

신경회로망을 이용한 원자력발전소 증기발생기의 지능제어

Intelligent Control of Nuclear Power Plant Steam Generator Using Neural Networks

김 성 수, 이 재 기, 최 진 영

(Sung Soo Kim, Jae-Gi Lee, and Jin Young Choi)

Abstract : This paper presents a novel neural based controller which controls the water level of the nuclear power plant steam generator. The controller consists of a model reference feedback linearization controller and a PI controller for stabilizing the feedback linearization controller. The feedback linearization controller consists of a neural network model and an inverting module which uses the neural network model for computing the control input to the steam generator. We chose Piecewise Linearly Trained Network(PLTN) and Recurrent Neural Network(RNN) for an approximator of the plant, and used these approximators in calculating the input from the feedback linearization controller. Combining the above two controllers gives a result of better performance than the case which uses only a PI controller. Each control result of PLTN and RNN is given.

Keywords : steam generator, neural network modeling, intelligent control

I. 서론

원자력 발전소의 운전 중 발생되는 강제 운전 정지의 근본 목적은 발전소의 상태가 안전을 고려한 제반 설계조건 또는 원전 조건에서 벗어남을 방지하여 플랜트의 안전성을 지키고자 함에 있고 따라서 모든 강제 운전 정지 신호는 원자로 보호계통으로부터 발생된다. 원자로 보호계통의 기능은 설계 안전 기준에서 벗어났을 때의 원자로 보호와 발전소 기기의 보호이다. 그러나, 이런 기능을 가진 강제 운전정지가 자주 발생하게 되면 발전소 가동율을 저하시킴에 따라 경제성에 큰 영향을 미치게 됨은 물론 발전소에 과도 현상을 야기시키게 됨으로써 주요 기기의 손상과 함께 ATW(Anticipated Transient Without Scram)와 같은 중대 안전사고와도 연결될 가능성을 배제할 수 없게 되며, 결국은 강제 정지의 본래 목적과 상충하게 된다. 한편, 강제 정지에 대한 통계를 살펴보면, 가동시 저수위에 의한 원자로 정지가 전체의 39%로서 가장 큰 비중을 차지하고 있다. 이와 같은 현상은 세계 각국에서 공통적인 경향을 보이고 있으며, 특히 증기발생기의 수위에 의한 강제정지는 발전소 기동과 같은 저출력 시 spurious trip의 커다란 원인이 되고 있다.

이와 같이 원자력 발전소에서 증기 발생기가 원자로 강제 정지의 큰 원인 중 하나가 되고 있는 것은 원자로 기동시와 같은 저출력 영역에서 소위 shrink 및 swell 현상이라는 증기발생기 고유의 열수력학적 특성에 의해 수위의 제어가 곤란해지기 때문이다. 이 현상은 원자력 발전소의 증기발생기 뿐만 아니라 화력발전소의 보일러 드럼과 같은

모든 형태의 열 교환기에서 공통적으로 발생되고 있는 현상이며, 증기발생기에 입력되는 증기량, 급수량, 급수온도, 1차축 냉각제 온도 및 기타 열수력학적 인자들이 복합적으로 작용하여 나타난다. 특히 수위의 입수량에 대한 비최소 위상적 특성을 나타나게 하는 중요한 요인인 되고 있다. 가령 운전원이 급수량을 증가시켜 증기발생기의 수위를 높이고자 할 때 수위의 초기 반응은 오히려 떨어지는 것으로 나타나며, 계속적으로 급수량을 증가시키면 이 현상은 더욱 심해진다. 급수의 계속적인 증가는 증기 발생기 내부의 균형을 깨뜨리게 되고 계속하여 급수량을 늘리면 결국에는 수위가 증가하게 되며 이에 따라 터빈 정지와 원자로 정지가 일어나게 된다.

이와 같은 현상이 특히 문제가 되는 때는 원자로 가동을 시작할 때이다. 이 때에는 증기 발생기의 수위 조절을 위해 들어가는 급수가 차가운 온도 상태에 있으나 증기 발생기 내부의 수온은 원자로에 의하여 높은 온도에 있으므로 입수와 큰 온도차를 갖게 된다. 따라서 이 온도차에 의해 발생하는 증기 발생기 내부 상태의 불안정은 증기발생기를 쉽게 제어하기 힘든 상태로 만든다. 일정 시간이 지나 원자로의 출력이 최고 출력의 약 20%를 넘어서게 되면 출력을 위해 사용되는 열량의 일부가 급수를 데워서 어느 정도 뜨거운 물이 된 후 증기 발생기에 제공되므로 이 후에는 위와 같은 문제가 상대적으로 적게 되며 따라서 증기발생기 내부의 제어는 어렵지 않게 된다.

이상과 같은 증기발생기 자체의 열수력학적 특성 이외에 발전소 가동시 수위제어가 곤란한 또 다른 이유는 급수계통의 기계적 문제 및 control scheme이다. 저유량인 경우 밸브(valve) 및 구동기(actuator)의 특성이 정확하지 않으며, 구동기의 히스테리시스(hysteresis) 등에 의해 발생되는 시간지연은 급수계통의 제어에 불안정을 야기한다. 특히 일정 출력을 기준으로 bypass regulation valve에서

접수일자 : 1999. 7. 12., 수정완료 : 1999. 11. 2.

김성수, 이재기, 최진영 : 서울대학교 전기공학부

* 본 논문은 한국전력공사의 지원에 의하여 기초전력공학공동연구소의 주관으로 수행되었음

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 발전되어 왔기 때문에 이상과 같이 비선형성이 강하고 복잡한 증기 발생기의 제어에는 한계가 있다. 단순히 조정(regulation) 문제라면 특정 동작점에서 동작하게 하므로, 그 동작점 근처에서 선형화된 모델을 사용하면 선형제어기로도 충분한 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 커질 경우 시스템이 불안정해 질 수 있다.

이러한 비모델 동력학은 선형시스템 관점에서 보면 불확실성(uncertainty)으로 간주된다. 이에 대처하는 제어 기법으로 자기동조 제어기(self_tuning regulator), 기준모델 적응제어(model reference adaptive control), 적응 예측제어, 자동동조 PID등의 적용제어 기법과 장인제어 기법등이 있다. 그러나 이러한 기법도 제한된 불확실성 내에서 적용가능하며 비선형성이 강하거나 동작점의 범위가 넓은 경우는 또 다른 대책을 강구해야 한다. 이런 경우에 대한 제어 방법으로는 동작점 별로 따로따로 제어기를 설계하고 동작점 변동에 따라 제어기를 교체하는 개념인 개인 스케줄링[8]이 있다.

한편 비선형제어 접근 방법으로 케환선형화, 가변구조 제어등의 기법이 있으며 이들은 특정조건하의 비선형 동적 모델을 알고 있는 경우 제어 가능할 개념들이다. 그러나, 실제로 복잡한 비선형 시스템의 정확한 모델을 구한다는 것은 어려우며, 모델을 수학적으로 구하는 것 자체가 설계 비용이 많이 드는 작업이다.

