

지능 제어를 위한 신경 회로망 기술 개요

金 眞 煥, 李 鍾 浩, 許 旭 烈

仁荷大學校 電氣工學科

I. 서 론

80년대 중반 이래로 신경 회로망에 대한 연구가 활발하여지고 다방면에서 응용의 가능성이 입증됨에 따라 제어분야에서도 신경 회로망에 대한 이론 및 제어계 응용에 대한 새로운 연구결과들이 발표되고 있다. 신경 회로망은 패턴인식, 정보처리, 또는 적응제어 같은 복잡한 문제들을 해결하기 위한 새로운 도구로서 평가되고 있다. 인간의 두뇌는 병렬 정보 처리, 학습, 패턴 인식, 연상 기억 능력 등에 있어서 기존의 디지털 컴퓨터와는 다른 정보 처리 체계를 가지고 있는데 이와 같은 두뇌의 기능을 모방하도록 connectionist network으로 모델링 한 신경 회로망은 대체로 다음과 같은 특성을 나타내게 된다.

- 1) 비선형성(Nonlinearity) : 신경 회로망은 비선형 시스템 제어에 효과적이다. 이것은 비선형 맵핑을 일반화시킬 수 있는 능력에 기인한다.
- 2) 병렬분산처리(Parallel distributed processing) : 신경 회로망은 기본적으로 병렬구조를 가지므로 한 개의 프로세서를 가지는 폰-노이만 컴퓨팅 방식과 비교할 때 하드웨어 속도면과 전반탐색(global search)성능면에서 장점을 지니고 있다.
- 3) 학습과 적응 : 학습용 패턴 데이터로써 적절히 학습된 신경 회로망은 학습 데이터에 포함되지 않은 입력에 대해서도 일반화하여 추정할 수 있으며 온-라인으로 적응화 할 수 있다.
- 4) Data Fusion : 신경 회로망은 동시에 다종의 정량적인 데이터와 정성적인 데이터를 분석, 판단하는 용도로 쓰일 수 있다.
- 5) 다변수 시스템 : 신경 회로망은 많은 독립적 입력의 상호작용에 의하여 출력을 산출하는 구조로 되어있으므로 다변수 시스템으로의 적용이 쉽다.

신경 회로망의 배경을 살펴보면 1940년에서 1960년대까지 지능적인 정보 처리를 위해 컴퓨터

와 두뇌의 원리에 대해 연구가 시도되었다. McCulloch와 Pitts^[1]는 뉴런을 모델한 여러 개의 인자들을 상호 연결하여 신경 회로망의 가능성을 제시하였고 1960년대 접어들어서 Rosenblatt의 Perceptron,^[2] Widrow와 Hoff의 Adaline,^[3] 패턴 인식을 위한 Stienbuch의 Learning Matrix^[3] 등의 발표로 학습 시스템의 윤곽이 보이기 시작했다. Perceptron은 발표 당시 상당한 관심을 불러일으켰지만 Minsky와 Papert^[5]가 복잡한 문제 해결에 Perceptron의 한계를 지적함으로써 한때 신경 회로망의 연구는 위축되었다. 1970년대는 소수의 학자들에 의해서만 신경 회로망의 연구가 진행되었다. Grossberg의 Adaptive Resonance Theory (ART),^[6] Kohonen의 self-organizing map,^[7] 인간의 기억 모델을 기초로 look-up table화한 Albus의 Cerebellar Model Articulation Controller(CMAC)^[8] 등이 발표되었고 제어에서 가장 많이 사용되고 있는 역전파 신경 회로망의 기본 알고리즘이 Werbos^[9]에 의해 개발되었다. 1980년대 중반에 Rumelhart^[10]에 의해 앞 먹임(feed-forward)알고리즘으로서 역전파 알고리즘이 재개발되었으며 이후로 Werbos^[11]에 의해 동적 시스템에 효과적인 “Back-propagation through the time”이 발표되었다. 한편 Hopfield^[12]는 recurrent형태의 신경 회로망을 소개하였고 이 밖에 Kosko^[13]의 Bidirectional Associative Memory(BAM), Hinton^[14]의 Boltzmann machine 등 80년대 이후 신경 회로망의 연구 개발은 활발히 진행되었고 제어 이외에도 영상 처리, 음성인식을 비롯한 다양한 분야에 적용되고 있다.

최근 들어 제어 분야에서 많은 종류의 자동 제어 방식이 개발되고 있고 제어 대상의 복잡화와 외란 등에 따라 견실성을 요구하는 효과적인 제어 기법들이 요구되고 있다. 1970년대 초반에 발표된 적응 제어(Adaptive Control)는 이러한 요구에 부응하는 제어 기법으로 알려져 있으나 이러한 전통적인 적응 제어 방식은 비선형 시스템 해석에 대한 한계, 미지의 파라미터 증가에 따른 복잡한 계산량 요구 등과 같은 문제점들을 나타내고 있다. 이에 반해 신경 회로망은 경험적 학습에 의하여 제어 시


스템의 비선형성과 불확실성(uncertainty)에 잘 대처할 수 있다. 제어 분야에서의 신경 회로망의 연구는 제어 시스템의 구조에 따라 분류할 수 있는데, 즉, Supervised control, inverse control, neural adaptive control, reinforcement learning control 등으로 구분된다. 이에 대한 설명은 다음 장에서 다시 하기로 하겠다.

