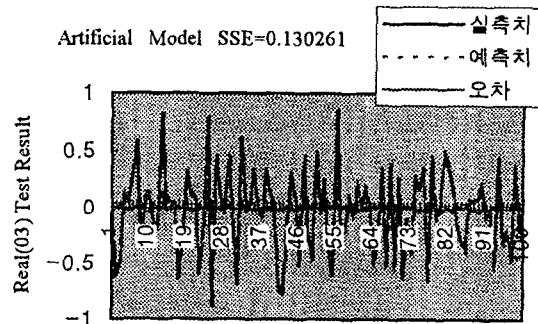


Fig. 18 Test of Real Data Artificial Model

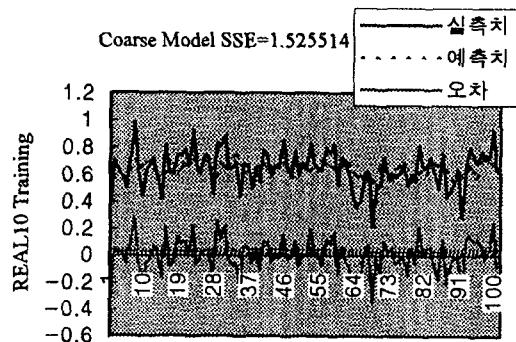


Fig. 19 Training of Real Data Real Model

설비가 이상 상태에 놓이게 되면 발생하는 시그널은 유형의 변화가 생기게 된다. Fig. 19는 설비의 나사가 완전히 조여 지지 않아 Unbalance 상태에 놓이게 된 경우 발생하는 시그널을 학습하여 Real Model을 형성한 모습이다. 대체적인 추세는 반영되고 있지만 정확한 예측값을 제공하지는 못하고 있다. Fig. 20의 학습되지 않은 데이터에 대한 테스트 결과 또한 같은 결과를 보이고 있다.

정밀화 과정으로써 2차 Artificial Model을 구축하게 되면 보다 정밀한 모델을 얻을 수 있다. Fig. 21은 Real Model의 Innovation과 임의로 생성한 시리즈가 새로운 Model(Artificial Model)을 형성한 예이다.

새로운 데이터에 대한 테스트 결과에서도 마찬가지로

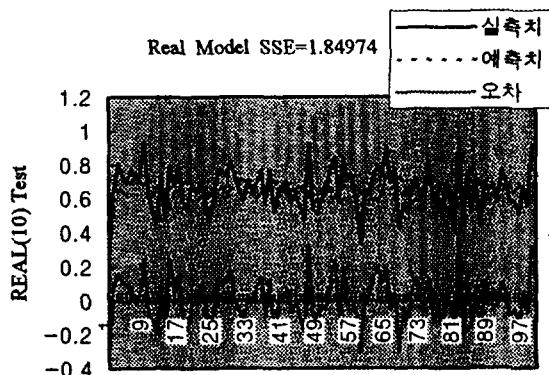


Fig. 20 Test of Real Data Real Model

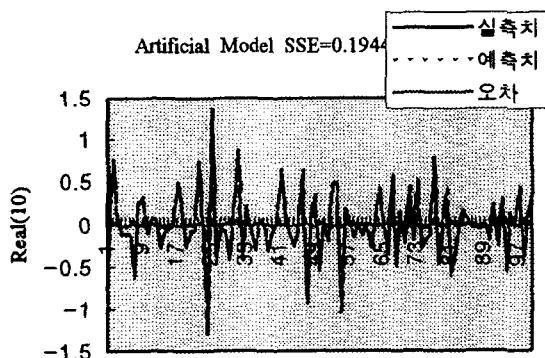


Fig. 21 Training of Real Data Artificial Model

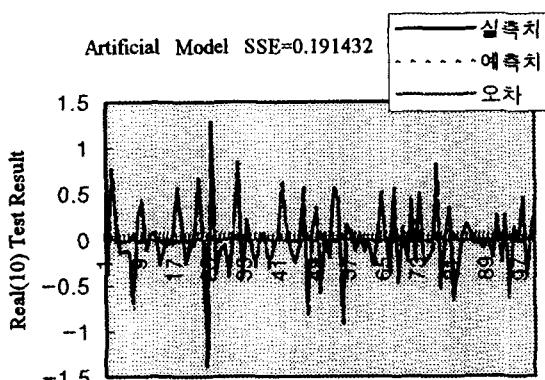


Fig. 22 Test of Real Data Artificial Model

구축한 Artificial Model은 정확한 추정 결과를 제공하고 있다. (Fig. 22)

이상의 결과에서 보는 바와 같이 Real Data에 대한 모델링에도 2단계 네트워크에 의한 모델 구축이 보다 정확한 결과를 제시해 주었다.