시변 특성, 부정확한 모델링등에 대한 대처방법은 실시간 적응보상(adaptive compensation)을 필요로 한다. 또한 모르는 시스템을 모델링하기 위해 비선형 시스템의 식별(system identification) 기법 역시 필요하다. 이때 임의의 비선형 시스템을 식별하기 위해서는 범용 함수 근사자(universal function approximator)가 사용되며 신경회로망이 범용 근사자로서의 역할을 할 수 있음이 밝혀져 있다.

범용 근사자로서의 신경회로망을 제어에 사용한 예로는 최소편차 제어, 예측 뉴로제어, 되먹임 오차 학습제어, 강화 학습제어, 자동조정 되먹임 뉴로제어, 모델기준 적응 뉴로제어, 근사 케환선형화 제어, 내부 모델 제어[2] 등이 있다.

본 연구에서는 범용 근사자로서의 신경회로망을 사용하여 복잡한 증기발생기 모델에 대한 모델링[4]과 이를 이용한 새로운 제어기법을 소개한다.

본 논문의 구성은 다음과 같다. 2절에서는 본 논문에서 학습 및 시험을 위한 데이터 수집에 이용한 증기발생기의 열수력학적 모델에 대해서 간단히 설명하고, 3절에서는 훈련에 사용된 신경망과 신경회로망의 입출력에 대한 정의 및 훈련결과를 보여준다. 4절에서는 3절에서 만들어진 신경회로망을 이용한 모델을 사용하여 제어기를 설계한다.

이 제어기를 사용한 수위제어의 결과를 5절에서 보여주며 6절에서 토의 및 결론을 맺는다.

II. 증기발생기의 열수력학적 모델

증기발생기는 원자로에서 가열된 물을 얇은 판을 통과시키면서 열에너지를 흡수하여 터빈에 증기를 공급하여주는 역할과 원자로를 냉각시키는 역할을 한다.

필요한 전력에 대해서 터빈을 돌리는데 필요한 증기량이 결정되고, 증기량의 변화에 따라 수위가 변하게 되는데, 수위는 일반적으로 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. 증기 발생기의 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.

연구에서 검토된 모델들 [5],[6],[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 한다.

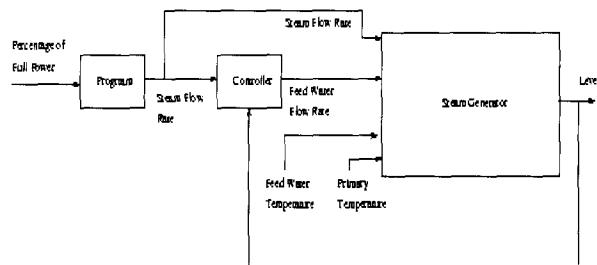


그림 1. 증기발생기의 입력과 출력.

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

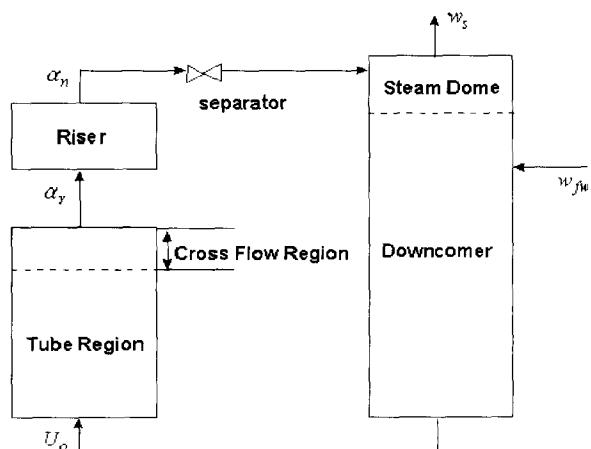


그림 2. 수정된 4-node 증기발생기 모델.

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 1 개의 momentum 평형방정식을 적용시키면, (1)과 같이 정리된다.

$$A \frac{d}{dt} \Phi = B,$$

$$\Phi = \begin{bmatrix} U_0 \\ V_v \\ \alpha_r \\ \alpha_u \\ p \\ W \end{bmatrix}$$

$$B = \begin{bmatrix} \bar{W}(h_o - h_r) + Q_b \\ \bar{W}(h_r - H_n) \\ \bar{W}(h_u - H_d) - w_s(h_g - H_k) \\ w_{fw}(h_{fw} - H_d) - \bar{W}(h_o - H_k) \\ w_{fw} - w_s \\ -F \end{bmatrix} \quad (1)$$

행렬 Φ 는 기본변수들로 이루어져 있는데, 각각 downcomer 출구의 내부에너지(U_0), steam dome에서 증기의 부피(V_v), riser의 입구쪽 void fraction(α_r), 출구쪽 void fraction(α_u), steam dome 내부의 압력(p), 연속적으로 돌아가는 유체의 평균 흐름율(\bar{W})을 나타낸다. 이 기본 변수들이 결국 위 식의 출현이 되어 나타나는데, 우리가 관심이 있는 출력인 수위 L_w 가 직접 나타나지 않으며, 수위는 기본 변수들과 steam dome의 기하학적 구조에 의해 결정된다. steam dome의 기하학적 구조는 각각의 증기 발생기에 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 것이다. 그 외 1차측 냉각제 온도(T_{pon}), 급수온도(T_{fw})는 일차측에서 이차측으로 넘어가는 열에너지(Q_b)에 직접 영향을 준다. h_o 는 downcomer에서 tube영역까지의 흐름율에 대한 엔탈피, h_r 은 tube영역에서 riser까지의 흐름율에 대한 엔탈피, h_u 은 riser출구 쪽의 흐름율에 대한 엔탈피, h_{fw} 는 급수량에 대한 엔탈피를 각각 의미하며 F 는 이운준모델[6]에서 사용된 평형방정식에서의 force를 의미한다.

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, 실현을 통해서 얻을 수밖에 없는 계수들을 사용하고, 상황에 따른 계수들의 불연속적인 변화 등이 나타

나고 있으며, 프로세서 모델 자체가 제어기 설계에 유용하지 않음을 알 수 있다.

III. 신경회로망을 이용한 증기발생기의 모델링

1. 비선형시스템의 신경회로망 모델링[4]

Narendra[8]에 의하면 비선형 시스템을 아래와 같이 제시하고 있다.

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

위 모델에 적용가능한 신경회로망 모델은 크게 두 가지로 나눌 수 있는데, 하나는 병렬식별 모델이고, 또 하나는 직병렬식별 모델이다. 병렬식별 모델에 위 모델을 적용할 경우

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

와 같이 출력의 과거값을 플랜트에서 얻는 것이 아니라, 식별 모델로부터 얻는 것이고, 직병렬식별 모델은

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

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

2. 증기발생기의 안정화

증기발생기의 열수력학적 모델의 수위는 개루우프에서 급수량과 증기량에 대하여 비최소위상 특성을 갖는다. 급수온도와 1차측 냉각제의 온도의 경우 일정시간이 지난 후에는 안정화되어 수위에 영향을 주지 않고 정상상태 오차만을 가지므로 전체적인 수위의 불안정성과는 직접적인 관련이 없다. 따라서 증기발생기의 불안정성에 관계된 두 개의 입력은 증기량과 급수량이며 이에 대한 수위의 변화는 그림 3에 나타나있다.