지능 제어 시스템의 한가지 특성으로 주변 환경의 변화에 따라 합리적으로 적용할 수 있는 제어 시스템을 생각할 수 있다. 이때 인식 판단 능력, 추론의 기능을 필요로 할 수 있으며 지식 베이스 시스템의 심볼화된 표현법에 의해 좀 더 사람에게 친숙한 전문가 시스템의 도입이 요구된다. 전문가 시스템의 구축은 퍼지 이론을 기본으로 할 수 있지만 학습 기능이 없기 때문에 룰의 선정에 있어서 상당한 경험이 요구된다. 이에 따라 80년말 이후로 신경 회로망과 퍼지 이론을 결합한 Hybrid Intelligent System에 대한 많은 연구 개발의 시도가 이루어지고 있다.^[15~17]

본 고에서는 지능 제어를 위한 퍼지 이론의 역할 보다는 신경 회로망을 중심으로 서술하고자 한다. 퍼지 이론과 신경 회로망은 각각의 장, 단점이 있지만 특히 자율 제어(Autonomous control)를 위한 처리(processing) 능력면에서 신경 회로망은 퍼지 이론과 더불어 체계적으로 이용될 수 있을 것으로 보여진다. 향후의 전망으로 볼 때 제어기의 핵심 프로세서로서 신경 회로망은 상당한 발전 가능성이 있다고 하겠다. 따라서 본 고의 구성은 신경 회로망의 기본 구조와 제어 분야에서 확립되고 있는 신경 회로망 제어 방식과 응용 사례에 초점을 맞추었다.

II. 신경 회로망 개요

신경 회로망의 구조는 회로망을 구성하는 기본 소자와 상호 연결 방법에 따라 구분될 수 있다. 기본 프로세싱 소자는 뉴런 또는 퍼셉트론으로 불리며 가중합산과 비선형 전달 함수의 기능을



<Fig. 1> Basic architecture of a neuron.

갖도록 <그림 1>과 같이 구성된다.

<그림 1>에서 보여지는 바와 같이 비선형 근사화는 활성화 함수(threshold function)이라 불리는 비선형 함수에 의해 가능하며 이를 위해 몇 가지 형태의 함수들이 사용된다. 가장 많이 쓰이는 sigmoid 함수, tanh 함수, 최근 들어 부각되고 있는 Radial Basis Function(RBF)^[18]은 각각 다음과 같다.

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

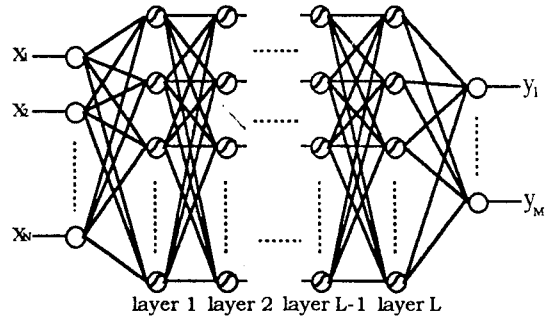
$$f(x) = \frac{1 - e^{-ax}}{1 + e^{-ax}} \quad -1 < f(x) < 1 \quad (2)$$

$$f(x) = g(\|c - x\|_2) \quad (3)$$

(3)식에서 c 는 basis function의 center이며 $g(\cdot)$ 는 linear, cubic, gaussian 등 여러 가지 함수 형태를 가질 수 있다.^[18]

1. Feed-Forward 신경 회로망

Feed-Forward 신경 회로망은 <그림 2>에서 보여지는 바와 같이 신호 전달이 한 방향으로 진행되는 구조를 가진다. 입, 출력 층외에 여러 개의 은닉 층을 포함하므로 Multilayer Neural Network 라고도 부르는 이 회로망의 학습을 위해 1980년대 Rumelhart^[10]는 Back-propagation 알고리즘을 제안하였으며 제어 분야에서 신뢰성 있게 보편적으로 사용하는 신경 회로망으로 평가되고 있다. BP 알고리즘은 비선형 최적화를 위해 gradient



<Fig. 2> Feedforward Neural Network.

algorithm을 사용한다. PDP 그룹의 Rumelhart와 McClelland에 의해 개발된 BP 알고리즘은 많은 신경 회로망 연구자들의 관심을 모았다. 일반화된 delta rule에 의한 학습 알고리즘의 오차 함수를 다음과 같이 놓는다.

$$E = \frac{1}{2} \sum_j (t_{pj} - O_{ij})^2 \quad (4)$$

여기서 t_{pj} 는 패턴 p 가 입력되었을 때 출력층의 j 번째 뉴우런의 바람직한 값이며 O_{ij} 는 이때 회로망 출력층의 j 번째 뉴우런의 실제 출력 값이다. 다층 회로망의 각 층의 출력은 다음과 같이 구한다.

$$S_{i,j} = \sum_i W_{i,jl} O_{l-1,i} \quad (5)$$

$$q_{i,j} = f(S_{i,j}) \quad (6)$$

여기서 $S_{i,j}$ 는 i 번째 층의 j 번째 뉴우런에 대한 가중 입력의 합산이며 $O_{i,j}$ 는 $S_{i,j}$ 가 비선형 함수를 거친 뉴우런의 출력이다. $W_{i,jl}$ 는 $l-1$ 층의 i 번째 뉴우런과 i 층의 j 번째 뉴우런이 결합 가중치이며 $O_{l-1,i}$ 는 $l-1$ 층의 i 번째 뉴우런의 출력이다.

