

論文98-35C-8-8

## 다단 신경회로망 예측제어기 개발

### (A Development of Multi-step Neural Network Predictive Controller)

李 權 純 \*

(Kwon Soon Lee)

#### 요 약

보일러는 외부의 요인에 따라 입·출력 유량이 수시로 변하고 제어 입력에 대한 응답시간의 지연이 긴 비선형 시스템이기 때문에 정확한 모델링과 제어에 많은 어려운 점들이 존재한다. 그러므로, 정확한 온도제어를 위하여는 현재의 출력값 뿐만 아니라 미래의 출력값을 예측하여 제어기의 입력으로 고려되어진다면 보다 우수한 보일러 시스템이 될 것이다. 본 연구에서는 외부의 요인에 따라 시스템 파라메타가 수시로 변하고 제어입력에 대한 시간 지연이 큰 시스템의 정확한 제어를 위하여 신경회로망 예측제어기(Neural Network Predictive Controller: NNPC)를 제안하고, 제안된 예측제어 기법의 타당성을 검증하기 위하여 보일러 온도제어 시스템에 적용하였다. 예측제어를 위한 신경회로망 구조는 플랜트의 특성을 예측할 수 있는 신경회로망 예측기(neural network predictor: NNP)와 최적의 제어량을 산출하는 특별학습구조의 신경회로망 제어기(neural network controller: NNC)의 두 부분으로 구성된다. 제안된 예측 제어기의 성능을 평가하기 위하여, 외란이나 외부 파라메타들의 변화에 대한 컴퓨터 시뮬레이션 및 실시간 온도제어 실험에서 제안된 신경회로망 예측제어기가 기존의 제어기들 보다 빠른 수렴을 나타내었으며, 정상상태에서의 온도편차도 다른 제어기들에 비해 월등히 적음을 알 수 있었다. 또한, 외란이 부가되었을 경우와 목표온도를 변화시켰을 때에도 제안된 신경회로망 예측 제어기는 다른 제어기들 보다 우수한 성능을 갖고 있음을 알 수 있었다.

#### Abstract

The neural network predictive controller(NNPC) is proposed for the attempt to mimic the function of brain that forecasts the future. It consists of two loops, one is for the prediction of output(NNP: neural network predictor) and the other one is for control the plant(NNC: neural network controller). The output of NNC makes the control input of plant, which is followed by the variation of both plant error and prediction error. The NNP forecasts the future output based upon the current control input and the estimated control output. The input and the output data of a system and a new method using evolution strategy are used to train the NNP. A two-step NNPC is applied to control the temperature in boiler systems. It was compared with PI controller and auto-tuning PID controller. The computer simulation and experimental results show that the proposed method has better performances than the other method.

\* 正會員, 東亞大學校 電氣工學科

(Dept. of Electrical Eng., Dong-A University, Pusan, Korea)

※ 본 연구는 한국전력공사의 연구비 지원에 의해 기초전력공학공동연구소 주관으로 수행된 과제임

接受日字: 1997年8月7日, 수정완료일: 1998年6月29日

#### I. 서 론

신경회로망을 응용한 분야로서는 신호처리, 패턴인식, 최적화, 시스템제어등 여러 분야에 걸쳐있지만, 최근에 신경회로망의 일반화 특성과 근사화 능력을 이용하여 동조기로 사용하거나 제어기로 사용하는 연구가 활발히 진행되고 있다<sup>[1,2]</sup>. 특히 신경회로망을 사용한

시스템 동조는 과거의 수학적 플랜트가 표현하지 못했던 시스템의 다양한 동특성을 학습하고 표현할 수 있으며, 이를 이용한 예측시스템에 관한 연구도 나오고 있다.

