

論文93-30B-1-10

자동조정기능의 지능형제어를 위한 신경회로망 응용 (Application of Neural Network for the Intelligent Control of Computer Aided Testing and Adjustment System)

具泳謨*, 李昇求*, 李榮敏**, 禹廣芳*

(Young Mo Koo*, Seung Koo Lee*, Young Min Rhee, and Kwang Bang Woo)

要約

본 논문은 완성된 전자제품 조정공정의 자동화를 위하여 대상 전자제품의 기능 조정을 자동화하는데 인공신경회로망을 응용하여 지능형 제어를 구현하는 방법연구에 관한 것이다. 다층신경회로망을 사용하고 Error Back Propagation 학습방법에 의해 학습토록 한다. 제어대상물에서 알 수 있는 정보는 초기상태 출력값, 입력의 증분값과 이에 대응하는 출력값 뿐이며 초기치 입력값에 대한 정보는 제공되지 아니한다. 인공신경회로망을 이용한 조정공정의 지능제어를 위하여 Neural Network Emulator (NNE) 와 Neural Network Controller (NNC)가 개발되며 각 신경회로망의 초기하중벡터는 대상제품 각각에 대해 오프라인 학습으로 결정하고, 자동조정 과정에서 온라인 학습하여 새로운 대상제품 상황에 적응하도록 설계되었다. 제안된 방법의 지능형 제어시스템은 컴퓨터 시뮬레이션과 실시스템 적용을 통해 검토되었다.

Abstract

This paper deals with a computer aided control of an adjustment process for the complete electronic devices by means of an application of artificial neural network and an implementation of neuro-controller for intelligent control. Multi-layer neural network model is employed as artificial neural network with the learning method of the error back propagation. Information initially available from real plant under control are the initial values of plant output, and the augmented plant input and its corresponding plant output at that time. For the intelligent control of adjustment process utilizing artificial neural network, the neural network emulator (NNE) and the neural network controller(NNC) are developed. The initial weights of each neural network are determined through off_line learning for the given product and it is also employed to cope with environments of the another product by on_line learning. Computer simulation, as well as the application to the real situation of proposed intelligent control system is investigated

Key Words : computer aided adjustment(자동조정), intelligent control(지능형제어),
neural network emulator(신경회로망 에뮬레이터),
neural network controller (신경회로망 제어기)

*正會員 延世大學校 電氣工學科

(Dept. of Elec. Eng., Yonsei Univ.)

**正會員 三星電子 生産技術센터 自動化 研究所

(Samsung Elec. Auto.R&D Institute Production Eng. Center)

接受日字: 1992年 8月 22日

1. 서론

신경회로망의 제어분야 응용을 위하여 이를 기존의 컴퓨터 제어방식에서 알고리즘으로 구현하는 경우, 적응학습능력에 의한 지속적인 성능개선이나 제어환

경 변화에 대한 견고성 등에서 수학적 제어이론보다 중요한 실용적 장점이 있다. 기존의 제어기법이나 제어기 설계가 모두 설계목표에 따른 제어기 설계를 위해 대상 플랜트의 선형 근사화 또는 이산화 모델을 필요로 한다. [1] 따라서 모델링 오차의 불확실성에 대한 견실성은 제한적인 것일 수 밖에 없으며 이러한 견실성을 확대하는 것이 지능형제어의 설계목적이 된다. [2]

신경회로망 관점에서 본다면 제어문제는 패턴인식 문제와 동일하게 생각될 수 있는데, 이는 시스템 성능 향상을 위해 제어대상 플랜트로의 "작용" 신호로 투영(mapping)될 제어대상 플랜트에서의 "변화" 신호를 패턴인식하는 것으로 설명할 수 있다. 따라서, 지능형 제어기는 이 "변화" 패턴을 실시간으로 인식, 분리하고, 불충분한 데이터로 "변화" 를 신속히 인식할 수 있는 경험으로부터 "학습" 되어야 한다. 그러므로 지능형 제어기의 설계 및 구현에 인공 신경회로망을 사용한다면 패턴인식, 지속적인 성능개선의 자기구성기능을 갖는 투영, 그리고 의사결정 등의 특성들을 기대할 수 있다. [3]

사시공정에서 전자제품의 가변소자를 실제 작업자가 일반 전압측정기 혹은 오실로스코프 등의 계측기를 사용하여 목시판단으로 조정하여 정해진 제품특성을 갖추도록 하는 조정공정을 자동화시키므로써 생산라인의 무인화, 다품종 소량생산 등의 필요에 적절히 대응할 수 있다. [4] 조정공정에서의 제어목적은 측정점의 계측파형이 정해진 기준에 적합하도록 가변소자를 조정사양에 따라 조정하는 것이며 이때 제어대상 조정공정이 가지는 특성은 첫째 동일한 모델의 제품에서도 피조정 가변소자의 초기값이 제품마다 임의의 값을 가진다. 둘째 비선형 임출력 특성을 갖는다. 셋째 입출력 특성의 변화정도가 미지의 관련소자가 가지는 오차범위에 의존한다. 이와같은 조정공정을 자동화 하기위한 자동 조정 제어기를 구성하는 경우 고려되어야 하는 점은 출력파형 계측과 가변소자의 자동구동이며 [5] 회전제어를 담당하는 모터의 기동/정지 시간이 고정되어 있기 때문에 위에서 언급한 조정공정의 세가지 특성에 적절히 대처하며 가능한한 적은 횟수의 조정신호를 가지고 제어 목적을 달성하기 위한 지능형 제어가 필요하다. 본 연구에서는 이와같은 조정공정을 자동화 하기 위하여 이의 지능제어를 위한 인공 신경회로망의 응용 및 제어기 구현방법에 관한 문제를 고찰한다.

