

工學碩士學位論文

신경회로망을 이용한 매니플레이터의
위치 및 힘 제어에 관한 연구

이 論文을 工學碩士學位論文으로 提出함



2006 年 2月

釜慶大學校大學院

制御計測工學科

金泰坤

金泰坤의 工學碩士 學位論文을 認准함

2005年 12月

主 審 工學博士 邊 基 植



委 員 工學博士 安 永 珠



委 員 工學博士 黃 龍 淵



목 차

목차	i
Abstract	iii
제1장 서론	1
제2장 신경회로망	3
2.1 신경회로망의 정의	3
2.2 신경회로망의 구성	4
2.2.1 신경소자	5
2.2.2 결선	6
2.2.3 학습	7
제3장 실험장치	9
3.1 로봇의 동역학 방정식	9
3.2 2링크 매니퓰레이터의 운동방정식	12
제4장 제어기의 구성	14
4.1 신경회로망에 의한 학습제어	14
4.2 오류역전파(error back-propagation) 알고리즘	16
4.3 위치 및 힘 제어기	19
제5장 실험	22
5.1 힘 제어 실험	23
5.1.1 학습률	23
5.1.2 입력충수	25
5.1.3 중간충수	27
5.2 위치 및 힘 제어 실험	33

제6장 결론 41

참고문헌 42

감사의 글

**A Study on the Position and Force Control of the Manipulator
Using Neural Network**

Tai-Gon Kim

*Department of Control and Instrumentation Engineering
Graduate School of
Pukyong National University*

Abstract

As the robot applying extent, nowadays, is enlarged, the expectations and uses of robots are becoming varied. In order to enhance productivity and decrease labor power, need more development of robot. Now, many fields need robot for various work as well as dangerous and hard environment with nuclear power plant, undersea, space, toxic waste cleanup, and so forth. Therefore the attention to the new controlling method which dispense with the exact modeling of control objects as neural network is gradually being increased.

Neural network is control method that modelling of system does not need. In this paper, controller composed of neural network and feedback controller is proposed in this paper.

Force control is necessary skill at cooperation work with robot and object. There is impedance way that is based in dynamics relation between robot and object, and hybrid way that control force directly by representative force control method.

This paper presents position and force control using neural network. It is concerned with the study of the position and force control of 2-link manipulator. After the completion of learning, the output of feedback controller is nearly equal to zero, and the neural network controller plays an important role in the control system. Therefore, the optimum retuning of parameters of feedback controllers is unnecessary. In other words, the proposed algorithm does not require any knowledge of the controlled system in advance.

The usefulness of the proposed controller is verified by position and force control experiment. The controller using neural network showed good result.

제1장 서론

최근 산업용 로봇에 의하여 많은 작업의 신속화와 정밀화가 이루어졌다. 특히 자동생산, 자동조립, 자동측정 등 부품을 생산, 조립, 분류 평가하는데 있어서 산업용 로봇의 역할은 그 중요성을 더해 가고 있다[1]. 그러나 생산성을 향상하고 맨-아워(man-hour)를 추가적으로 줄이기 위해서는 다양한 산업용 로봇의 개발이 더욱더 필요한 실정이다. 단순 조립, 가공 작업에서 발전하여 정확한 위치제어와 힘 제어를 통한 정밀 가공이 가능한 산업용 로봇의 요구가 높아지고 있다[2].

지금까지의 산업용 로봇은 단순하고 반복적인 작업을 미리 정해진 순서대로 수행함으로써 인간의 노동력을 대신해 주고 있으나, 핵발전소, 심해탐사, 우주 탐험등과 같이 위험하고 힘든 환경뿐만 아니라 초정밀가공 등 다양하고 지능적인 작업 수행에 로봇의 필요성이 대두되고 있다[3][4]. 이런 이유로 지능을 인공적으로 구현하기 위한 많은 연구가 있었고, 그중 눈에 띄는 결과중의 하나가 신경의 구조를 이용한 신경회로망(Neural Network)이다[5].

로봇의 발전과 함께 많은 알고리즘이 제안되고 실제 로봇에 적용되어 산업현장에서 일을 수행하고 있다. 로봇의 힘 제어 방식은 매우 세련된 로봇 제어기술로서 로봇과 대상물체와의 협조 작업에 반드시 필요한 기술이다[6][7]. 대표적인 힘 제어 기술로는 로봇과 대상사이의 역학관계에 근거한 임피던스 제어방식과 원하는 힘을 직접 제어하는 하이브리드 제어 방식이 있다. 그 외에는 두 방식을 결합한 하이브리드 임피던스 방식이 제안되었고, 적분기를 사용하여 원하는 힘을 추종할 수 있는 제어방식이 제안되었다[8][9].

이러한 관점에서 본 논문에서는 제2장에서 대상물체의 특성변화에 적절히 대처 할 수 있는 신경회로망에 대하여 간략히 설명을 하고, 제3장에서는 실험장치인 2-링크 매니플레이터의 동역학 방정식과 운동 방정식을 설명한다. 제4장에서 본 논문에서 위치 및 힘 제어 실험

에 사용한 제어기에 대해서 설명하며, 제5장에서 위치 및 힘 제어가 발생하는 모든 불확실성을 보상하는 제어기로 신경회로망을 이용하여 학습률, 입력층수, 중간층수의 변화에 따른 실험을 2링크 매니플레이터에 적용하여 신경회로망의 유효성을 확인한다.

제2장 신경회로망

2.1 신경회로망의 정의

인간은 오랜 경험으로부터 어떤 행동에 대한 지식을 습득하고 있다. 이러한 경험에 의한 지식은 명확한 형태로 표현하는 것이 쉽지는 않다. 같은 패턴(pattern)의 운동을 여러 번 반복하는 동안에 운동 요령을 습득하여 손발의 구체적인 움직임을 특별히 의식하지 않더라도 일련의 운동 패턴을 재현할 수 있게 되는 것이 좋은 예이다. 이런 인간의 지능을 로봇에 적용하면 로봇이 지능화된 모습으로 여러 가지 동작을 구현하는 능력을 가지게 될 수 있을 것이다. 때문에 많은 학자들이 뇌의 구조와 기능에 대하여 구체적으로 알기 위해서 다방면의 연구를 수행하였다.

그러나 공학자들의 관심은 뇌의 생리학적 구조와 기능을 밝히는데 있지 않다. 그보다는 뇌의 복잡한 구조적특징과 이로부터 비롯되는 고도의 신호처리 체계를 연구하여 고난도의 실제 문제에 적용할 수 있는 새로운 연산기법, 즉 신경회로망(neural network)을 개발하는데 그 목표를 두고 있다. 신경회로망이란 뇌의 구조와 기능을 이해함으로써 뇌가 수행하는 연산기능의 원리로부터 새로운 개념을 추출하여 이를 구현하는 것을 의미한다.

신경회로망에 대한 연구는 1950년대에 생물의 신경계통에 대한 연구를 계기로 1957년에 퍼셉트론(perceptron)이란 최초의 신경회로망 모델이 제안되면서부터 본격 적으로 시작되었다. 단층구조의 회로망이 훈련을 통해 여러 가지 패턴을 학습 시키는 퍼셉트론 이론은 몇 가지 문제점이 지적되어 신경회로망에 대한 연구는 쇠퇴하였다. 그러나 1980년대에 새로운 아이디어가 도입되어 그 때까지의 퍼셉트론으로는 선형분리가 불가능한 패턴에 대한 학습이 가능하게 되어, 또 다시 신경회로망에 대한 연구가 활성화되었다. 그 중에서도, 목표신호와 실제

출력과 의 자승오차를 평가함수로 하여, 이것을 최소로 하는 학습방법인 오차역전파법(error back-propagation) 알고리즘이 제안되어, 계층형 신경회로망에 의한 여러 가지 패턴학습이 가능하게 되었다.

신경회로망은 알고리즘을 프로그램 명령어에 의해 순차적으로 처리하는 Von neumann 방식의 컴퓨터로는 해결하기 곤란한 패턴인식, 음성인식, 음성합성, 힘 제어, 자동번역, 최적화, 적응제어 등 많은 분야에 응용되고 있다[10][11].

2. 2 신경회로망의 구성

신경회로망은 단순한 기능을 수행할 수 있는 신경소자들의 수많은 병렬연결로 이루어져 있다. 생물학적 신경망과 마찬가지로 병렬분산 처리를 할 수 있을 뿐만 아니라, 학습이나 훈련을 통해서 결합하중을 조정하며 정보를 추가하거나 변경할 수 있는 적응특성을 가지고 있다. 신경회로망을 구성하는 기본 적인 요소로는 다음과 같은 세 가지를 꼽을 수 있다.