매 학습 시마다 Delta rule에 의해 오차에 대한 가중치 변화는 오차를 최소화하도록 다음 식으로 표현된다.

$$\Delta W_{l,ji} = -\frac{\partial E}{\partial W_{l,ji}} \quad (7)$$

(7)식은 체인 rule에 의해 다음과 같이 나눌 수 있으며

$$\frac{\partial E}{\partial W_{l,ji}} = \frac{\partial E}{\partial S_{l,j}} \frac{\partial S_{l,j}}{\partial W_{l,ji}} \quad (8)$$

(8)식의 두번째 요소는 다음과 같이 구할 수 있다.

$$\frac{\partial S_{l,j}}{\partial W_{l,ji}} = \frac{\partial}{\partial W_{l,ji}} \sum_k W_{l,jk} O_{l-1,k} = O_{l-1,k} \quad (9)$$

이때 다음을 역전과 오차로 정의하면 가중치의 변화분은 (12)식과 같이 구할 수 있다.


$$\delta_{l,j} = -\frac{\partial E}{\partial S_{l,j}} \quad (10)$$

$$-\frac{\partial E}{\partial W_{l,ji}} = \delta_{l,j} O_{l-1,i} \quad (11)$$

$$\Delta W_{l,ji} = \eta \delta_{l,j} O_{l-1,i} \quad (12)$$

2. 순환형 신경 회로망

순환형 신경 회로망(Recurrent Neural Network)은 뉴우런간의 상호 연결이 순환적인 되먹임 형태의 구조를 가지기 때문에 다이나믹 시스템에의 응용에 적합하다고 볼 수 있다. 순환형 신경망은 80년대 Hopfield^[12]에 의해 에너지 개념으로 해석되며 그 응용 가능성이 제시되었으며 Hopfield 신경망으로도 불려진다. Hopfield 신경망에 대한 연구는 최적화 문제나 연상 기억 시스템의 구현을 위해 진행되어 왔으며 제어 응용에서는 계수 추정(parameter identification)을 위한 동정기(identifier)로도 사용되었다.^[19] 최근의 제어 공학 분야에서 주된 이슈는 제어 시스템의 견실성으로



(Fig. 3) Hopfield Neural Network.

모아지고 있으며 적응 제어 방식에서의 견실성은 동정기의 견실성을 전제하므로 전통적인 선형 수학을 바탕으로 한 견실한 동정기에 관한 연구가 계속되고 있으며 Hopfield 신경망은 이러한 요구에 부합되는 신경망이다. Hopfield 신경망은 이산형과 연속 시간형으로 구분할 수 있으며 연속 시간형에 대한 Hopfield 신경망의 구조와 출력 방정식은 다음과 같이 표현될 수 있다.

$$\frac{dU}{dt} = -WV - I, \quad V = f(U) \quad (13)$$

여기서 V는 뉴우런 출력 벡터, U는 입력 벡터, W는 가중치, I는 바이어스이고 f(·)는 비선형 함수이다. 이와 같은 다이나믹 시스템을 표현할 때 최적화 문제를 위한 2차형(quadratic form)의 오차 함수는 다음과 같다.

$$E = \frac{1}{2} V^T W V + I^T V + C \quad (14)$$

오차함수를 최소화 하기 위한 출력 V는 다음 식을 만족하는 곳에서 안정된다.^[19]

$$\begin{aligned} \frac{dE}{dt} &= \frac{dE}{dV} \frac{dV}{dt} = \{V^T W + I^T\} \frac{dV}{dt} = -\left\{\frac{dU}{dt}\right\}^T \frac{dV}{dt} \\ &= -\left\{\frac{df^{-1}(V)}{dt}\right\}^T \frac{dV}{dt} = 0 \end{aligned} \quad (15)$$

또한, 순환형 신경망의 다른 부류로서 Zispert와 Willams^[20]에 의해 제시된 Feed-Forward 신경망

의 뉴우런간 상호 연결된 구조를 가지는 순환형 신경망이 있다. 90년대에 들어서 Recurrent 신경망에 대한 연구는 Feed-Forward 신경망의 구조를 빌어서 연구가 진행되고 있는데 Zisper와 Williams에 의한 순환형 신경망은 다음과 같다.

$$O_o(t) = f(S_o(t)) \tag{16}$$

$$S_o(t) = \sum_j W_j O_s(t) \tag{17}$$

$$O_s(t) = \sum_i W_{ji} X_i(t) + \sum_k W_{D,jk} O_k(t-1) \tag{18}$$

여기서 단순화를 위해 한 개의 은닉 층을 가지고 출력 층의 뉴우런은 하나로 가정한다. O_o 는 회로망의 출력, W_j 는 은닉 층의 j -번째 뉴우런과 출력 뉴우런의 연결 가중치, S_o 은 출력 뉴우런의 가중 입력 합산, O 는 은닉 층의 j -번째 뉴우런 출력이고 $W_{D,jk}$ 는 은닉 층의 j -번째 뉴우런과 k -번째 뉴우런의 이전 출력간의 가중치를 나타낸다.

오차함수를 (4)식과 같이 할 때 회로망의 가중치 변화분은 다음과 같이 구할 수 있다.


$$\Delta W_{ji} = -\eta \gamma \cdot \frac{\partial E}{\partial W_{ji}} = e \cdot \frac{\partial O_o(t)}{\partial W_{ji}} \tag{19}$$

여기서 $e = t(t) - O$ 는 학습 오차이다.

$$\begin{aligned} \frac{\partial O_o(t)}{\partial W_{ji}} &= \frac{\partial O_o(t)}{\partial S_o(t)} \frac{\partial S_o(t)}{\partial W_{ji}(t)} \\ &= f(S_o(t)) \sum_j \left(\sum_k W_{D,jk} \frac{\partial O_k(t-1)}{\partial W_{ji}} + \delta_{ji} X_i(t) \right) \end{aligned} \tag{20}$$

여기서 $f(\cdot)$ 는 비선형 함수, δ 는 Kronecker delta 연산자이고 $W_{D,jk} \{\partial O_k(t-1) / \partial W_{ji}\}$ 는 recurrent 항이다.

순환형 신경망을 이용한 다이내믹 시스템의 적용은 발전소(power plant)와 같은 복잡한 프로세스의 모델링에^[21] Feed-forward 신경망보다 효과



(Fig. 4) Recurrent Neural Network.