II. 자동조정시스템

본 연구에 사용된 자동조정시스템 으로는 검사조정

시스템(Fara WAT-CT1) 을 사용하였다. 이 시스템은 다종다양한 신호원과 그의 검사조정 항목을 수용하기 위해 공통적으로 필요한 부분을 기본사양으로 하고 각 공정별로 적용할 때 예외적인 부분은 모듈화하여 접속형으로 구성된다. 임의파형에 대한 검사조정을 위해 다음과 같은 알고리즘을 조합할 수 있다. [4] · Regression 해석 · FFT · 임의파형 탐색 · 검파기, 비교기, Window비교기 · 파형의 일정영역에서 상한과 하한 사이의 값 계수 · 파형탐색에서 Noise Level지정기능 · 파형기억 및 재생. 검사조정시스템(Fara WAT-CT1)의 하드웨어 구성은 그림1과 같다. 그림1에서 오실로스코프로 계측된 측정점의 데이터는 GP-IB를 통해 PC에 전달되며 이에의해

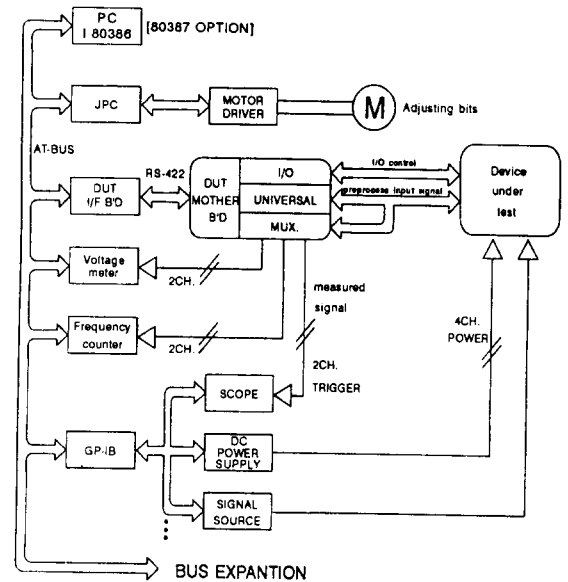


그림 1. 범용 검사조정제어기 하드웨어 구성
Fig. 1. Hardware organization of computer aided testing & adjustment system.

PC내부에서 결정된 조절량은 JPC로 출력된다. JPC는 이를받아 모터와 직결된 조정턱의 회전량을 motor driver로 전달하여 조정이 이루어지게 한다. 본 연구에서는 부품조립이 완성된 사시공정의 제품에서 피검사 측정점의 출력파형을 오실로스코프로 관찰하여 미리 정한 범위에 들어가도록 피조정 소자를 자동조정하게 된다. 작업자가 수동으로 조정하는 경우의 조정 기준은 오실로스코프 화면 전체의 모양을 인식하고 조정할 양을 추론하여 피조정 소자의 조정 결과가 최소의 조정작업으로 정해진 범위에 들어가도록 하는데 소요되는 시간에 의해 결정된다. 이와같은

유형의 조정작업을 요구하는 플랜트를 실시간으로 자동조정하기 위해서는 컴퓨터 제어 방식이 가장 적절하며 오실로스코프 화면에 나타나는 모든 데이터의 실시간 처리가 어렵다. 따라서 오실로스코프 화면에서 관찰기준이 되는 점의 D.C. level 만을 플랜트의 출력으로 보고 이것만으로 자동조정 하도록 한다. 그림1의 시스템을 사용하여 자동조정하기 위한 측정 대상물(부품조립이 완료된 메인 프린트 회로기판)의 조정항목은 세가지 이다. 조정항목(I)은 측정 대상물의 해당 측정점(TP1)을 오실로스코프로 계측한 파형이 그림2와 같을때 P₁점에서의 값이 최소가 되도록




그림 2. 조정항목(I)의 해당 측정점(TP1) 계측파형
(a) 조정전 (b) 조정후
Fig. 2. Waveform of appropriate test point(TP1) for item(I)
(a) before adjustment
(b) after adjustment

피조정코일(i)을 자동조정 하는 것이며 조정항목(II)는 측정 대상물의 해당 측정점(TP2)를 오실로스코프로 계측한 파형이 그림4와 같을때 P₂점에서의 값이 영이 되도록 피조정 코일(ii)를 자동조정 하는 것




그림 3. 조정코일(i) 변화에 대한 조정항목(I)에서 해당 측정점(TP1)의 P₁점 출력 변화
Fig. 3. P₁ point output change of appropriate point(TP1) for item(I) by coil(i).