- (1) 신경소자(neuron) 또는 처리소자(PE : processing element)
- (2) 결 선 (connection)
- (3) 학습규칙(learning rule) 또는 훈련 알고리즘(training algorithm)

신경회로망은 단순한 기능을 가진 무수히 많은 신경소자(neuron) 또는 처리소자(PE : processing element)들이 병렬 연결된 연산구조로 되어 있다. 그 특징은 다음과 같다.

- (a) 각 신경소자는 다른 신경소자들과 완전히 독립된 기능을 갖는다. 즉, 각 신경소자의 출력은 자신과 연결된 결합을 통하여 직접 전달되는 정보에만 의존할 뿐, 다른 정보들과는 무관하며 병렬처리가 가능

하므로 연산속도가 매우 빠르다.

(b)신경회로망은 무수히 많은 결선을 가지고 있어서 정보 분산표현 및 처리가 가능하다. 또, 중복성(redundancy)이 크므로 Fault-tolerant 할 뿐만 아 니라 일부의 정보로부터 전체를 얻을 수 있는 연상기억 (associative menlory) 특성을 갖는다.

(c) 학습이나 훈련을 통해 결합하중을 조정함으로써 새로운 정보를 추가하거나 변경할 수 있는 적응특성을 가지고 있다.

2.2.1 신경소자

신경회로망의 종류에 따라 매우 다양한 형태를 가지고, 신경회로망 에서 이루어지는 연산을 수행하는 중심 요소이며, 같은 종류의 신경 소자들은 보통 층(layer)을 구성한다. Fig. 1은 층을 구성하고 있는 i 번째 신경소자를 보인 것이다.

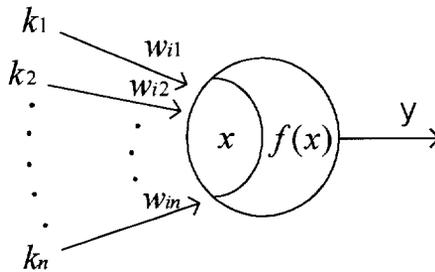


Fig. 1 Neuron

그림에서 k_1, k_2, \dots, k_n 은 신경소자에 인가된 입력이다. 외부로부터 인가된 입력일 수도 있고, 같은 층에 포함된 신경소자들의 출력이거나 다른 층에 있는 신경소자들의 출력, 또는 이들이 섞여있는 것일

수도 있다. 신경소자들 간의 결선은 신호가 전파되는 방향의 화살표로 나타낸다. $w_{i1}, w_{i2}, \dots, w_{in}$ 는 n 번째 입력으로부터 i 번째 신경소자에 이르는 입력층과 중간층의 결합하중, $f(x)$ 는 중간층과 출력층으로 변환되는 활성화함수이다.

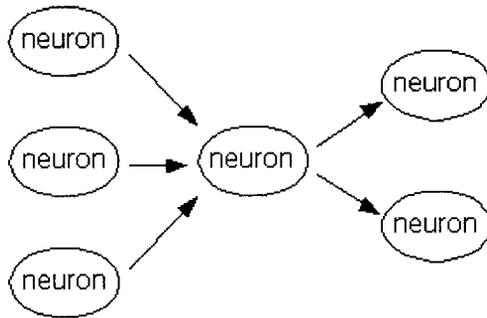


Fig. 2 Structure of neuron

Fig. 1의 신경소자들이 결합을 하여 신경회로망을 구성하며, Fig. 2는 신경소자들의 결합을 신경회로망의 관점으로 나타내었다.

2.2.2 결선

신경소자들의 층을 가지고 있는 신경회로망에서는 같은 층에 속한 신경소자들 사이의 층내 결선 (intra-layer connection)과 서로 다른 층에 속한 신경소자들 사이의 층간 결선 (inter-layer connection)이 존재한다. 층내 결선은 신호의 피드백을 야기하므로 신경소자들의 상태는 동적으로 변화한다. 그러나 층간 결선을 가진 신경소자들의 상태는 일반적으로 정적 변화를 한다고 볼 수 있다.

Fig. 1에서 각 입력은 결선을 통해 변조되어 i 번째 신경 소자에 전파된다. 이 변조작용은 결합하중 w_{in} 에 의해 결정된다. 이 때, $w_{in} > 0$ 인 것을 여기성 결선(excitatory connection)이라 하고, $w_{in} < 0$ 인 것을 억제성 결선(inhibitory connection)이라 한다.

2.2.3 학습

신경회로망에서의 학습(learning)이란, 외부 세계에서 신호를 입력했을 때 네트워크를 구성하는 결합하중을 바람직한 값으로 변화시키는 것을 말한다. 일반적으로 i 번째와 n 번째의 신경소자를 결합하는 결합하중 w_{in} 은 식(2.1)와 같이 표현할 수 있다.

$$\Delta w_{in} = \eta \delta_n y_i \quad (2.1)$$

여기서 η 는 학습률, δ_n 은 학습신호, y_i 는 신경소자의 출력을 각각 나타낸다.

신경회로망의 학습은 크게 지도학습(supervised learning)과 자율학습(unsupervised learning)으로 나누어 볼 수 있다. Fig. 3에 나타낸 것과 같이 지도학습은 오차가 최소가 되도록 규칙에 따라 결합하중을 조정하는 방법이며, 자율학습은 입력패턴들에 대해서 각 신경소자들이 유사한 출력을 생성하도록 결합하중을 조정하는 방법이다.

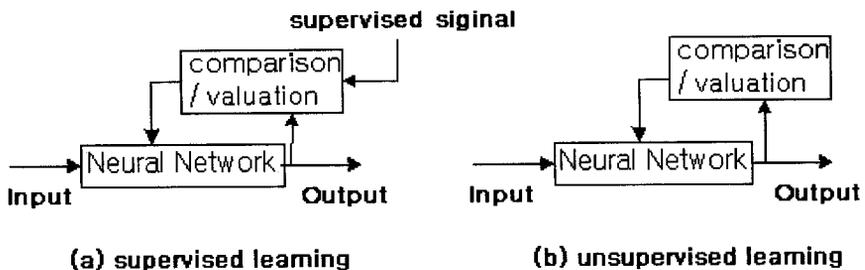


Fig. 3 Control of connection

결합하중을 조절하는 방법은 여러 가지가 있으나 가장 일반적인 방법은 목적패턴과 출력값 사이의 차이 즉, 오차(error)를 기준으로 하여 이루어진다. 이렇게 연결가중치를 조절하는 방법을 학습규칙이라

하며, Hebb의 규칙, Delta 규칙, 일반화된 Delta규칙 등이 있다.

Hebb의 규칙은 어떤 신경세포들의 활성이 다른 신경세포가 활성화 하는데 계속적으로 공헌한다면, 두 신경세포간의 연결가중치를 증가시켜 주어야 한다는 규칙이다. Hebb의 학습규칙을 이용한 연결가중치의 조절은 간단하다. 즉, 현재 연결가중치에 더해질 연결가중치의 조절량은 단지 연결의 양 끝에 붙어있는 신경세포의 활성값을 곱하기만 하면 된다. 이렇게 구해진 연결가중치 조절량을 기존의 연결가중치에 더해주면 된다.

Delta 규칙은 연결가중치를 조절함으로써 신경회로망을 학습시킨다는 기본 개념에 있어서는 Hebb의 규칙과 동일하지만, 연결가중치를 조절하는 방법에 있어서 다소 차이가 있다. Delta 규칙이 Hebb 규칙과 다른 점은 주어진 입력패턴에 대한 목표패턴과 신경회로망의 출력패턴의 차이, 즉 Delta를 이용하여 학습을 수행한다는 것이다. 즉, 연결가중치의 조절식에 있어서 조절량 Δw 는 연결된 두 뉴런의 활성값을 곱하여 구해지는 것이 아니라, 앞 층 뉴런의 활성값에 오차를 곱하여 구해진다.

일반화된 Delta규칙은 오늘날 가장 많이 사용하는 신경회로망 학습 규칙 중의 하나로 오류역전파 알고리즘(error back-propagation algorithm)이라고 불리고 있다. 델타 규칙과 동일하나 델타 규칙에 없는 내용이 출력층 신경세포의 잘못된 출력패턴에 대한 책임은 바로 아래층 신경세포에게만 있는 것이 아니라 그 신경세포에 연결된 그 아래층 신경세포에게도 책임이 있기 때문에 같이 연결가중치를 조절해야 한다는 규칙이다[12][13].

제 3장 실험장치

본 논문에서는 로봇의 작업시 최적화 상태로 작업을 수행하도록 로봇의 위치 및 힘 제어를 신경회로망을 이용하여 적용하고자 한다.