신경회로망 예측제어는 공학의 여러 분야에 걸쳐서 연구되고 있으며, 일단 예측제어기(one-step predictive controller)에 의한 실시간 제어기의 구현에 관한 논문<sup>[3~5]</sup>과 다단 예측제어기 관한 논문<sup>[6~7]</sup>이 제시되었다. 그러나 다단 예측 제어기(multi-step predictive controller)에 관한 논문에서의 결과는 아직 그 성과가 미미한 수준이며, 단지 신경회로망을 이용한 그 구조의 제시에 머무르고 있는 실정이다.

본 논문에서는 비선형 시스템의 제어를 위한 다단 신경회로망 예측제어기(multi-step neural network predictive controller: MNNPC)를 제시하고자 한다. 이는 신경회로망 예측기(neural network predictor: NNP)와 신경회로망 제어기(neural network controller: NNC)의 두 부분으로 구성된다.

MNNPC의 구조는 일반적인 신경회로망 제어기 중에서 출력과 기준 신호와의 오차를 플랜트를 경유하여 역전파 시키는 특별학습구조(specialized learning architecture)의 제어기를 이용하여 구성하였다. 그러나 특별학습구조에서는 Jacobian을 구하기 어려운 단점이 있는데, 본 논문에서는 Nguyen 등이 제안한 신경회로망 동조기를 이용한 학습법을 사용하였다<sup>[8]</sup>.

본 논문에서의 MNNPC는 오프-라인(off-line)으로 학습이 완료된 NNP에 의한 플랜트의 미래의 출력과 임의의 목표 출력간의 오차와 현재의 플랜트 출력과 목표출력과의 오차를 입력으로 하고, MNNPC 학습은 NNP를 통한 시스템의 근사화된 Jacobian을 이용하여 학습하였다.

제시한 제어기의 성능은 컴퓨터 시뮬레이션과 온도제어 시스템에 적용하여 알아보았다.

## II. 다단 신경회로망 예측제어기 설계

### 1. 신경회로망 예측기

예측기가 어떤 비선형 동적 시스템을 예측하기 위해 서는 그 시스템의 입력출력 관계를 잘 동정하여야 한다. 본 논문에서는 신경회로망을 이용한 비선형 동적 시스템의 동정을 위해 아래의 3가지 문제를 가지고 그 해결책을 얻고자 하였다.

#### 가. 학습신호의 선택

비선형 동적시스템에 대한 학습신호는 제어되는 시스템의 모든 동특성에 관한 정보를 포함하여야 한다는 것을 알 수 있다. 선형 시스템과는 달리 비선형 시스템을 위한 학습신호의 선택에 있어서는 이론적인 기본과 일반적인 설명이 없다. 그러나 신경회로망 예측기가 시스템의 전 공정을 잘 예측하기 위해서는 그 학습신호가 시스템의 전 주파수 범위와 진폭에 걸쳐서 선택되어져야 한다는 것을 알 수 있다. 신경회로망 예측기의 학습이 최소 자승법에 의하여 오차를 최소화하는 방법을 사용하기 때문에 선택되는 학습신호 집합은 어떤 작은 부분에 한정된다든지, 아니면 너무 작은 진폭으로 변화하여서는 안된다. 이를 위해서 본 논문에서는 제어대상이 되는 플랜트에 관한 적당한 학습신호의 선택을 위해서 몇 개의 입력력 신호들을 이용하였다. 이들 입력력 신호들은 시스템의 공정 동특성에 관한 일반적인 특성과 제어기의 성능을 고려하여 선택하였다.

#### 나. 다단신경회로망 예측기 구조

본 논문에서 사용한 신경회로망 예측기의 구조는 그림 1과 같이 3층 신경회로망 구조를 하고, 학습하려는 플랜트의 입·출력 데이터를 이용해 오프-라인으로 학습을 하였다.

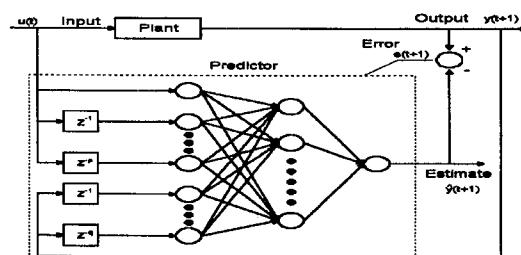


그림 1. 신경회로망 예측기의 구조

Fig. 1. A structure of a neural network predictor.

