

신경회로망을 이용한 원자력 발전소 증기발생기의 모델링

Modeling of Nuclear Power Plant Steam Generator using Neural Networks

이재기, 최진영
(Jae-Gi Lee and Jin Young Choi)

Abstract : This paper presents a neural network model representing complex hydro-thermo-dynamic characteristics of a steam generator in nuclear power plants. The key modeling processes include training data gathering process, analysis of system dynamics and determining of the neural network structure, training process, and the final process for validation of the trained model. In this paper, we suggest a training data gathering method from an unstable steam generator so that the data sufficiently represent the dynamic characteristics of the plant over a wide operating range. In addition, we define the inputs and outputs of neural network model by analyzing the system dimension, relative degree, and inputs/outputs of the plant. Several types of neural networks are applied to the modeling and training process. The trained networks are verified by using a class of test data, and their performances are discussed.

Keywords : steam generator, neural network modeling, data gathering, learning, validation

I. 서론

원자력발전소에서 증기발생기는 필요한 전력 생산을 위한 증기를 공급하는 역할과 함께 원자로에서 나온 고온의 유체로부터 열에너지를 흡수하여 저온으로 만들어 다시 원자로로 보내어주어 원자로를 냉각하는 역할을 한다. 이상의 두 가지 역할을 안전하게 수행하기 위해서는 증기발생기의 수위를 어느 적정 수준에서 유지하는 것이 필요한데, 최근의 자료들을 살펴보면, 원자력발전소의 강제 정지 사례 중에서 증기발생기 수위 제어 실패로 인한 정지가 많은 부분을 차지하고 있다.

이와 같이 원자력 발전소에서 증기발생기가 원자로 강제 정지의 큰 원인 중 하나가 되고 있는 것은 원자로 기동과 같은 저출력 영역에서 소위 shrink 및 swell 현상이라는 증기발생기 고유의 열수력학적 특성에 의해 수위의 제어가 곤란하기 때문이며 이 현상은 원자력발전소의 증기발생기 뿐만 아니라 화력발전소의 보일러 드럼과 같은 모든 형태의 열교환기에서 공통적으로 대두되고 있는 현상이다. 이 현상은 증기발생기의 입력이 되는 증기량, 급수량, 급수온도, 1차측 냉각제 온도 및 기타 열수력학적 인자들이 복합적으로 작용하여 나타나는 현상이다. 이상과 같은 증기발생기 자체의 열수력학적 특성이 외에 저출력에서의 수위제어가 곤란한 또 다른 이유는 급수계통의 기계적 문제 및 제어기 구조이다. 저유량인 경우 밸브 및 구동기의 특성이 정확하지 않으며, 구동기의 hysteresis 등에 의해 발생되는 시간지연은 급수계통의 제어에 불안정을 야기한다. 특히 일정 출력을 기준으

로 bypass regulation valve에서 main regulation valve로 전환될 때 구동기 및 밸브 동작의 불연속은 제어 시스템의 불안정으로 이어지므로 급수조절은 더욱 어렵게 된다. 현재까지의 제어기법은 선형 시스템에 기반한 제어 이론을 중심으로 발전되어왔기 때문에 이상과 같이 비선형성이 강하고 복잡한 증기발생기의 제어에는 한계가 있다. 증기발생기의 경우와 같이 레귤레이션 문제라면 특정 동작점에서 동작하므로, 그 동작점 근처에서 선형화된 모델을 사용하면 선형제어기로도 어느 정도 제어 성능을 발휘할 수 있다. 그러나, 증기발생기의 경우 모델링 자체에 경험적 상수들이 들어가 있고, 기계적 마모, 측정 오차, 밸브와 구동기의 부정확한 특성 등 비모델 동력학이 존재한다. 이러한 비모델 동력학(unmodeled dynamics)이 제어 시스템 성능에 미치는 영향이 커지면 시스템이 불안정해질 수 있다. 한편 비선형제어 접근 방법으로는 궤환선형화, 가변구조 제어 등의 기법이 있으며 특정조건하의 비선형 동적 모델을 알고 있는 경우 제어 가능하다. 그러나 비선형 동적 모델링이 정확하지 않을 때 시스템의 안정성, 즉 강인성을 보장하지는 않는다. 이러한 문제점을 해결하기 위해서 최근 새로운 접근을 시도하고 있다. 기존의 PI 제어기의 이득값을 개선하는 방법이나 현대 제어 이론을 사용하는 것은 증기발생기의 정확한 열수력학적 모델이 선행되어야 한다. 그러나, 증기발생기를 열수력학적으로 모델링하는 것은 설계비용이 많이 드는 작업이고, 시변특성이나 부정확한 모델링일 가능성이 있다. 이처럼 모델링 자체가 어려운 상태에서는 적절한 제어기를 만들 수 없다.

자연계의 시스템을 모델링할 때 수학적 모델링과 함께 전문가 법칙, 퍼지 모델링 그리고 신경회로망 모델링과 같은 지능 모델링 기법을 이용할 수 있다. 그 중에서 신

접수일자 : 1997. 8. 14., 수정완료 : 1998. 7. 13.

이재기, 최진영 : 서울대학교 전기공학부

* 본 논문은 한국전력공사의 지원에 의하여 기초전력공학공동 연구소의 주관으로 수행되었습니다.

경회로망을 이용한 모델링은 시스템의 입출력 관계를 기반으로 하기 때문에 신경회로망은 시변 특성, 부정확한 모델링 등에 대한 실시간 적응보상이 가능하다. 또한 신경회로망은 임의의 비선형 시스템을 식별할 수 있는 범용 합수근사자 역할을 할 수 있음이 밝혀져 있기 때문에, 비선형 특성을 갖고 모델링이 어려운 증기발생기의 모델링 및 제어에 효율적으로 사용될 수 있다.

본 논문에서는 신경회로망을 이용하여 증기발생기의 복잡한 열수력학적 특성을 모델링하고자 한다. 신경회로망을 이용한 동력학 시스템 모델링의 기본 과정은 시스템을 충분히 나타낼 수 있는 데이터의 수집, 신경회로망의 입출력 정의, 학습, 그리고 최종단계의 검증과정을 포함한다.

첫번째 과정으로서 학습 데이터를 얻기 위해서 실제 원전 데이터를 이용할 수가 있지만, 원전 기동시 확보된 데이터의 양이 방대할 뿐 아니라, 임의의 입력에 대한 출력값을 얻기가 어렵다. 따라서, 현재까지 연구되어온 증기발생기의 열수력학적 모델들[5]-[7]을 검토하여 그 중에서 실제 플랜트를 가장 잘 표현한다고 판단되는 모델을 선정하여 학습 데이터를 구한다. 이때 증기발생기 자체가 불안정한 시스템이므로 열수력학적 모델에 적절한 제어기를 삽입하여 안정화시킨 후에 학습 데이터를 구하는 방법을 사용한다. 또한, 학습된 신경회로망 모델의 유효성 검증을 위해 열수력학적 모델로부터 학습 데이터와는 다른 시험 데이터를 여러 가지 입력 상황을 고려하여 선정한다.

다음 과정으로 증기발생기의 동력학 특성을 분석하여 신경회로망의 입력을 정의한다. 신경회로망의 입력으로는 증기발생기의 입력에 해당하는 증기량, 급수량, 급수온도, 그리고 1차측 냉각제의 온도들의 시간 지연된 값들과 증기발생기의 출력에 해당하는 수위의 시간 지연된 값들로 정의되며, 신경회로망의 출력으로는 현재의 수위로 정의된다. 학습과정에서는 다층인식자(Multi-Layer Perceptron ; MLPN)[1], 원형역전파 신경회로망(Circular Back-Propagation Network ; CBPN)[2], 부분선형학습 신경회로망(Piecewise Linearly Trained Network ; PLTN)[3], 회귀 신경회로망(Recurrent Neural Network ; RNN)[4] 등의 신경회로망을 사용한다. 최종적으로 적절한 시험데이터를 수집하여 학습된 신경회로망 모델의 유효성을 검증하고, 성능을 비교 검토한다.

