

신경회로망을 이용한 제어기 설계기술



이 원 창

(부산수산대학교 전자공학과)

- '79-'83 서울대학교 공과대학 제어계측과(학사)
 '83-'85 한국과학기술원 전기 및 전자공학과(석사)
 '88-'92 포항공대 전자전기공학과(박사)
 '85-'88 한국표준과학연구원 연구원
 '93-현재 부산수산대학교 전임강사



김 일 환

(KIMM 자동화연구부)

- '78-'82 서울대학교 공과대학 제어계측과(학사)
 '85-'88 서울대학교 공과대학 제어계측과(석사)
 '89-'93 일본 동북대학 기계공학과(박사)
 '82-현재 한국기계연구원 선임연구원



정 광 조

(KIMM 자동화연구부)

- '73-'77 연세대학교 공과대학 전기공학과(학사)
 '81-'83 연세대학교 공과대학 전기공학과(석사)
 '91-'94 경남대학교 전기공학과(박사)
 '79-'83 한국과학기술원 연구원
 '83-현재 한국기계연구원 선임연구원

1. 서 론

최근에 들어서서 기존의 방법으로 풀기 어려운 문제들을 해결하는 한 방법인 지능을 갖는 시스템에 대한 관심이 높아지고 있다. 이러한 시스템에서 중요한 역할을 하는 것이 신경회로망(neural network)으로서 이에 대한 연구가 정보처리의 새로운 수단으로서 활발히 연구되고 있다. 여기서 일컫는 신경회로망이란 생물의 뇌신경조직을 수학적인 모델로 모방한 것으로 뇌의 뛰어난 특징, 예를 들면, 정보의 병렬처리, self-organization 능력을 이용하고자 하는 목적으로 고안된 것이다. 신경회로망은 많은 선형 혹은 비선형 신경세포 모델이 연결되어 있어서 정보의 병렬처리가 가능하여 빠른 속도로 계산을 수행할 수 있으며, 학습을 할 수 있다는 장점을 가지고 있다. 또한 신경회로망은 데이터의 변화에 적응할 수 있으며, 입력과 출력간의 mapping을 학습할 수 있다. 이러한 점과 신경회로망의 비선형성으로 인해 신경회로망은 임의의 함수를 근사화하는데에도 적용된다.

신경회로망의 역사를 간단히 살펴보면 다음과 같다. 1960년대 초반에 Rosenblatt가 Perceptron을 [1], Widrow와 Hoff가 Adaline을 학습시스템의 하나의 설계안으로 발표하였다[2]. Perceptron은 처음 발표되었을 때 개념이 간단하여 상당한 반응을 불러 일으켰으나, Minsky와 Papert가 Perceptron은 복잡한 논리 함수에 적용될 수 없다는 것을 수학적으로 증명함으로 인하여 관심밖으로 밀려나게 되었다[3]. 한편 LMS(least mean square) 알고리즘을 사용하는 Adaline은 적응신호처리 및 적응제어에 응용되었다. 1970년대에서는 신경회로

망에 대한 연구가 활발하지 않았으나 Grossberg에 의해 ART(adaptive resonance theory)가 개발되었고 [4], Kohonen에 의해서 self-organization에 대한 연구가 발표되었다[5]. 또한 Albus는 CMAC(cerebellar model articulation controller)를 개발하였다 [6]. 한편 1970년대에 Werbos는 이미 다층 perceptron(back-propagation 신경회로망)에 대한 학습 알고리즘인 역전달 알고리즘(back-propagation algorithm)을 독자적으로 개발하였으나[7] 이공학분야에는 잘 알려지지 않았다. 그러던 중 1980년대에 들어서 Rumelhart 등에 의하여 이 역전달 알고리즘이 재발견되면서 perceptron에 대한 관심이 다시 높아지게 된다[8]. 이 역전달 학습 알고리즘을 갖는 다층 perceptron은 dynamic system에 가장 많이 적용되고 있다고 할 수 있다. 이외는 달리 Hopfield는 recurrent-type 신경회로망을[9], Kosko는 BAM(Bidirectional Associative Memory)을 개발하였고[10] Hinton등은 Boltzmann machine을 발표하였다[11]. 이러한 1980년대의 활발한 연구는 신경회로망에 대한 관심을 급격히 고조시켜서, 여러분야에 대한 응용예가 수많은 논문을 통해 발표되었고 또한 일부 실용화되었다.

신경회로망은 패턴인식, 영상인식, 음성인식, 최적화 등에 널리 응용되어 왔으며 제어분야도 예외는 아니다. 최근의 제어분야에서는 자동제어 이론과 기술이 발달함에 따라 많은 분야에서 이러한 이론들이 중요한 역할을 해 왔다. 그러나, 적용대상이 점점 복잡해짐에 따라 제어이론도 또한 진보되어왔고 학습이 가미된 제어이론도 등장하였으나 그 적용성의 한계가 없을 수 없었다. 예를 들자면 학습이 가미된 제어 이론인 MRAC(model reference adaptive control)이나 STR(self-tunning regulator) 같은 적용제어의 경우에는 이론적으로는 uncertainty가 많은 시스템에 적용이 가능하지만, 미지의 parameter수의 증가에 따라 계산량과 복잡도가 엄청나게 증가한다는 점, 안정성 문제, 광범위한 uncertainty에 대한 강인성(robustness) 문제 및 비선형 시스템에 대한 적용이 용이하지 못한 점 등은 현장에 적용하는데 장애가 되었고, 아직도 완전히 해결된 상태는 아니다. 뿐만 아니라 여러 시스템들이 연결되어 있는 아주 복