3.3 보다 복잡한 모델에 적용한 경우

공정이 복합 고장의 상태에 놓이게 되면 보다 복잡한 신호를 발생하게 된다. 이 절에서 사용된 데이터는 1989년 4월 미국 Texas주의 엘링턴시의 물 사용량⁽⁸⁾으로 이 데이터를 전통적인 시계열 분석 방법으로 모델링하기 위해서는 SARIMA(Seasonal Auto-Regressive Integrated Moving average) 모형을 사용하여야 할 것이나 SARIMA 모형으로는 정확한 모델링을 할 수 없었다.⁽⁸⁾ Real Model에서 Network이 시스템 모델링을 잘 못할 경우 Artificial Model과의 SSE는 더욱 큰 차이를 보이게 된다. 이 예의 경우에는 데이터의 값들이 대체로 크기 때문에 (식 2)에서 $a_j (j=1,2,3,4)$ 의 값은 모두 1로 설정하였다. 즉, 사용된 Artificial Series는 다음과 같다.

$$z_t = u_1(t-1) + u_1(t-2) - u_2(t-1) - u_2(t-2) + \varepsilon_t$$

Where, $u_1, u_2 \sim \text{Uniform Distn.}(-1,1)$

ε_t = Real Model의 $y_t - \hat{y}_t$

100개의 입력 벡터에 대하여 과거 24개의 데이터에 의하여 현재의 출력값이 나온다는 가정 아래(급수 요구량을 매 시간마다 기록하였으므로, 매 24시간마다 Seasonality가 반복 되리라는 가정) Input Node의 수는 24로 결정하였다. 이와 같은 데이터를 학습해 본 결과는 다음의 Fig. 23에 나타나 있다. Fig. 24는 구축된 Real Model이 얼마나 정확한지를 알아보기 위하여 새로운 100개의 입력 벡터에 대하여 테스트해 본 결과이다.