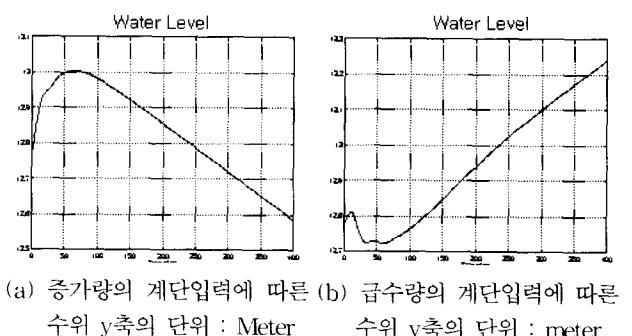


그림 3. 증기량과 급수량의 계단 입력에 따른 수위 변화.

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

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 하므로써 적분기의 효과로 수위와 기준 수위간의 오차를 없애고, 동시에 증기가 되어 증기발생기에 빠져나가는 양과 급수량으로 증기발생기에 공급되는 양을 같게 하는 효과를 동시에 볼 수 있게된다.

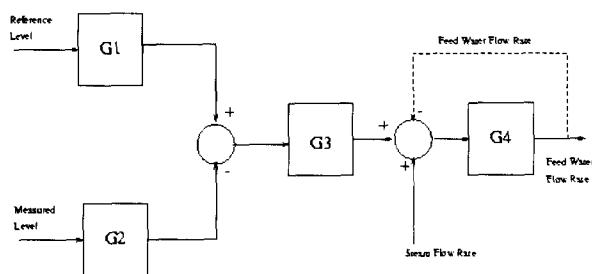


그림 4. 증기발생기의 수위 제어.

Fig. 4. Water level control in steam generator.

그림 4에서처럼 현재 이용되고 있는 제어기를 안정화를 위한 제어기로 사용한다. 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. 각 제어기는 간단한 PI 제어기를 사용하는데, 아래와 같은 식으로 구한다[5].

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

위의 제어기를 사용했을 때 각각의 이득값은 실험적으로 구한다.

3. 신경회로망 모델링을 위한 증기발생기의 입출력 모형

(1)의 증기발생기 상태공간 모델을 이산시간 입출력 시스템으로 표시하면,

$$\begin{aligned} L_w(k) = f & (L_w(k-1), L_w(k-2), \dots, L_w(k-n), \\ & w_s(k-d), w_s(k-d-1), \dots, w_s(k-n), \\ & w_{fw}(k-d), w_{fw}(k-d-1), \dots, w_{fw}(k-n), \\ & T_{pn}(k-d), T_{pn}(k-d-1), \dots, T_{pn}(k-n), \\ & T_{fw}(k-d), T_{fw}(k-d-1), \dots, T_{fw}(k-n)) \end{aligned}$$

와 같다. 여기서 d 는 상대차수를 나타내며, n 은 시스템의 차수를 나타낸다. 위 식에서 증기발생기는 4개의 입력외란인 ($w_s, w_{fw}, T_{pn}, T_{fw}$)과, 1개의 출력을 갖는 함수 식으로 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 입출력 관계를 신경회로망을 통해서 표현하는 것이 목표이므로, 입력 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

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

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

4.1 부분선형학습 신경회로망

부분선형학습 신경회로망(Piecewise Linearly Trained Network, PLTN)은 입력공간을 국부영역으로 분할하고, 이 국부영역에서 선형사상을 나타내도록 하는 모듈형 신경회로망의 하나이다[9]. 이 신경회로망은 범용 근사자로 함수 f 를 임의의 정확도를 갖도록 근사화할 수 있다[9]. PLTN에 의해 근사화된 함수 \hat{f} 는 다음과 같이 표현된다.

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

여기서, $|x - c_i|$ 는 입력 x 와 방사형 기저함수 $\mu_i(x)$ 의 중심점 c_i 간의 유clidean 거리를 의미하며, b 은 은닉층의 전체 유닛 개수이다. γ 는 국부영역의 크기를 결정하는 경쟁 변수이다.

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.

4.2 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. 그러나, 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].

$$\begin{aligned}\hat{x} &= D_c \hat{x} + A_c T(\hat{x}) + B_c u \\ \hat{y} &= C_c \hat{x} + \text{Bias} \\ T(\hat{x}) &= [\tanh(\hat{x}_1), \dots, \tanh(\hat{x}_n)]^T\end{aligned}\quad (2)$$

이산시간 형태의 회귀 신경회로망은 (3)과 같이 나타낼 수 있다.

$$\begin{aligned}\hat{x}(k+1) &= D \hat{x}(k) + A T(\hat{x}(k)) + B u(k) \\ \hat{y}(k) &= C \hat{x}(k) + \text{Bias}\end{aligned}\quad (3)$$

이상의 신경회로망 구조에 대한 학습 알고리듬은 연속 시간 형태에서와 같은 방법을 A, B, C 의 각 원소에 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 률을 적용시켜 보면 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. $\frac{\partial x_i}{\partial a_i}(k)$ 와 $\frac{\partial x_i}{\partial b_{ij}}(k)$ 는 (3) 을 미분하면 얻을 수 있으며, 정리해보면,

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

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

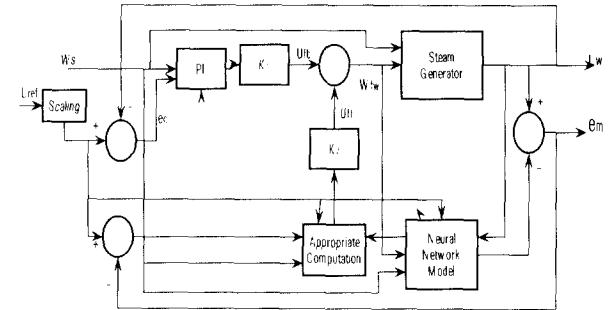


그림 5. 전체적인 수위제어기의 구조.

Fig. 5. Overall structure of water-level controller.

IV. 증기 발생기의 지능제어기 설계

1. 전체적인 구조

기존의 일반적인 신경회로망 제어기[2]는 비최소위상 시스템에는 적용할 수가 없다. 이러한 제어기는 기본적으로 시스템의 역모델에 기반하기 때문이다. 따라서 본 연구에서는 이를 극복하기 위해 신경망 제어기와 기존의 PI 제어기를 혼용하는 다음의 방법을 제안한다. 이 구조는 기본의 PI 제어기를 유지하면서 신경회로망 제어기가 성능을 향상시키도록 하는 구조이다. 이 제안된 방법에 의해 비최소위상 특성이 강한 저출력인 경우에 대해 성능향상이 이루어짐을 확인하였다.