신경회로망의 입력으로는 플랜트 현재 입·출력값과 시간지연을 갖는 입·출력값으로서 다음과 같이 구성한다.

$$IN(u(t), y(t), u(t-1), y(t-1))$$

학습이 완료된 신경회로망 예측기는 플랜트와 등가로 볼 수 있기 때문에 같은 무게치를 가지는 신경회로망 예측기를 그림 2와 같이 직렬 연결함으로써 다단 예측이 가능하다.

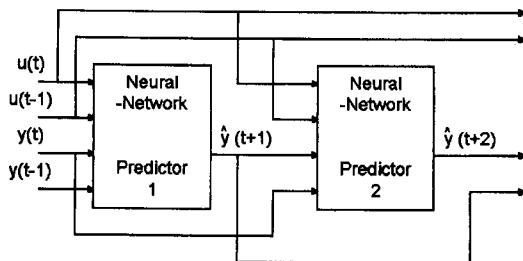


그림 2. 다단 신경회로망 예측기의 블록 다이어그램  
Fig. 2. A block diagram of multi-step neural network predictor.

#### 다. ES에 의한 신경회로망의 학습 방법

이제까지의 신경회로망 학습방법은 오차를 최소화하도록 하는 최급강하법의 일종인 역전파(back-propagation)학습 알고리즘을 주로 사용하여 왔다. 역전파 학습법은 여러 가지 단점으로 인하여 최근에는 변형된 학습알고리즘이 제안되고 있다. 본 논문에서는 최근에 최적 파라미터 탐색법으로 많은 연구가 되고 있는 진화전략(evolution strategy: ES)을 사용한 신경회로망 학습 방법을 사용하고자 한다<sup>[9~11]</sup>.

ES는 자연 진화 과정을 모방한 진화 알고리즘중의 하나로서 유전알고리즘(genetic algorithm: GA)과 더불어 최적 파라미터를 찾는 연구에 많이 이용되고 있다.

ES는 우수한 개체가 경쟁을 통해서 생존해 나아가는 진화 과정을 모방한 최적해 탐색 기법으로서 이는 임의의 모집단을 선택한 후 그 집단 내의 각 개체들의 적합도(fitness)를 평가하여 그 중 적합도가 가장 우수한 개체를 선택하고 이것에 가우시안 분포를 따르는 랜덤변수를 더함으로써 다음 세대를 발생시키는 방법이다. 즉, 선택된 개체 집단이 일차 변환(돌연변이형태)과 고차 변환(교배형태)을 경험하여 이런 개체들은 선택시킴, 보다 나은 개체로의 편향, 다음 세대의 선택 등으로 생존을 위해 노력한다. 결국 몇 세대가 반복된 후 프로그램은 수렴을 하게 되며 최적의 개체가 최적해를 가진다고 기대한다. GA가 이진화 부호를 사용하는 반면에 ES는 적용 시스템에 쓰이는 실 변수를 그대로 사용하기 때문에 부호화 과정이 필요 없고, 구성 또한 간단하다는 장점이 있다.

본 논문에서 적합도를 평가하기 위해 사용된 평가함수  $F(X)$ 는 다음과 같다.

$$F(X_i) = \frac{\alpha}{\beta + |\Sigma e(i)|} \quad (1)$$

여기서,  $\Sigma e(i)$ : i번째의 개체에 의한 오차의 합,  
 $\alpha, \beta$ : 임의의 상수.

평가함수는 오차의 합이 작으면 적합도가 커지므로 개체가 선택될 확률이 크며 오차의 합이 크면 적합도가 작아지므로 개체의 선택 확률이 작다는 것을 의미 한다.