매니플레이터의 선단을 대상물체에 접촉시켜 센서로부터 힘을 측정함으로써 그때의 값을 모니터링 하여 원하는 힘으로 제어하는 실험을 행하였다. 2개의 서보모터(YOKOGAWA-SD1060B02)를 사용하였고, 로봇의 선단에 장착된 힘 센서는 Nitta(주)의 UFS-67M25A인 6축 힘/토크 센서를 사용하였고, 센서 전용 DSP 보드를 사용하여 실험하였다. Fig.4 와 같은 2링크 매니플레이터를 사용하였다.

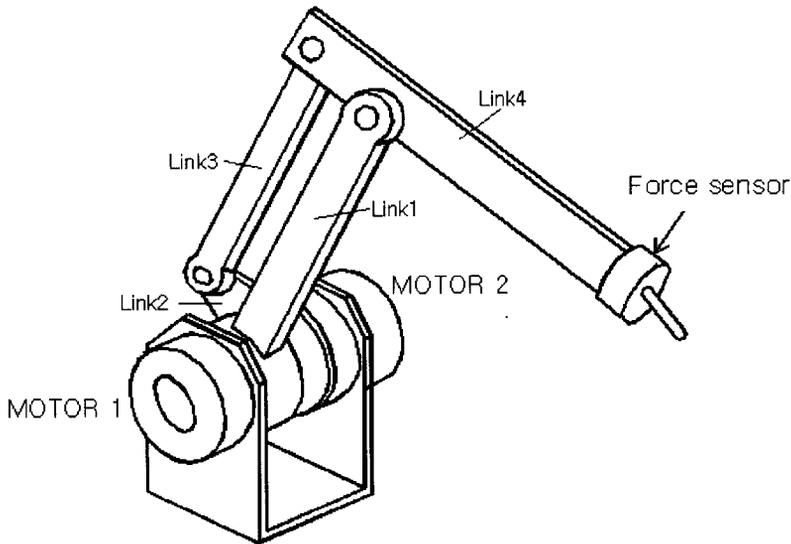


Fig. 4 2Link Manipulator

3.1 로봇의 동역학 방정식

회전관절을 갖는 다자유도 로봇의 동역학 방정식은 일반적으로 다음과 같이 나타낼 수 있다.

$$\tau = M(\theta)\ddot{\theta} + H(\theta, \dot{\theta}) + G(\theta) \quad (3.1)$$

여기서, τ 는 회전관절에서의 발생토크, 우변의 제1항은 관성행렬, 제2항은 원심력 및 코리올리력 벡터, 제3항은 중력벡터를 나타내며, $\theta, \dot{\theta}$ 및 $\ddot{\theta}$ 는 관절각, 각속도, 각가속도벡터를 나타낸다. 실험에 사용된 Fig. 4와 같은 매니플레이터의 동역학 방정식은 다음과 같다.

$$\tau_1 = M_{11}\ddot{\theta}_1 + M_{12}\ddot{\theta}_2 + H_{12}\dot{\theta}_2^2 + G_1 \quad (3.2)$$

$$\tau_2 = M_{21}\ddot{\theta}_1 + M_{22}\ddot{\theta}_2 - H_{12}\dot{\theta}_1^2 + G_2 \quad (3.3)$$

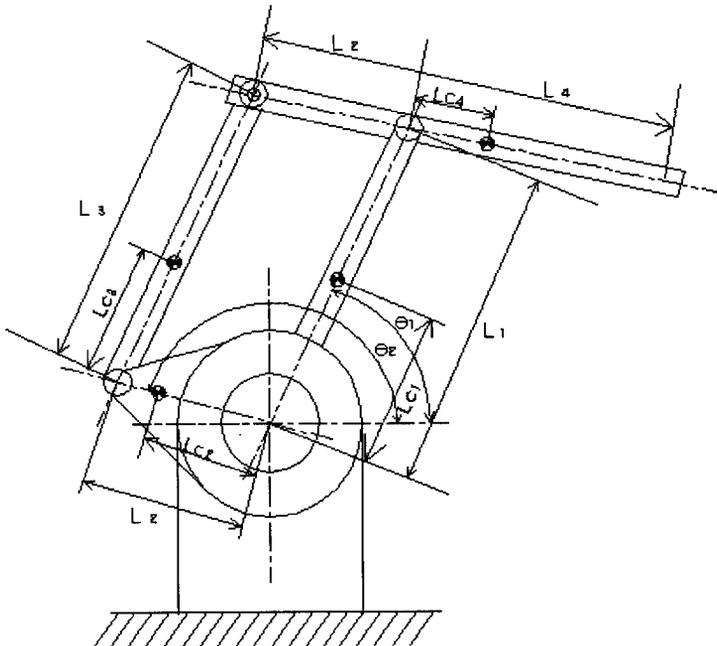


Fig 5 Characteristic of manipulator

여기서, I_i 를 i 관절 축 주위의 관성모멘트, l_i 를 링크 i 의 길이, l_{ci} 를 관절 i 에서 링크질량중심까지의 길이, g 를 중력가속도라 할 때, M_{ij} , H_{12} 및 G_i ($i = 1, 2, j = 1, 2$)는 Fig. 5를 참고하면 다음과 같이 구할 수 있다.

$$M_{11} = I_1 + m_1 l_{c1}^2 + I_3 + m_3 l_{c3}^2 + m_4 l_1^2 \quad (3.4)$$

$$M_{12} = M_{21} = (m_3 l_2 l_{c3} - m_4 l_1 l_{c4}) \cos(\theta_1 - \theta_2) \quad (3.5)$$

$$M_{22} = I_2 + m_2 l_{c2}^2 + I_4 + m_4 l_{c4}^2 + m_3 l_2^2 \quad (3.6)$$

$$H_{12} = (m_4 l_1 l_{c4} - m_3 l_2 l_{c3}) \sin(\theta_1 - \theta_2) \quad (3.7)$$

$$G_1 = g \cos \theta_1 (m_1 l_{c1} + m_3 l_{c3} + m_4 l_1) \quad (3.8)$$

$$G_2 = g \cos \theta_2 (m_2 l_{c2} + m_3 l_2 - m_4 l_{c4}) \quad (3.9)$$

식(3.2), 식(3.3)에서 알 수 있듯이 2자유도 평행링크 로봇의 경우, $\dot{\theta}_i \dot{\theta}_j (i \neq j)$ 항으로 표현되는 코리올리력이 작용하지 않아, 평행링크구조는 직렬링크구조에 비해 비선형 항을 줄일 수 있다.

그리고 모터의 관성을 J , 점성마찰계수를 B , 쿨롱마찰을 F 라 하면, 매니플레이터 모터의 운동방정식은 일반적으로 다음과 같이 나타낼 수 있다.

$$\tau = J \ddot{\theta} + B \dot{\theta} + F(\dot{\theta}) \quad (3.10)$$

여기서, J 및 B 는 다음과 같이 정의한다.

$$J = \begin{bmatrix} J_1 & 0 \\ 0 & J_2 \end{bmatrix} \quad (3.11)$$

$$B = \begin{bmatrix} B_1 & 0 \\ 0 & B_2 \end{bmatrix} \quad (3.12)$$

또한 모터의 쿨롱마찰 F 를 동마찰토크를 f_d , 최대 정지마찰토크를 f_s 라 하면 다음과 같이 구할 수 있다.

$$F(\dot{\theta}) = \begin{cases} f_d & (\dot{\theta} > 0) \\ -f_d & (\dot{\theta} < 0) \\ \tau & (\dot{\theta} = 0 \text{ and } \tau \leq f_s) \end{cases} \quad (3.13)$$

3.2 2링크 매니퓰레이터의 운동방정식

평행링크 로봇의 동역학 방정식인 식 (3.1)과 DD모터의 운동방정식인 식 (3.10)으로부터 매니퓰레이터 전체의 운동방정식을 구하면 다음과 같다.

$$\tau = R(\theta)\ddot{\theta} + B\dot{\theta} + V(\theta, \dot{\theta}) + F(\dot{\theta}) \quad (3.14)$$

여기서, $R(\theta)$ 및 $V(\theta, \dot{\theta})$ 는 다음과 같이 정의 한다.

$$R(\theta) = M(\theta) + J \quad (3.15)$$

$$V(\theta, \dot{\theta}) = H(\theta, \dot{\theta}) + G(\theta) \quad (3.16)$$

식(3.15)와 식(3.16)으로부터 관성모멘트는 θ 의 함수로 되어 있으므로 모터 구동각도에 의존하여 변화한다는 것을 알 수 있다. 또한 원심력, 중력 등의 비선형 외란도 각 모터의 동작 상태에 서로 영향을 주어 모터가 비독립적으로 서로 간섭함을 알 수 있다.