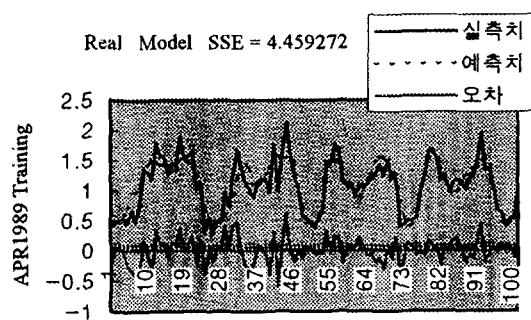


Fig. 23 Training of Complex Real Data Real Model

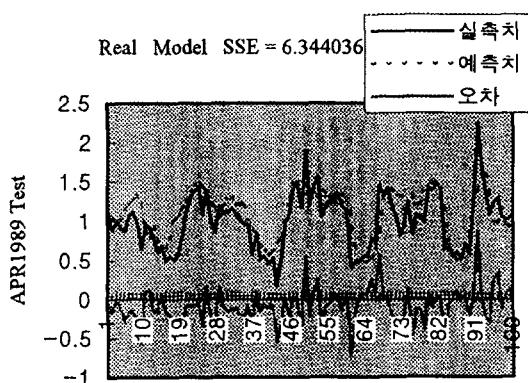


Fig. 24 Test of Complex Real Data Real Model

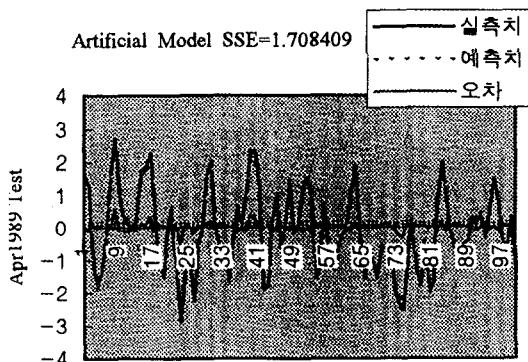


Fig. 25 Training of Complex Real Data Artificial Model

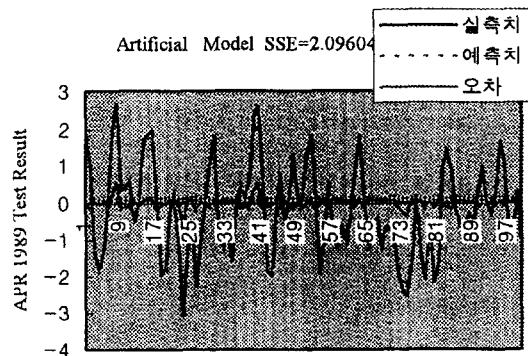


Fig. 26 Test of Complex Real Data Artificial Model

SSE가 6.3정도로 정확한 예측이라고는 보기 어려운 정도의 정도(精度)인데, Network 2를 구축하게 되면 보다 정확한 결과를 얻을 수 있게 된다. Fig. 25는 Artificial Model을 구축한 모습이다. Real Model과는 비교가 되지 않을 정도로 작은 SSE값을 보이고 있다. 이와 같은 대략화(Approximation)의 과정으로의 1단계 네트워

크와 정밀화(Polishing)의 과정으로의 2단계 네트워크를 사용하여 보다 정밀한 모델링을 할 수 있다.

Fig. 26은 구축된 Artificial Model에 Real Model으로부터 발생한 Innovation을 테스트한 결과이다.

이상의 시뮬레이션에서 얻어진 SSE값들을 문제의 유형별로 정리해 보면 다음의 표와 같다.

Table 4 Comparison of SSEs

모델 구조	Real Model		Artificial Model	
	Learning	Test	Learning	Test
AR(3)+AR(4)+AR(5)	0.599019	0.906508	0.273434	0.265041
AR(2)+AR(3)+AR(4)+AR(5)	0.474223	0.815054	0.239486	0.197073
Real(03)	2.209959	2.548611	0.20576	0.130261
Real(10)	1.525514	1.84974	0.194487	0.191432
April 1989	4.459272	6.344036	1.708409	2.096049

4 결 론

본 연구에서는 Non-linear, non-stationary 상태의 복잡한 데이터를 모델링하기 위하여 Network 1을 형성하여 1차 모델링을 시도하고, Network 1의 Innovation을 일부 입력 요소로 사용하는 2차 네트워크(Network 2)를 형성하여 정밀한 전체적인 모델링을 시도하였다. Network 1의 Innovation을 일부 입력 요소로 사용하는 2차 네트워크는 확정 모델로서 정확한 학습이 가능한 시리즈(본 연구에서는 -1~1의 범위를 가지는 Uniform 분포를 사용하였다.)에 전 단계의 오차를 포함시켜 Neural Network의 기본 성질인 일반화 특성(Generalization Capacity)을 최대한 발휘하도록 하였으며, Network 2는 1단계 모델링의 보상기(Compensator) 역할을 하게 된다.

이와 같은 모델링 방법은 기존의 2단계 모델링 방법과 차별성을 가지며, 1차 네트워크에서 학습이 어려운 경우에 탁월한 효과를 발휘했다. 특히 네트워크의 학습이 제대로 되지 경우에도 비교적 정확한 모델링이 가능했다. 또한 2차 네트워크를 형성하게 될 Artificial Series의 계수 값(식 1의 a_j 값들)들을 조정하면 2차 네트워크 추정의 정밀도를 조절 할 수 있다. 일반적인 경우라면 본 논문에서 사용한 식(3) $\text{Max}|a_{j+1}| \leq \text{Max}|e_i|$ 나 식(4) $\text{Min}|a_{j+1}| \geq \text{Min}|e_i|$ 를 사용하는 것이 효과적으로 사용될 수 있음이 실험 결과에서 입증되었다.