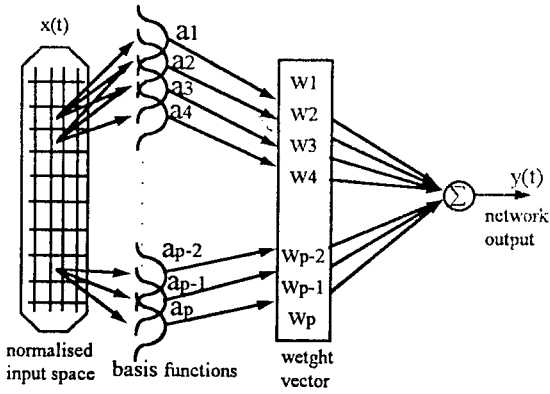
적이라 알려져 있다. 최근에는 순환형 신경망에 대한 연구는 활발히 이루어졌으며 Feed-Forward 신경망을 기반으로 한 좀 더 단순화된 구조를 갖는 순환형 신경망에 대한 연구 결과가 제시되기도 하였다.^[22]

3. Cerebellar Model Articulation Controller (CMAC)

신경 회로망의 종류에는 구조와 학습 알고리즘에 따라 Feed-Forward 신경 회로망과 순환형 신경 회로망이외에 제어에서 자주 사용되는 회로망으로 CMAC이 있다. CMAC은 복합적인 신경 회로망의 local generalization과 local learning을 일반화하기 위해 개개의 뉴우런의 특성을 모델화한다. CMAC은 원래 Albus^[8]에 의해 robot manipulator를 온-라인으로 적응 제어하기 위해 개발되었다. 이후 adaptive modelling과 control을 위해 계속 변형, 개발되고 있으며 최근 들어서 신경회로망 분야에서 CMAC에 대한 관심이 높아지고 있다. Kraft와 Campagana^[23]는 CMAC-based controller와 STR, MRAC의 추적 성능을 비교하였고 Miller^[24]는 vision robot의 real-time control을 위해 CMAC을 사용한 다양한 결과를 보여 주었다.

회로망의 입력을 x 라 할 때 회로망의 출력은 다음과 같다.

$$\begin{aligned} y(x) &= \sum_{i=1}^{\rho} a_i(t) w_i(t-1) \\ &= \sum_{i=1}^{\rho} a_{adi}(t) w_{adi}(t-1) \end{aligned} \tag{21}$$



〈Fig. 5〉 Schematic illustration of Basic CMAC.

여기서 $ad(i)$ 는 non-zero basis function의 주소를 반환하는 함수이며 ρ 는 은닉 층에서 non-zero 변수들의 개수를 나타낸다.

CMAC은 인간의 사고에 대해 모델화하며 국부적 정보를 저장한다. 그러나 CMAC을 이용한 제어는 모델링 정도 또는 학습 알고리즘에 의해 성능이 달라진다. 또한, CMAC은 설계자에 의해 많은 파라미터들의 선정을 요구하는데 look-up table과 basis function에 대한 파라미터들은 모델링의 성능을 결정하는 요인이 된다. 즉, 파라미터의 설정이 잘못된다면 회로망의 성능도 나쁘게 되며 따라서 파라미터의 적응화를 피하는 방법이 필요하다.

III. 시스템 동정과 모델링

비선형 시스템을 근사화 시키는 성질은 제어에서 신경 회로망을 사용하고자 하는 중요한 이유가 되는데 시스템의 동정에 있어서 시스템의 비선형 다이내믹스 뿐만 아니라 역 다이내믹스도 표현하도록 회로망을 학습시키는 문제에 대해서 고찰해보자.

선형 수학기론을 바탕으로 한 동정(identification)에서의 기본 문제는 주어진 특정한 구조의 모델이 있을 때 이 모델은 시스템을 적절하게 표현할 수 있는 구조를 가졌느냐 하는 점이다. 그러나 신

경 회로망을 사용할 때는 특정 구조를 가져야 하는 전제 조건이 필요없다. 다음과 같은 비선형 시스템을 고려해 보도록 한다.

$$y(t+1) = f(y(t), \dots, y(t-n+1), u(t), \dots, u(t-m+1)) \quad (22)$$


여기서 $f(\cdot)$ 는 비선형 시스템, m, n 은 각각 입력, 출력 차수를 의미한다.

이와 같은 비선형 시스템을 모델링하기 위해 Narendra와 Parthasarthy^[25]는 입력, 출력이 모두 비선형이거나, 입력이나 출력중 어느 하나가 비선형인 경우에 대한 동정 결과를 보여 주었다.


〈그림 7〉은 (22)식과 같은 구조의 신경 회로망을 이용한 모의 실험 결과를 나타낸다.

〈그림 7〉에서 실선은 기준 입력을 나타내며 점선은 신경 회로망에 의한 출력이다. 그림에서 보여지듯이 거의 정확히 동정됨을 볼 수 있다.

다이내믹 시스템의 inverse modelling은 제어에



〈Fig. 6〉 Identification.



〈Fig. 7〉 Identification for plant.

서 유용하게 사용된다. Psaltis에 의해 제시된 generalized inverse learning^[26]은 network의 출력과 시스템의 입력의 오차에 의해 회로망을 학습시킨다. 그러나 이와 같은 방법은 다음과 같은 단점을 가진다. 첫째, 회로망을 제대로 학습시키기 위해서는 매우 넓은 범위의 시스템 입력을 추출해야 한다. 그러나 실제로 모든 동작 범위에서의 입력을 미리 알기란 매우 어렵다. 이것은 시스템 동정과 관련해서 생각하면 persistent excitation의 개념과 같다. 다시 말해서, 적응 제어에서 충분한 persistent excitation를 가지지 못하면 parameter 수렴을 보장할 수 없다는 성질이 있다. 둘째, 비선형 시스템에 대한 맵핑이 일 대 일 대응이 아니기 때문에 모든 동작 범위에 대해서 역 다이내믹스를 제대로 학습시키지 못할 수 있다. 이러한 단점을 보완할 수 있는 방법으로 Psaltis에 의해 specialized inverse learning^[26]이 제시되었고 이것은 온-라인 상태에서 inverse model을 학습시킴으로써 원하는 동작 범위 내에서 학습 시그널을 만드는 방법이다. inverse model은 다음식으로 표현된다.

$$u(t) = f^{-1}(y(t)), \dots, y(t-n+1), u(t-1), \dots, u(t-m+1) \quad (23)$$

여기서 f^{-1} 은 inverse model이며 신경 회로망을 사용하여 시행토록 하였으며 m, n 은 입, 출력 차수이고 $r(t)$ 는 기준 입력이다.