본 연구에서 제안하는 제어기는 그림 5와 같이 신경회로망을 이용하는 앞먹임(feedforward)제어기와 되먹임(feedback) PI 제어기로 구성된다. 제어기의 출력은 플랜트의 입력인 급수량 $u (= W_{fe})$ 가 되며, 아래와 같이 신경회로망 제어기 신호와 PI 제어기 신호를 더한 값으로 정한다.

$$u = u_{fb} + u_{ff}$$

u_{fb}	: 되먹임 PI 제어기의 출력
u_{ff}	: 신경회로망 앞먹임 제어기의 출력

2. 되먹임 PI 제어기

되먹임 제어기 설계시 정상상태(steady state)에서의 제어입력이 w_s 이 되어야 한다. 즉, 증기발생기 수위 제어의 특성상 제어 입력이

$$u = w_s = u_{fb,s} + u_{ff,s}$$

$u_{fb,s}$: 되먹임 제어기의 정상상태에서의 출력값
$u_{ff,s}$: 앞먹임 제어기의 정상상태에서의 출력값

와 같이 되어야 한다. 그러나 이와 같이 단순히 더할 경우 다음과 같은 문제가 발생한다. 즉, 제각기 설계된 앞먹임 PI 제어기와 되먹임 신경망 제어기의 출력은 정상상태에서 모두 w_s 와 같아서 위와 같은 식을 적용할 경우 $2w_s$ 의 입력이 들어가게 되어 발산한다. 따라서 본 연구에서는, 두 입력이 정상상태에서 w_s 의 상수배 이어야 하는 사실을 이용하여 $u_{fb,s} = K_1 w_s$, $u_{ff,s} = K_2 w_s$, $K_1 + K_2 = 1$ 와 같은 방법을 사용하였다.

2.1 고출력의 경우

일반적인 증기발생기에서 사용하는 고출력에서의 PI 제어기는 그림 6과 같으며, $G_1 = a + \frac{b}{s}$, $G_2 = c + \frac{d}{s}$ 이다.

그러나, 앞서 말했듯이 본 연구에서 사용하는 제어기에는 K_1, K_2 가 추가되므로 w_{fw} 의 되먹임 위치를 어디에서 하느냐에 따라 두 가지 경우가 존재하게 된다. 우선 그림 7과 같이 할 수 있다.

그림 7에서와 같이 정상상태 이득(steady state gain)을 주게 되면 입력 측 외란과 출력 오차에 대한 제어 입력의 전달 방정식은 (4)와 같이 되어 steady state에서의 이득값은 맞출 수 있다.

$$u_{fb} = \frac{K_1 G_2 G_1}{1 + G_2} e_c + \frac{K_1 G_2}{1 + G_2} w_s \quad (4)$$

그러나 이 방법을 사용하게 되면 신경회로망 제어기의 출력(u_{ff})이 직접 플랜트로 들어가게 되므로 불안정한 상황을 발생시킬 수 있다.

또한 그림 8와 같이 되먹임을 할 수 있는데 이 경우에는 제어 입력의 전달 방정식이 (5)와 같이 된다.

$$\begin{aligned} u_{fb} &= \frac{K_1 G_2 G_1}{1 + K_1 G_2} e_c + \frac{K_1 G_2}{1 + K_1 G_2} w_s \\ &\quad - \frac{K_1 K_2 G_2}{1 + K_1 G_2} u_{ff} \end{aligned} \quad (5)$$

이 경우에는 그림 7의 방법과는 달리 PI제어기의 제어 입력(u_{fb})뿐만 아니라 신경회로망 제어기의 입력(u_{ff})도 되먹임이 되기 때문에 신경회로망 제어기가 직접적으로 플랜트를 조절하는 일이 발생하지 않게 된다. 따라서 상대적으로 안정적인 제어 성능을 얻을 수 있다.

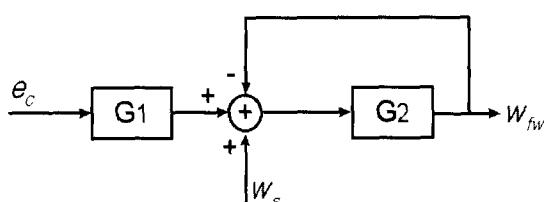


그림 6. 고출력에서 PI 제어기 구조.

Fig. 6. Structure of PI controller at high power.

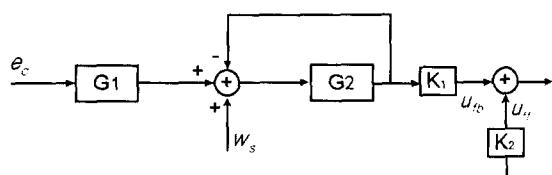


그림 7. 고출력에서 되먹임 제어기와 앞먹임 제어기를 분리할 경우.

Fig. 7. First case of feedback at high power.

2.2 저출력의 경우

원래의 플랜트에서 사용하는 저출력의 PI제어기는 그림

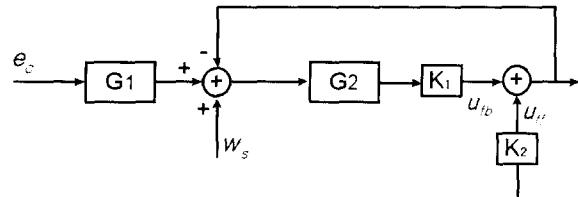


그림 8. 고출력에서 되먹임 및 앞먹임 제어기가 결합된 형태.

Fig. 8. Second case of feedback at high power.

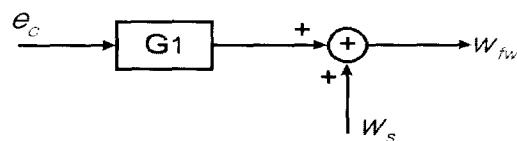


그림 9. 저출력에서 PI 제어기 구조.

Fig. 9. Structure of PI controller at low power.

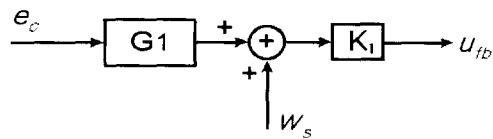


그림 10. 저출력에서 PI 제어기를 플랜트에 적용한 모습.

Fig. 10. Method of feedback at low power.

6와 같다. 그러나 고출력의 경우와는 달리 증기량의 값이 작고, 고출력에 비해 정확하지 못하다. 따라서 G_2 갖는 의미가 거의 없기 때문에 그림 9과 같은 제어기를 이용하였다.

따라서 제어 입력에 대한 되먹임이 없으므로 그림 10과 같은 방법으로 u_{fb} 를 구한다. 이 때, 정상 상태에서의 이득값은 아래 식과 같다.

$$u_{fb} = K_1 w_s + K_1 \left(a + \frac{b}{s} \right) e_c$$

3. 앞먹임 신경회로망 제어기

본 연구의 신경회로망 제어기는 기본적으로 근사 케환 선형화 기법을 기반으로 제시된다. 이때 플랜트의 역모델을 이용하게 된다. 이 역모델은 앞에서 제시된 프랜트의 신경회로망 모델을 이용하여 구할 수 있다.

3.1 부분선형학습신경회로망 (PLTN)을 이용한 신경회로망 제어기

신경회로망 모델링은 역함수를 구하기 용이하게 하기 위해 유사 비선형 모델(affine nonlinear model)로 모델링하였다. 따라서 증기발생기의 비선형 모델은

$$y(k+1) = f(y(k), \dots, y(k-n); u(k), \dots, u(k-n))$$

의 형태에서

$$\begin{aligned} y(k+1) &= f_1(y(k), \dots, y(k-n); u(k-1), \dots, u(k-n)) \\ &\quad + f_2(y(k), \dots, y(k-n); u(k-1), \dots, u(k-n))u(k) \end{aligned}$$

의 형태로 바꾸어 쓸 수 있다. 따라서 증기발생기의 신경회로망 모델은

$$\begin{aligned} \hat{y}(k+1) &= \hat{f}_1(x(k)) + \hat{f}_2(x(k))u(k), \\ x(k)^T &\equiv [y(k), \dots, y(k-n); u(k-1), \dots, u(k-n)] \end{aligned}$$

와 같이 둘 수 있다.