제4장 제어기의 구성

4.1 신경회로망에 의한 학습제어

본 논문에서 사용한 제어기는 Fig. 6과 같이 입력층, 중간층, 출력층의 3층 구조를 가지는 신경회로망이다. 각층 뉴런(neuron) 사이의 결합은 존재하지 않는 것으로 하며, 입력층에서 출력층의 방향으로 한 쪽 방향으로만 결합되는 것으로 한다. 각각의 층수를 L, M, H 라 놓으면 각층의 입출력관계는 $i(=1, 2, \dots, L)$, $j(=1, 2, \dots, M)$, $n(=1, 2, \dots, H)$ 일 때 다음과 같이 정의 한다.

$$y_i = x_i \quad (4.1)$$

$$x_j = \sum_{i=1}^L w_{ij} y_i \quad (4.2)$$

$$y_j = f(x) \quad (4.3)$$

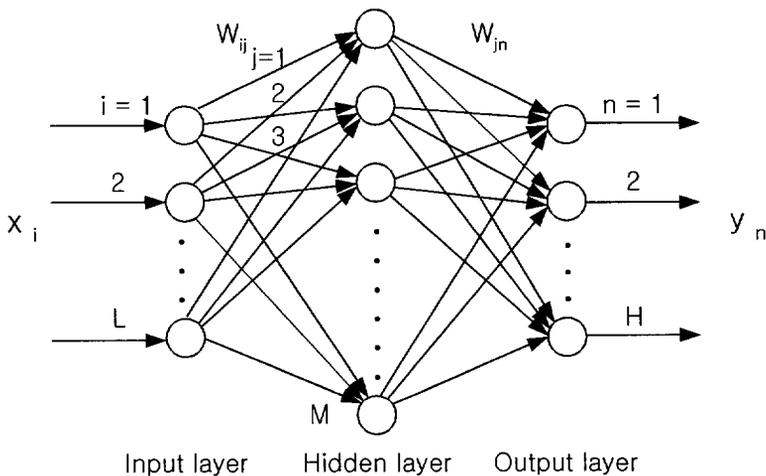


Fig. 6 Neural Network

$$x_n = \sum_{j=1}^M w_{jn} y_j \quad (4.4)$$

$$y_n = f(x_n) \quad (4.5)$$

$$f(x) = \frac{2}{1+e^{-x}} - 1 \quad (4.6)$$

x_i, y_i : 입력층 i 번째 뉴런의 입력, 출력
 x_j, y_j : 중간층 j 번째 뉴런의 입력, 출력
 x_n, y_n : 출력층 n 번째 뉴런의 입력, 출력
 w_{ij} : y_i 와 x_j 사이의 결합하중
 w_{jn} : y_j 와 x_n 사이의 결합하중

또한 입력층의 입출력관계는 선형이며, 중간층과 출력층의 출력은 Fig. 7와 같은 시그모이드(sigmoid) 함수를 통과시킨 것으로, $-1 < f(x) < 1$ 의 범위의 값을 취하는 것으로 한다.

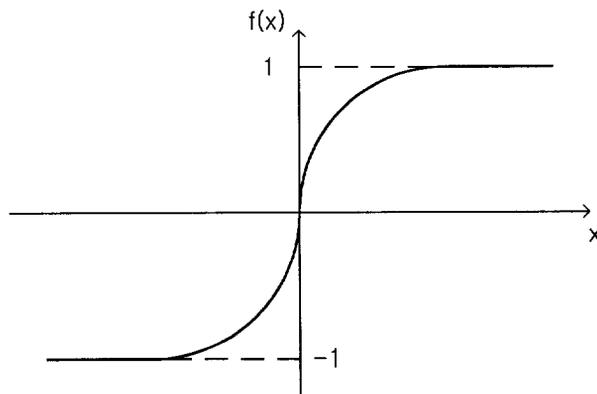


Fig. 7 Sigmoid Function

4.2 오류역전파 알고리즘

신경회로망에서의 학습의 의미는 앞에서 언급한 것처럼 입력신호를 원하는 출력신호로 출력되도록 결합하중을 조정해가는 과정이다. 본 논문에서는 오차를 줄여서 원하는 출력을 얻을 수 있는 학습방법으로 오류역전파(error back-propagation) 알고리즘을 제안하고 있으며, 이것에 대해 서술하면 다음과 같다. 단, 학습을 시작하기 전에 결합하중에 대한 정보가 없기 때문에 임의의 값으로 초기화를 하였다. 신경회로망에 입력신호를 입력하여 출력을 계산한 후, 활성화함수에 의해 최소가 되도록 결합하중을 조정하여 평가를 하고, 이런 일련의 과정을 반복하여 임의의 입력신호에 대하여 원하는 출력신호가 출력되면 학습이 완료되는 것으로 한다.

입력층의 각 유니트에 입력신호가 주어지면 이 신호는 입력층과 중간층 사이의 결합하중 w_{ij} 에 의해 변환되어 중간층에 전달되고, 다시 중간층과 출력층 사이의 결합하중 w_{jn} 에 의해 변환되어 출력층의 y_n 으로 출력하게 된다. 이 출력값과 목표값을 비교하여 그 차이를 줄여나가는 방향으로 각 결합하중의 값을 역순으로 조절, 즉 중간층과 출력층사이의 결합하중을 조절한 후, 이것을 토대로 입력층과 중간층사이의 결합하중을 조절하는 것이다.

여기서 신경회로망의 오차함수 E 는 식(4.7)과 같이 정의한다.

$$E = \frac{1}{2} \sum_{n=1}^H (v_n - y_n)^2 \quad (4.7)$$

식(4.7)에서 v_n 은 원하는 목표출력이고, y_n 은 신경회로망의 실제출력이다.

이 오차함수 E 는 유니트간의 결합하중 w 의 함수이므로, E 가 최소가 되도록 결합하중 w 를 수행하기 위해서 오차함수 E 에 대해 다음의 최급하강법을 도입한다.

$$w(m+1) = w(m) - \eta \frac{\partial E}{\partial w} \quad (4.8)$$

식(4.8)에서 m 은 학습횟수(결합하중의 조절회수), η 는 학습률, $w(m)$ 은 수정전 결합하중이며, $w(m+1)$ 은 수정된 결합하중이다.

식(4.8)을 중간층과 출력층사이의 결합하중의 변화량 Δw_{jn} 으로 나타내면 다음과 같다.

$$\begin{aligned} \Delta w_{jn} &= -\eta \frac{\partial E}{\partial w_{jn}} \\ &= -\eta \frac{\partial E}{\partial x_{jn}} \frac{\partial x_n}{\partial w_{jn}} \\ &= \eta \delta_n y_j \end{aligned} \quad (4.9)$$

여기서 δ_n 은 결합하중을 조절하기 위한 역전파 오차이며, 식(4.5), (4.7)로부터 다음과 같이 구해진다.

$$\begin{aligned} \delta_n &= -\frac{\partial E}{\partial x_n} \\ &= f'(x_n) \cdot (v_n - y_n) \end{aligned} \quad (4.10)$$

이다. 그리고 식(4.10)에서 $f'(x_n)$ 은 식 (4.6)으로부터 다음과 같다.

$$f'(x_n) = \frac{1}{2}(1 - y_n^2) \quad (4.11)$$

또한, 입력층과 중간층사이의 결합하중의 변화량 Δw_{jn} 는 다음과 같이 정의한다.

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = \eta \delta_j y_i \quad (4.12)$$

$$\delta_j = -\frac{\partial E}{\partial x_j} = f'(x_j) \sum_{n=1}^H \delta_n w_{jn} \quad (4.13)$$

그러므로 각층 사이의 결합하중은 식(4.8), (4.9), (4.12)로부터 다음과 같이 조절된다.

$$w_{jn}(m+1) = w_{jn}(m) + \sum_{j,n} \eta \delta_n y_j \quad (4.14)$$

$$w_{jn}(m+1) = w_{ij}(m) + \sum_{i,j} \eta \delta_j y_i \quad (4.15)$$

4.3 위치 및 힘 제어기

Fig. 8 은 본 논문에서 제안한 매니플레이터의 위치 및 힘 제어를 나타낸다. PD제어기가 주제어기로 사용되며 학습이 시작되고 응답이 목표치에 도달하면 신경회로망이 주제어기가 되어 제어가 된다[14]. Fig. 5와 같은 매니플레이터에서 힘 센서의 끝부분의 위치를 r 이라 하면, r 은 운동학 함수 $\Lambda(\theta)$ 를 이용하여 다음과 같이 나타낼 수 있다.

$$r = \Lambda(\theta) \quad (4.18)$$

여기서, l_n 를 Fig.5에 나타낸 각각의 링크길이($l_1 = 0.4 \text{ m}$, $l_2 = 0.2 \text{ m}$, $l_3 = 0.545 \text{ m}$, $l_4 = 0.062 \text{ m}$) 라 할 때, r , θ , $\Lambda(\theta)$ 는 다음과 같이 정의한다.