IV. 신경망 제어기 구조

일찍이 제어 분야에서 신경 회로망의 주된 역할은 비선형 특성에 대한 근사화에 초점이 맞추어졌다. 신경 회로망은 앞에서 설명한 바와 같이 비선형성, 학습, 병렬 처리 등의 특성을 가짐으로서 지능 제어를 위해 학습 자료의 일반화에 이용될 수 있다. 제어분야에서 적용하는 신경 회로 망으로서 supervised control, inverse control, neural adaptive control 및 reinforcement learning al-

gorithm을 확장한 adaptive critics 등이 있다.

Supervised Control은 Widrow^[3]에 의해 제시되었으며 일반적인 자동 제어기로 처리하기 어려운 상황에서 인간의 대응 행동들을 모방할 필요가 있을 때 신경 회로망은 인간의 처방을 학습하기 위해 시스템에 대한 바람직한 입력을 인간으로부터 얻고 이를 모방하도록 회로망을 학습시키는 방법이다.

Inverse Control은 시스템의 inverse dynamics를 신경 회로망으로 학습시키는 것이다. inverse control은 되먹임이 없기 때문에 강인성 부족이라는 약점을 가진다. 이러한 약점은 온-라인 학습을 통해 극복할 수 있다. Psaltis와 Yamamura^[26]는 generalized learning architecture를 통해 inverse dynamics를 학습시킬 수 있었고 specialized learning architecture를 통해 온-라인 상의 학습을 보완하여 제어 환경에서 발생하는 불확실성에 대해서도 고려하였다. Nguyen과 Widrow^[27]는 inverse control을 사용하여 truck의 후진 제어 문제를 다루었다.


Neural Adaptive Control은 적응 제어의 방식을 사용하고 있으며 Narendra와 Parthasarathy^[25]에 의해 일반화된 이 방법은 신경 회로망을 사용한 제어 방식에 상당한 영향을 끼쳤다. 적응 제어에서 사용되었던 간접(indirect) 방식의 동정기와 제어기에 신경 회로망을 도입하였으며 한 스텝 이후의 오차 계산으로 제어기를 학습시키는 방법이다.

Adaptive critics는 reinforcement learning의 확장된 방식이며 두개의 learning system, 즉, ASE(Associate Search Element)와 ACE(Associate Critic Element)로 구성된다. ASE는 reinforcement feedback하의 입, 출력 사이의 관계를 찾게 되고 ACE는 action network 역할을 한다.^[28]

다음은 신경 회로망을 이용한 제어기에 대해 살펴해보도록 한다. 신경망 제어기는 구조면에서 다음의 4가지로 구분할 수 있다.

1. Forward Neural Control

신경 회로망을 이용한 제어기의 기본 구조는 대



〈Fig. 8〉 Basic architecture of Feedforward Neural Network.


상 시스템의 역 다이내믹스를 사용하는 것으로서 이때 제어기의 구조는 〈그림 8〉과 같다.

〈그림 8〉에서 볼 수 있듯이 제어기는 플랜트의 역 다이내믹에 대한 모델로 구성된다. 제어기의 성능은 오프-라인에서 플랜트의 역 다이내믹스를 얼마나 학습시켰는지에 따라 영향을 받는다.

2. Inverse Dynamic Training

Inverse dynamic training은 대상 시스템의 역 다이내믹스를 사용하여 제어기를 학습시키는 방식으로서 이것은 Psaltis에 의해 제시된 generalized inverse learning의 구조^[26]로서 〈그림 9〉와 같다.

Inverse dynamic training은 〈그림 9〉에서와 같이 플랜트의 출력에 대해 실제 제어 입력과 신경망의 출력과 오차에 의해 제어기를 학습시킨다. 신경망 제어기의 오프-라인 학습은 〈그림 9〉와 같은 구조를 사용한다.

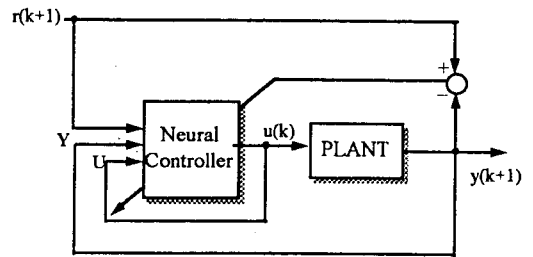


〈Fig. 9〉 Architecture of Inverse Dynamic Control.

3. Direct Inverse Control

Direct Inverse Control은 Inverse dynamic control의 단점을 보완한 specialized inverse learning 구조를 도입한 것으로 온-라인 상에서 학습이 가능하다.

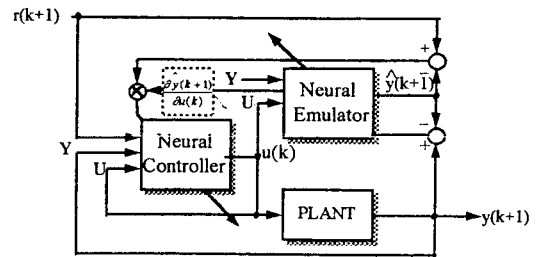
〈그림 10〉에서 신경망 제어기는 플랜트의 역 다이내믹스를 오프-라인에서 어느 정도 학습시킨 후 온-라인 제어시 플랜트의 출력과 기준 입력간의 오차에 의해 제어기를 학습시킨다. 그러나 대상 시스템의 입력 대 출력 감도(sensitivity)를 알 수 없기 때문에 선형 제어에서 혼한 비최소 위상 모델에도 많은 학습이 필요하게 된다. 이에 대한 개선된 제어 방식으로는 다음에서 소개되는 Indirect Inverse Control이 있다.