본 논문의 구성은 다음과 같다. 2절에서는 본 논문에서 학습 및 시험을 위한 데이터 수집에 이용한 증기발생기의 열수력학적 모델에 대해서 간단히 설명하고, 3절에서는 신경회로망의 입력 및 출력에 대해서 정의하고 본 논문에서 이용한 신경회로망의 구조들과 증기발생기의 열수력학적 모델에서 학습 데이터를 얻기 위한 수위제어기의 구성에 대해서 기술한다. 4절에서는 PE(Persistently Exciting) 조건을 만족하고 안정적인 학습 데이터를 수집 및 신경회로망 모델의 유효성 검증을 위한 시험데이터의 수집에 대하여 설명한다. 또한 여러 가지 신경회로망들을 학습시켜 증기발생기를 모델링하고, 학습된 모델의

유효성 검증을 실험적으로 알아본다. 마지막으로 5절에서는 실험을 통해 확인된 결과들을 검토하고, 앞으로의 과제에 대해 언급한다.

II. 증기발생기의 열수력학적 모델

증기발생기는 원자로에서 가열된 물을 얇은 판을 통과시키면서 열에너지를 흡수하여 터빈에 증기를 공급하여주는 역할과 원자로를 냉각시키는 역할을 한다. 따라서 증기발생기는 원자로의 안전과 전력의 안정적인 출력에 중요한 역할을 한다. 필요한 전력에 대해서 터빈을 돌리는데 필요한 증기량이 결정되고, 증기량의 변화에 따라 수위가 변하게 되는데, 수위는 일반적으로 어떤 적정 수준에서 유지되어야 하며, 이때 수위조절을 위해 급수량을 조절하여 수위를 제어하게 된다.

따라서 증기량과 급수량은 증기발생기의 입력으로 볼 수 있고, 증기발생기의 수위는 출력으로 볼 수 있다. 증기발생기의 다른 입력으로는 급수 온도와 1차측 냉각제 온도가 있다. 이를 입력이 직접적으로 수위에 미치는 영향은 크지는 않지만 증기발생기의 과도 현상 즉, shrink/swell 현상에 미치는 영향이 크기 때문에 고려해야 한다. 이 과정을 그림으로 보면 그림 1과 같다.

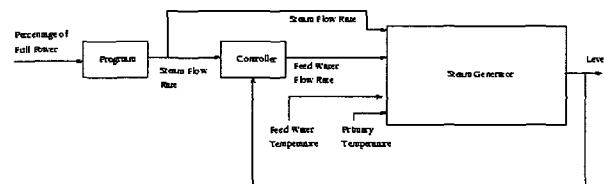


그림 1: 증기발생기의 입력과 출력.

Fig. 1. The inputs and outputs of steam generator.

본 논문에서 검토된 모델들 [5]-[7] 중에서 Stoymayer[7]의 4-node model을 수정한 Modified 4-node model을 기초로 하여 열전달 및 momentum 식을 보완한 이윤준의 모델[6]을 이용하기로 결정하였다. 아래에 이윤준의 모델에 대해 간략하게 소개하기로 하겠다.

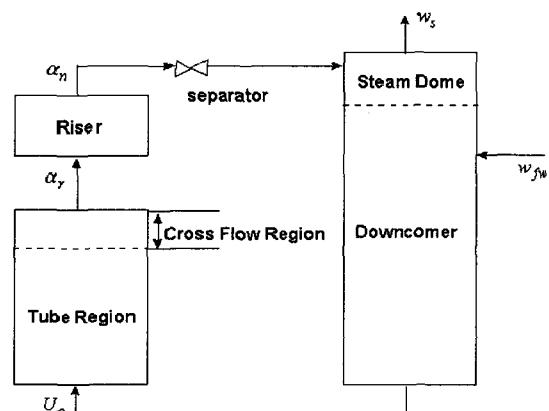


그림 2: 수정된 4-node 증기발생기 모델.

Fig. 2. Modified 4-node steam generator model.

Modified 4-node model은 그림 2와 같이 증기발생기를

steam dome, downcomer, riser, tube 부분으로 나누고, tube 부분을 saturated region과 subcooled region으로 나눈다. 각 부분들에 대해 질량 및 에너지 평형 방정식을 적용시키고, 급수의 순환 경로를 따라 1개의 momentum 평형방정식을 적용시키면, (1)과 같이 정리된다.

$$A \frac{d}{dt} \Phi = B, \quad (1)$$

$$\Phi = \begin{bmatrix} U_o \\ V_v \\ \alpha_r \\ \alpha_n \\ \frac{p}{W} \end{bmatrix}$$

$$B = \begin{bmatrix} \bar{W}(h_o - h_r) + Q_b \\ \bar{W}(h_r - H_n) \\ \bar{W}(h_n - H_k) - w_s(h_g - H_k) \\ w_{fw}(h_{fw} - H_k) - W(h_o - H_k) \\ w_{fw} - w_s \\ -F \end{bmatrix}$$

행렬 Φ 는 기본변수들로 이루어져 있는데, 각각 downcomer 출구의 내부에너지, steam dome에서 증기의 부피, riser의 입구쪽 void fraction, 출구쪽 void fraction, steam dome 내부의 압력, 연속적으로 돌아가는 유체의 평균 흐름율을 나타낸다. 이 기본 변수들이 결국 위 식의 출력이 되어 나타나는데, 우리가 관심이 있는 출력인 수위 L_w 가 직접 나타나지 않는데, 수위는 기본 변수들과 steam dome의 기하학적 구조에 의해서 결정된다. steam dome의 기하학적 구조는 각각의 증기발생기에 따라 다르게 나타나며, 하나의 steam dome에서 여러 가지 형태의 단면을 보이고 있으므로 수식으로 나타내기가 힘든다. 행렬 B 에는 증기발생기의 입력측 외란이 직접 영향을 주는 요소가 있다. 증기량(w_s), 급수량(w_{fw})이 그런 것이며, 그외 1차측 냉각제 온도(T_{pin}), 급수온도(T_{fw})는 일차측에서 이차측으로 넘어가는 열에너지(Q_b)에 직접 영향을 준다.

행렬 A 의 각 요소들은 기본 변수(Φ)들의 미분으로 표시되고 steam table로 계산할 수 있다. 여기서 행렬 A 의 요소들은 앞서 설명하였듯이, 수위의 위치에 따라, 증기발생기의 기하학적인 구조에 따라 구하는 식이 틀려진다. 이상에서 구한 증기발생기의 열수력학적 모델은 비선형함수이고, 실험을 통해서 얻을 수밖에 없는 계수들을 사용하고, 상황에 따른 계수들의 불연속적인 변화 등이 나타나고 있으며, 프로세서 모델 자체가 제어기 설계에 유용하지 않음을 알 수 있다.

III. 신경회로망을 이용한 증기발생기의 모델링

1. 비선형시스템의 신경회로망 모델링

신경회로망을 이용하여 임의의 비선형 시스템을 학습에 의해 모델링하는 모형은 아래와 같이 구할 수 있다. 시스템의 식별과 특징분류는 시스템 이론에서 근본적인 문제인데, 특징분류문제는 시스템의 수학적 표현과 관련되어있다. 즉, 어떤 시스템의 모델링은 시스템을 입력 공

간 U 에서 출력 공간 Y 로의 오퍼레이터 P 로 표현하는 것이고 목표는 P 가 속하는 클래스 \mathbf{P} 를 특징짓는 것이다. P 가 $\hat{\mathbf{P}}$ 의 원소라는 사실에서 식별 문제는 $\hat{P} \in \hat{\mathbf{P}}$ 가 P 를 충분히 근사화할 수 있도록 하는 클래스 $\hat{\mathbf{P}}$ 를 결정하는 것이다. \mathbf{P} 의 결정은 정확도와 정량적 분석의 용이함과 관련되어있다. 또한 P 를 표현하기 위한 모델 \hat{P} 의 학습은 정확도, 얼마나 쉽게 표현할 수 있는가, 정확도의 전제조건을 만족하지 않을 경우 어떤 방법으로 확대되어 나가는가, 그리고 \hat{P} 이 온라인으로 이용되는지 아니면 오프라인으로 이용되는 지에도 관련되어 있다.