그림 4. 조정항목(II)의 해당 측정점(TP2) 계측파형
(a) 조정전 (b) 조정후
Fig. 4. Waveform of appropriate test point(TP2) for item(II).
(a) before adjustment
(b) after adjustment

이고 조정항목(Ⅲ)은 측정 대상물의 해당 측정점 (TP3)를 오실로스코프로 계측한 파형이 그림6과 같을때 C₃점과 P₃점에서의 값이 일치하도록 피조정 코일(iii)을 자동조정 하는 것이다. 그림3은 조정항목 (Ⅰ)에서 피조정 코일(i)을 한쪽 끝에서 다른쪽 끝으로 일정각씩 돌려서 구동모터의 위치에 대한 P₁점의 계측 데이터를 나타내며 그림5는 조정항목(Ⅱ)에서 피조정 코일(ii)를 한쪽 끝에서 다른쪽 끝으로 일정각씩 돌려서 구동모터의 위치에 대한 P₂점에서의 계측 데이터를 나타내고 그림7은 조정항목(Ⅲ)에서 피조정 코일(iii)을 한쪽 끝에서 다른쪽 끝으로 일정각씩 돌려서 구동모터의 위치에 대한 C₃점과 P₃점 및 두점의 차(C₃-P₃)를 계측한 데이터이다.





그림 5. 조정코일(ii) 변화에 대한 조정항목(Ⅱ)에서 해당 측정점(TP2)의 P₂점 출력 변화
Fig. 5. P₂ point output change of appropriate point(TP2) for item(Ⅱ) by coil(ii).


이상의 조정항목(Ⅰ),(Ⅱ),(Ⅲ)을 자동조정하기 위하여 측정대상물을 Set up 한 후 각 조정항목의 측정점들(TP1, TP2, TP3)을 계측하여 조정에 필요한 피조정 코일(i, ii, iii)의 변화량을 추출하는 기능이 요구된다. 이때 고려되어야 하는 점은 첫째, 조정도중 피조정코일의 회전방향이 반전되는 경우 피조정코일과 이에 결합된 조정팁 사이의 간격에 따른 오차 발생이며 둘째로는 피조정코일의 변화에 대한 해당 측정점의 출력변화가 동일한 종류의 측정대상물에 대해서도 측정대상물의 조립에 사용된 회로소자가 가지는 허용오차로 인해 대히 일정하지 않은 점이다.

Ⅲ. 신경회로망을 이용한 자동조정

피조정코일의 변화에 대한 자동조정 대상 제품 조정항목의 해당 측정점에서 계측한 파형중 P점의 출력을 다음의 이산치 형태로 표현할 수 있다.



(a)



(b) after adjustment

그림 6. 조정항목(Ⅲ)의 해당 측정점(TP3) 계측파형
(a) 조정전 (b) 조정후

Fig. 6. Waveform of appropriate test point (TP3) for item(Ⅲ).
(a) before adjustment
(b) after adjustment

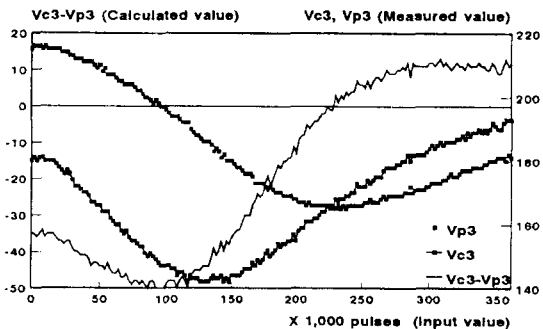


그림 7. 조정코일(iii)의 변화에 대한 조정항목(Ⅲ)에서 해당 측정점(TP3)의 C₃점, P₃점 및 C₃점-P₃점 출력 변화

Fig. 7. C₃ Point, P₃ point & C₃ Point - P₃ Point output change of appropriate point(TP3) for item(Ⅲ) by coil(iii).

$$y_k = f\left(\sum_{i=1}^k U_i\right) = f\left[f^{-1}(y_{k-1}) + U_k\right] \quad (1)$$

여기서 y_k 는 k 시점에서 P 점의 출력, u_k 는 k 시점에서 피조정 코일의 변화량. 이와같은 조정한목을 자동 조정하기 위해서 식(2)의 평가함수 J_C 를 최소화 하는 식(3)의 피조정 코일의 변화량 u_k 를 구하는 함수 g 가 요구된다.

$$J_C = \frac{1}{2}(y_d - y_k)^2 \quad (2)$$

$$U_k = g(y_d, y_{k-1}) \quad (3)$$

여기서 y_k , y_d 는 k 시점에서 P 점의 출력과 원하는 출력을 각각 나타낸다. 비선형 함수인 f , g 는 그 구조와 무관하게 다층 신경회로망으로 표현할 수 있으며^[6] 이와같은 학습에 EBP(Error Back Propagation)방법을 사용할 수 있다.^[7] 이를 온라인으로 수행하기 위한 전체 블록 선도는 그림8과 같다.

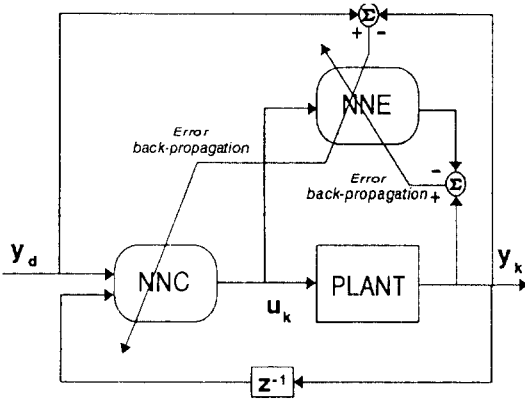


그림 8. 제어 블록 다이어그램
Fig. 8. Control block diagram.