잡한 실제 시스템인 경우는 제어이론의 적용만으로 만족할 만한 결과를 얻는다는 것은 쉬운 일이 아닐 것이다. 이러한 점에 비추어 볼 때 신경회로망을 제어시스템에 응용하고자 하는 시도는 당연한 귀결이 아닌가 생각된다. 왜냐하면 신경회로망은 자체의 비선형성, 학습능력, mapping능력 등으로 인해 제어시스템의 비선형성, uncertainty을 처리할 수 있으며, 시스템 identification 등과 같은 합수근사화에도 적용이 가능하기 때문이다. 신경제어기의 장점을 요약하면 다음과 같다.

- 플랜트나 주위 환경에 대한 모델의 불필요
 - 시스템의 identification과 학습으로 제어기의 성능 개선이 가능
 - 비선형성과 uncertainty의 처리
 - 플랜트나 환경의 변화에 적용 가능
 - 잡음(noise)에 강인한 구조
 - 정보의 분산으로 인한 fault tolerance
 - 병렬처리에 의한 real-time 제어 가능
 - 학습이 되지 않은 부분에 대해서도 interpolation이 가능한 일반화 특성
- 제어시스템에 대한 신경회로망의 응용은 제어시스템의 구조에 따라 몇 가지로 크게 나누어질 수 있으며 이를 중점적으로 소개하고자 한다.

2. 신경회로망 모델

생물학적인 뇌의 구조를 살펴보면 수 많은 신경세포들이 서로 연결되어 하나의 네트워크를 구성하여 여러가지 지능적인 활동을 하게 된다. 인공적인 신경회로망도 이를 모방하여 신경세포 모델을 어떠한 형태로든 연결하여 구성된다. 신경회로망의 구성 형태는 여러가지로 분류될 수 있겠으나 일반적으로 크게 나누어 recurrent와 feedforward형 두 가지로 나누어질 수 있다하겠다. 이 장에서는 대표적인 recurrent형인 Hopfield net와 feedforward형 중 가장 흔히 쓰이는 CMAC, 다층 perceptron에 대해 설명하고자 한다.

2.1 다층 perceptron

그림1(a)는 다층 perceptron의 구조로서 입력층

(input layer), 출력층(output layer) 및 내부층(hidden layer)으로 이루어져 있다. 그림에서 보는 바와 같이 뉴런간의 연결은 단지 순방향으로만 되어 있다. 이 신경회로망의 내부층(hidden layer)과 출력층(output layer) 뉴런의 구조는 그림 1(b)와 같으며 뉴런의 입출력은 식(1)을 만족한다.

$$y_i = f(\sum_{j=1}^n w_{ji} x_j - \theta)$$

여기서 함수 f 로는 다음 두 가지가 주로 사용된다.

$$\text{sigmoid함수 : } f(x) = \frac{1}{1+e^{-x}} \quad (0 < f(x) < 1)$$

$$\tanh\text{함수 : } f(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (-1 < f(x) < 1)$$

또한 입력과 출력 뉴런은 외부와 직접 연결되어 있고, 내부에 위치한 뉴런은 그의 입력이나 출력이 외부와 직접적으로 연결이 되어 있지 않다.