ES의 최적해 탐색과정은 다음과 같다.

- (1) 구하고자 하는 해의 범위 내에서 초기해 집단  $X_i$  ( $i=1, 2, \dots, p$ )를 랜덤하게 발생시킨다.
- (2) 이 해집단에 가우시안 랜덤 변수(평균은 0)이고 표준편차는 임의의 값)를 각각의  $X_i$ 에 더함으로써 새로운 해집단  $X'_i$ 를 만든다.
- (3) 이 두 해집단의 각 개체들을  $F(X_i)$ 와  $F(X'_i)$  ( $i=1, 2, \dots, p$ )의 오차를 비교하여 가장 작은 오차를 가지는 개체를 선택하여 다음 세대의 해집단을 형성한다.
- (4) 만족할 만한 해가 얻어지기까지 b)~c) 과정을 반복한다.

#### 2. 신경회로망 예측제어기

본 논문에서 사용하는 신경회로망 제어기는 비선형 시스템을 제어하기 적합한 적응형 제어기의 간접 방식을 응용하여 다단 신경회로망 예측기를 결합한 형태를 사용하였다.

제안한 다단 신경회로망 예측제어기의 구조는 그림 3과 같으며, 다단 신경회로망 예측기를 통한 자코비안은 신경회로망의 학습을 위해서 쓰인다.

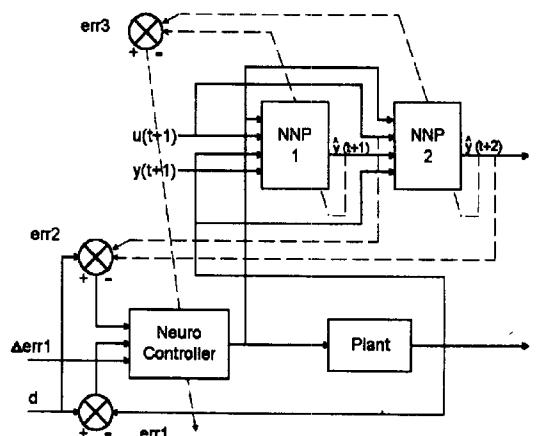


그림 3. 2단 신경회로망 예측 제어기

Fig. 3. Two-step neural network predictive controller.

$\frac{\partial \hat{y}(k+1)}{\partial u_k(k)}$  를 다단 예측에 대한 시스템 자코비

안 식으로 고쳐 쓰면 다음 식과 같이 된다<sup>[7]</sup>

$$\frac{\partial \hat{y}(t+n)}{\partial u(t)} = \frac{\partial \hat{y}(t+1)}{\partial u(t)} + \alpha \left( \frac{\partial \hat{y}(t+2)}{\partial u(t)} - \frac{\partial \hat{y}(t+1)}{\partial u(t)} \right) + \dots + \beta \left( \frac{\partial \hat{y}(t+n)}{\partial u(t)} - \frac{\partial \hat{y}(t+n-1)}{\partial u(t)} \right) \quad (2)$$

여기서  $\alpha, \beta$ 는 비례상수이다.

식 (2)에서  $\frac{\partial \hat{y}(t+1)}{\partial u(t)}, \frac{\partial \hat{y}(t+2)}{\partial u(t)}, \frac{\partial \hat{y}(t+n)}{\partial u(t)}$ 은 각각 신경회로망 예측기 1, 신경회로망 예측기 2, 그리고 신경회로망 예측기 n에서 구할 수 있다.