본 연구는 입력 패턴의 정보를 알 수 없거나 복잡한 시

스템을 모델링하는 새로운 2단계 모델링 방법을 제시한 데 의의가 있으며, Multiple Failure Diagnosis를 진단하는 시스템의 인식에 사용될 수 있다. 또한 2단계 모델링이 모든 경우에 적용 효과가 있다기 보다는 1단계 모델링이 충분하지 않을 경우 적용할 때 보다 큰 효과를 기대 할 수 있다. 2단계 모델링 역시 충분하지 않을 경우에는 단계로 확장 적용해야 하는데, 최적의 단계 수를 결정하는 것은 차후 연구 과제중의 하나이다. 또한 본 연구에서 사용된 Backpropagation Network 대신 Radial Basis 등. 을 사용하면 On- Line 모델링이 가능하게 된다.

참 고 문 헌

1. Gi-Nam Wang, Gwang-Sub Kim and Y.S. Jeong: "Two-Phase Radial Basis Hybrid Neural Network for On- Line Modeling of Machine Conditions", Journal of Society of Plant Engineers Japan, vol. 6, No. 3, pp. 20~28, 1994, 12.
2. Gi-Nam Wang; "An Adaptive Hybrid Neural Network Approach to Prediction of Nonstationary Process", Hybrid Intelligent System Applications, Edited by Dr. Jay Liebowitz, IOS Press, 1995.
3. Werbos, P.J.: 'Beyond Regression : New Tools for Prediction and Analysis in the Behavior Science', Ph.D. Dissertation, Harvard University, Cambridge, MA. Committee on Applied Mathematics, Nov. 1974. Also Published as Report of the Cambridge Project, Cambridge, MA. The 1975.
4. Narendra, K. S., and Parthasarathy, K.: "Identification and Control of Dynamical Systems using Neural Networks", I.E.E.E. Transaction on Neural Networks, 1, pp. 4~27, 1990.
5. Neumerkel, D., Murray, Smith R., and Gollee, H.: 'Modeling Dynamic Processes with Clustered Time-Delay Neurons'. Proceedings of 1993 International Joint Conference on Neural Networks(IJCNN '93 Nagoya Japan), Oct. 25~29, pp. 1765~1768, 1993.
6. Gi-Nam Wang, G.S. Kim and Y.S. Jeong: "Radial Basis Hybrid Neural Network Modeling for On- Line Detection of Machine Condition Change", Journal of the Korean Institute of Industrial Engineers, vol 20, pp.113~134, Dec. 1994.
7. Gi-Nam Wang, and Young cheol Go, "On- Line Neuro- Tracking of Non- Stationary Manufacturing Processes", Computers ind. Engng Vol. 30, No.3, pp.449~461, 1996.
8. Gi-Nam Wang, "An Adaptive Hybrid Neural Network Approach for Learning Nonstationary Manufacturing Process", Texas A & M University, 1993.
9. Astrom, K. J. and Wittenmark, B.: "Computer-Controlled Systems Theory and Design", Englewood-Cliffs, Prentice Hall, New Jersey, 1984.
10. Elanayar, S. and Shin, Y. C.: "Tool Wear Estimation in Turning Operations based in Radial Basis Functions", in Dagli, C.H., S.R.T. Kumara, and Y.C. ShinEds). Intelligent Engineering System Through Artificial Neural Network Proceedings of the Artificial Neural Networks in Engineering), pp.685-691, Nov. 10~13, 1991.
11. Kil, R. M. and Choi, J. Y.: "Time-Series Prediction Based on Global and Local Estimation", World Congress on Neural Networks(WCNN), Oregon, July 11~15, vol. 4, pp. 617~621, 1993.
12. K. T. Chong and D. P. Hong., "System Identification of Nonlinear System using Local Time Delayed Recurrent Neural Networks", Journal of the Korean Society of Precision Engineering, vol. 12. No. 6., June 1995.
13. Sastri, T., and Wang, G. N.: "Neuro-Identification of Time Series for On- Line Prediction", Modeling and Scientific Computing: Neural Network for Identification and Control of Dynamic System, 1993.
14. Sastri, T., Wang G. N.: "Adaptive Model Identification Method", Neural Parallel and Scientific Computations, 1993.
15. S. Rangwala and D. Dornfeld.: "Sensor Integration using Neural Networks for Intelligent Tool Condition Monitoring", Journal of Engineering for Industry, vol. 112 Aug. 1990.