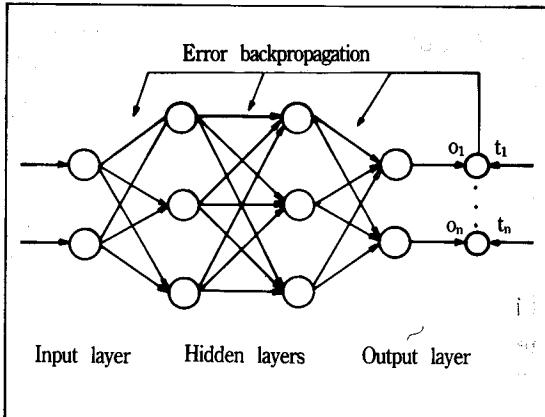


그림 1(a) 다층 perceptron 신경회로망의 구조

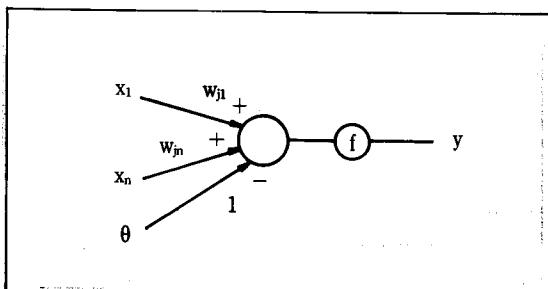


그림 1(b) 뉴런 모델

이 다층 perceptron의 학습을 위해 사용되는 것이 바로 최소자승법(least mean square)을 일반화한 역전달 알고리즘(back-propagation algorithm)으로 서로 연결된 뉴런간의 연결 weight를 신경회로망의 출력과 원하는 출력과의 오차를 이용하여 적절히 조절하는 방법이다. 서론에서도 언급한 바와 같이 이 학습 알고리즘이 일반적으로 많이 쓰이기 시작한 것은 Rumelhart 등에 의해서이다[8]. 하지만 이 방법은 항상 global minimum에 수렴한다고 보장할 수 없으며[26], 수렴시간이 많이 걸린다는 단점을 안고 있어서 이러한 문제를 해결하기 위한 연구 또한 진행되어 왔다. 고 밖의 다른 문제점으로서는 내부층(hidden layer)의 갯수 및 각 층의 뉴런의 수를 어떻게 하면 효과적으로 결정할 수 있는지에 대한 명확한 해결책이 아직 제시되지 않았다는 것이다. 하지만 perceptron에 내부층을 도입하고 나름대로 효과적인 학습방법을 고안함으로서 이 신경회로망이 아직도 여러 분야에서 널리 쓰이고 있다.

2.2 CMAC(Cerebellar Model Articulation Controller)

이 신경회로망은 Albus[6]에 의해 제안된 인간의 기억작용에 대한 모델로서 다른 신경회로망과 달리 table-look-up 구조로 되어 있다. 그림 2에서 보는 바와 같이 CMAC의 기본구조는 $S \rightarrow A \rightarrow A' \rightarrow F$ 의 연속된 mapping으로 되어 있다. 입력공간 S의 점들이 A메모리의 몇 개의 주소로 mapping이 된 후, 메모리의 크기를 줄이기 위해 A에서 A'으로 random hash coding 한다. 그 다음 축소된 메모리 A'에 저장된 값을 합하여 출력을 낸다. CMAC의 학습은 출력이 원하는 결과가 나오도록 A'메모리에 저장된 값을 변화시키는 것이다.

2.3 Hopfield Net

이 신경회로망은 Hopfield[8]에 의해 제안된 것으로 recurrent형의 대표적인 것이다. 그림 3에서 보는 바와 같이 feedforward형과는 달리 뉴론들이 서로 연결되어 있다는 점이다. 이 신경회로망은

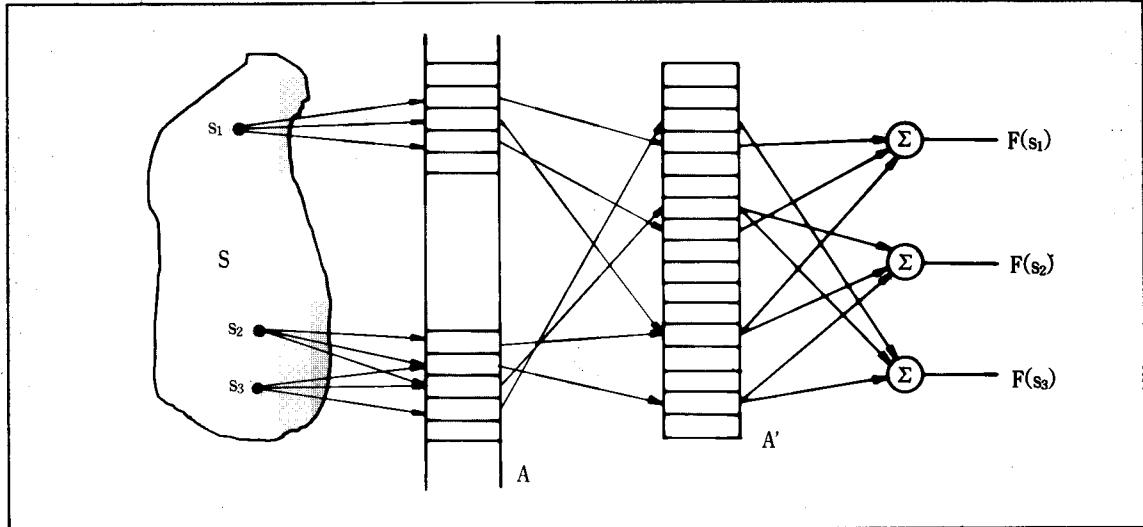


그림 2. CMAC mapping 구조

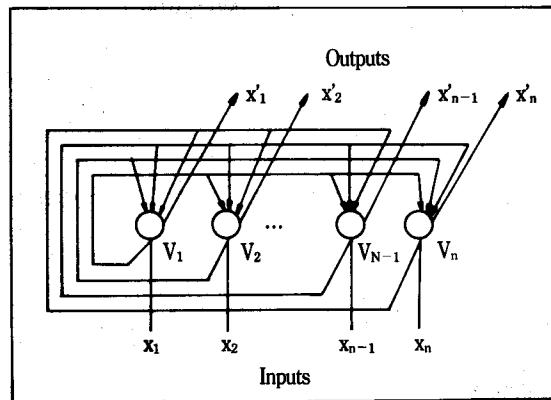


그림 3. Hopfield Network

Hopfield 자신이 Traveling Salesman Problem에 적용을 하였으며 주로 최적화 문제에 주로 응용이 되고 있다[12].

3. 신경제어기(Neurocontroller)의 종류

신경회로망은 기본적으로 비선형이며 학습이 가능할 뿐만 아니라 병렬처리능력이 있기 때문에 이를 제어분야(일종의 지능제어)에 응용하고자 하는 많은 노력이 기울여져 왔다. 이들은 몇 가지로 크게 나눌 수 있으나[13], 그 중에서 supervised control, inverse control, neural adaptive control에 대해서 설명하고자 한다. 아울러 2장에서 소개된

신경회로망의 몇 가지 모델중 제어시스템에 가장 널리 쓰이는 것이 역전달 학습 알고리즘을 갖는 다층 perceptron이라는 점을 밝혀 두고자 한다.