그림8 에서 NNE와 NNC는 neural network emulator (NNE)와 neural network controller (NNC)를 포함하며 각 1개의 입력층, 중간층, 출력층으로 구성되고 중간층 출력에는 비선형 시그모이드 함수, 출력층 출력은 선형함수가 사용된다. NNE 와 NNC는 각각 두 단계로 학습되는데 첫 단계에서는 오프라인 학습이 된다.

1. 측정불가능한 왜란의 존재 기계류와 결합된 플랜트에서 일반적으로 존재하는

요소가 백래쉬(Backlash)이며 이의 기구적 해결이 진보되어 왔다. 그러나, 이 방법은 조정탑의 삽입/해체를 원활히 하는 것과는 반대되는 효과를 가지게되 가변소자에 회전력을 전달하는 과정에서 생기는 백래쉬는 큰값을 가지게 될 수 있으며 수동작업에서 작업자가 이를 감안하여 추론하듯이 조정작업을 자동으로 수행하기 위해서 지능이 필요하다. 따라서 우리는 이러한 필요에 의한 지능을 부여하기 위해 신경회로망의 학습능력을 통해 백래쉬를 반영하도록 하였다. 회전방향의 반전이 있는 경우 일정량을 가/감 하여 백래쉬를 해결하기위해 반복/경험에 의해 그 값을 결정하면 이 값은 고정된 값이 되어 조정탑과 피조정 단자 사이의 간격이 제품마다 일정하지 않은 자동조정의 경우 적절하지 않은 결과를 낼 수 있다. 따라서 이에 대처하여 백래쉬를 유발하는 불규칙한 간격에 적용하는 지능을 얻기위해 신경회로망을 이용하여 백래쉬를 학습한 결과의 값을 가/감의 양으로 할 필요가 있다. 이 경우 다음 두가지 단계로 학습이 일어난다.

- 1) 임의의 제품에 대한 사전학습을 통해 신경회로망의 초기하중들을 결정.
- 2) 학습된 초기 하중값으로 시작하여 조정대상 가변소자에 대한 백래쉬를 조정과 동시에 실시간 학습.

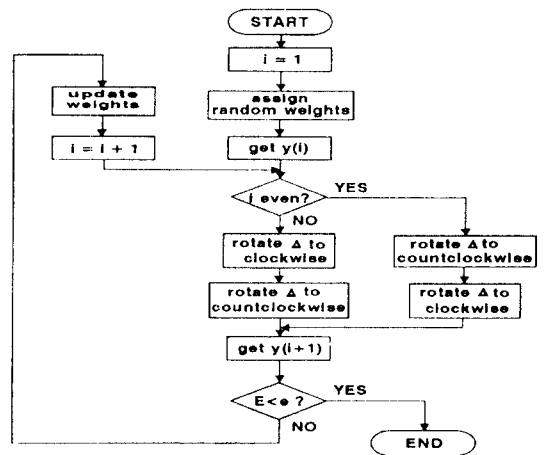


그림 9. 초기 백래쉬 학습 흐름도
Fig. 9. Flowchart to learn backlash of initial state.

이와같이 하여 1)단계 에서 보편적인 백래쉬의 양을 보상할 수 있는 지능을 부여받고 2)단계 에서 조정대상 제품마다 가지는 고유한 양을 상세히 보상하는 지능을 획득하게 된다. 초기 백래쉬 학습의 알고리즘은 다음과 같으며 이때 Δ 값은 예상되는 값보다

충분히 큰 값으로 정한다. 학습시 입력은 고정된 임의의 값이며 출력은 백래쉬 보상값이다. 또한, 교차신호는 $y(i)$ 와 $y(i+1)$ 의 차이가 되며 그림9는 조정항목(Ⅰ)의 경우에 사용되는 초기 백래쉬 학습 알고리즘이다.

2. 주변환경 변화에 대한 적응

조정의 기준값이 있는 경우 측정대상물에서 알 수 있는 정보는 초기치 출력, 입력의 증가치 그리고 그때의 출력값 뿐이므로 새로운 조정이 시작될 때마다 임의의 초기치 출력을 갖는 것은 주변환경의 변화로 볼 수 있다. 플랜트의 역함수가 알려져 있거나 정확한 모델링이 가능한 경우는 초기값을 플랜트 모델식에 작용하는 매개변수로 놓고 매개변수 추정과정이 포함되어 있는 적응제어기법을 적용하여 제어할 수 있다. 그러나, 본 연구에서의 고찰대상에서처럼 플랜트에 대한 정보가 블랙박스과 같이 입출력 뿐이며, 비선형 특성을 갖고, 최소의 제어명령을 요구하는 경우에 대처하기 위해서는 이와같은 방법보다는 어떤 형태의 자율학습능력을 갖춘 지능제어가 요구된다. 따라서, 학습에 의한 비선형 플랜트 추정이 가능한 신경회로망을 플랜트추정에 이용하여 주변환경 변화에 익숙해 지도록 한다면 임의의 초기치 출력을 갖는 경우에도 적절히 대응하며 플랜트 특성을 구현할 수 있게 된다. 플랜트와 동일한 특성을 갖는 신경회로망을 가질 수 있다는 것은 플랜트의 자코비안(Jacobian)을 구할 수 있다는 의미에서 플랜트를 다루는데 중요한 역할을 한다. 신경회로망을 사용하여 플랜트를 추정하는 경우 조정항목(Ⅱ)는 다음 식(4)와 같이 입력이 2개이고 출력이 하나인 신경회로망을 사용하여 제어입력과 초기치 출력만으로 모델링 할 수 있다.