동적 시스템에서 주어진 플랜트에 의해서 정의되는 오퍼레이터 P 는 시간에 대한 함수인 입력과 출력에 의해 정의된다. 목표는 $|\hat{y} - y| = |\hat{P}(u) - P(u)| \leq \epsilon, u \in U$ 가 되는 \hat{P} 를 찾는 것이다. $\hat{P}(u) = \hat{y}$ 는 식별모델의 출력이고, $\hat{y} - y = e$ 는 측정된 플랜트의 출력 y 와 식별모델 \hat{P} 에서 만들어진 출력간의 차이를 말한다. Narendra [1]에 의하면 비선형 시스템을 아래와 같이 4개의 차분방정식형태로 제시하고 있다.

식별모델 1 :

$$y_p(k+1) = \sum_{i=0}^{n-1} \alpha_i y_p(k-i) + g[u(k), u(k-1), \dots, u(k-m+1)]$$

식별모델 2 :

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1)] + \sum_{i=0}^{m-1} \beta_i u(k-i)$$

식별모델 3 :

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1)] + g[u(k), u(k-1), \dots, u(k-m+1)]$$

식별모델 4 :

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1); u(k), u(k-1), \dots, u(k-m+1)]$$

식별모델 1은 입력의 과거값과는 비선형의 관계를 가지고 출력의 과거값들과는 선형의 관계를 가지고 있으며, 식별모델 2는 입력의 과거값과는 선형의 관계를 가지고 출력의 과거값들과는 비선형의 관계를 가지고 있다. 식별모델 3은 입력의 과거값, 출력의 과거값들과는 서로 별도의 함수를 가지고 비선형의 관계를 가지고 있으며, 식별모델 4는 가장 일반적인 형태를 지니고 있다. 특히 식별모델 2는 제어이론의 적용이 용이한 형태를 가지고 있으나 일반성이 떨어져 식별에는 적용성이 떨어지고, 식별모델 4는 제어이론 적용에는 용이하지 않지만, 식별에는 정확성을 가질 수 있는 형태여서 본 논문에서는 식별모델 4의 형태로 식별을 시도한다.

신경회로망 모델은 크게 두 가지로 나눌 수 있는데, 하나는 병렬식별 모델이고, 또 하나는 직병렬식별 모델이다. 병렬식별 모델은 식별모델 4를 기준으로 볼 때

$$\hat{y}_p(k+1) = f[\hat{y}_p(k), \hat{y}_p(k-1), \dots, \hat{y}_p(k-n+1); u(k), u(k-1), \dots, u(k-m+1)]$$

과 같이 출력의 과거값을 플랜트에서 얻는 것이 아니라,

식별 모델로부터 얻는 것이고, 직병렬식별 모델은

$$\widehat{y}_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1); u(k), u(k-1), \dots, u(k-m+1)]$$

와 같이 출력의 과거값을 플랜트로부터 취한다. 일반적으로 직병렬식별 모델의 성능이 더 좋게 나타나기 때문에 본 논문에서는 직병렬식별 모델을 이용하기로 한다.

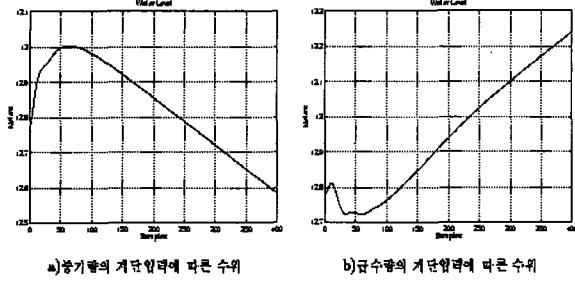


그림 3. 증기량과 급수량의 계단 입력에 따른 수위 변화.

Fig. 3. Water level step response due to steam flow rate and feed water flow rate.

2. 증기발생기의 안정화

증기발생기의 열수력학적 모델이 개루우프에서 어떤 응답 특성을 가지는지를 정리해보면 다음과 같다. 다른 입력은 그대로 유지하고 증기량에 계단 입력을 가해보면, 일정시간 이 지난 후에는 적분하는 효과를 나타내고, 그 이전에서는 비최소위상 시스템의 특성을 보여준다. 이는 앞서 밝힌 shrink/swell 현상으로 나타난다. 급수량에 대해서 앞의 실험을 해보면, 증기량과 마찬가지로 일정시간 이 지난 후에는 적분하는 효과를 나타낸다. 그 이전에서는 비최소위상 시스템의 특성을 보여준다. 단, 증기량은 음으로 적분하고, 급수량은 양으로 적분하는 차이가 있다. 급수온도와 1차측 냉각제의 온도의 경우 일정시간 이 지난 후에는 안정화되어 수위를 더 이상 변화하지 않고, 정상상태 오차만을 가지므로 전체적인 수위의 불안정성과는 직접적인 관련이 없다. 증기발생기의 불안정성에 관계된 두 개의 입력에 대한 수위의 변화는 그림 3에 나타나있다.

이상과 같이 증기발생기의 열수력학적 모델에서 알 수 있듯이 개루우프 응답 특성이 불안정하고 비최소위상 시스템 특성을 보이므로 학습데이터 획득이 용이하지 않다. 따라서 기존에 수위제어 방법을 동원하여 모델링하고자 하는 플랜트를 안정화시키기 위해 사용된 제어기는 PI제어기로 증기량, 수위를 되먹임하여 급수량을 계산한다[5][6]. 이렇게 함으로써 적분기의 효과로 수위와 기준 수위간의 오차를 없애고, 동시에 증기가 되어 증기발생기에서 빠져나가는 양과 급수량으로 증기발생기에 공급되는 양을 같게 하는 효과를 동시에 볼 수 있게된다.

제어기의 입력은 증기량과 수위가 되고, 출력은 급수량이 된다. 급수온도, 1차측 온도 역시 입력측의 외란으로 볼 수 있으며, 수위에 영향을 미치지만 그 정도가 매우 적기 때문에 제어기에서는 고려하지 않는다. 제어기 구조를 그림 4에 나타나있다.

그림 4에서처럼 현재 이용되고 있는 제어기는 일반적으로 2-mode 제어기를 사용하여 수위를 적정 수준에 맞추기 위한 급수량을 결정한다. 여기서 2-mode란 저출력(낮은 전력량)에서는 수위와 증기량을 이용하여 급수량을 제어하고, 고출력(높은 전력량)에서는 수위, 증기량, 그리고 급수량의 되먹임을 이용하여 급수량을 제어하는 것을 말한다. 저출력에서는 급수량의 되먹임을 이용하지 않는 이유는 저출력에서는 급수량이 매우 적기 때문에 측정이 곤란하기 때문이다.

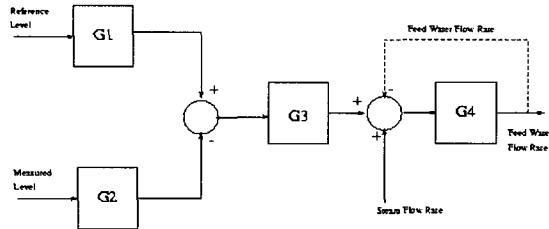


그림 4. 증기발생기의 수위 제어.

Fig. 4. Water level control in steam generator.

각 제어기는 간단한 PI 제어기를 사용하는데, 아래와 같은 식으로 구한다[5].

$$G_1(s) = \frac{1}{1+\alpha s}, \quad G_2(s) = \frac{1}{1+\beta s} \\ G_3(s) = c + \frac{d}{s}, \quad G_4(s) = a + \frac{b}{s}$$

위의 제어기를 사용했을 때 각각의 이득값은 실험적으로 구한다.