3.1 Supervised Control

이 제어방식에서 신경회로망은 센서입력으로부터 원하는 동작까지의 mapping을 주어진 training set를 사용하여 학습한다. 이러한 시스템을 처음 사용한 예는 1960년대의 broom balancer였으며[14], Guez등은 보다 발전된 복잡한 방식을 제안하였다[15]. 최근에는 인간의 기술을 모델링하여 이를 teaching data로 사용하여 신경회로망이 이를 모방하도록하는 방식을 로보트 등에 적용한 예가 보고되고 있다[16]. 그림 4는 supervised control의 한 형태를 나타낸 것이다.

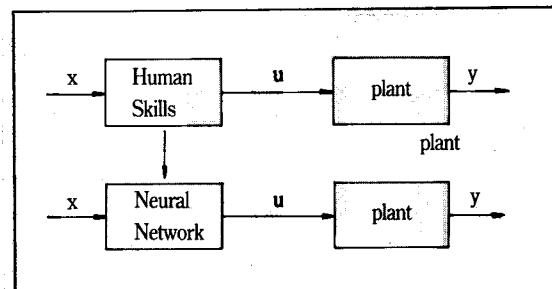


그림 4. Supervised control

3.2 Inverse Control

이 방식에서 신경회로망이 제어대상 시스템의 inverse dynamics를 학습하는 역할을 하며 제어 루프에 사용되기도 하고, 신경제어기가 다른 방법에 의해 직접 설정되기도 한다[17]. Inverse control은 직접방식과 간접방식으로 분류될 수 있으며 직접방식은 안정성 등의 문제로 인해 복잡한 전처리 과정들을 거쳐야 하는 단점이 있으나 사용하기가 쉬운 반면, 간접방식은 직접방식에 비해 구조가 조금 복잡하지만 전처리 과정이 필요없다는 장점이 있다. 그림 5는 간접 inverse 제어기의 구조이며, 직접 inverse 제어기의 구조는 그림 9와 유사하다.

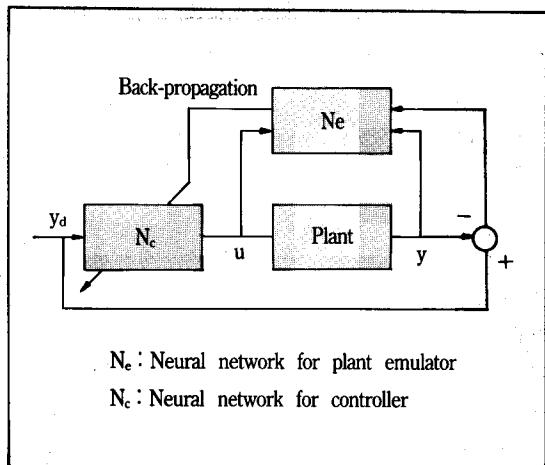


그림 5. 간접 inverse 제어

3.3 Neural Adaptive Control

이러한 제어방식은 일반적인 적응제어의 문제점을 개선해 보고자하는 의도에서 출발한 것으로, 신경회로망은 다른 신경제어방식과 마찬가지로 주어진 mapping을 대신하는데 사용된다. 이 방식에서 지금까지 사용된 형태는 model reference adaptive control에 기초를 둔 것[18]과 self-tunning regulator에 초점을 맞춘 형태[19] 두 가지로 나눌 수 있으며 그림 6과 그림 7은 두 가지의 블럭도이다.

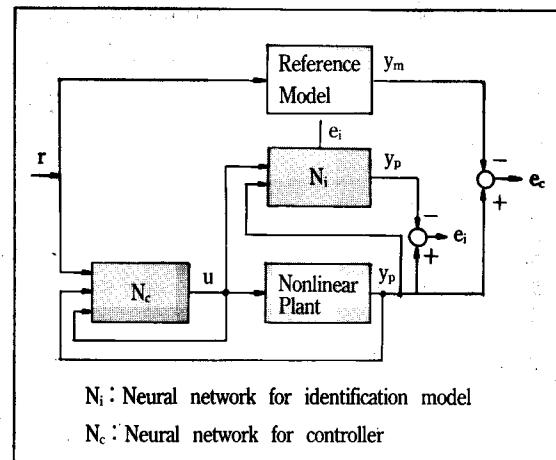


그림 6. MRAC형의 neural adaptive controller

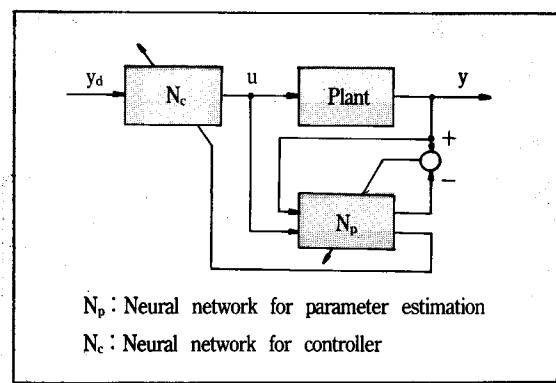


그림 7. STR형의 neural adaptive controller

4. 신경제어기의 학습방법

신경제어기의 학습방법은 크게 나누어 supervised learning과 unsupervised learning이 있다. 입력과 이에 상응하는 원하는 출력값들의 training set를 주어 학습시키는 경우가 전자이고, 원하는 출력값을 모르는 경우 단지 어떤 보상함수를 최대화하는 방향으로 신경회로의 각 뉴런간의 연결 weight를 변화시키는 경우가 후자이다. 이 장에서는 적용예가 더 많은 supervised learning의 몇 가지 학습방법에 대해 설명하고자 한다[17].