PLTN 모델인 경우 다시 써보면,

$$\begin{aligned} \hat{y}(k+1) &= \sum_{j=1}^M \overline{\mu_j}(x(k))(w_j^T x(k) + \alpha_j u(k) + b_j) \\ &= \sum_{j=1}^M \overline{\mu_j}(x(k))(w_j^T x(k) + b_j) \\ &\quad + \sum_{j=1}^M \overline{\mu_j}(x(k))\alpha_j u(k). \quad (6) \\ \overline{\mu_j}(x(k)) &= \frac{\mu_j(x(k))}{\sum_{i=1}^M \mu_i(x(k))} \end{aligned}$$

이 된다. 여기서 주의할 점은 지역화할 때 $[x(k)u(k)]$ 를 이용한 것이 아니라 $x(k)$ 만 이용한다는 것이다. (6)에서

$$\begin{aligned} z(k) &\equiv \sum_{j=1}^M \overline{\mu_j}(x(k))(w_j^T x(k) + b_j) \\ \alpha(k) &\equiv \sum_{j=1}^M \overline{\mu_j}(x(k))\alpha_j \end{aligned}$$

와 같이 정의하면,

$$\hat{y}(k+1) = z(k) + \alpha(k)u(k) \quad (7)$$

로 나타난다. 제어 입력을

$$u(k) = -\frac{1}{\alpha(k)}(z(k) - y_p(k+1))$$

라고 하면, (7)은 $\hat{y}(k+1) = y_p(k+1)$ 가 된다.

만약 잘 예측되었다면, 즉 $|\hat{y}(k+1) - y_p(k+1)| < \epsilon$ 이면,

$$\begin{aligned} |y_p(k+1) - y_p(k+1)| &= |y_p(k+1) - \hat{y}(k+1)| \\ &\quad + |\hat{y}(k+1) - y_p(k+1)| \\ &< |y_p(k+1) - \hat{y}(k+1)| \\ &\quad + |\hat{y}(k+1) - y_p(k+1)| \\ &< \epsilon \end{aligned}$$

와 같이 되어 시간이 지남에 따라 $y_p(k) \rightarrow y_p(k)$ 가 된다. 이는 최소편차 제어기법에 기반한 것이 된다. 그러나 시스템의 응답지연시간이 있으므로 기준 명령을 그대로 추종하는 것은 불가능하며 오히려 성능을 저하 시킬 수 있다. 따라서 다음과 같이 기준모델을 따라가도록 제어기를 설계한다. 즉 제어 입력을

$$u(k) = -\frac{1}{\alpha(k)}(z(k) - v(k))$$

로 두면, $\hat{y}(k+1) = v(k)$ 이다. 여기서,

$$\begin{aligned} v(k) &\equiv y_p(k+1) - \rho_0(\hat{y}(k) - y_p(k)) \\ &\quad - \rho_1(\hat{y}(k-1) - y_p(k-1)) \\ &\quad - \cdots - \rho_m(\hat{y}(k-m) - y_p(k-m)) \end{aligned}$$

이고 $\hat{e}_c(k-i) \equiv \hat{y}(k-i) - y_p(k-i)$ 라고 정의하면,

$$\hat{e}_c(k+1) + \rho_0 \hat{e}_c(k) + \cdots + \rho_m \hat{e}_c(k-m) = 0$$

이다. 이 특성방정식은 근을 $m+1$ 개를 갖게된다. 이 근들이 모두 단위원 내에 있도록 $\rho_i, i=0, \dots, m$ 를 조절하게 되면, $\hat{e}_c(k)$ 는 시간이 지남에 따라 0이 된다. 여기서 $\rho_i, i=0, \dots, m$ 를 일반적으로 구할 수 있는 방법이 없다. 따라서 많은 실험을 통해 경험적으로 구할 수밖에 없는 단점이 있다. 만약 $\alpha(k) \rightarrow 0$ 이면, $u(k)$ 를 구하는 것이 불가능해진다. 이를 방지하기 위해 본 연구에서는 다음과 같은 방법을 사용하였다.

$$\begin{aligned} \alpha(k) &= \bar{\alpha} & \text{if } -\frac{1}{\alpha} \leq \alpha(k) < \bar{\alpha} \\ \alpha(k) &= -\bar{\alpha} & \text{if } -\bar{\alpha} < \alpha(k) < 0 \end{aligned}$$

여기서, $\bar{\alpha}$ 는 지나치게 작지 않은 양의 값을 취한다. 이러한 방법을 사용하면 신경회로망의 과도기에 발생할 수 있는 신경회로망 제어 입력 값의 발산을 방지할 수 있다.

3.2 회귀 신경회로망 (RNN)

증기발생기 모델을 회귀 신경회로망 모델로 표현하면 다음식과 같이 된다.

$$\begin{aligned} x(k+1) &= Dx(k) + AT(x(k)) + B_1 u_1(k) \\ &\quad + B_2 u_2(k) \quad (8) \\ \hat{y}(k) &= Cx(k) + d \end{aligned}$$

여기서 시스템 식별 시에는 입력 u 를 4×1 벡터를 이용하였는데, 실제로 조작 가능한 입력은 1 개이고, 나머지 3 개는 입력 측에서의 외란에 해당한다. 회귀 신경회로망의 내부 state 수를 n 개라고 할 때 각각의 행렬과 벡터의 차수는 아래와 같이 나타난다.

$$\begin{aligned} D &\in R^{n \times n}, A \in R^{n \times n}, B_1 \in R^{n \times 1}, B_2 \in R^{n \times 3}, \\ u_1 &\in R, u_2 \in R^{3 \times 1}, T: R^{n \times 1} \rightarrow R^{n \times 1}, \end{aligned}$$

(8)은

$$\begin{aligned} \hat{y}(k+1) &= Cx(k+1) + d \\ &= CDx(k) + CAT(x(k)) \\ &\quad + CB_1 u_1(k) + CB_2 u_2(k) \end{aligned}$$

와 같이 쓸 수 있고,

$$\begin{aligned} u_1(k) &\equiv -\frac{1}{CB_1} [CDx(k) + CAT(x(k)) \\ &\quad + CB_2 u_2(k) - v(k)] \end{aligned}$$

라고 두면, $\hat{y}(k+1) = v(k)$ 가 된다. PLTN을 이용한 제어에서와 마찬가지로

$$\begin{aligned} v(k) &= y_r(k+1) - \rho_0(\hat{y}(k) - y_r(k)) \\ &\quad - \rho_1(\hat{y}(k-1) - y_r(k-1)) \\ &\quad - \cdots - \rho_m(\hat{y}(k-m) - y_r(k-m)) \end{aligned}$$