3. 신경회로망 모델링을 위한 증기발생기의 입출력 모형
식별모델 4의 구조로 직병렬식별 모델에 적용할 경우
(1)과 같은 증기발생기 상태공간 모델은 다음과 같은 입
출력 미분방정식으로 나타나며,

$$L_w^{(n)}(t) = f(L_w^{(n-1)}(t), L_w^{(n-2)}(t), \dots, L_w(t), \\ w_s^{(n-d)}(t), w_s^{(n-d-1)}(t), \dots, w_s(t), \\ w_{fw}^{(n-d)}(t), w_{fw}^{(n-d-1)}(t), \dots, w_{fw}(t), \\ T_{pin}^{(n-d)}(t), T_{pin}^{(n-d-1)}(t), \dots, T_{pin}(t), \\ T_{fw}^{(n-d)}(t), T_{fw}^{(n-d-1)}(t), \dots, T_{fw}(t))$$

이를 이산시간 시스템으로 표시하면,

$$L_w(k) = f(L_w(k-1), L_w(k-2), \dots, L_w(k-n), \\ w_s(k-d), w_s(k-d-1), \dots, w_s(k-n), \\ w_{fw}(k-d), w_{fw}(k-d-1), \dots, w_{fw}(k-n), \\ T_{pin}(k-d), T_{pin}(k-d-1), \dots, T_{pin}(k-n), \\ T_{fw}(k-d), T_{fw}(k-d-1), \dots, T_{fw}(k-n))$$

와 같다. 여기서 d 는 상대차수를 나타낸다. 위 식에서 증기발생기는 4개의 입력외란 ($w_s, w_{fw}, T_{pin}, T_{fw}$)과, 1개의 출력을 갖는 함수식으로 표현할 수 있음을 알 수 있는데, 입력 외란인 증기량 (w_s)이 결정되면 급수량 (w_{fw})은 수위 (L_w)와 증기량에 의해서 제어기 출력값으로 결정된다. 즉, $w_{fw} = c(w_s, L_w)$ 의 형태가 되어 급수량을 독립변수로 보기 어렵다. 하지만, 여기서는 증기발생기의 입출력관계를 신경회로망을 통해서 표현하는 것이 목표이므로, 입

력 변수로 생각한다. 이 모델에 여러 가지 신경회로망을 적용하기 위해 신경회로망의 입출력 관계를 다음과 같이 설정한다. 신경회로망의 출력을 $y(k) = L_w(k)$ 로 정의하고, 입력은

$$x(k)^T = [L_w(k-1), L_w(k-2), \dots, L_w(k-n), w_s(k-d), w_s(k-d-1), \dots, w_s(k-n), w_{fw}(k-d), w_{fw}(k-d-1), \dots, w_{fw}(k-n), T_{mn}(k-d), T_{mn}(k-d-1), \dots, T_{mn}(k-n), T_{fw}(k-d), T_{fw}(k-d-1), \dots, T_{fw}(k-n)]$$

로 정의하면 신경회로망은 증기발생기의 입출력 함수관계인

$$y(k) = f(x(k))$$

이 되며, 신경회로망 식별모델이

$$\hat{y}(k) = \hat{f}(\theta, x(k))$$

을 출력하도록 모델링한다. $\hat{f}(\cdot)$ 는 임의의 신경회로망을 나타내며, θ 는 신경회로망의 가변매개변수를 의미한다. 신경회로망 모델링을 위한 학습은 오차 $e(k) = y(k) - \hat{y}(k)$ 의 함수인 목적함수를 최소화하는 신경회로망의 구조 및 θ 를 학습에 의해 찾아내는 것이다.

4. 증기발생기 모델링을 위한 신경회로망

1) 원형역전파 신경회로망

1개의 은닉층을 갖는 원형역전파 신경회로망(Circular Backpropagation Network : CBPN)의 구조를 수식으로 표현하면 아래와 같다[2].

$$\begin{aligned} s_i(k) &= \sum_{j=1}^m w_{ij}^{(1)} x_j(k) + \sum_{j=1}^m w_{ij} x_j^2(k) + b_i^{(0)} \\ v_i(k) &= \tanh(s_i(k)) \\ \hat{y}(k) &= \sum_{i=1}^p w_{ij}^{(2)} v_i(k) + b_i^{(1)}, \quad w_{ij} \geq 0 \end{aligned}$$

여기서, $w_{ij}^{(1)}$ 는 입력층 j 노드에서 은닉층 i 노드로의 가중치이고, $b_i^{(0)}$ 는 은닉층 i 노드로의 bias 가중치이며, $w_{ij}^{(2)}$ 는 은닉층 i 노드에서 출력층으로의 가중치이고, $b_i^{(1)}$ 는 출력층의 bias 가중치이다. 위의 식에서 보듯이 기존의 MLPN과 거의 유사한 구조를 가지고 있고 차이점은 입력 패턴이 신경회로망에 인가될 때 신경회로망이 각각의 입력 값들에 대한 제곱항을 더해서 MLPN이 m 차원의 입력패턴을 이용한다면, CBPN은 $2m$ 차원의 신경회로망 입력 패턴을 이용한다는 것이다. 기존의 MLPN이 패턴인식을 할 경우 입력공간을 은닉층 노드의 수 p 와 같은 차원의 평면으로 나누었다면, CBPN은 제곱항의 특성을 이용하여 p 차원의 평면, 구(sphere), 혹은 타원으로 나눈다는 차이점이 있다. 이런 차이점들에서 CBPN은 기존 MLPN과 비교할 때 표현 능력이 향상되었고, 일반화 능력은 비슷하며, 학습된 지식의 해석이 더 쉬운 정점을 지닌다. 또한 MLPN과 RBFN(Radial Basis Function Network)의 특성을 동시에 나타낼 수 있다[2]. 따라서, 함수 f 에 대해 임의의 오차 ϵ 를 가지고 근사화할 수 있다[1][8].

이 신경회로망의 학습은 다층인식자와 동일한 구조를 가지므로 다층인식자에서 설명한 일반적인 오차역전파(error backpropagation)학습법을 그대로 적용할 수 있다[9].

2) 부분선형학습 신경회로망

부분선형학습 신경회로망(Piecewise Linearly Trained Network : PLTN)은 입력공간을 국부영역으로 분할하고, 이 국부영역에서 선형사상을 나타내도록 하는 모듈형 신경회로망의 하나이다[3]. 이 신경회로망은 범용 근사자로 함수 f 를 임의의 정확도를 갖도록 근사화할 수 있다[3]. PLTN에 의해 근사화된 함수 \hat{f} 는 다음과 같이 표현된다.

$$\begin{aligned} \hat{y}(k) &= \hat{f}(x(k)) = \sum_{i=1}^p \overline{\mu}_i(x(k)) \Psi_i(x(k)) \\ \Psi_i(x(k)) &= w_i^T x(k) + b_i \\ \overline{\mu}_i(x(k)) &= \frac{\mu_i(x(k))}{\sum_{j=1}^M \mu_j(x(k))} \\ \mu_i(x(k)) &= \exp(-|x(k) - c_i|^2 / \gamma) \end{aligned}$$

여기서, $|x - c_i|$ 는 입력 x 와 방사형 기저함수 $\mu_i(x)$ 의 중심점 c_i 간의 유clidean 거리를 의미하며, p 은 은닉층의 전체 유닛 개수이다. γ 는 국부영역의 크기를 결정하는 경쟁변수이다. 이 신경회로망의 학습은 자기 구성(self-organizing)을 위한 비지도 학습(unsupervised learning)과 국부선형사상 (local linear mapping) 학습을 위한 지도학습(supervised learning)을 동시에 한다.

3) 회귀 신경회로망

회귀 신경회로망(Recurrent Neural Network : RNN)은 아래의 (2)과 같은 구조를 가진다. 동력학 시스템이 $\dot{x} = f(x, u)$, $y = h(x)$ 형태로 주어질 때, 모든 상태변수의 측정이 가능하고, 함수 $f(\cdot)$, $h(\cdot)$ 을 안다면, 여러 가지 제어 방법을 적용할 수 있을 것이다. 수학적, 물리적 방법을 이용하여 함수 $f(\cdot)$, $h(\cdot)$ 을 찾기가 힘든 경우나 상태변수의 측정이 불가능한 경우에 동적 신경회로망을 이용하여 동적 시스템을 모델링할 수 있다면, 여러 가지 제어방법의 적용이 가능할 것이다[4]. 실제로 (2)과 같은 동적 신경회로망이 임의의 오차한계를 가지고 함수 $f(\cdot)$, $h(\cdot)$ 을 근사화할 수 있음이 증명되었다[10][11].

$$\begin{aligned} \dot{\hat{x}} &= D\hat{x} + AT(\hat{x}) + Bu \\ \hat{y} &= C\hat{x} + Bias \\ T(\hat{x}) &= [\tanh(\hat{x}_1), \dots, \tanh(\hat{x}_n)]^T \end{aligned} \quad (2)$$