플랜트의 자코비안은 예측기 정도에 비례하여 일단에서의 자코비안과 2단에서의 자코비안의 합에 의하여 계산된다. 신경회로망 예측제어기의 입력으로는 기준입력과 현재 플랜트의 출력과의 오차인 e, 오차의 변화율인  $\Delta e$ , 그리고 기준 입력과 예측된 플랜트의 출력과의 오차인  $\Delta \hat{e}$ 를 입력으로 하여서 구성하였다. 여기서 예측 출력 오차인  $\Delta \hat{e}$ 의 개수는 예측기의 예측 범위에 따라서 그 숫자가 결정된다. 이렇게 함으로써 신경회로망 예측제어기는 플랜트의 예측 출력에 따라서 민감하게 반응하게 된다. 예측제어기의 중간층은 15개의 노드수를 가지며 출력층으로는 하나의 노드를 가진다. 중간층의 활성함수로는 시그모이드함수를 사용하였으며, 출력층의 활성화함수는 선형함수를 사용하였다.

### III. 컴퓨터 시뮬레이션

제안한 다단 신경회로망 예측제어기의 성능을 알아보기 위하여 시정수가 크므로 인하여 온도변화의 시간지연이 큰 보일러 시스템에 적용하여 보았다. 시뮬레이션을 위하여 사용한 보일러 시스템은 그림 4와 같으며 열 손실이 없다고 가정하였고, 온도 분포 또한 보일러 내에서 균일한 분포를 가진다고 가정하였다.

보일러 시스템의 온도 방정식은 다음과 같이 나타낼 수 있다<sup>[12]</sup>.

$$\frac{dy}{dt} = -\frac{1}{V} F(t)y(t) + \frac{1}{V} F(t)T(t) + \frac{1}{CV} u(t) \quad (3)$$

식 (3)을 1차 Euler근사법에 의해 이산시간 모델로 나타내면 아래와 같다.

$$y(t+1) = y(t) - \frac{A}{V} F(t)y(t) + \frac{A}{V} F(t)T(t) + \frac{A}{CV} u(t) \quad (4)$$

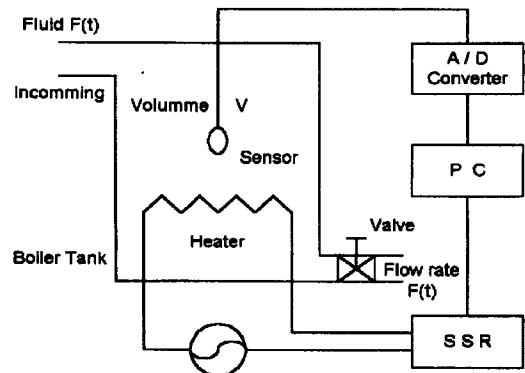


그림 4. 보일러 시스템의 블록 다이어그램

Fig. 4. A block diagram of the boiler system.

시뮬레이션을 위하여 각 변수들의 값을 표 1과 같이 주었다.

표 1. 보일러 시스템의 파라미터  
Table 1. Parameters of the boiler system.

Parameter	Values	Description
T(t)	18 [°C]	유입 액체의 정상 상태 온도
F(t)	0.02, 0.09 [kg/sec]	정상 상태에서의 액체의 유량
u(t)	0~6[kal/sec]	정상 상태에서의 제어열량
V	4 [kg]	탱크 내의 액체의 질량
C	1.0[kal/kg°C]	액체의 비열
A	1[sec]	샘플링 시간

초기 기준 온도는 40°C로 설정을 하였으며, 초기 유량은 0.02 [kg/sec]로 하였다.

그림 5는 본 논문에서 제안한 예측 제어시스템에서 1단(One-step) 예측제어기로 구성하였을 때의 플랜트의 응답특성이며 그림 6은 2단(Two-step) 예측제어기로 구성하였을 때의 시뮬레이션에 대한 응답특성이다. 현재의 제어입력값은 예측한 출력값을 고려하여 제어입력을 신출을 함으로 플랜트의 출력특성에서 오버슈트에 대한 성능이 매우 우수함을 알 수 있다. 시뮬레이션 결과에서 보듯이 오버슈트가 거의 발생하지 않음을 알 수 있고 2단 예측제어기는 1단 예측제어기 보다 나은 정상상태 성능을 가진다. 그리고 외란에 대해서도 나은 성능을 보이고 있는데, 본 시뮬레이션에서의 외란은 1000~1200 [sec] 동안 유량을 초기유량 0.02 [kg/sec]에서 0.09 [kg/sec]를 변화하여 인가하였으며 외란이 인가하는 구간에서 1단 예측 제

어시스턴트의 출력특성은 설정치값에서 약 1~2°C정도의 오차를 보이고 있으나 2단 예측 제어시스템에서는 거의 0을 나타내고 있다.