라고 두고, $\hat{e}_c(k-i) = \hat{y}(k-i) - y_r(k-i)$ 로 정의하면,

$$\hat{e}_c(k+1) + \rho_0 \hat{e}_c(k) + \cdots + \rho_m \hat{e}_c(k-m) = 0$$

이다. 이 특성방정식은 근을 $m+1$ 개를 갖게된다. 이 근들이 모두 단위원 내에 있도록 $\rho_i, i=0, \dots, m$ 를 조절하게 되면, $\hat{e}_c(k)$ 는 시간이 지남에 따라 0이 된다. 즉

$$\exists N \text{ such that } |\hat{y}(k) - y_r(k)| < \frac{\varepsilon}{2}, \quad \varepsilon > 0, \forall k > N$$

이다. 또한 시스템 식별의 결과 충분히 좋다면, $|\hat{y}(k) - y_p(k)| < \frac{\varepsilon}{2}$ 이다. 따라서

$$\begin{aligned} |y_p(k+1) - y_r(k+1)| &= |y_p(k+1) - \hat{y}(k+1) \\ &\quad + \hat{y}(k+1) - y_r(k+1)| \\ &< |y_p(k+1) - \hat{y}(k+1)| \\ &\quad + |\hat{y}(k+1) - y_r(k+1)| \\ &< \varepsilon \end{aligned}$$

이므로, 시간이 지나면, $y_p(k)$ 가 $y_r(k)$ 를 추종하게 된다.

그러나, PLTN의 경우와 마찬가지로 $\rho_i, i=0, \dots, m$ 를 일반적으로 구할 수 있는 방법이 없다. 따라서 PLTN에서처럼 많은 실험을 통해 경험적으로 구할 수밖에 없다.

V. 모의 실험

1. 모의실험의 개요

본 절에서는 증기발생기의 모의 실험 방법을 설명한다. 특히 모의실험시에 영향을 미친 여러 요소들과 제한사항들에 대한 설명을 한 후, 모의실험의 진행 순서와 방법을 설명한다.

1.1 모의실험에 영향을 미친 여러 요소들과 제한사항들 우선 제어에 관련된 요소로서 모의실험에 영향을 준 것들은 기준 모델 적용 뉴로제어에서 사용하는 오차 동력학(error dynamics)의 pole의 위치, error dynamics의 차수, PI제어시 feedback의 위치, PI제어기와 신경회로망 제어기의 제어입력 비율이 있으며, 신경회로망 제어기의 구현과 관련된 요소로서는 PLTN과 RNN 중 무엇을 선택할 것인가와 실시간 적응(online adaptation)을 사용할 것인가의 두 가지가 있다.

우선 실험과정에서 error dynamics의 pole의 위치와 차수는 고정되어있다. 현재까지는 pole의 위치와 차수를 구하는 일반적 방법이 제시되어 있지 않은 상황이기 때문에 차수는 이윤준의 모델을 사용하여 4차로 지정하였다. 2개의

pole을 dominant pole로 삼아서 고전 제어기법을 사용하여 위치를 배정한 후 나머지 2개의 pole은 큰 영향을 주지 않는 곳에 배치하는 방법을 사용하였다. 아래의 결과들에서 저출력과 고출력의 error dynamics의 pole 위치는 각각 고정되어있다. 다음으로 feedback의 위치는 본문에서 언급한 안정성 문제 때문에 그림 8과 같은 경우로만 한정하였다. 또, PLTN은 실시간 적응을 사용하지 않았고 RNN은 사용했다. 그 이유는 신경회로망을 충분히 학습시켰을 경우 PLTN은 실시간 적응(online adaptation)을 하면서 제어한 것과 오프라인 적응(offline adaptation)을 하지 않으며 제어한 것에는 거의 차이가 없으나 RNN은 실시간 적응을 사용하여야 더 나은 모델링 결과를 나타내기 때문이다 [4]. 실험은 저출력(최대 출력의 20% 미만)과 고출력으로 나누어서 실험하였으나 실제상황에서 문제가 되는 영역은 저출력 부분이므로 여기서는 저출력 부분만 언급하겠다. 이 때 PLTN의 경우 PI제어기의 제어입력 비율이 0.2일 때, RNN을 사용할 경우에는 0.3일 때 안정적인 최적의 성능을 보여주는 것으로 나타났다. 이보다 더 적은 비율로 PI제어기를 사용하면 몇 가지 입력에 대해서는 더 나은 성능을 보여주지만 매우 급격한 신호가 들어올 경우 드물지만 발산하는 경우가 있었다. 따라서 본 실험에서는 위의 수치를 사용하였으며 실험에 사용된 표본추출 시간간격은 0.1초이다.

1.2 모의실험의 순서와 방법

저출력에서의 제어성능을 실험하였다. 실험은 원하는 출력을 다양하게 변화시키면서 이를 외란으로 가정하여 원하는 수위를 제대로 제어해 내는지에 대한 실험을 하였다. 이는 원하는 수위는 (L_{ref})는 고정되어 있기 때문이다. 가장 먼저 계단함수를 사용한 결과를 보여준다. 실제 원자력 발전소의 운영에 계단 함수를 사용하는 일은 거의 없지만 계단입력에 대한 출력이 시스템의 응답특성을 잘 나타내기 때문에 이에 대한 시스템의 반응을 알아보는 실험을 진행하였다. 계단입력을 사용할 때에는 여러 가지 크기의 변화를 다양하게 실험해 보았다. 여기서는 그 실험 결과들을 압축적으로 보여주기 위하여 연속적인 계단함수를 사용하여 하나의 그래프에 담았다.

다음으로 선형증가 함수 입력에 대한 결과를 보여준다. 이는 실제 플랜트에서 주로 사용하는 방법이기 때문에 중요한 데이터가 될 수 있다. 역시 기울기가 다른 여러 값들에 대하여 실험을 진행하였으며 연속적인 계단 입력에 대한 출력을 그래프로 나타내었다. 끝으로 정현파에 대한 응답특성을 조사하였다. 다양한 주파수와 크기에 대하여 실험하였으며 결과에 나타는 그래프는 연속적인 정현파에 대한 응답을 다루고 있다.

그림 11과 같은 연속적인 계단 입력(step input : 그림 11(a))과 선형 입력(ramp input : 그림 11(b)) 끝으로 정현파 입력(sine input : 그림 11(c))에 대해서 제어성능을 평가해 본다(여기서 입력은 원하는 증기량의 변화를 의미한다).