본 논문에서 증기발생기와 같이 느린 프로세스에 대해 적용시킬 때 학습데이터의 수집간격이 크다면 연속시간 형태로 이용하는 것은 어렵게 된다. 따라서 이산시간 형태로 바꾸어서 사용하였고, 행렬 A 의 경우 대각 행렬(diagonal matrix)을 이용하였는데, 구조상에서 보면 은닉층의 유닛들간에 cross talk가 없는 경우가 된다. 이산시간 형태를 식으로 나타내면 아래와 같다. 우선 이산시간 형태의 회귀 신경회로망은 (3)과 같이 나타낼 수 있다.

$$\begin{aligned} \hat{x}(k+1) &= D\hat{x}(k) + AT(\hat{x}(k)) + Bu(k) \\ \hat{y}(k) &= C\hat{x}(k) + Bias \end{aligned} \quad (3)$$

이상의 신경회로망 구조에 대한 학습 알고리듬은 연속시간 형태에서와 같은 방법을 적용해 보면 아래와 같이 정리된다.

$$\begin{aligned} a_i(k+1) &= a_i(k) + \Delta a_i(k), \quad i=1, \dots, p \\ b_{ij}(k+1) &= b_{ij}(k) + \Delta b_{ij}(k), \\ &\quad i=1, \dots, p, j=1, \dots, m \\ c_i(k+1) &= c_i(k) + \Delta c_i(k), \quad i=1, \dots, p \end{aligned}$$

여기서, p 는 신경회로망 내부 상태 수를 나타내며, m 은 신경회로망의 입력 수를 나타낸다.

$\Delta a_i(k)$, $\Delta b_{ij}(k)$ 그리고 $\Delta c_i(k)$ 은 $E = \frac{1}{2}(y(k) - \hat{y}(k))^2$ 에 델타 룰을 적용시켜보면 아래와 같다.

$$\begin{aligned} \Delta a_i(k) &= \eta_1 e(k) c_i \frac{\partial x_i}{\partial a_i}(k) \\ \Delta b_{ij}(k) &= \eta_2 e(k) c_i \frac{\partial x_i}{\partial b_{ij}}(k) \\ \Delta c_i(k) &= \eta_3 e(k) x_i(k) \end{aligned}$$

여기서, $e(k) \equiv y(k) - \hat{y}(k)$ 이다.

$\frac{\partial x_i}{\partial a_i}(k)$ 과 $\frac{\partial x_i}{\partial b_{ij}}(k)$ 는 (3)을 미분하면 얻을 수 있으며, 정리해보면,

$$\begin{aligned} \frac{\partial x_i}{\partial a_i}(k+1) &= d_i \frac{\partial x_i}{\partial a_i}(k) + \tanh(x_i(k)) \\ &\quad + a_i \tanh'(x_i(k)) \frac{\partial x_i}{\partial a_i}(k) \\ \frac{\partial x_i}{\partial b_{ij}}(k+1) &= d_i \frac{\partial x_i}{\partial b_{ij}}(k) \\ &\quad + a_i \tanh'(x_i(k)) \frac{\partial x_i}{\partial b_{ij}}(k) + u_j(k) \end{aligned}$$

와 같고, 여기서 $\tanh'(x_i(k)) = \frac{dtanh(x_i(k))}{dx_i(k)}$ 이다.

IV. 신경회로망 모델의 학습 및 검증

1. 증기발생기 입출력 데이터 수집

1) 학습 데이터의 수집

신경회로망 모델을 오프라인으로 학습시키기 위해서 시스템의 특성을 완전히 표현할 수 있는 입출력 데이터가 필요한데, 가장 유용하게 사용할 수 있는 것이 백색 잡음이다[9],[12],[13]. 백색 잡음을 그대로 사용할 경우 시뮬레이터를 통해서는 데이터를 얻을 수 있을지는 모르지만, 실제 시스템에 적용할 시 입력값의 한계로 인해 시뮬레이터에 대응하는 데이터를 얻을 수 없다. 또한, 실제 실험에서도 드러났지만, 시뮬레이터에서도 안정된 입출력값을 구할 수 없었다. 백색 잡음을 입력으로 주었을 때 안정된 입출력 데이터를 얻기 위하여 다음과 같은 몇 가지 방법을 동원한다.

본 논문에서 이용한 증기발생기의 시뮬레이터는 정상상태에 있는 증기발생기에 입력외란이 주어지면 어떤 반응을 보이는지를 알 수 있게 구성되어 있는데 연속적인 백색 잡음의 입력외란을 가하여 안정된 입출력 데이터를 얻을 수 없었기 때문에, 몇 개의 기준 전력량에 대해 증기량(w_s)을 구하고, 이 값에 *dithering noise*를 첨가해서 입출력값을 구했다[13]. 백색잡음을 첨가하는 방식은 전력량이 결정되면 w_s 가 결정된다고 했는데 이를 $w_{s,nominal}$ 이라고 하면 $w_s = w_{s,nominal} + dithering noise$, 와 같다.

여기서, *dithering noise*는 백색 잡음을 저대역 필터를 통과시켜 구할 수 있으며, 백색잡음의 크기는 $w_{s,nominal}$ 의 크기에 따라 적절히 조절해 주어야 주어진 제어기로 안정한 출력을 얻을 수 있었다. 이 과정을 그림으로 보면 그림 6과 같다.

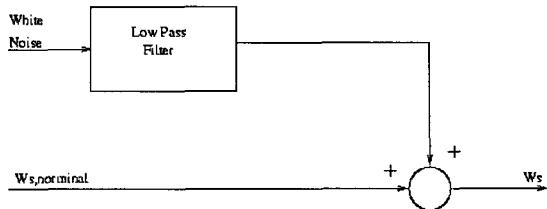


그림 5. 학습 데이터 수집을 위한 증기발생기의 입력.

Fig. 5. The inputs of steam generator for gathering training data.

그림 6에서 저대역 필터는 간단한 1차식을 사용하였다. 급수량은 제어기를 통해서 나오기 때문에 백색잡음을 더하면 안정적인 출력을 얻을 수 없으므로 제어기 출력을 그대로 이용하였고, 급수온도와 1차측 냉각제의 온도는 증기량에서와 마찬가지로 적당한 크기의 백색잡음을 첨가하였다.

본 논문에서는 초기 전체 전력량의 5%에서부터 100%까지를 20단계로 나누어 각 단계별로 0.1초의 Runge-Kutta방법으로 1000초까지 시뮬레이션하고, 5초단위로 샘플을 취해서, 총 4020개의 학습데이터를 만들었다. 학습데이터를 증기발생기의 입력과 출력으로 구분하여 그림으로 나타내면, 그림 7에서는 프로세스의 입력부분인 증기량, 급수량, 급수온도, 그리고 1차측 냉각제 온도들을 나타내고 있으며, 그림 8에서는 증기발생기의 출력인 수위의 변화를 나타내고 있다.

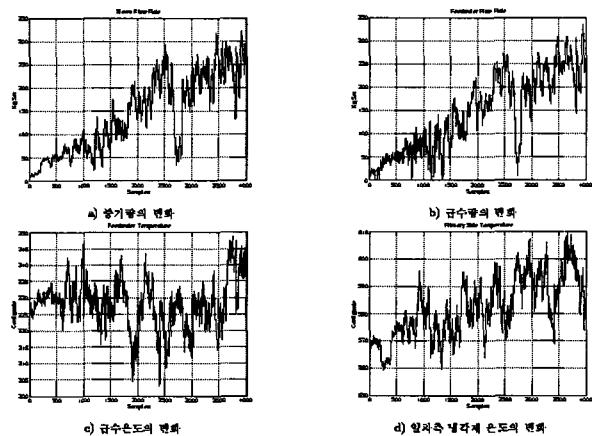


그림 6. 학습데이터-증기발생기의 입력 (증기량, 급수량, 급수온도, 일차측 냉각제 온도).

Fig. 6. Training data-the inputs of steam generator (steam flow rate, feedwater flow rate, feedwater temperature, primary side temperature).