$$r = [r_x \ r_y]^T \quad (4.19)$$

$$\theta = [\theta_1 \ \theta_2]^T \quad (4.20)$$

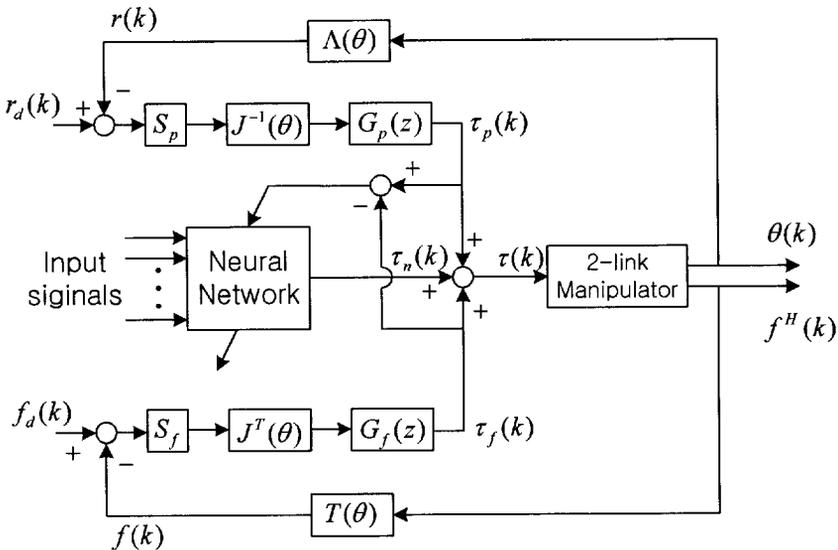


Fig. 8 Position and Force control of the manipulator

$$A(\theta) = \begin{bmatrix} l_1 \cos \theta_1 - l_3 \cos \theta_2 - l_4 \sin \theta_2 \\ l_1 \sin \theta_1 - l_3 \sin \theta_2 + l_4 \cos \theta_2 \end{bmatrix} \quad (4.21)$$

센서좌표계를 기준으로, 한 접촉면과의 접촉힘 f^H 를 좌표변환행렬 $T(\theta)$ 에 의해 로봇 하단부의 직각좌표계로 변환하면 다음과 같다.

$$f = T(\theta) f^H \quad (4.22)$$

여기서, f 및 $T(\theta)$ 는 다음과 같이 정의한다.

$$f = [f_x \ f_y]^T \quad (4.23)$$

$$T(\theta) = \begin{bmatrix} -\cos \theta_2 & \sin \theta_2 \\ -\sin \theta_2 & -\cos \theta_2 \end{bmatrix} \quad (4.24)$$

위치제어 및 힘 제어의 선택행렬을 각각 S_p, S_f 라 하면, 목표위치 r_d 와 실제위치 r 과의 오차, 목표 접촉힘 f_d 와 실제 접촉힘 f 와의 오차는 Jacobian 행렬 $J(\theta)$ 를 이용하여 관절좌표계를 기준으로 한 관절 각변위 $\Delta\theta$ 및 토크변화량 $\Delta\tau$ 로 다음과 같이 각각 변환시킬 수 있다.

$$\Delta\theta = (r_d - r) S_p J^{-1}(\theta) \quad (4.25)$$

$$\Delta\tau = (f_d - f) S_f J^{-1}(\theta) \quad (4.26)$$

여기서 $J(\theta), S_p, S_f$ 는 각각 다음과 같다.

$$J(\theta) = \begin{bmatrix} -l_1 \sin \theta_1 & l_3 \sin \theta_2 - l_4 \cos \theta_2 \\ l_1 \cos \theta_1 & -l_3 \cos \theta_2 - l_4 \sin \theta_2 \end{bmatrix} \quad (4.27)$$

$$S_p = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad (4.28)$$

$$S_f = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \quad (4.29)$$

신경회로망의 출력을 τ_N , 힘 제어기의 출력을 τ_f , 위치제어기의 출력을 τ_p 라 하면, 제어대상인 로봇의 조작량 $\tau = [\tau_1 \ \tau_2]^T$ 는 다음과 같이 주어진다. 단, τ_1 은 x 방향의 조작량이고, τ_2 는 y방향의 조작량이다.

$$\tau = \tau_f + \tau_p + \tau_N \quad (4.30)$$

Fig. 8의 전달함수 행렬은 다음과 같이 정의한다.

$$G_p(z) = \begin{bmatrix} G_{px}(z) & 0 \\ 0 & G_{py}(z) \end{bmatrix} \quad (4.31)$$

$$G_f(z) = \begin{bmatrix} G_{fx}(z) & 0 \\ 0 & 0 \end{bmatrix} \quad (4.32)$$

여기서, K_p 를 비례 이득(gain), K_D 를 미분 이득이라 하면, $G_{px}(z)$, $G_{py}(z)$, $G_{fx}(z)$ 는 각각 다음과 같이 정의한다.

$$G_{px}(z) = G_{py}(z) = K_p + K_D(1 - z^{-1}) \quad (4.33)$$

$$G_{fx}(z) = K_p^f \quad (4.34)$$

제 5장 실험

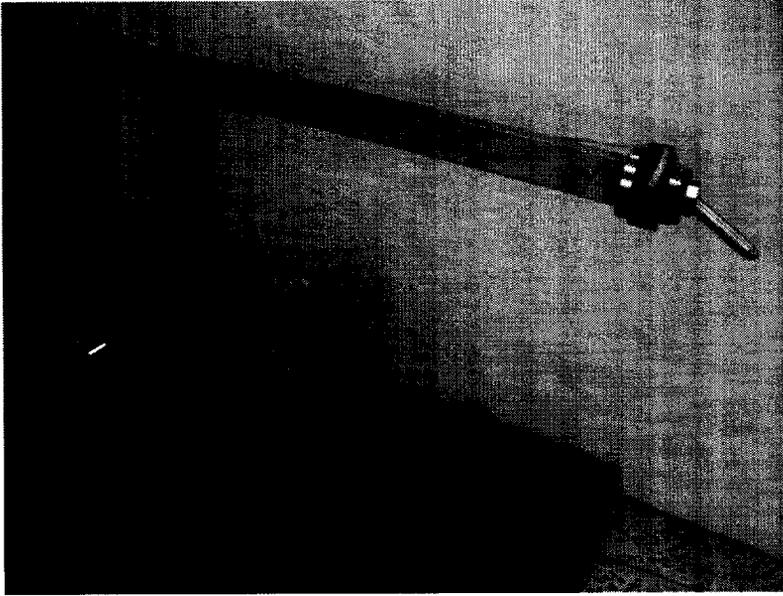


Fig. 9 Experimental Manipulator

실험은 Fig.9의 매니퓰레이터를 사용하여 선단을 대상물체에 일정한 힘으로 수직방향으로 압력을 가하도록 프로그래밍 하여, 학습률 η 의 변화, 입력층수, 중간층수의 변화에 따른 각각의 결과값의 오차를 분석하여 최소의 *Error*가 나오는 값을 취하고, 그 때의 변수값을 각각 기록하여 이후의 실험 파라미터값으로 사용하였다. 여기서 오차 *Error*는 1부터 샘플링수 $N(600)$ 까지의 목표치 f_d 에 출력치 f 를 감산하여 제공한 값의 총합을 총 샘플링수 N 로 나눈 값이다. 식으로 나타내면 다음과 같다.

$$Error = \frac{\sum_{k=1}^N (f_d(k) - f(k))^2}{N} \quad (5.1)$$

피드백제어기는 PD제어기를 사용하였고, 이득값은 제어기가 충분히 안정되도록 하는 범위 내에서 임의의 값으로 $K_P = 350$, $K_D = 30$, $K_P^f = 10$ 을 선택하였다. 실험의 정확도를 높이기 위해서 각각의 실험은 10번씩 시도하였다.