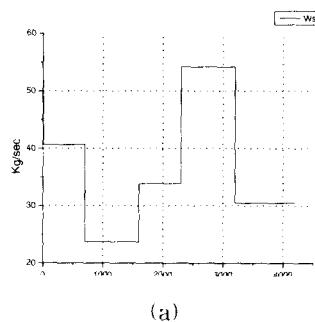
2. 제어성능

계단형 외란(원하는 증기량 입력)에 대한 제어 성능을 살

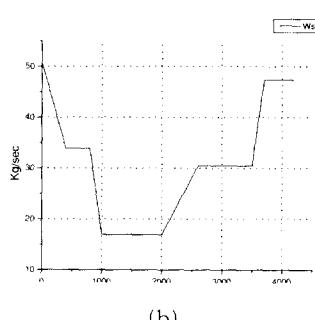
펴보자. 그림 12-(b)를 보면 PI만을 사용한 경우에는 급격한 외란이 들어올 경우 진동을 하는 것을 관찰할 수 있다. 그러나 신경회로망 제어기를 사용한 경우에는 약 80초의 시정수를 갖고 수위가 제어되고 있는 것을 볼 수 있다.(그림 12-(b)) 또한 그림 12-(c)에서 보듯이 출력 전력을 매우 안정적으로 동작하는 것을 볼 수 있다. 실험결과 PI제어기의 비율이 낮으면 낮을수록 수위제어시의 시정수는 커지는 경향을 보였으며, 반대로 출력 전력은 원하는 증기량 입력에 더욱 가깝게 안정정으로 수렴하였다. PI제어기의 입력비율이 15%미만이 될 경우는 입력이 발산하게 되었는데 이는 PI제어기가 신경회로망 제어기의 출력을 더 이상 조절할 만한 능력이 없어졌기 때문으로 분석된다. PLTN과 RNN의 제어성능에는 거의 차이가 없었다.

선형 외란에 대한 성능도 신경회로망 제어기를 사용함으로써 개선되었음을 확인할 수 있다 (그림 13). 특히 기울기가 클 경우 PI제어기는 더 이상 수위를 제어하지 못하고 진동시키게 되지만(그림 13-(b)) 신경회로망을 사용한 경우에는 진동현상이 거의 사라졌다. 기울기가 급격한 경우를 제외하면 신경회로망 제어기와 PI제어기의 제어성능이 비슷하게 나타남도 볼 수 있다. PI제어기가 진동현상을 보이기 시작하는 기울기는 2.5Kg/sec부근으로 나타났다. 특히 감소할 때 진동현상은 심하게 나타났으며 이는 저출력 일수록 비선형성이 더욱 커지기 때문으로 분석된다.

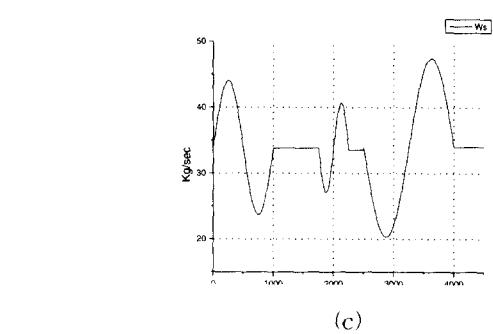
정현파 외란에 대한 제어 성능을 테스트한 결과는 제안된 제어기를 사용한 경우와 PI제어기만을 사용한 경우가 큰 차이 없는 것으로 나타났다. 그러나 기울기가 급격한 부분을 통과할 때에는 PI제어기가 수위제어 측면에서는 더 나은 결과를 나타내었다.(그림 14-(b)) 그러나 이 경우에는 출력 전력의 형태는 신경회로망 제어기를 사용한 경우에 더 나은 성능을 발휘하고 있다. 특히 짧은 주파수를 갖는 외란에 대해서 더 나은 성능을 보인다.(그림 14-(c))



(a)



(b)



(c)

그림 11. 테스트 파형.

Fig. 11. Test Signal.

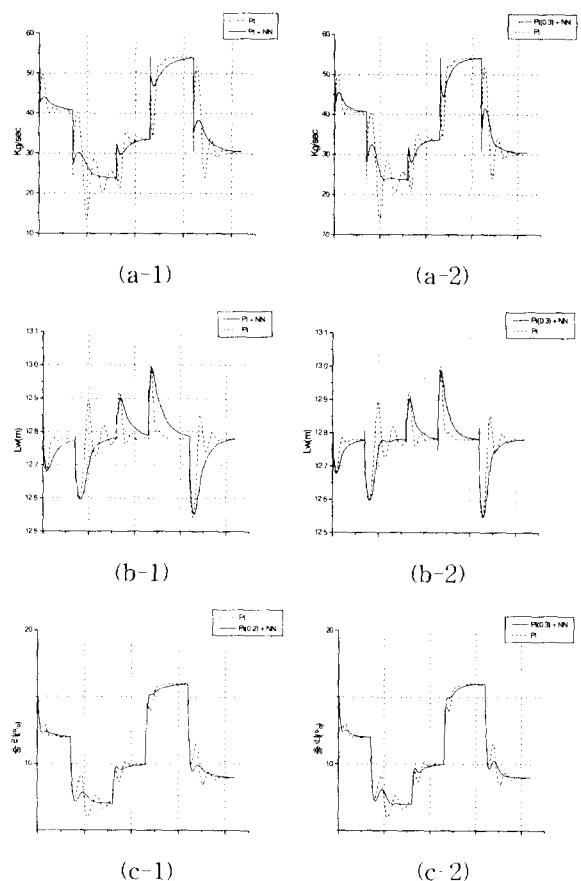


그림 12. 계단 입력. (a)제어입력, (b)수위, (c)출력전력의 최대전력에 대한 백분율. (a-1, b-1,c-1:PLTN, a-2,b-2,c-2:RNN) 점선 : PLTN의 경우 신경망 제어입력이 0.8의 비율일 때이며, RNN의 경우 0.7의 비율일 때.

Fig. 12. Step input. (a)Control input, (b)Water level, (c)Percentage of power, (a-1, b-1,c-1:PLTN, a-2,b-2,c-2:RNN) dot-line:Using only PI controller, solid-line:PLTN case->Input ratio of NN controller is 0.8, RNN case-> 0.7.

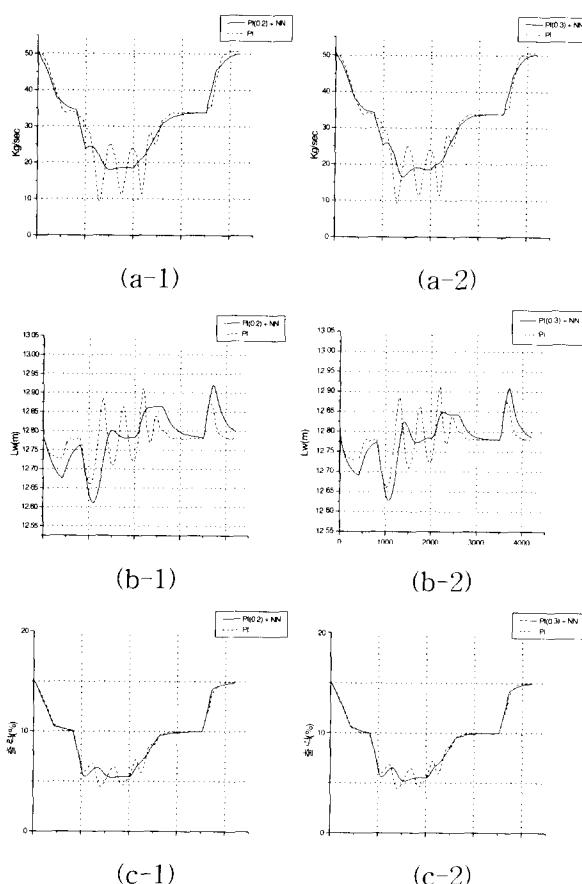


그림 13. 선형 입력. (a)제어입력, (b)수위, (c)출력전력의 최대전력에 대한 백분율. (a-1, b-1, c-1:PLTN, a-2,b-2,c-2:RNN) 점선:PI제어기만을 사용한 경우, 실선 : PLTN의 경우 신경망 제어입력이 0.8의 비율일 때이며, RNN의 경우 0.7의 비율일 때.