$$y_k = Ne^I [u_k, y_{k-1}] \quad (4)$$

조정항목(Ⅲ)인 경우 그림7에서와 같이 두 점의 초기출력 값으로 가능한 모든 주변환경 변화를 구분할 수 있으므로 식(5)와 같이 현재 제어입력과 두 점의 초기출력을 입력으로한 출력뉴런2, 입력뉴런3인 신경회로망으로 모델링 할 수 있다.

$$[y^{11}_k, y^{12}_k] = Ne^II [u^1_k, y^{11}_{k-1}, y^{12}_{k-1}] \quad (5)$$

조정항목(Ⅱ)가 조정항목(Ⅲ)에 종속되어 있는 경우는 독립된 두개의 신경회로망을 사용하여 식(6), 식(7)로 모델링할 수 있다.

$$[y^{11}_k, y^{12}_k] = Ne^I [u^1_k, y^{11}_{k-1}, y^{12}_{k-1}] \quad (6)$$

$$y^2_k = Ne^2 [u^2_k, y^2_{k-1}, y^{11}_k, y^{12}_k] \quad (7)$$

여기서 u^1_k 는 조정항목(Ⅲ)에 인가되는 k 시점에서의 제어입력값, u^2_k 는 조정항목(Ⅱ)에 인가되는 k 시점에서의 제어입력값을 각각 나타낸다.

위와같이 신경회로망을 사용하여 플랜트의 입출력 값만으로 모델링하여 얻을 수 있는 장점은 다음과 같다.

- 1) 임의의 초기값을 갖는 조정대상 플랜트의 모델링이 간편해진다.
- 2) 임의의 한 제품에 대한 입출력값을 직접 학습에 사용하므로 조정팁과 가변소자 사이의 백래쉬를 쉽게 반영할 수 있다.

일반적으로 신경회로망을 실 시스템에 적용할 때에는 학습시간이 오래걸린다는 점이 문제로 되고 있다. 그러나 이점은 앞절에서와 같이 첫째, 실 시스템에서 임의의 한 제품에 대해 임의의 입력값을 발생시켜 보편적인 주변환경에 대한 학습을 실행한 후, 둘째, 제어신호가 발생할 때마다 자동조정과 동시에 조정대상 제품 고유의 환경에 대처하도록 신경회로망을 학습하므로 자동조정작업 중에 필요로 하는 학습양을 감소시켜 극복할 수 있다.

3. 의사결정

제어동작을 실행하여 자동조정한 것은 현재의 플랜트 상태에 대한 정보에 기준하여 정해진 목표에 도달하는데 필요한 제어량을 발생하는 것과 발생시킨 제어량에 의한 플랜트 출력과 기대한 결과와의 차이에 적응하여 새로운 제어량을 발생하는 추론작업의 연속이다. 따라서, 제어량 발생과 적응에 각각 패턴인식과 학습기능이 있는 신경회로망을 사용하면 제어기의 동작목표가 설계자에 의해서 고정되고 정의되는 기존의 제어방식에서 얻을 수 없었던 지능제어를 수행할 수 있게된다. 플랜트의 역함수가 모델링될 수 있으면 식(3)에 의해 제어량을 발생시킬 수 있으므로 신경회로망제어기는 우선 플랜트의 역함수를 학습하여야 한다. 이를 한 제품에 대해 실행하여 보편적인 플랜트 역함수를 학습하여 자동조정시 신경회로망 제어기(NNC)의 초기값으로 사용한다. 이와같이 학습된 신경회로망 제어기는 현재의 플랜트 상태에 대한 정보에 기준하여 정해진 목표에 도달하는데 필요한 제어량을 발생시킬 수 있으나 이는 동작목표를 학습하여 정의하였을 뿐이므로 학습에 사용된 데이터에 의해 동작목표가 고정되어 새로운 제품이 갖는 환경에 적응하는 기능을 충족시킬 수 없게된다. 즉, 그림8과 같이 구성된 자동조정 제어 시스템에서 신경회로

망 제어기(NNC)는 발생시킨 제어량에 의한 플랜트 출력과 예상한 결과와의 차이에 적응하는 추론기능이 있어야 한다. 이를 위해 NNC는 조정작업과 함께 새로운 제품이 갖는 특성에 대처하기 위한 온라인 학습을 수행한다. NNC가 학습하기 위해서는 교사신호가 필요한데 이를 위해서는 플랜트 출력값에서의 차이를 제어량의 차이로 투사하는 방법이 있어야 한다. 플랜트의 자코비안을 알면 플랜트를 신경회로망에 추가된 또하나의 층으로 보고 이를 구할 수 있으나^[6] 그렇지 않은 경우 플랜트의 미분값을 구하지 않고 신경회로망 에뮬레이터를 통해 출력에서의 오차를 후향 전달하는 방법^[9]을 사용할 수 있다. 신경회로망 제어기의 초기하중 벡터를 결정하기 위해 조정항목(Ⅱ)의 경우는 $u_k = Nc^1 [y_k, y_{k-1}]$ 로, 조정항목(Ⅲ)의 경우는 $u^1_k = Nc^1 [y^1_{k-1}, y^2_{k-1}]$ 로, 조정항목(Ⅱ)가 조정항목(Ⅲ)에 종속된 경우는 $u^1_k = Nc^1 [y^1_{k-1}, y^2_{k-1}]$, $u^2_k = Nc^2 [y^{11}_k, y^{12}_k, y^{21}_k, y^{22}_k]$ 로 각각 표현되는 신경회로망 제어기를 구성하여 임의의 한 제품에 대