〈Fig. 10〉 Architecture of Direct Inverse Control.

4. Indirect Inverse Control

Indirect Inverse Control은 신경망 동정기(Neural Identifier)를 학습시킴으로써 한 스텝 이



〈Fig. 11〉 Architecture of Indirect Inverse Control.

후의 시스템 반응에 대한 예측이 가능하다. 따라서 현재 주어진 입력 대 출력 감도, $\partial \bar{y}(k+1)/\partial u(k)$ 를 알 수 있기 때문에 제어기의 학습이 효과적이다.

〈그림 11〉과 같은 indirect 방식은 현재 신경망 제어 구조중 가장 많이 쓰이는 형태이며 특히, 프로세스 제어 분야에서 자주 사용한다.


5. 모의 실험

모의 실험으로 비최소 위상 특성을 가지는 플랜트에 기준 제어를 비선형 함수로 인가할 때 direct control과 indirect control의 결과를 보도록 한다.

$$y(y) = \frac{(1-2q^{-1})}{(1-0.7q^{-1})} r(t-1) \quad (24)$$

(24)식에서 기술된 플랜트는 안정한 극점과 불안정한 영점, 즉, 0.7과 2를 가진다. 이와 같은 비최소 위상 플랜트는 선형 제어 방법으로도 제어하기 쉽지 않다. 이에 대해 신경 회로망을 사용했을 때의 제어 성능을 보도록 한다. 신경 회로망은 비선형성 시스템에 효과적이기 때문에 플랜트의 기준 명령 시그널을 비선형 신호로 인가하기로 한다.

〈그림 12〉에서 여기서 점선은 기준 입력이며 실은 신경망으로 제어한 플랜트 출력이다. 〈그림 12〉(a)는 플랜트의 역 다이내믹스를 제어기에 적당히 학습 시킨 후 〈그림 10〉의 방식을 도입하여 제어한 결과이다. 시스템이 비 최소 위상을 가지며 기준 시그널이 비선형이기 때문에 입력 대 출력




〈Fig. 13〉 Indirect Inverse Control Simulation.

감도는 학습 오차의 부호 방향과 반대이며 이득도 크다. 따라서 발산하는 결과를 보여준다. 〈그림 12〉(b)는 제어기에 플랜트를 충분히 학습한 후 제어한 결과이다. 거의 정확하게 제어됨을 확인할 수 있다. 즉, direct 방식은 비 최소 위상 플랜트와 같은 시스템에 대해서는 오프-라인 상에서 충분한 제어기의 학습이 필요하다. 다음은 〈그림 11〉의 indirect control방식을 사용한 경우로서 〈그림 13〉에서 점선이 기준 입력이고 실선이 신경망으로 제어된 플랜트 출력이다. 〈그림 13〉은 오프-라인에서 학습시키지 않고 온-라인에서 학습시키며 제어한 결과이다. 임, 출력 감도를 동정기로 알 수 있기 때문에 direct control방식보다 효과적임을 알 수 있다.

V. 응용 사례

패턴 인식에 대한 신경회로망의 연구는 이미 널리 수행되어 왔고 recurrent network과 feedforward network은 영상, 음성 인식에 주로 많은 효과를 보이고 있다. 또한, 최적화 문제에 대해서도 Traveling Salesman Problem에서 보여진 바와 같이 상당히 많은 양을 계산을 요구하는 문제에 대해서는 전통적인 방법으로 최적의 경로를 구하기 힘들지만 병렬 처리 구조를 가지는 신경회로망을 사용하여 최적해를 효과적으로 찾을 수 있다.



〈Fig. 12〉 Direct Inverse Control Simulation.

앞에서 서술한 바와 같이 신경회로망은 비선형성, 병렬 처리, 학습 등의 특성을 가지기 때문에 진보된 지능 제어에서 핵심 처리 도구로 사용될 수 있다. 이와 같이 제어 분야에서 신경회로망의 적용이 시도되어 왔는데 앞에서 분류한 바 대로 응용 사례들을 열거해 보고자 한다.

Supervised control로서는 Widrow^[29]가 bloom balacer에 적용하였고 Asada^[30]는 학습 데이터를 사용하여 신경회로망이 인간의 기술을 모방할 수 있음을 보여 주었다.

Inverse control에 대한 응용 사례는 Psaltis와 Yamamura^[26]가 inverse learning 방법을 제시하여 극 좌표에서 카테시안(cartesian) 좌표로 변환하는데 신경회로망을 제어기로 사용하였고 Nguyen와 Widrow^[27]는 최소의 에너지를 사용하는 트럭의 후진 문제를 다루었다. Kawato^[31]는 Robot manipulator의 trajectory control을 indirect inverse control 방식으로 시도하였고 Fukuda^[32]는 Robot manipulator에 uncertainty를 고려한 hybrid position/force 제어를 위해 indirect inverse control 방식을 사용하였다.

Neural adaptive control로서는 전통적인 적응 제어의 방식을 이용하여 Narendra와 Parthasarathy^[25]이 Model Reference Adaptive Control에 초점을 맞추어서 여러 가지 비선형 프로세스에 대한 모의실험을 보여 주었고 Tokita^[33]는 Robot manipulator의 force control을 위해 시스템의 파라미터 추정을 하기 위한 신경회로망 Self-Tuning regulator를 고안하였다. 이것은 신경회로망을 이용하여 시스템의 다이내믹스를 동정하고 미래의 프로세스 출력을 예측하여 예측오차가 최소화 되도록 제어기를 구성하는 방식이다.