2) 검증 데이터의 수집

신경회로망 모델을 검증하기 위해서는 증기발생기의 전동작 영역에서의 시험데이터가 필요하지만, 학습데이

터의 생성에서 보았듯이 전동작 영역에서의 데이터 수집은 불가능하다. 따라서 가능하면 실제 원자력발전소에서 여러 가지 경우의 데이터를 취하여 신경회로망의 성능을 확인해 볼 필요가 있다. 하지만 여기서는 우선 증기발생기의 열수력학적 모델을 이용하여 아래의 설명과 같이 여러 경우의 입출력 관계를 가정하고 시험데이터를 구해보았다.

• 증기량의 계단입력(step input)

$$1) w_s : 16.94(\text{kg}/\text{Sec}) \rightarrow 27.00(\text{Kg}/\text{Sec})$$

$$2) w_s : 16.94(\text{kg}/\text{Sec}) \rightarrow 67.77(\text{Kg}/\text{Sec})$$

$$3) w_s : 33.90(\text{kg}/\text{Sec}) \rightarrow 16.94(\text{Kg}/\text{Sec})$$

$$4) w_s : 135.2(\text{kg}/\text{Sec}) \rightarrow 67.60(\text{Kg}/\text{Sec})$$

• 증기량의 계단입력과 급수온도 및 1차측 냉각제 온도의 임의 변화¹⁾

5) Test Set 1 + T_{pin}, T_{fu} 에 필터를 통과한 백색잡음첨가

6) Test Set 2 + T_{pin}, T_{fu} 에 필터를 통과한 백색잡음첨가

7) Test Set 3 + T_{pin}, T_{fu} 에 필터를 통과한 백색잡음첨가

8) Test Set 4 + T_{pin}, T_{fu} 에 필터를 통과한 백색잡음첨가

• 증기량의 연속적인 계단입력

9) 초기 전력량 : 5%, Δw_s : 30(Kg/Sec) 800초 동안 모의 실험을 실시한 다음 다시 증기량을 변화시키는 것을 10회 반복

10) 초기 전력량 : 50%, Δw_s : random²⁾ 800초 동안 모의 실험을 실시한 다음 다시 증기량을 변화시키는 것을 10회 반복

11) 초기 전력량 : 15%, Δw_s : random³⁾ 800초 동안 모의 실험을 실시한 다음 다시 증기량을 변화시키는 것을 10회 반복⁴⁾

2. 신경회로망 모델의 학습 및 검증

1) 부분선형학습 신경회로망

부분선형학습 신경회로망(PLTN)의 학습은 문턱값과 γ 에 의해서 은닉층의 노드를 자동으로 만들므로 은닉층 노드의 개수를 따로 정의할 필요는 없다. 또한, PLTN은 다른 신경회로망들에 비해 학습속도가 매우 빠르기 때문에 다양한 실험을 해 볼 수 있다. 신경회로망을 학습시키는데는 플랜트의 차수와 상대차수를 알아야 하는데, 일반적인 방법이 존재하지 않지만, PLTN의 빠른 학습

1) 여기서는 1차측 냉각제의 온도와 급수온도가 임의로 변화할 경우에 대한 시험 데이터를 구성하였다. 1차측 냉각제의 온도와 급수온도가 수위에 직접 미치는 영향은 상대적으로 적지만, 증기발생기의 열수력학적 특성인 shrink/swell 현상에 미치는 영향이 크기 때문에 이 값들에 대한 수위의 변화를 관찰하여야 한다.

2) [-100 100] 구간에서 균일 분포

3) [-30 30] 구간에서 균일 분포

4) 여기서 증기발생기의 shrink/swell 현상이 저출력에서 더욱 두드러지게 나타난다는 사실 때문에 가능한 넓은 저출력 부분에서 시험데이터를 수집하고자 하였다.

속도를 이용하여 여러 경우에 대해 실험적으로 결정할 수 있다.

4020개의 학습데이터에 대해 학습하였고, 신경회로망의 입력값의 범위가 넓게 펴져있기 때문에 학습데이터를 검사하여 가장 큰 값을 찾아내고 이를 이용하여 입력 공간을 정규화 하는 작업을 거쳤다. 이 작업을 하지 않을 경우 오차가 줄어드는 양이 매우 작게 나타났다. 보통 3번의 반복만 거치면 수렴하여 아주 빠른 학습속도를 보여 주었다. 본 실험에서는 문턱값을 고정시키고 γ 값을 변화시키며 3회 반복 학습시켰다. 반복 시행에 의하여 좋은 성능을 보이는 γ 값은 0.5, 0.1, 0.08이었고, 각각의 γ 값에 의해 자동 생성된 은닉층의 노드 수는 2, 5, 6 이었다.

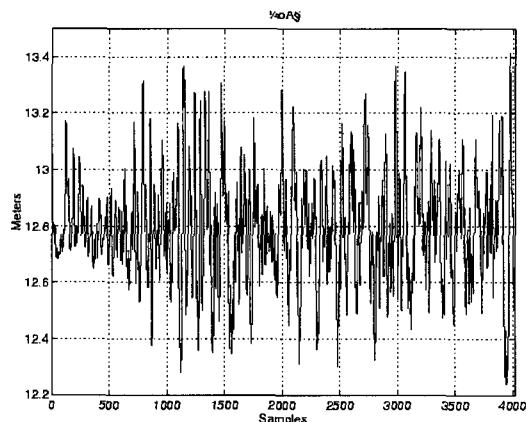


그림 7. 학습 데이터-증기발생기의 출력(수위).

Fig. 7. Training data-the output of steam generator.

학습된 신경회로망 모델의 유효성 검증을 위해서 시험데이터에 적용시켜본 결과는 표 1에 정리되어 있고, PLTN 뒤의 숫자는 자동 생성된 은닉층 노드의 개수이다. 여기서, 각 시험데이터의 개수가 서로 다르기 때문에 정규화된 RMS(Root-Mean-Square) 오차, E 로 신경회로망 모델들의 성능을 비교하겠다.

$$E = \frac{\langle [\hat{y}(k) - y(k)]^2 \rangle^{\frac{1}{2}}}{\langle (y(k) - \langle y(k) \rangle)^2 \rangle^{\frac{1}{2}}}$$

여기서, $\langle \cdot \rangle$ 는 평균값을 말한다. 따라서 E 의 분모는 프로세스 출력의 표준편차를 나타내며, 분자는 RMS를 나타낸다.

2) 다층인식자

본 논문에서 이용된 다층인식자 (MLPN)의 구조는 1개의 은닉층을 가지고 있으며, 은닉층의 노드 개수를 다양하게 설정하여 다층인식자를 구성하였고, 4020개의 학습데이터로 오차역전파 학습알고리듬(error backpropagation)을 이용하여 8,000회 반복을 거쳤다. 학습률은 0.01이고, 모멘텀은 0.85이었다. 여기서 반복 횟수의 결정은 학습 오차가 어느 정도에서 더이상 줄어들지 않을 때까지 계속 실행하면서 결정하였고, 학습률과 모멘텀은 학습 과정 중에 발산하지 않는 정도에서 실험적으로 결정하였다. PLTN에서 와 마찬가지로 입력공간을 정규화하였다.

여러 가지 다층인식자 중에서 검증 결과가 가장 좋은 은닉층의 노드수가 20, 30, 50, 80개인 경우의 검증 결과를 표2에 나타내었고, MLPN 뒤의 숫자는 은닉층 노드의 개수이다. 표의 내용은 PLTN에서와 같은 정규화 된 RMS이다.

3) 원형역전파 신경회로망

원형역전파 신경회로망 (CBPN)은 MLPN에서와 마찬가지로 은닉층 노드 수를 여러 가지로 구성하여 10,000번의 반복을 거쳤고, 학습률은 0.001이고, 모멘텀은 0.4이었다. 학습 알고리듬은 오차역전파 학습알고리듬(error backpropagation)을 이용하였다. MLPN에서와 마찬가지의 이유로 반복횟수, 학습률, 모멘텀을 결정하였고, 입력공간의 차원이 MLPN에 비해서 크기 때문에 학습이 느리게 진행되어 반복횟수를 늘렸다.

학습된 CBPN 중에서 검증 결과가 가장 좋은 은닉층의 노드수가 5, 30, 40, 80개인 경우의 검증 결과를 표 3에 나타내었고, CBPN 뒤의 숫자는 은닉층 노드의 개수이다. 표의 내용은 PLTN에서와 같은 정규화된 RMS이다.