4.1 일반 학습방법(General Learning)

이 방법은 신경회로망이 플랜트의 inverse dyna-

mic model을 구성하도록 하는 것이다. 그림 8에서 보는 바와 같이 신경회로망의 학습과정은 플랜트의 입력을 다양하게 바꿔가면서 플랜트의 출력을 신경회로망의 입력으로 사용하여, 플랜트의 입력 u 와 신경회로망의 출력 u_n 과의 오차 e^o 을 최소화하는 방향으로 진행된다. 일단 학습이 끝나면 신경회로망의 뉴런간의 연결 weight는 고정이 되고, 신경회로망은 플랜트 앞에 위치하여 제어기로 사용되게 된다. 이 방식의 성공 여부는 학습과정에서 사용되어지지 않았던 입력에 대한 신경회로망의 적용 능력에 크게 좌우된다. 한편 이 방법을 사용할 경우의 문제점으로는 플랜트의 원하는 출력에 대응하는 입력을 알 수 없기 때문에 원하는 영역에 국한해서 시스템을 훈련시킬 수가 없다는 점, 학습과정이 off-line으로 이루어져야 한다는 점, 그리고 플랜트에 꼭 필요한 입력 데이터를 모르기 때문에 학습시에 불필요한 데이터가 많이 사용된다는 점 등을 들 수 있다.

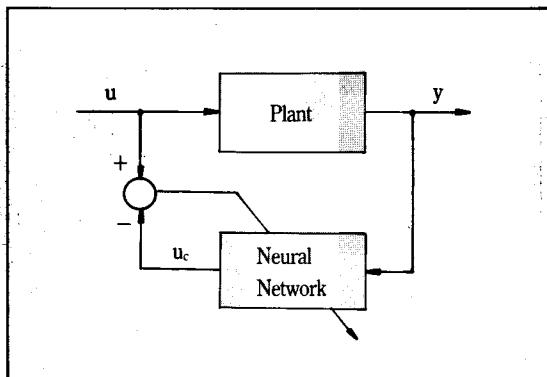


그림 8. 일반 학습방법

4.2 특정 학습방법(Specialized Learning)

그림 9과 같이 일반 학습방법의 문제점을 제거하기 위하여 feedforward 제어시에 on-line으로 신경회로망을 학습시킨다. 이 경우는 신경회로망의 입력이 reference 값이기 때문에 신경제어기는 원하는 동작범위 내에서 훈련이 가능하다. 학습 과정에 있어서는 플랜트의 출력이 reference 값에 근접하도록 신경회로망을 학습시킨다. 이 때 신경회로망의 weight들은 플랜트의 출력과 reference 값과의 오차가 가장 적어지도록 조정된다. 이 방

법에서 다층 perceptron을 사용한다면 신경회로망의 학습을 위해서 플랜트에 대한 사전정보 즉 weight들에 대한 적절한 초기치가 필요하다. 만일 이 값들이 준비되어 있지 않다면 초기 학습과정에서 전체 시스템이 불안정하게 될 수가 있기 때문이다. 따라서, 먼저 일반 학습방법으로 학습을 시켜서 weight들에 대한 정보를 얻은 다음 특정 학습방법으로 fine-tunning하는 것이 좋은 방법이라 하겠다.

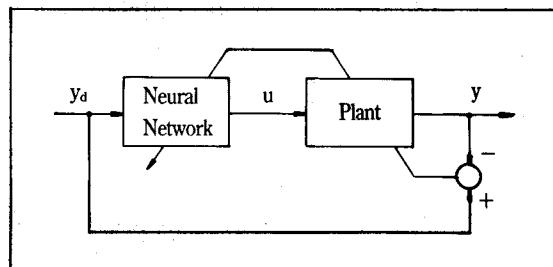


그림 9. 특정 학습방법

4.3 궤환 오차 학습방법(Feedback Error Learning)

이 방식은 Kawato 등에 의하여 제안된 것으로 [20, 21], 그림 10에서 보는 바와 같이 신경회로망이 feedforward 제어기로 사용되고 있으며 궤환 제어기(feedback controller)의 출력으로 학습된다. Indirect inverse control에 속하는 이 방법의 가장 주된 문제점은 플랜트의 dynamic model을 잘 모르는 상태에서 신경회로망의 입력으로 reference 값을 사용하여 플랜트의 inverse dynamics를 신경회로망이 구현하도록 해야 한다는 점이다. 학습 후 실제 제어에 있어서 feedback loop는 계속 작용할 수도 있고 제거될 수도 있다.