5. 1 힘 제어 실험

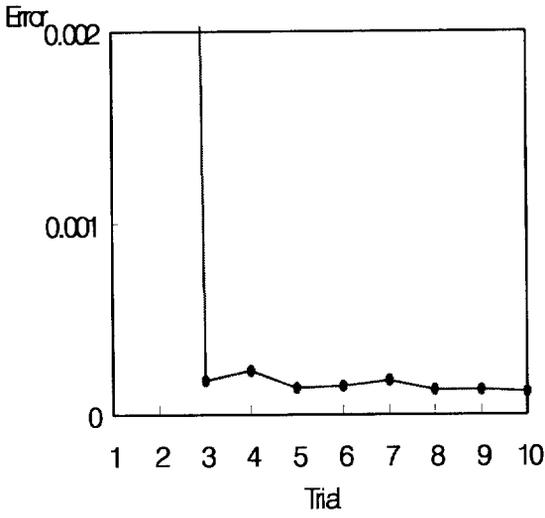
5.1.1 학습률

학습은 결합하중을 바람직한 값으로 변화시키는 것을 말한다. 학습률의 변화에 따른 *Error*의 값을 아래의 Table 1 에 나타내었다. 학습률 η 가 0.005일때 *Error*값은 가장 작게 나오지만 실험응답속도가 아주 불량하였고, 학습률 η 가 0.01일때 응답속도도 양호하며 10번 측정 후 오차가 가장 작았다.

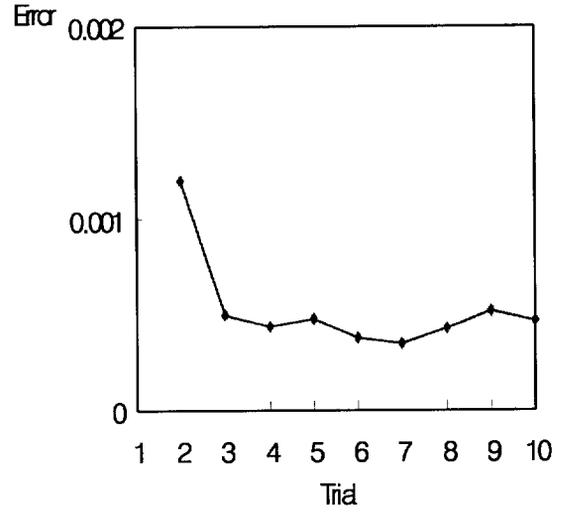
학습률	($Error = \frac{\sum_{k=1}^N (f_d(k) - f(k))^2}{N}$)
0.005	0.000116
0.01	0.000470
0.05	0.000491
0.1	0.000642

Table 1 Experimental results for η

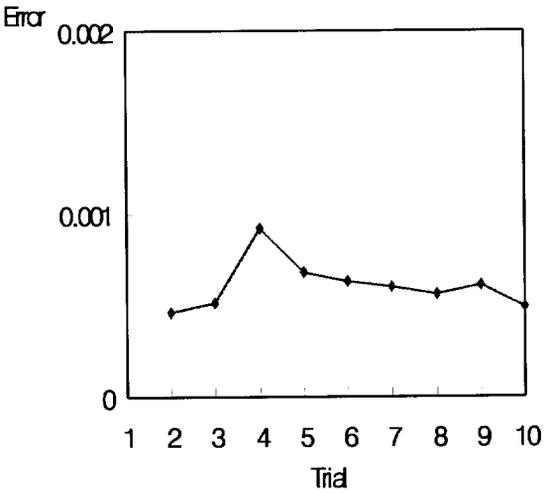
Fig. 10은 학습률 η 의 변화에 따른 *Error*값의 변화를 나타내고 있다. (a)는 첫 번째와 두번째 시도 *Error*가 상당히 크고 응답속도가 느렸다. (b), (c), (d) 그래프는 전반적으로 유사하나 응답속도와 10번까지 시도했을 경우 전체적인 응답은 (b)의 그래프가 가장 우수하였다. 그러므로 이후 실험에서 학습률 η 는 0.01로 선택하였다.



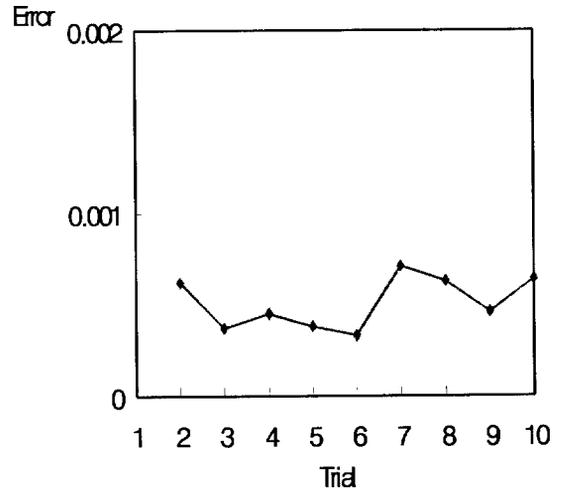
(a) $\eta = 0.005$



(b) $\eta = 0.01$



(c) $\eta = 0.05$



(d) $\eta = 0.1$

Fig. 10 Experimental results for η

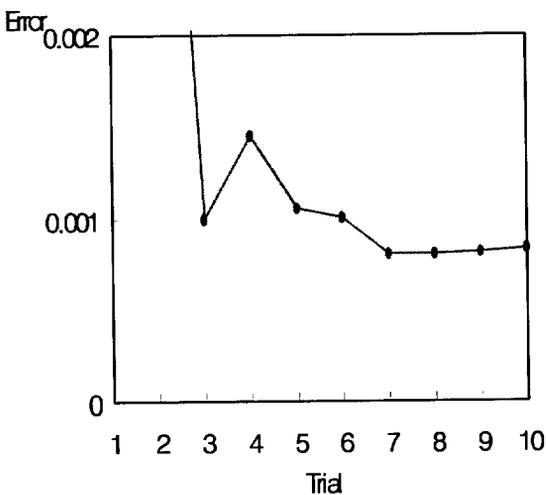
5.1.2 입력층수

입력층수의 변화에 따른 *Error*값을 Table 2. 에 나타내었다. 앞의 실험에서 설정한 학습률(0.01)을 사용하였다. 실험 방법은 동일하며 10 번 시도하였다.

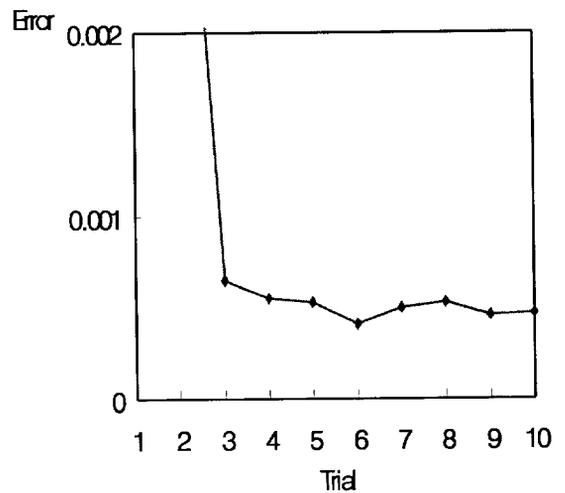
입력층수	$(Error = \frac{\sum_{k=1}^N (f_d(k) - f(k))^2}{N})$
2	0.000838
4	0.000468
6	0.000394
8	0.000944

Table 2 Experimental results for input layer

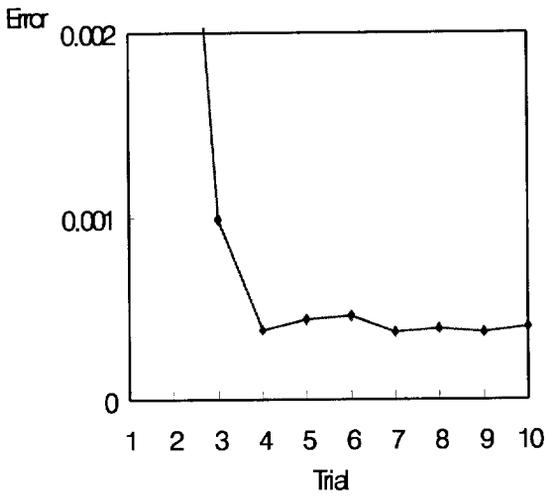
Table 2 의 결과와 같이 입력층수의 수가 6일때 *Error*가 가장 양호 하였다. 따라서 이후의 실험에서 입력층수의 수는 6으로 선택하였다.



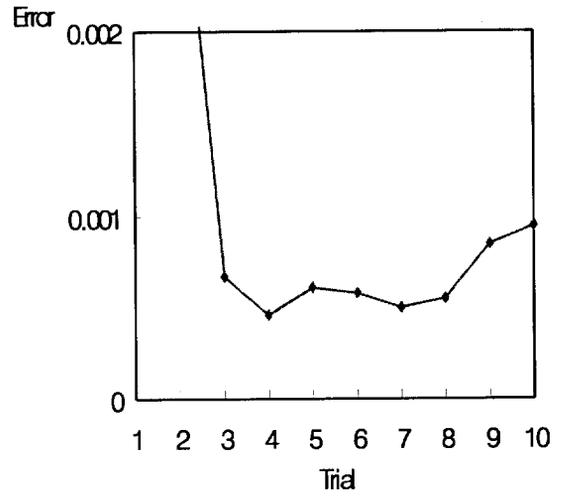
(a) Input layer = 2



(b) Input layer = 4



(c) Input layer = 6



(d) Input layer = 8

Fig. 11 Experimental results for input layer

Fig. 11은 입력층수의 변화에 따른 *Error*를 나타내고 있다. Table 2.의 결과와 동일하게 Fig. 11의 (c)그림인 입력층수가 6일 때의 응답이 가장 양호한 것을 알 수 있다.