4) 회귀 신경회로망

회귀 신경회로망(RNN)의 경우에는 우선 상태방정식의 선형부분 행렬 D 의 원소는 0.01로 고정하고, 비선형부분 행렬 A 는 대각행렬 형태로 두었으며, 출력 부분 Bias를 12.78로 두었는데, 그 이유는 증기발생기의 정상 상태 수위가 12.78이기 때문이다. 은닉층의 노드수를 여기서는 상태(state)수라고 할 수 있다. 내부 상태 수를 여러 가지로 두고 동적 신경회로망을 구성하였고, 4020개의 학습데이터에 대해서 학습률 0.01, 모멘텀 0.1로 10,000번 반복으로 학습시켰다.

표 1. PLTN 시험결과.

Table 1. The result of PLTN test.

시험데이터	PLTN2	PLTN5	PLTN6
Test Set1	0.0350	0.0380	0.0347
Test Set2	0.0480	0.0464	0.0411
Test Set3	0.0231	0.0273	0.0228
Test Set4	0.0235	0.0353	0.0340
Test Set5	0.0348	0.0337	0.0300
Test Set6	0.0457	0.0464	0.0440
Test Set7	0.0311	0.0300	0.0259
Test Set8	0.0235	0.0352	0.0340
Test Set9	0.0689	0.0794	0.0765
Test Set10	0.0439	0.0540	0.0509
Test Set11	0.0431	0.0429	0.0406
평균	0.0389	0.0426	0.0398
표준편차	0.0130	0.0145	0.0148

회귀신경회로망 모델은 학습 능력이 다른 신경회로망 모델에 비해서 좋지 않게 나타났다. 이유는 동적 신경회로망을 구성할 때 상태의 초기 상태값을 단순히 0으로 보았는데, 초기상태가 틀려짐으로 해서 학습에 많은 지장을 주고 있다. 하지만, 시간이 지남에 따라 상태값이 프로세스의 상태를 표시할 수 있을 정도가 되면 결과가 좋아진다는 것을 알 수 있다. 따라서 회귀신경회로망은 온라인 학습이 필수적이다. 학습된 RNN 중에서 검증 결

과가 가장 좋은 상태수가 20, 30, 50개인 경우의 검증 결과를 표 4에 나타내었다. 표의 내용은 PLTN에서와 같은 정규화된 RMS이며, + 표시는 온라인 적용을 실시하였음을 나타낸다. 그리고, RNN 뒤의 숫자는 은닉층 노드의 개수, 즉 신경회로망의 내부 상태 수이다.

표 2. MLTN 시험결과.

Table 2. The result of MLTN test.

시험데이터	MLTN20	MLTN30	MLTN50	MLPN80
Test Set1	0.1504	0.1749	0.1820	0.1680
Test Set2	0.1141	0.1157	0.1202	0.1112
Test Set3	0.0954	0.1114	0.1168	0.1125
Test Set4	0.0649	0.0679	0.0686	0.0641
Test Set5	0.2220	0.2774	0.2883	0.2702
Test Set6	0.1154	0.1180	0.1226	0.1136
Test Set7	0.0859	0.0937	0.0983	0.0945
Test Set8	0.0648	0.0676	0.0685	0.0642
Test Set9	0.1222	0.1287	0.1327	0.1271
Test Set10	0.0726	0.0723	0.0746	0.0752
Test Set11	0.1203	0.1482	0.1504	0.1349
평균	0.1117	0.1251	0.1294	0.1214
표준편차	0.0454	0.0607	0.0634	0.0585

표 3. CBPN 시험결과.

Table 3. The result of CBPN test.

시험데이터	CBPN5	CBPN30	CBPN40	CBPN80
Test Set1	0.1301	0.0546	0.1481	0.0471
Test Set2	0.1044	0.0534	0.0988	0.0629
Test Set3	0.0656	0.0513	0.0673	0.0328
Test Set4	0.0616	0.0635	0.0521	0.0508
Test Set5	0.1720	0.0504	0.2158	0.0450
Test Set6	0.1048	0.0508	0.0997	0.0625
Test Set7	0.0628	0.0505	0.0558	0.0359
Test Set8	0.0614	0.0636	0.0515	0.0508
Test Set9	0.1416	0.1805	0.1462	0.1422
Test Set10	0.0653	0.0888	0.0623	0.0571
Test Set11	0.1286	0.0785	0.1519	0.0646
평균	0.0998	0.0720	0.1045	0.0596
표준편차	0.0393	0.0400	0.0542	0.0292

표 4. RNN 시험결과.

Table 4. The result of RNN test.

시험데이터	RNN20+	RNN30+	RNN50+
Test Set1	0.0652	0.0596	0.0883
Test Set2	0.0499	0.0411	0.0618
Test Set3	0.0366	0.0336	0.0463
Test Set4	0.0356	0.0313	0.0467
Test Set5	0.1071	0.1057	0.1496
Test Set6	0.0524	0.0444	0.0652
Test Set7	0.0369	0.0292	0.0406
Test Set8	0.0366	0.0333	0.0499
Test Set9	0.0653	0.0521	0.0799
Test Set10	0.0521	0.0413	0.0570
Test Set11	0.0461	0.0368	0.0537
평균	0.0531	0.0462	0.0672
표준편차	0.0209	0.0218	0.0310

5) 성능 비교분석

이상의 실험에서 다층인식자에 비해 부분 선형 신경회로망은 학습속도가 매우 빠르게 나타나는데, 대부분 3회의 반복을 거치면 수렴하였다. 나머지 신경회로망은 8000~10000회의 반복을 거쳐야 했고, 학습이 끝난 후의 오차도 부분선형학습 신경회로망보다 좋지 않게 나왔다.

부분선형학습 신경회로망의 학습속도가 빠르기 때문에 신경회로망 모델의 개발에서 필요한 시스템의 차수 및 상대차수를 확인하기에 적합하다. 현재 나와 있는 증기발생기의 열수력학적 모델은 대부분 선형으로 근사화된 모델을 사용한다고 밝혔는데, 이 선형 모델들의 경우 시스템의 차수를 3으로, 상대차수를 1로 하고 있었고, 본 논문에서는 이 근처에서 시스템의 차수와 상대차수를 확인해 보았다. 시스템의 차수는 3이나 4일 경우 거의 비슷한 결과값을 나타내고 있었고, 상대차수는 1일 경우가 가장 좋은 결과를 나타내었다. 시스템 차수가 늘어나면, 신경회로망 입력 벡터의 차원이 늘어나는 현상을 보이므로, 가능하면 계산량을 줄이기 위해 시스템의 차수를 3으로 두고, 상대차수를 1로 두어 나머지 신경회로망 모델을 개발하였다.

표 5. 신경회로망의 성능 비교.

Table 5. Performance comparison of neural networks.

	PLTN2	CBPN80	MLPN20	RNN30+
평균	0.0389	0.0596	0.1117	0.0462
표준편차	0.0130	0.0292	0.0454	0.0310

표 5에서 나타난 것처럼 부분선형학습 신경회로망의 식별능력이 본 논문에서 이용한 시험데이터에 대해서는 가장 뛰어난 것을 알 수 있다. 원형역전파 신경회로망도 다층인식자와 비교해보면 식별능력이 좋은 것으로 나타났다. 회귀 신경회로망의 경우 온라인 적용이 없을 경우에는 식별능력이 다른 신경회로망에 비해 좋지 않게 나타났지만, 온라인 적용을 하면 식별능력이 향상되었고, 구조가 제어이론의 적용이 용이하게 되어 있기 때문에 향후 아주 유용한 증기발생기의 신경회로망 모델이 될 수 있다. PLTN2와 RNN30+에 대해서 결과를 그림으로 살펴보면 그림 9, 10과 같이 나타난다. 여기서 각 그림의 아래는 플랜트의 출력에서 신경회로망의 출력을 뺀 값을 나타낸다.

V. 결론 및 향후 과제

증기발생기와 같은 비선형 시스템을 특별한 형태의 함수들의 집합으로 표시할 수 있다고 가정하고 그 집합을 신경회로망으로 선정하였다. 신경회로망 집합의 원소들 중에서 현재 비선형 시스템의 식별에 가장 많이 이용되어온 다층인식자를 이용하여 식별해 보았고, 이를 기준으로 해서 최근에 연구가 진행되어 오고 있는 세 가지의 신경회로망을 검토해 보았다.