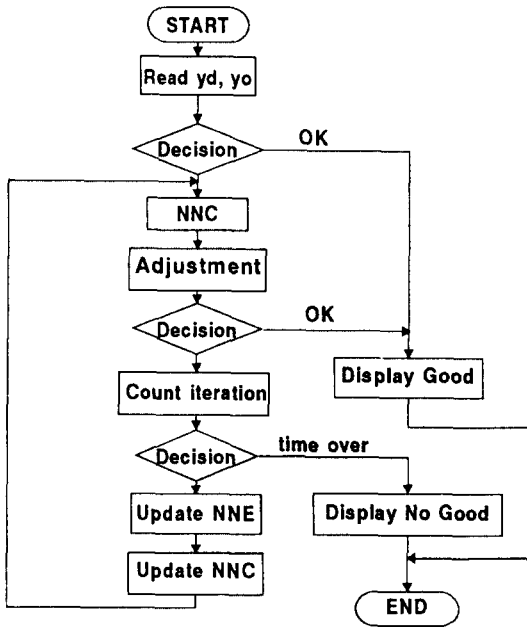


그림 10. 자동조정 시스템의 지능형제어의 흐름도
Fig. 10. Flowchart for intelligent control of computer aided adjustment system.

해 학습시키며 이와같이 학습된 신경회로망 제어기와 앞절 에서와 같이 학습된 신경회로망 에뮬레이터를 사용하여 그림8의 제어구조에서 지능제어하기 위한 흐름도는 그림10과 같다.

Ⅳ. 실험 및 결과고찰

1. 최소값으로의 조정

그림3과 같이 표시되는 플랜트의 출력을 임의의 초기값에 대하여 최소값이 되도록 자동조정하는 문제는 일반 탐색알고리즘^[10]을 수행하여 해결할 수 있으나 기계류와 결합되어 있는 시스템이므로 조정팁과 피조정 단자 사이에 발생하는 백래쉬를 고려해야 하므로 이를 보상하지 않은 경우와, 경험에 의한 일정값으로 보상 및 신경회로망의 학습기능으로 보상을 한 세가지 경우에 대해 실제 시스템에서 실험하였다. 경험에 의한 값으로 보상을 한 값은 8000pulse이었으며, 신경회로망을 사용했을때는 3.1절에서 언급한 대로 임의의 제품에 대한 사전학습에서 5131pulse를 보상하도록 학습되었다. 100회의 임의 초기값에 대한 자동조정작업을 하였을 때 플랜트 출력값의 분포는 표1과 같이 나타났으며, 플랜트 출력에 대한 조정작업수는 그림 11과 같다. 표 1에서 1%이내인 경우 보상을 받은 경우가 가장 좋은 결과를 보이니 이는 항상 보장받을 수 있는 결과가 아니기 때문에 무시할 수 있다. 그림12는 이를 누적된 값으로 표시한 것이며, 신경회로망으로 백래쉬를 보상을 한 경우 다른 방법에 비해 더 많이 최소값에 가깝게 자동조정할 수 있음을 보여준다. 이때 사용한 신경회로망에는 10개의 뉴런을 갖는 하나의 중간층만을 사용하였다.




그림 11. 조정후 플랜트출력에 대한 조정작업의 분포

Fig. 11. Distribution of work for plant output after adjustment.

표2는 100번의 조정작업을 했을 때 조정완료에 사용된 조정팁의 조정횟수와 조정작업의 분포를 나타내며 세가지 경우 모두 평균 9회만에 조정을 완료함을 알 수 있다.

2. 주변환경 변화에 대한 적응




그림 12. 조정후 플랜트출력에 대한 조정작업의 누적분포

Fig. 12. Cumulative distribution of work for plant output after adjustment.

표 1. 조정완료된 플랜트출력과 플랜트 최소값의 관계 분포

Table 1. Distribution of relation between minimum value & plant output.

보상방법	1%이내	2%이내	3%이내	4%이내	5%이내	6%이내
신경회로망	22	69	87	97	100	100
경험	13	50	74	95	100	100
보상 없음	28	60	78	83	92	100

표 2. 필요한 조정횟수와 조정작업의 관계 분포
Table 2. Distribution of relation between adjustment work & command needed.