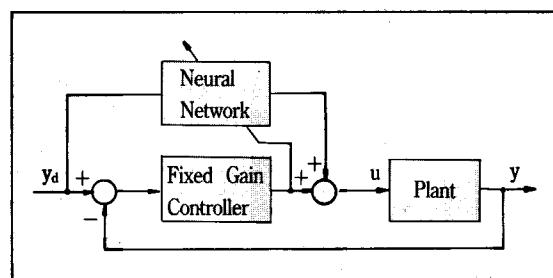


그림 10. 궤환 오차 학습방법

5. 로보트 분야의 신경제어기

이 장에서는 신경회로망이 로보트의 어떤 분야에 적용이 되고 있는지에 대해 소개하고자 한다. 신경회로망은 일반적인 자동제어 이론을 적용하는 것 보다는 훨씬 지능적인 제어를 가능하게 하는 효과적인 도구라고 할 수 있다. 따라서, 자동제어 이론만을 적용하였을 때에 만족할 만한 결과를 얻기가 힘든 비선형 시스템이나 전혀 정보가 주어져 있지 않은 black box 형태의 시스템등이 신경회로망을 적용하기 좋은 대상이 되며, 로보트가 이러한 시스템의 대표적인 예라고 볼 수 있다. 신경회로망은 다음과 같은 로보트의 분야에 응용될 수 있다.

- 위치 및 궤적 제어(Position/trajectory control)
- 힘 제어(Force control)
- 로보트 비전(Robot vision)
- 궤적계획(Path planning)
- 역기구학의 해(Solution to the inverse kinematics)

위에서 열거한 분야에 적용될 때 신경회로망은 전반적인 제어기로 사용되기도 하지만 uncertainty나 비선형성을 보상해 주는 보상기(compensator), 또는 시스템 identification을 위한 도구로 사용되어지기도 한다. 로보트 분야에 신경회로망을

사용한 예는 여러 학술지를 통하여 많이 발표되었으나, 일일이 다 소개할 수는 없으므로 그 중 몇 가지만 예를 들고자 한다.

5.1 CMAC을 이용한 로보트 제어

그림 11은 Miller 등에 의해 발표된 CMAC을 이용한 로보트 제어의 구조의 블럭도이다[22]. 여기서 CMAC 메모리가 CMAC 모델의 A' 메모리이며, CMAC function generation 모듈의 출력이 로보트의 inverse dynamics가 되도록 신경회로망을 학습시킨다.

5.2 Indirect inverse control을 이용한 로보트 제어

그림 12은 indirect inverse control 방법을 사용한 로보트 제어의 한 형태에 대한 블럭도이며[23], 이 경우 고정된 이득을 갖는 선형 제어기가 신경회로망과 함께 사용되고 있으며, 신경회로망이 dynamics를 가지게 하기 위해 time delay를 사용하는 경우도 있다. 이러한 형태의 제어기에서 신경회로망은 비선형성과 uncertainty를 보상해 주는 목적을 가질 수도 있지만 궁극적으로는 로보트의 inverse dynamics를 구현한다.