Fig. 13. Ramp input. (a)Control input, (b)Water level, (c)Percentage of power, (a-1, b-1, c-1:PLTN, a-2,b-2,c-2:RNN) dot-line: Using only PI controller, solid-line:PLTN case->Input ratio of NN controller is 0.8, RNN case-> 0.7

VI. 결론 및 향후 과제

증기발생기를 열수력학적으로 모델링하였을 때 실제 플랜트와의 오차뿐 아니라, 그 모델 자체가 제어이론을 적용시키기가 곤란하였다. 따라서 현재까지는 주로 플랜트의 입출력 관계를 적당한 선형식으로 나타내어 접근하고 있으나 특히 저출력에서는 비최소위상 특성을 보이며, 많은 모델링 오차를 가지고 있고 계수가 시변 특성을 보이기 때문에 실제 원전에서는 저출력에서는 운전원의 수조작으로 수위를 제어하고 있다.

본 연구에서는 부분선형신경망과 회기신경망을 이용하여 증기발생기를 모델링하고 제어하는 방법을 제시했다. 이들 두 신경망은 역함수를 직접 구할 수 있어 제어기를 바

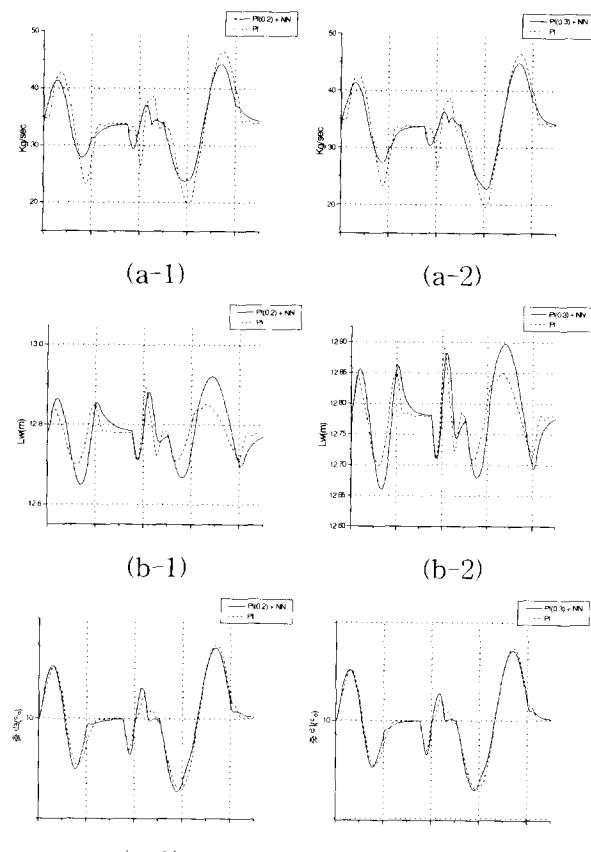


그림 14. 정현파 입력. (a)제어입력, (b)수위, (c)출력전력의 최대전력에 대한 백분율. (a-1, b-1,c-1:PLTN, a-2,b-2,c-2:RNN) 점선:PI제어기만을 사용한 경우, 실선 : PLTN의 경우 신경망 제어입력이 0.8의 비율일 때이며, RNN의 경우 0.7의 비율일 때

Fig. 14. Sine Input. (a)Control Input, (b)Water Level, (c)Percentage of Power, (a-1, b-1, c-1:PLTN, a-2,b-2,c-2:RNN) dot-line: Using only PI controller, solid-line:PLTN case->Input ratio of NN controller is 0.8, RNN case-> 0.7

로 구할 수 있는 장점이 있다. 부분선형신경망은 훈련시간이 짧고 훈련성능이 뛰어나지만 일반화성능이 회기신경망보다 떨어지고 회기신경망의 경우 훈련이 느리다는 단점이 있었으나 충분한 훈련을 한 후에는 모두 비슷한 제어결과를 보여주었다. 또한, 본 연구에서는 안정성을 보장하기 위해서 PI제어기를 병렬로 연결하는 방법을 병행하였다. 제어입력은 PI제어기에서 나온 제어신호와 신경회로망 제어기에서 나오는 제어신호를 일정 비율로 더하여 플랜트를 제어하는 방법을 사용하였다.

본 논문에서는 저출력 영역에서의 제어 성능 향상에 중점을 두었다. 왜냐하면 실제 시스템에서는 저출력에서의 비선형성이 가장 큰 문제가 되며 많은 경우 수조작을 하기

때문이다. 따라서 저출력에서 성능향상을 가져와야 하는 필요가 발생했다. 이에 대해 연구를 진행한 결과 매우 큰 폭으로 성능 향상을 가져왔다. 급격한 변화를 주는 입력에서도 지능제어기는 PI제어기가 보이지 못한 안정성을 보여주었다. 그러나 제안된 방법은 안정성이 증명된 방법은 아니며, PI제어기를 포함한 전체 증기발생기의 안정성 증명에 대한 연구가 더 진행되어야 할 것이다.

참고문헌

- [1] S. K. Menon and A. G. Parlos, "Gain-scheduled nonlinear control of u-tube steam generator water level," *Nuclear Science and Engineering*, 3(111): 294- 308, 1992.
- [2] 최진영, 박현주, "신경회로망을 이용한 시스템 모델링 및 제어" 제어·자동화·시스템공학 학회지, 제1권, 제3호, pp. 62-73, Nov. 1995.
- [3] Riccardo Marino, Patrizio Tomei, Nonlinear Control Design, pp. 35-94, Prentice Hall, 1995.
- [4] 이재기, 최진영, "신경회로망을 이용한 원자력발전소 증기발생기의 모델링" 제어·자동화·시스템공학 논문지, vol. 4, no. 4, Aug., 1998.
- [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, 2월 1991.
- [7] W. H. Strohmayer, "Dynamic modeling of vertical U-tube steam generators for operational safety systems," PhD thesis, MIT, 1982.
- [8] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural network," *IEEE Trans. on Neural Networks*, vol. 1 no.1 pp. 4-27, March., 1990.
- [9] J. Y. Choi and H. J. Park, "Adaptive learning control of affine piecewise linearly trained network," *IEEE International Conference on Neural Networks*, November 1995.
- [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] Ken-Ichi Funahashi and Yuichi Nakamura, "Approximation of dynamical systems by continuous time recurrent neural networks," *Neural Networks*, vol. 6 pp. 801-806, 1993.



김 성 수

1976년 2월 3일생. 1998년 서울대학교 전기공학부 졸업. 관심분야는 신경회로망, 적응제어 및 지능제어.

최 진 영

제어·자동화·시스템공학 논문지 제4권, 제4호, 참조.

이 재 기

제어·자동화·시스템공학 논문지 제4권, 제4호, 참조.