보상방법	6회	7회	8회	9회	10회	평균
신경회로망	0	13	11	40	32	4
경험	0	16	10	37	32	5
보상 없음	2	3	20	38	33	4

조정대상 플랜트가 임의의 초기치 출력을 갖는 것을 주변환경의 변화로 보고 식(4), 식(6) 및 식(7)과 같이 조정대상 플랜트를 각각 신경회로망으로 모델링 하였을 때 임의로 선택한 100개의 입출력 패턴에 대해 출력에서의 평균제곱오차(MSE)가 학습이 진행됨에 따라 변하는 추이를 관찰하였다. 식(4)로 모델링된 경우 두개의 입력과 하나의 출력을 가지는 신경회로망에서 그림5의 데이터에 근거하여 입출력 패턴을 선정하였으며, 식(6)의 경우 세개의 입력과 두개의 출력을 가지는 신경회로망에서 식(7)인 모델에서는 네개의 입력과 하나의 출력을 가지는 신경회로망에서 그림7의 데이터에 근거하여 입출력 패턴을 선정하였다. 학습이 진행됨에 따른 각 신경회로망의 하중공간(weight space)에서의 MSE평면이 변화하는 추이를 시각적으로 관찰하기 위해 임의로 선택한 두개의 하중에 대한 MSE평면을 검토하였다. 표 3은 초기상태와 5만회, 20만회, 30만회 학습시켰을때 나머지 하중

들은 고정시키고 임의로 선택한 두개의 하중만을 변화시켰을때의 MSE값의 변화를 수치로 나타내며 30만회 학습한 뒤에는 각각 0.036464, 0.007028, 0.000002로 감소하였다.

3. 의사결정

그림8과 같이 구성하여 자동조정할 때 현재의 플랜트 상태에 대한 정보에 기준하여 정해진 목표에 도달하는데 필요한 제어량을 발생시키기 위해 신경회로망 제어기에 플랜트의 역함수를 학습시켰다. 임의로 선택된 한 제품에 대해 3.3절 예사와 같이 각 경우에 따라 신경회로망 제어기를 학습시켰을 때, 100개의 입출력 패턴에 대한 MSE는 학습횟수에 따라 표4와 같이 나타났다.

표 3. 학습횟수에 따른 NNE의 MSE 값

Table 3. MSE value of NNE with iterations of learning.

	학 습 횟 수			
	초기상태	5만회	20만회	30만회
N_c^0	0.719591	0.325956	0.041018	0.036464
N_c^1	4.678664	0.168392	0.012781	0.007028
N_c^2	0.778517	0.000475	0.001519	0.000002

표 4. 학습횟수에 따른 NNC의 MSE값

Table 4. MSE value of NNC with iterations of learning.

	학 습 횟 수			
	초기상태	5만회	20만회	30만회
N_c^0	21.71775	0.042067	0.005601	0.002816
N_c^1	42.73894	0.349318	0.070409	0.060846
N_c^2	1.508662	0.317324	0.096956	0.059236
N_c^3	0.501366	0.000575	0.000064	0.000041

이와같이 학습된 신경회로망 제어기는 조정작업 때마다 새로운 주변환경과 왜란을 가지고 인가되는 플랜트에 적응하기 위해서 3.3절의 알고리즘에 의해 학습과 조정을 동시에 수행한다. 500개의 새로운 제품을 계속 인가하여 조정작업을 수행했을 때의 결과가 그림13, 그림14, 그림15와 같다. 그림13의 결과는 그림5의 직접 목표값을 주는 경우에 대한 소요 조정작업의 횟수를 나타내며 평균 소요횟수는 3.222회이며, 그림14의 결과는 그림7에서 두값의 차이가 목표값으로 주어진 경우에 대한 소요 조정작업 횟수를 나타내는데 평균 소요횟수는 4.104회 이다.




그림 13. 조정항목(Ⅱ)에서 신경회로망을 사용한 경우 조정에 소요된 횟수

Fig. 13. Iterations needed for adjustment in case of using Neural Network for item(Ⅱ).






그림 14. 조정항목(Ⅲ)에서 신경회로망을 사용한 경우 조정에 소요된 횟수

Fig. 14. Iterations needed for adjustment in case of using Neural Network for item(Ⅲ).



(a)



(b)

그림 15. 상호 종속인 때 신경회로망을 사용한 경우 조정에 소요된 횟수

(a) 조정항목(Ⅱ) (b) 조정항목(Ⅲ)

Fig. 15. Iterations needed for adjustment in case of using Neural Network for two dependent plants.

(a) Item(Ⅱ) (b) Item(Ⅲ)

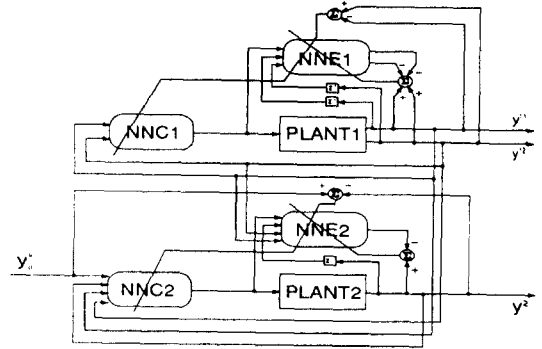


그림 16. 신경회로망을 사용한 상호종속인 조정 대상 플랜트의 폐루프 제어 블록선도

Fig. 16. Block diagram of a closed loop control for two dependent plants using Neural Network.

그림15는 앞의 두 경우의 조정항목이 순위를 가지고 수행되는 상호종속인 경우의 소요 조정작업 횟수를 나타내며 평균 소요 조정작업 횟수는 조정항목(Ⅱ)인 경우 6.592회, 조정항목(Ⅲ)의 경우 3.381회이다. 그림16은 이때의 자동조정 블록선도를 보여준다. 그림 16에서 PLANT1은 조정항목(Ⅲ)을 나타내고 PLANT2는 조정항목(Ⅱ)를 표시하며 조정항목별로 신경회로망 에뮬레이터와 신경회로망 제어기가

각각 부가되어 있음을 알 수 있다.