원형역전파 신경회로망은 다층인식자와 비슷한 구조를 가지고 있고, 식별 문제에서 다층인식자보다 나은 성능을 보여 주었다. 부분선형학습 신경회로망은 학습 횟수가 다른 신경회로망들에 비해 매우 짧았다. 대부분 3회

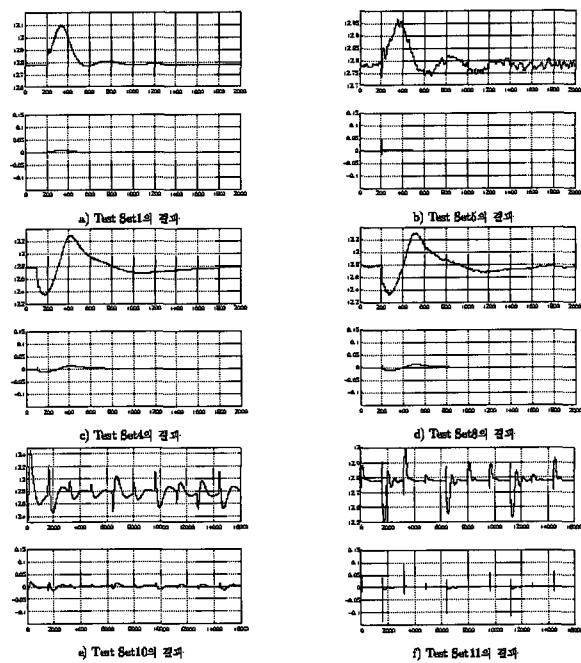


그림 8. γ 가 0.5이고, 은닉층 노드가 2개 생성된 PLTN 시험 결과.

Fig. 8. The test result of PLTN with two hidden units with γ 0.5.

의 반복으로 수렴함을 보여 주었다. 또한, 검증단계에서도 다른 신경회로망들에 비해 좋은 결과를 보여 주었다. 회귀신경회로망은 다층인식자에 비해 학습속도가 매우 느리게 나타났고, 검증 단계에서 온라인 적용이 없을 경우에는 식별 오차가 매우 크게 나타나고 있다. 하지만, 온라인 적용을 하는 경우에는 다른 신경회로망들에 비해 초기에는 좋지 않은 결과가 나타나지만, 시간이 지남에 따라 좋은 결과를 나타내었고, 구조가 제어이론의 적용에 매우 용이하다는 이점이 있었다. 증기발생기에 수위 제어기를 첨가했음에도 불구하고 전동작영역에서의 안정된 입출력 데이터를 얻기가 어려웠다.

하지만, 신경회로망 모델들이 증기발생기의 열수력학적 모델 식별이 가능했기 때문에 신경회로망을 이용한 뉴로제어기를 구성하고 기존의 수위제어기보다 넓은 영역에서 수위를 제어할 수 있게 되면, 학습데이터를 증기발생기의 동작영역을 확대해감으로써 구할 수 있을 것이다. 이렇게 구해진 학습데이터를 이용하여 신경회로망을 학습시키면 식별 능력이 향상되고 뉴로제어기에 적용하여 더 넓은 동작 영역에서 안정된 제어기를 설계할 수 있게 될 것이다.

동시에 실제 원전 동작 데이터를 이용한 검증과 온라인 학습을 통하여 실제 증기발생기의 동력학적 특성을 표현할 수 있는 신경회로망 모델의 유도가 가능할 것이며 최종적으로 증기발생기의 수위제어기로서 뉴로제어기를 구할 수 있게 될 것이다. 뉴로제어기를 이용함으로써 증기발생기를 더욱 안정하게 동작시키고 이를 통해 원자로의 강제정지 등의 불안정한 동작 상태를 줄일 수 있게 된다.

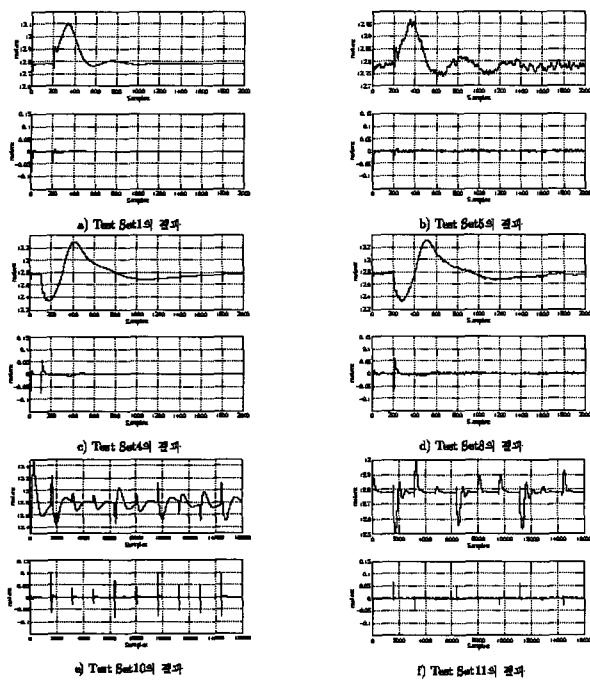


그림 9. 30개의 은닉층 노드를 가지고 온라인 적응을 하는 경우 RNN 실험 결과.

Fig. 9. The test result of RNN with 30 hidden nodes under on-line adaptation.

참고문헌

- [1] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural network," *IEEE Trans. Neural Networks*, vol. 1, no. 1, pp. 4-27, March, 1990.
- [2] S. Ridella, S. Rovetta and R. Zunino, "Circular backpropagation networks for classification," *IEEE Trans. Neural Networks*, vol. 8, no. 1, pp. 84-136, January, 1997.
- [3] J. Y. Choi and H. J. Park, "Adaptive learning control of affine piecewise linearly trained network," *IEEE International Conference on Neural Networks*, November, 1995.
- [4] M. A. Bryds, G. J. Kulawski and J. Queved, "Recurrent networks for nonlinear adaptive control," (To be appeared).
- [5] G. W. Suh and H. C. No, "Dynamic modeling and optimum level controller design for steam generators in pressurized water reactors," *Nuclear Science and Engineering*, vol. 90, pp. 236-247, January, 1985.
- [6] 이윤준, "원자력발전소 증기발생기의 저출력 수위조절에 대한 연구," PhD thesis, 서울대학교, 1991, 2.
- [7] W. H. Strohmayer, "Dynamic modeling of vertical U-tube steam generators for operational safety systems," PhD thesis, MIT, 1982.
- [8] A. Krzyzak, T. Linder and G. Lugosi, "Nonparametric estimation and classification using radial basis function nets and empirical risk minimization," *IEEE Trans. Neural Networks*, vol. 7, no. 2, March, 1996.
- [9] S. Haykin, *Neural Networks*, MacMillan, 1994.
- [10] A. Delgado, C. Kambhampati and K. Warwick, "Dynamic recurrent neural network for system identification and control," *IEEE Proc. Control Theory Appl.*, vol. 7, no. 2, pp. 307-314, July, 1995.
- [11] K.-I. Funahashi and Y. Nakamura, "Approximation of dynamical systems by continuous time recurrent neural networks," *Neural Networks*, vol. 6, pp. 801-806, 1993.
- [12] S. Ridella, S. Rovetta and R. Zunino, *Adaptive Inverse Control*, Prentice Hall, 1996.
- [13] K. J. Astrom and B. Wittenmark *Adaptive control*, Addison Wesley, 1995.

이재기



1996년 서울대 전기공학부 졸업. 동대학원 석사(1998). 1998년~현재 서울대학교 박사 과정. 관심분야는 신경회로망, 뉴로 모델링 및 지능 제어.

최진영

1982, 1984, 1993년 서울대학교 제어계측학과 학사, 석사, 박사. 1989년~1994년 한국전자통신연구소 연구원, 선임연구원. 1994년~현재 서울대학교 전기공학부 조교수. 주 관심분야는 신경회로망 연산 및 제어 (Neural Computing and Control) 이론 및 응용.