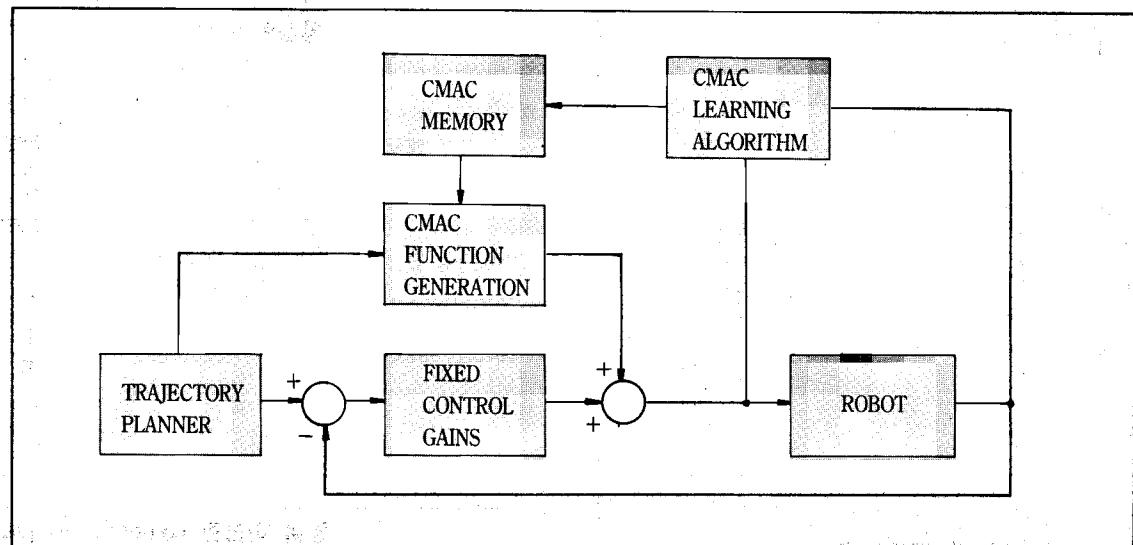


그림 11. CMAC을 이용한 로보트 제어

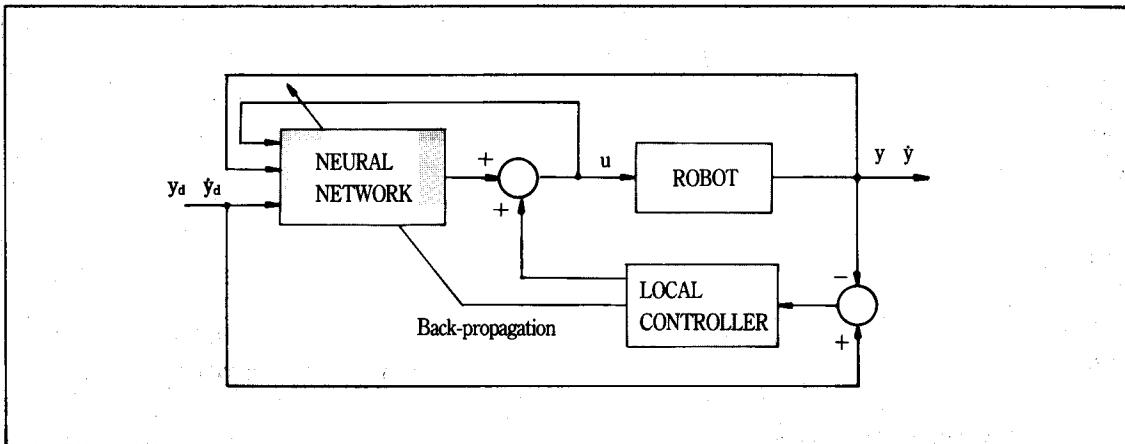


그림 12. Indirect inverse 제어기

5.3 신경회로망을 이용한 Hybrid 위치/힘 제어

로보트가 조립이나 deburring 작업 등과 같은 일을 할 때에는 위치, 궤적뿐만 아니라 로보트와 주위 환경 사이에 작용하는 힘의 제어도 필요하다. 힘 제어에 있어서는 주위 환경의 특성을 고려해야 하지만 uncertainty를 많이 포함하고 있기 때문에 그 모델링이 쉽지 않다. 이러한 점에서 신경제어기의 필요성이 제기된다. 그림 13은 힘 제어 방식 중의 하나인 Hybrid 위치/힘 제어에 신경회로망을 사용한 예를 블럭도이다[23, 24].

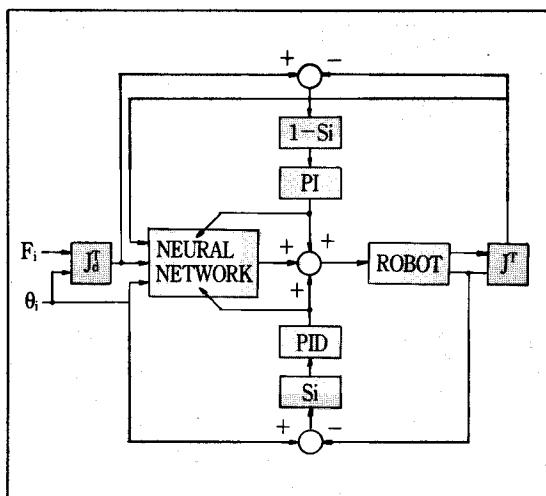


그림 13. Hybrid 위치/힘 제어용 신경제어기

5.4 로보트의 uncertainty의 보상을 위한 신경회로망

이 절에서 소개하고자 하는 것은 로보트의 제어에 computed torque 방법을 사용했을 때의 문제점을 신경회로망을 이용하여 보상하는 형태의 제어기이다. 로보트 매니퓰레이터의 dynamics는

$$\tau = M(\theta) \ddot{\theta} + h(\theta, \dot{\theta})$$

로 표현된다. 여기서 τ 는 조이트 토크, M 은 관성 행렬, h 는 원심력 및 코리올리항이다. 제어기로 computed torque 방법을 사용했을 때 estimated model인 \hat{M} 와 \hat{h} 가 참값인 M 과 h 와 일치한다면 원하는 대로 제어가 되지만, 일반적으로 uncertainty로 인해 그 값들은 일치하지 않아 오차가 발생한다. 그때, 그림 14과 같이 uncertainty를 보상해 주기 위해 신경회로망을 이용할 수 있다[25].

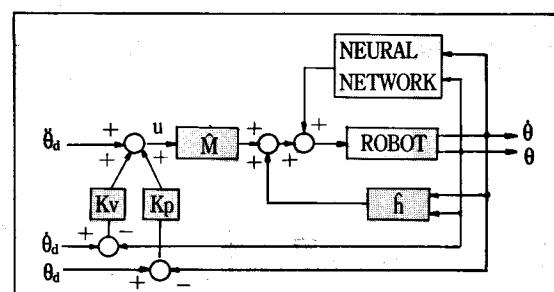


그림 14. 신경회로망을 이용한 computed torque 방법

6. 결론 및 향후의 전망

지금까지 신경회로망의 광범위한 응용 분야 중에서 제어에 어떻게 응용이 되는가를 간단히 살펴보았다. 신경회로망의 제어분야에 대한 응용은 소규모 제어 시스템으로부터 산업체 공정 제어 시스템에 이르기 까지 폭이 넓다고 하겠다. 그러나, 아직까지 상업적으로 사용된 예는 혼자 않고 주로 실험실 단계에서 실제 시스템에 적용이 되고 있는 실정이다. 그러나 다양한 학습 알고리즘과 소프트웨어의 등장, 특히 아날로그 및 디지털 신경회로망 chip의 개발 등은 신경회로망의 상업적 응용을 점점 더 용이하게 하고 있다고 볼 수 있다. 또한 최근에 들어서는 신경회로망에 전문가 시스템과 퍼지 등의 개념을 도입하여 서로의 장점을 적극 활용하고 단점을 보완하려는 연구가 활발히 진행되고 있으며, 현재 나름대로 좋은 결과를 보여 주고 있다. 이러한 연구들이 점점 더 발전하면, 종래의 제어 방식으로는 해결하기 힘들었던 문제들을 해결하고 기존의 제어 시스템을 보다 효율적으로 개선하는, 상당한 지능을 가진 제어기의 출현이 가능할지도 모른다.