V. 결론

본 논문에서는 자동조정장치의 지능제어를 위한 신경회로망 응용에 관한 연구결과를 제시하였다. 조정 작업의 특성에 따라 각각의 플랜트에 대한 페루프 제어계를 구성하여 제어법칙을 수립, 컴퓨터로 제어하였다. 자동조정장치에 요구되는 지능제어를 정의하였으며 자동조정의 목표가 1) 상태인 경우, 2) 목표값인 경우, 3) 목표값이며 두 플랜트가 상호 종속인 경우 등에 대한 신경회로망을 응용한 지능제어를 시뮬레이션과 실제 시스템에의 적용이 검토되었다. 본 연구에서 제안된 방법으로 자동조정장치를 지능제어하여 얻은 결론은 아래와 같다.

- 1) 신경회로망 에뮬레이터를 사용하여 자동조정 대상 플랜트가 모델링 된다.
- 2) 임의의 초기 플랜트 출력값이 주변 환경변화로 고려된다.
- 3) 신경회로망을 이용한 지능제어에 의해 기계류와 결합되어 있는 계통에서 혼한 백래쉬가 용이하게 고려된다.
- 4) 신경회로망을 이용하여 작업자의 추론과정을 재현하도록 학습시킨다.

끝으로 신경회로망 에뮬레이터와 신경회로망 제어기의 사전학습에 소요되는 시간을 단축시킬 수 있는 학습 알고리즘에 대한 연구가 더욱 요망됨을 밝힌다.

参考文献

- [1] C.S.Draper, "Control, navigation, and guidance," *IEEE Control Systems Magazine*, pp.4-7, Dec. 1981
- [2] "Challenge to control : a collective view. Report of the workshop held at the University of Santa Clara on September 18-19, 1986", *IEEE Transactions of Automatic Control*, vol. AC-32, no.4, pp. 275-285, April, 1987
- [3] Behnam Bavarian, "Introduction to Neural Networks for Intelligent Control," *IEEE Control Systems Magazine*, pp.3-7, April, 1988
- [4] 김형철, 오학서, 김성권, "범용 검사 조정 제어기 구현," '92 로보틱스 및 자동화 연구회 워크샵 논문집, pp.56-59, 1992
- [5] Yukimichi Okamura, Yoshihiro Yatabe, Isao Saso, Hiroshi Kasai, Norikazu Takatori, "Automatic Adjustment and Test System for Television Receivers", *National Technical Report*, vol.36, no.2, pp.65-72, April, 1990
- [6] Lippmann, R. P., "An introduction to computing with neural nets," *IEEE ASSP Magazine*, pp.4-22, April, 1987
- [7] Rumelhart, D.E., McClelland J.L. and the PDP Research Group, "Parallel distributed processing, explorations in the microstructure of cognition, Vol.1: Foundations," A Bradford Book, Cambridge, Mass., and London, 1986
- [8] Demetri Psaltis, Athanasios Sideris, and Alan A. Yamamura, "A Multilayered Neural Network Controller," *IEEE Control Systems Magazine*, pp.17-21, April, 1988
- [9] Marzuki Khalid and Sigeru Omatu, "A Neural Network Based Control Scheme With An Adaptive Neural Model Reference Structure," *Proc. of IEEE IJCNN '91 S'pore*, pp.2128-2133, 1991
- [10] S. S. Rao, Optimization theory and applications, *John Wiley & Sons*, 1984, pp.214-255

著者紹介



具泳謨(正會員)

1961年 3月 7日生. 1984年 2月 연세대학교 전기공학과 졸업(B. S.). 1986年 2月 연세대학교 대학원 전기공학과 졸업(M. S.). 1988年 3月 ~현재 연세대학교 대학원 전기공학과 박사과정 재학 중. 주관심 분야는 지능형 제어, 신경회로망의 응용 등임.



李榮敏(正會員)

1961年 5月 10日生. 1984年 2月 연세대학교 전기공학과 졸업(B. S.). 1986年 2月 연세대학교 대학원 전기공학과 졸업(M. S.). 1986年 3月 ~현재 삼성전자 생산 기술본부 근무. 주관심 분야는 자동화 생산 시스템 등임.



李昇求(正會員)

1967年 11月 8日生. 1990年 2月 연세대학교 전기공학과 졸업(B. S.). 1992年 8月 연세대학교 대학원 전기공학과 졸업(M. S.). 1992年 9月 ~현재 금성사 생활시스템 연구소 연구원. 주관심 분야는 신경회로망의 응용, 자동화 기기 설계 등임.



禹廣芳(正會員)

1934年 1月 25日生 1957年 연세대학교 이공대 전기공학과 졸업. 1964年 미국 Oregon 주립대학교 대학원 전기공학과 졸업(공학박사). 1960年 미국 와싱턴 대학교 (St. Louis) 전기공학과 조교수. 1971年 미 국립암연구소 책임 연구원. 1979年 미국 The Johns Hopkins 대학교 의대 연구원. 1985年 Tokyo 대학 객원 연구원. 1980年, 1981年 재미 한국과학기술자 협회장. 현재 연세대학교 공대 전기공학과 교수. 주관심 분야는 지능형 제어, Discrete Event Dynamic Systems, 자동화 생산 시스템 등임.