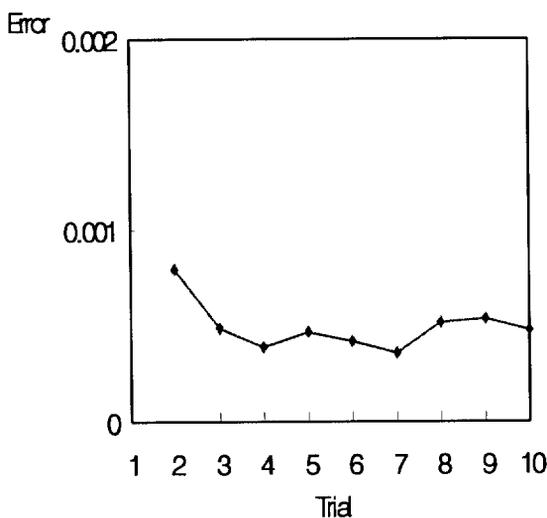
5.1.3 중간층수

마지막으로 중간층수의 변화에 따른 *Error*값을 Table 3 에 나타내었다. 앞선 두 실험에서 선정된 학습률(0.01)과 입력층수(6)을 사용하였다. 실험은 10번 시행하였다.

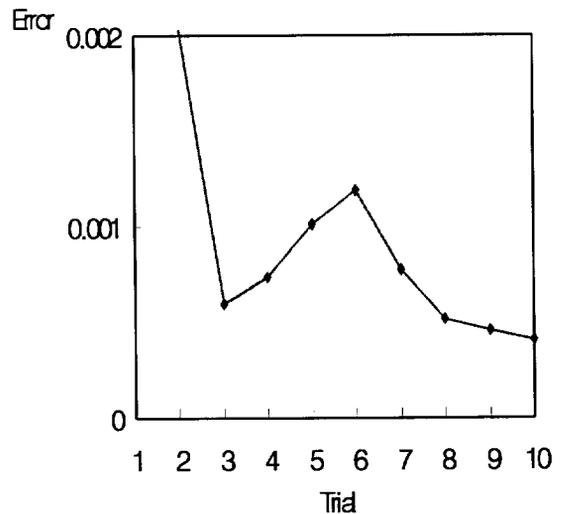
중간층수	($ Error = \frac{\sum_{k=1}^N (f_d(k) - f(k))^2}{N} $)
5	0.000474
8	0.000407
10	0.000245
12	0.000155

Table 3 Experimental results for middle layer

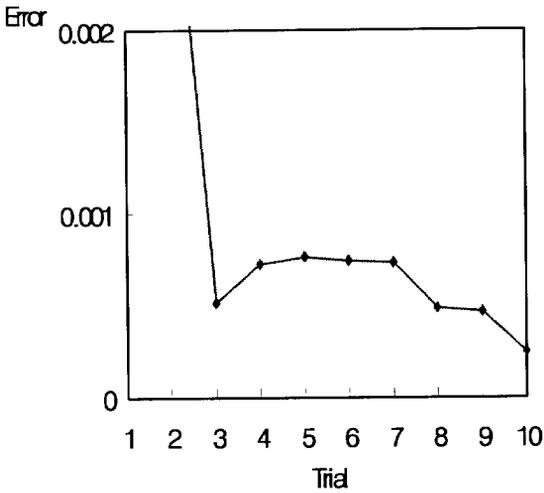
Fig. 12에 실험 결과를 나타내었다. 중간층수가 12일때 *Error*가 가장 양호하였으나 Fig. 12의 (d)그림에서 볼 수 있듯이 전체적인 실험의



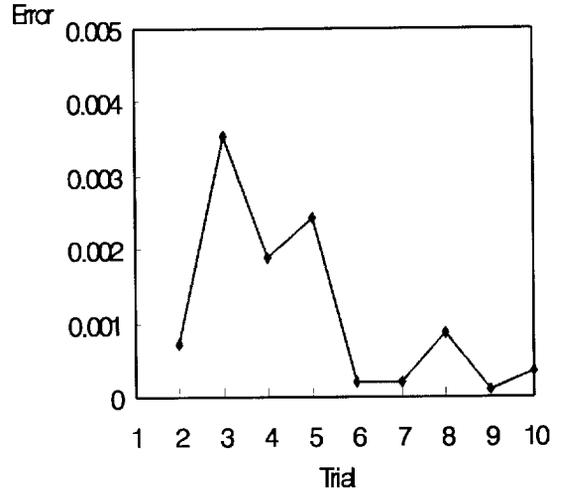
(a) Middle layer = 5



(b) Middle layer = 8



(c) Middle layer = 10



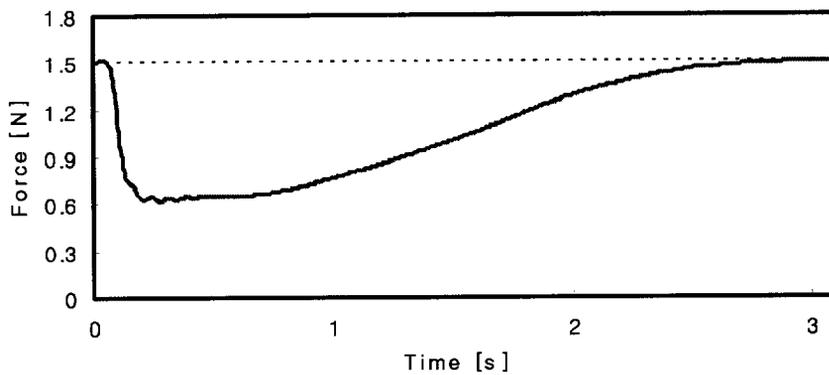
(d) Middle layer = 12

Fig. 12 Experimental results for middle layer

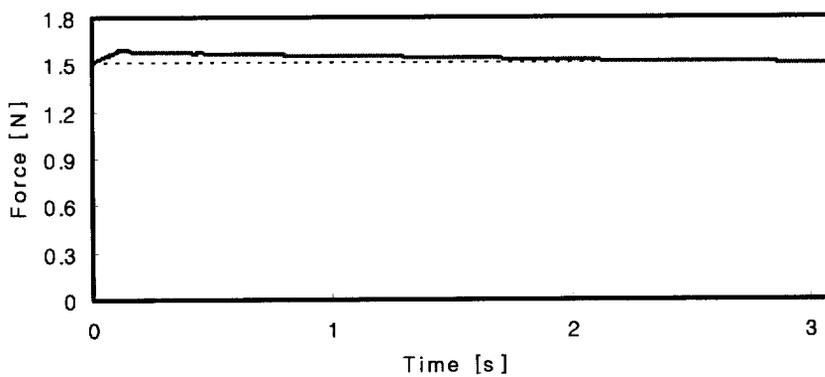
응답이 불량하였다. 그러나 (c)그림의 결과와 같이 중간층수가 10일 때 전체적인 응답이 가장 우수하였다. 그러므로 이후의 실험에서의 중간층수는 10으로 선택하였다. 앞선 실험들의 결과로 Fig. 6의 신경회로망의 입력층수 L이 6개, 중간층수 M이 10개, 출력층수 H를 2개로 각각 선택하였다.

다음실험으로 앞선 3가지 실험에서 선택한 각각의 학습률, 입력층수, 중간층수의 값을 이용하여 센서의 접촉대상이 되는 대상물체에 따른 응답에 대해서 알아보았다. 처음으로 실험한 대상은 마우스 패드이며 1.5[N]의 일정한 힘으로 패드에 하중을 가하였다. Fig. 13에 실험결과를 표시하였다.