#### IV. 실험 및 결과 고찰

제안한 다단 예측제어기의 온도제어실험을 위하여 그림 7과 같이 실험 장치를 구성하였다. 다단 신경회로망 예측제어기는 PC-586에서 구현하였으며, A/D Converter는 12bit의 분해능을 가지는 3 1/2 디지털 A/D Converter인 TSC14433을 사용하였다. 전열기의 입력은 샘플링 시간을 1초로 하여 전압을 출력으로 하는 소자인 SSR의 출력을 ON-OFF 제어입력으로 구현하였다. 실험에 사용한 전열기는 100V, 60W의 빠른 전구와 500W짜리 보일러를 사용하였으며, 온도의 측정은 온도변화에 따라 저항값이 거의 선형적으로 변하는 PT100을 사용하였다.

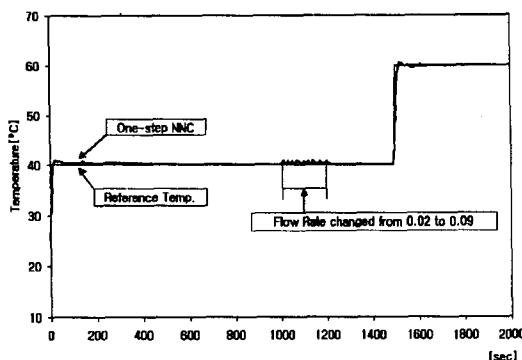


그림 5. 1단 신경회로망 예측 제어기의 출력 결과  
Fig. 5. An output result of one-step neural network predictive controller.

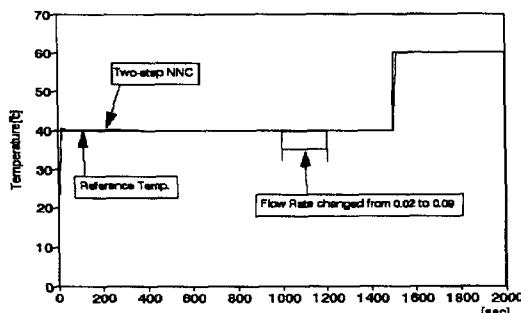


그림 6. 2단 신경회로망 예측 제어기의 출력 결과  
Fig. 6. An output result of two-step neural network predictive controller.

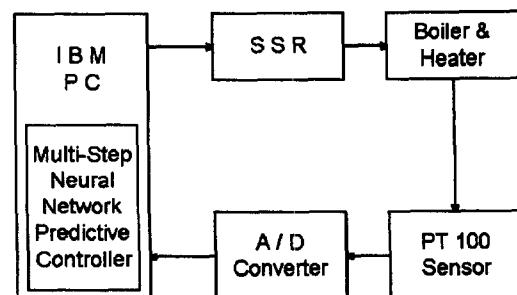


그림 7. 다단 신경회로망 예측 제어기의 블록도  
Fig. 7. A schematic diagram of multi-step neural network predictive controller.

그림 8은 PI제어기를 사용하였을 경우의 전열기 온도 그래프이며 그림 9는 2단 신경회로망 예측제어기를 사용한 경우의 온도 그래프이다.