Adaptive critic은 reinforcement learning의 확장 개념으로 Barto^[34]가 제안한 두 개의 회로망을 사용한 reinforcement learning이 있으며 또한 Franklin^[35]는 두 개의 adaptive critic algorithm이 많은 문제들에 대해 잘 대처함을 보여 주었다.

이외에도 Omatu^[36]는 indirect adaptive control 방식을 사용하여 욕조내의 물 온도 제어를 온-라인으로 하였고 McAvoy^[37]는 역전파 신경회로

망에 예측제어 개념을 도입하여 CSTR(continuously stirred tank reactor)의 pH 농도 제어에 효과적인 실험 결과를 보여 주었다. 또한, Irwin^[38]은 발전소의 Turbogenerator와 같은 대용량 다변수 시스템에 역전파 신경 회로망을 사용하여 제어 하였고 Song^[39]은 역시 다변수 시스템인 gas turbin에 간접 적응 제어(indirect adaptive control)방식을 이용하여 효과적인 제어 결과를 보여 주었다. 신경회로망의 제어 응용 분야중 많은 사례가 발표되는 분야로서 robot관련 분야를 들 수 있는데 Saga^[40]는 Mobil robot 구동 제어를 위해 supervised control learning방식을 도입하였고 Cheng^[41]은 두 개의 link를 가지는 Rigid manipulator의 tracking control을 위해 신경회로망을 사용하였다.

IV. 결 언

이상으로 신경 회로망의 구조와 학습 원리에 대하여 간략히 설명하였으며 제어 공학 분야에서의 적용을 위한 신경 회로망의 여러 가지 접근 방법들을 대별하여 기술하였다. 신경 회로망의 일반적인 특성들, 즉, 학습에 의한 일반화(generalization), 온-라인 적응성, 병렬성과 전반 탐색(global search)능력 및 연상 추정 능력 등은 제어 기법의 개선을 위하여 요구되어지는 특성 요소들의 많은 부분을 담당할 수 있으리라 여겨진다. 미래의 지능 제어 기술이 자율적(autonomous) 시스템을 지향한다고 할 때 신경 회로망의 상기 특성들은 향후의 신 제어 기법의 개발에 더욱 기여 하게될 것으로 보여진다.

참 고 문 헌

- [1] W.S.McCulloch and W.Pitts, "A logical calculus of the ideas immanent in nervous

- activity," *Bulletins of Mathematical Biophysics*, vol. 9, pp.127~147, 1943.
- [2] F.Rosenblatt, "The perceptron : a probabilistic model for information storage and organization in the brain," *Psychological Review*, vol. 65, pp.386~408, 1958.
- [3] B.Widrow and M.E.Hoff, "Adaptive switching circuits," *IRE WESCON Convention Record New York : IRE*, pp.96~104, 1960.
- [4] K.Steinbuch and V.A.W.Piske, "Learning matrix and their applications," *IEEE Trans. Electron. Comput.*, vol. EC-12, pp. 846~862, 1963.
- [5] M.Minsky and S.Papert, *Perceptrons*, Cambridge MA, MIT Press, pp.1~20, 1969.
- [6] S.Grossberg, "Adaptive pattern classification and universal recording 2 : Feedback, expectation, olfaction, and illusions," *Biol. Cyber.*, vol. 23, pp.187~202, 1976.
- [7] T.Kohonen, "Self-organized formation of topologically correct feature maps," *Biol. Cyber.*, vol. 43, pp.59~69, 1982.
- [8] J.S.Albus, "A new approach to manipulator control : The cerebellar model articulation controller (CMAC)," *J. Dynamics Sys. Measu. Contr.*, pp.220~227, 1975.
- [9] P.Werbos, "Beyond regression : new tools for prediction and analysis in the behavioral science," Ph.D.dissertation, Harvard University, Cambridge, MA, MIT Press, 1986.
- [10] D.E.Rumelhart, G.E.Hinton, and R.J.Williams, *Parallel Distributed Processing*, Cambridge, MA : MIT Press, 1986.
- [11] P.J.Werbos, "Backpropagation through the time : What it does and how to do it," *Proc. IEEE*, vol. 78, no. 10, pp.1550~1560, Oct 1990.
- [12] J.J.Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proc. Natl. Academy Sci.*, vol. 79, pp.4947~4960, 1987.
- [13] B.Kosko, "Adaptive bidirectional associative memories," *Appl. Optics*, vol. 26, pp. 2947~2960, 1987.
- [14] G.E.Hinton and T.J.Sejnowski, *Learning and Relearning in Boltzmann Machines*, in *Parallel Distributed Processing*, vol. 1, Cambridge, MA : MIT Press, Chapter 7, 1986.
- [15] M.M.Gupta and J.Qi, "On fuzzy neuron models," in *Proc. IJCNN '91*, vol. 2, Seattle, WA, pp.431~436, 1991.
- [16] P.K.Simpson, "Fuzzy min-max classification with neural network," *Heuristics*, vol. 4, no. 1, pp.1~9, 1991.
- [17] B.Kooco, *Neural Network and Fuzzy Systems*, Prentice Hall, 1992.
- [18] M.Brown and C. Harris, *NeuroFuzzy Adaptive Modelling and Control*, Prentice Hall, 1994.
- [19] T.H.Lee, A.P.Loh and V.Srinivasan, "A technique for on-line parameter estimation based on an analog artificial neural net structure," *Neurocomputing*, vol. 6, pp. 405~417, 1994.
- [20] R.J.Williams and D.Zipser, "A Learning Algorithm for Continually Running Fully Recurrent Neural Networks," *Neural Computation*, vol. 1, pp.270~280, 1989.
- [21] A.G.Parlos, K.T.Chong, and A.F.Atiya, "Application of the Recurrent Multilayer Perceptron in Modeling Complex Process Dynamics," *IEEE Trans. Neural Networks*, vol. 5, no. 2, pp.255~266, March 1994.
- [22] C.C.Ku and K.Y.Lee, "Diagonal Recurrent Neural Networks for Dynamics Systems Control," *IEEE Trans. Neural Networks*, vol. 6, no. 1, pp.144~156, Jan. 1995.