참 고 문 현

- [1] F. Rosenblatt, "The perceptron : A probabilistic model for information storage and organization in the brain," *Psychological Rev.*, vol. 65, 1958.
- [2] B. Widrow and M. E. Hoff, Jr., "Adaptive switching circuits," Standford Electron Laboratory, Palo Alto, CA, Tech. Rep., 1960.
- [3] M. Minsky and S. Papert, *Perceptrons : The MIT Press*, 1969.
- [4] S. Grossberg, "Adaptive pattern classification and universal recording, II : Feedback, expectation, olfaction, and illusions," *Biol. Cybern.*, vol. 23, 1976.
- [5] T. Kohonen, "Self-organization formation of topologically correct feature maps," *Biol. Cybern.*, vol. 43, 1982.
- [6] J. S. Albus, "A new approach to manipulator control : The cerebellar model articulation controller (CMAC)," *J. Dynamic Syst. Meas. Contr.*, 1975.
- [7] P. Werbos, "Beyond regression : New tools for prediction and analysis in the behavioral sciences," Ph. D. dissertation, Harvard University, 1974.
- [8] D. E. Rumelhart, J. L. McClelland, *Parallel Distributed Processing : The MIT Press*, 1986.
- [9] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proc. Nat. Academy Sci.*, vol. 79, 1982.
- [10] B. Kosko, "Adaptive bidirectional associative memories," *Appl. Optics*, vol. 26, 1987.
- [11] G. E. Hinton, T. J. Sejnowski, and D. H. Ackley, "Boltzmann machines : Constraint satisfaction networks that learn," Carnegie-Mellon University, Dept. of Computer Science, Tech. Rep., 1984.
- [12] J. J. Hopfield and D. W. Tank, "Neural computation of decisions in optimization problems," *Biol. Cybern.*, vol. 52, 1986.
- [13] P. J. Werbos, *Neurocontrol and Related Techniques*, Hand Book of Neural Computing Applications : Academic Press, 1990.
- [14] B. Widrow and F. W. Smith, "Pattern recognition control systems," *Proc. COINS*, 1963.
- [15] A. Guez and J. Selinsky, "A trainable neuro-morhic controller," *J. Robotic Syst.*, vol. 5, no. 4, 1988.
- [16] H. Asada and S. Liu, "Transfer of human skills to neural net robot controllers," *Proc. R&A*, 1991.
- [17] D. Psaltis, A. Sideris, and A. A. Yamamura, "A multi-layered neural network controller," *IEEE Control Syst. Mag.*, April, 1988.
- [18] K. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," *IEEE Trans. Neural Networks*

- rks, vol. 1, no. 1, 1990.
- [19] F. C. Chen, "Back-propagation neural networks for nonlinear self-tunning adaptive control," IEEE Control Syst. Mag., April, 1990.
- [20] M. Kawato, K. Furukawa, and R. Suzuki, "A hierachical neural network model for control and learning of voluntary movement," Biol. Cybern., vol. 57, 1987.
- [21] H. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback-error-learning neural network for trajectory control of a robotic manipulator," Neural Networks, vol. 1, 1988.
- [22] W. T. Miller, F. H. Glanz, and L. G. Kraft, "Application of a general learning algorithm to the control of robotic manipulators," The Int. J. of Robotics Research, vol. 6, no. 2, 1987.
- [23] T. Fukuda and T. Shibata, "Neural network applications for robotic motion control," IEEE Int. Workshop Intell. Motion Contr., 1990.
- [24] T. Fukuda, T. Shibata, M. Tokita, and T. Mit-suoka, "Neumorphic control : Adaptation and learning," Proc. Int Joint Conf. Neuarl Networks, 1990.
- [25] S. Okuma, A. Ishiguro, T. Furuhashi, and Y. Uchikawa, "A Neural network compensator for uncertainties of robotic manipulators," Proc. of the 29th Conf. on CDC, 1990.
- [26] R. P. Lippmann, "An introduction to computing with neural nets," IEEE ASSP Mag., vol. 4, 1987.
- [27] M. H. Raibert and J. J. Craig, "Hybrid position/force control of manipulators," ASME J. Dynamic Syst. Meas. Contr., vol 102, 1981.
- [28] T. Fukuda and T. Shibata, "Theory and applications for neural networks for industrial control systems," IEEE Trans. Ind. Elec., vol. 39, no. 6, 1992.
- [29] P. J. Werbos, "Neural control and Elastic Fuzzy Logic : Capabilities, concepts, and applications," IEEE Trans. Ind. Elec., vol. 40, no. 2, 1993.