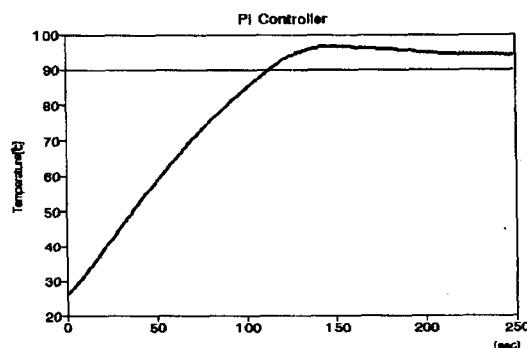


그림 8. PI 제어기의 출력 온도  
Fig. 8. Output temperature in PI controller.

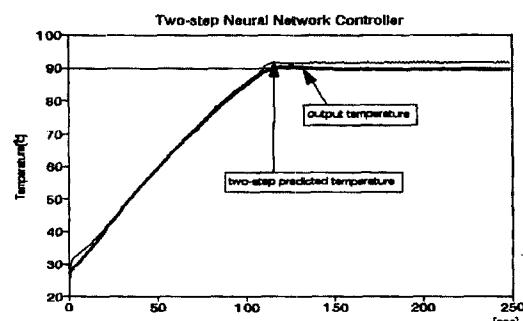


그림 9. 2단 신경회로망 예측 제어기의 출력 온도  
Fig. 9. Output temperature in two-step NNPC.

그림 10은 보일러 온도 제어시의 자동동조 PID제어기의 온도변화를 보여주고 있으며 그림 11은 2단 신경회로망 예측 제어기 경우의 출력 온도 변화를 나타내고 있다.

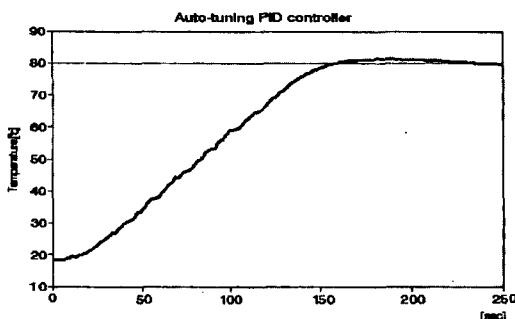


그림 10. 자동동조 PID 제어기의 출력 온도  
Fig. 10. Output temperature in auto-tuning PID controller.

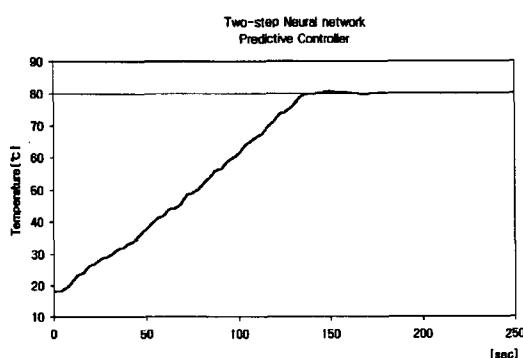


그림 11. 2단 신경회로망 예측 제어기의 출력 온도  
Fig. 11. Output temperature in two-step NNPc.

위에서 보듯이 MNNPC는 자동동조 PID 제어기보다 상승시간이 약 40 [ sec ] 정도 빠름을 알 수 있다. 이는 PID제어기의 경우 오버슈트를 줄이기 위하여 설정온도 약 10°C 이전부터 제어 입력값이 작아져 설정치까지 천천히 도달하지만, MNNPC는 설정치 부근에서 제어 입력값을 줄임으로써 상승속도가 PID제어기 보다 빨랐다.

## V. 결 론

신경회로망을 이용한 플랜트 제어기법 중 플랜트 예측기를 가지는 다단 신경회로망 예측 제어기를 제안한다. 제안된 다단 신경회로망 제어기는 신경회로망 예측기 부분과 신경회로망 제어기 부분으로 이루어진다. 다단 신경회로망 예측기는 일단 신경회로망 예측기를 다단으로 직렬 연결하여서 실현하였고, 신경회로망 제어기는 적응형 제어기의 간접 방식을 이용하였다. 이의 학습을 위하여 진화 알고리즘의 하나인 ES를 사용

하였으며, 신경회로망 제어기는 역전파 알고리즘과 모멘트 법으로 학습하였다.