- [23] L.G.Kraft and D.P.Campagan, "A Comparison Between CMAC Neural Network Control and Two Traditional Adaptive Control Systems," *IEEE Control Systems Mag.*, pp.36~43, April 1990.
- [24] W.T.Miller, "Real-time application of neural networks for sensor-based control of robots with vision," *IEEE Trans. Sys. Man. Cyber.*, vol. 19, pp.825~831, April 1989.
- [25] K.Narendra and K.Parthasarathy, "Identification and control of dynamical systems using neural networks," *IEEE Trans. Neural Networks*, vol. 1, no. 1, pp.4~27, 1990.
- [26] D.Psaltis, A.Sideris, and A.A.Yamamura, "A Multilayered Neural Network Controller," *IEEE Control Systems Mag.*, pp.17~21, April 1990.
- [27] D.H.Nguyen and B.Widrow, "Neural Networks for Self-Learning Control Systems," *IEEE Control Systems Mag.*, pp. 18~23, April 1990.
- [28] T.Fukuda and T.Shibata, "Theory and Applications of Neural Networks for Industrial Control Systems," *IEEE Trans. Ind. Elec.*, vol. 39, no. 6, pp.472~489, 1992.
- [29] B.Widrow and F.W.Smith, "Pattern-recognition control systems," in *Proc. COINS*, 1963.
- [30] H.Asada and S.Liu, "Transfer of Human skills to neural net robot controller," in *Proc. R & A*, pp. 2442~2448, 1991.
- [31] M.Kawato, K.Furukawa, and R.Suzuki, "A hierarchical neural network model for control and learning of voluntary movement," *Biol. Cybern.*, vol. 57, pp.169~185, 1987.
- [32] T.Fukuda, "Neural servo controller ; Adaption and learning," in *Proc. IEEE Int. Workshop Advanced Motion Control*, pp.107~115, 1990.
- [33] M.Tokita, T.Mitsuoka, T.Fukuda, and T. Kurihara, "Force control of robots by neural network models : Control of one-dimensional manipulators," *J. Japan Society of Robotics Engineers*, vol. 8, no. 3, pp.52~59, 1989.
- [34] A.G.Barto, R.S.Sutton, and C.W.Anderson, "Neuro-like adaptive elements that can solve difficult learning control problems," *IEEE Trans. Sys. Man. Cyber.*, vol. SMC-13, pp.834~846, 1983.
- [35] J.A.Franklin, "Reinforcement of robot motor skills through reinforcement learning," in *Proc. 27th IEEE Conf. on Decision and Control*, pp.1096~1101, 1988.
- [36] J.Tanomaru and S.Omatu, "Process Control by On-Line Trained Neural Controller," *IEEE Trans. Ind. Elec.*, vol. 29, no. 6, pp.511~521, 1992.
- [37] N.V.Bhat, P.A.Minderman, J.T.McAvoy, and N.S.Wang, "Modeling chemical process systems via Neural Computation," *IEEE Control Systems Mag.*, pp.24~30, April 1990.
- [38] Q.H.Wu, B.W.Hogg, and G.W.Irwin, "A Neural Network Regulator for Turbogenerators," *IEEE Trans. Neural Networks*, vol. 3, no. 1, pp.95~100, Jan. 1992.
- [39] Q.Song and M.J.Grimble, "Design of a Multivariable Neural Controller and its Application to Gas Turbines," *Proc. ACC. Seattle Washington*, pp.2297~2301, June 1995.
- [40] K.Saga, T.Sugasaka, M.Sekiguchi, S. Nagata, and K.Asakawa, "Mobil Robot Control by Neural Networks using Self-Supervised Learning," *IEEE Trans. Ind. Elec.*, vol. 39, no. 6, pp.537~541, Dec.

1992.
[41] W.Cheng and T.Y.John, "A Two-Time-Scale Neural Controller for the Tracking

Control of Rigid Manipulators," *IEEE Trans. Sys. Mans, Cyber.*, vol. 24, no. 7, pp. 991~1000, July 1994.

저자 소개



李 鍾 浩

1953年 4月 14日生

1976年 2月 서울대 전기공학과(학사)

1978年 2月 서울대 전기공학과(석사)

1986年 8月 아이오와 주립대 전기 및 컴퓨터공학과(박사)

1979年 8月~1982年 6月 해군사관학교 전기공학과 전임강사

1986年 8月~1989年 5月 (美)노틀담대학교 전기 및 컴퓨터공학과 교수

1989年 8月~현재 인하대학교 전기공학과 교수

1994年 1月~1995年 1月 (美)브라운대 두뇌 및 신경망 연구소 방문교수

주관심분야 : Computational Intelligence, Neural Network 및 VLSI CAD



許 旭 烈

1951年 12月 13日生

1974年 2月 서울대 전기공학과(학사)

1978年 2月 서울대 전기공학과(석사)

1982年 8月 서울대 전기공학과(박사)

1977年~1980年 서울대학교 조교

1980年~현재 인하대학교 전기공학과 교수, 제어계측 신기술 연구센터 참여교수

1985年~1986年 (美)일리노이대학 전기 및 컴퓨터공학과 방문교수

주관심분야 : Servo Control, Intelligent Control, Adaptive Control



金 眞 煥

1967年 5月 15日生

1991年 2月 인하대 전기공학과(학사)

1993年 2月 인하대 전기공학과(석사)

1993年~현재

인하대학교 전기공학과 박사과정

주관심분야 : Process Control, Adaptive Predictive Control, Fuzzy Control,
Neural Network