신경회로망 예측제어기를 사용한 전열기와 보일러 온도 제어 시스템을 제작하였으며, PI제어기 그리고 자동동조 PID제어기와 성능을 비교하여 보았다. 실험 결과에서 제안한 제어기가 PI제어기 보다 미리 앞을 예측함으로 인하여 오버슈트(over-shoot)가 현저히 적음을 확인할 수 있었고, 자동동조 PID제어기 보다 상승시간이 작음을 알았다.

## 참 고 문 헌

- [ 1 ] K. S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Network," IEEE Trans. on Neural Network, vol. 1, pp. 4-27, 1990.
- [ 2 ] M. Saerens and A. Soquet., "Neural Controller Based on Back-propagation Algorithm," IEE Proc. F, vol. 138, no. 1, pp. 55-62, 1991.
- [ 3 ] H. J. L. Van Can, H. A. B. Te Braake, C. Hellinga, A. J. Krijgsman, H. B. Verbruggen, K. Ch. A. M. Luyben, and J. J. Heijnen, "Design and Real Time Testing of a Neural Model Predictive Controller for a Nonlinear System," Chemical Engineering Science, vol. 50, no. 15, pp. 2419-2430, 1995.
- [ 4 ] B. Widrow and R. Winter, "Neural Nets for Adaptive Filtering and Adaptive Pattern Recognition," IEEE Computer, pp. 25-39, 1988.
- [ 5 ] J. S. Donat, N. Bhat, and T. J. Mcavoy, "Neural Net Based Model Predictive Control," INT J. Control, vol. 54, no. 6, pp. 1453-1468, 1991.
- [ 6 ] Dianhui Yang and Tianyou Chai, "Neural-net Based Multi-steps Nonlinear Adaptive Model Predictive Controller Design," Proc. of the American Control Conference, pp. 4192-4193, 1995.
- [ 7 ] Y. Takahashi. "Adaptive Predictive Control of Nonlinear Time-Varying Systems using Neural Network," IEEE Int'l Conf.

- on Neural Network, vol 3, pp. 1464-1468, 1993.
- [ 8 ] D. H. Nguyen and B. Widrow, "Neural Networks for Self-learning Control Systems," IEEE Control Systems Magazine, vol. 10, no. 2, pp. 18-23, 1990.
- [ 9 ] David B. Fogels, "An Introduction to Simulated Evolutionary Optimization," IEEE Trans. on Neural Network, vol. 5 no. 1 1994.
- [ 10 ] Alen Varsek, Tanja Urbancic, and Bogdan Filipic, "Genetic Algorithms in Controller Design and Tuning," IEEE Trans. on Systems, Man, and Cybernetics, vol. 23, no. 5, 1993.
- [ 11 ] David E. Goldberg, "Genetic Algorithms in Search, Optimization, and Machine Learning," Addison-Wesley, 1989.
- [ 12 ] Benjamin C. Kuo, "Automatic Control Systems," Prentice-Hall, 1996.

## 저자소개



李 權 純(正會員)

1977년 2월 충남대학교 공과대학 공업교육과 (전기전공) 공학사. 1981년 2월 서울대학교 대학원 전기공학과 졸업 공학석사. 1990년 7월 오레곤주립대학교 전기 및 컴퓨터공학과 졸업 Ph. D. 1994년 10월 1일 ~ 현재 동아대학교 공과대학 전기공학과 부교수. 1992년 3월 1일 ~ 현재 대한의용생체공학회 학술위원. 1998년 1월 1일 ~ 현재 대한전기학회 편집위원. 1990년 10월 1일 ~ 1994년 9월 30일 동아대학교 공과대학 전기공학과 조교수. 1982년 3월 1일 ~ 1990년 9월 30일 동아대학교 공과대학 전기공학과 전임강사. 주 관심분야는 비선형 시스템, 지능제어, 의용생체 시스템