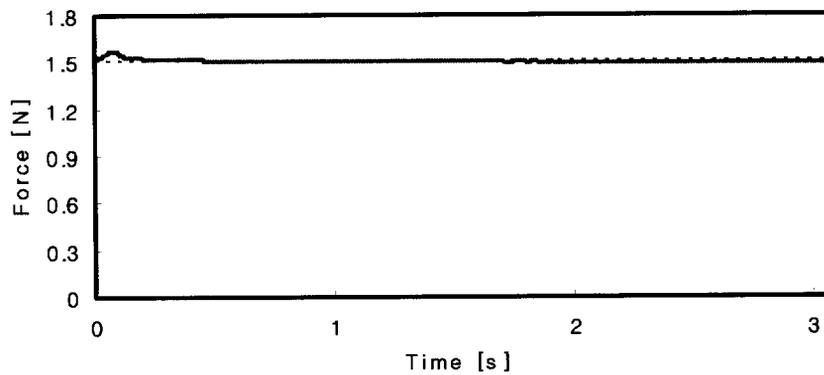
Fig. 13의 (a)그림은 첫 번째 실험결과이다. 목표치와는 차이가 많이 있으나 신경회로망을 이용하여 학습한 실험부터는 목표값과 실험값이 거의 일치하였다. (d)그림의 10번째 시도에서 볼 수 있듯이 학습할수록 응답결과가 좋아짐을 알 수 있다.



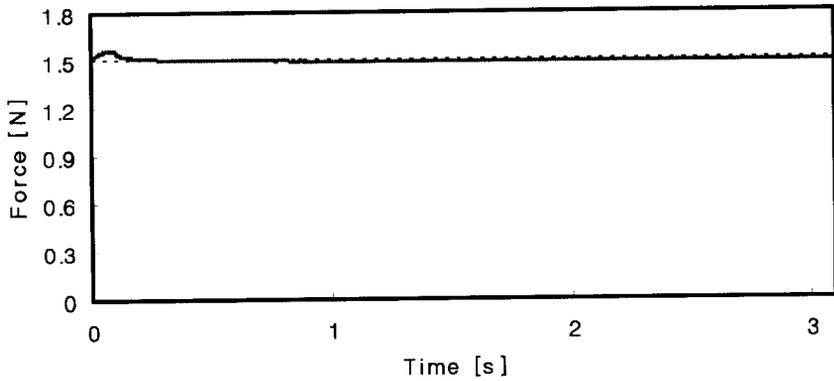
(a) 1st trial



(b) 2nd trial



(c) 5th trial

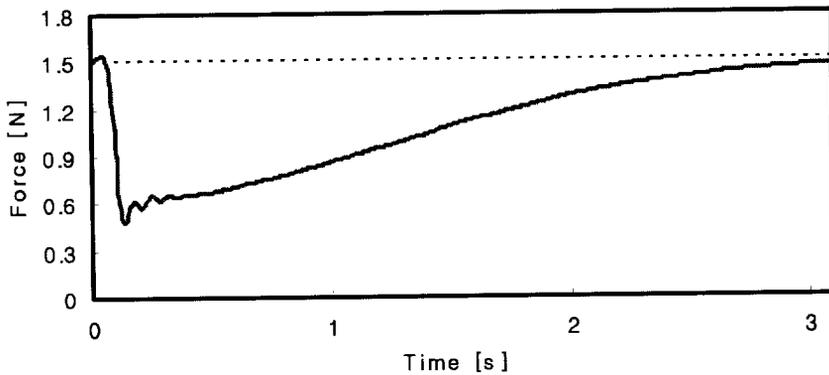


(d) 10th trial

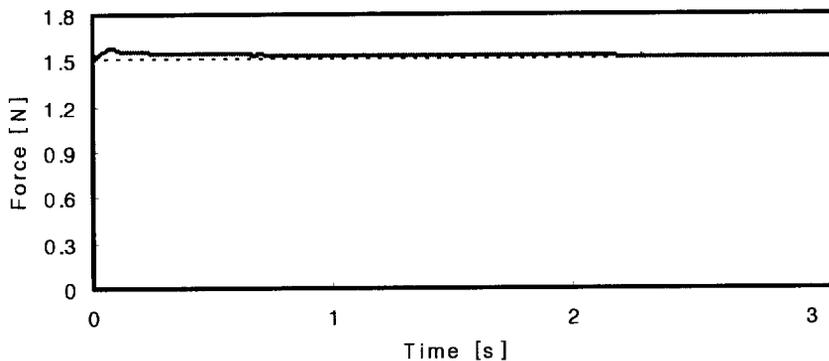
Fig. 13 In case of pad

대상물체의 변화에 따른 2번째 실험은 강철을 이용하여 실험하였다. 실험방법은 동일하며 Fig. 14에 실험결과를 표시하였다.

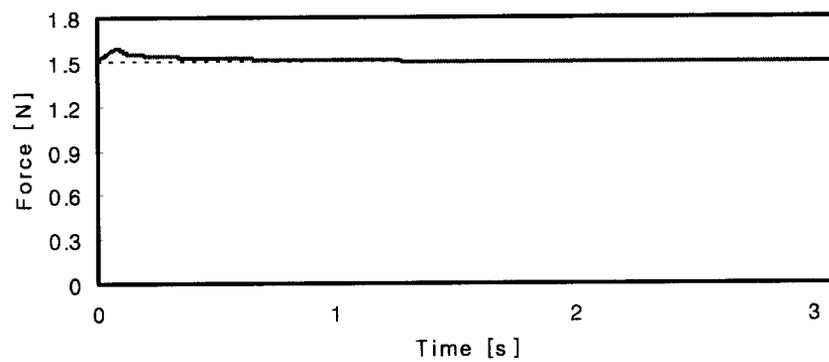
Fig. 14의 (a)그림은 첫번째 접촉 실험결과이다. 대상물체가 패드일 경우와 마찬가지로 원하는 목표치와는 차이가 많이 남을 볼 수 있다. 그러나 신경회로망을 이용한 학습 후부터는 목표값과 실험값이 거의 일치하였다. 10번째 시도에서 볼 수 있듯이 학습할수록 응답결과가 좋아짐을 알 수 있다.



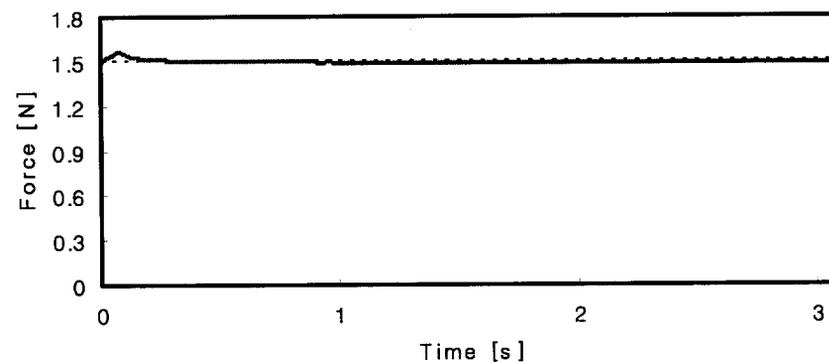
(a) 1st trial



(b) 2th trial



(c) 5th trial



(d) 10th trial

Fig. 14 In case of steel

대상물체가 달라짐에도 불구하고 신경회로망을 이용한 제어기는 만족할 만한 결과를 나타내었다.

5.2 위치 및 힘 제어 실험

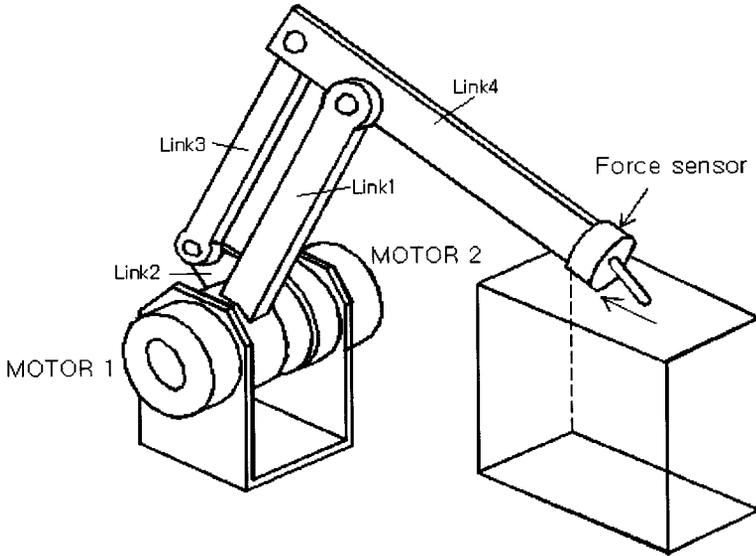


Fig. 15 Experimental Manipulator

위치 및 힘 제어 실험은 Fig. 15과 같이 1.5[N]의 일정한 힘을 가하며 수직방향으로 누른 상태에서 매니플레이터 방향으로 0.1[m] 이동함으로써 실시하였다. 처음시도에는 PD제어기만이 사용되어 응답이 불량하나, 일정 값을 지나게 되면 신경회로망이 주 제어기가 되어 학습함으로써 만족할만한 응답을 보였다. 실험에 사용한 신경회로망은 힘 제어실험에서의 결정한 값으로 Fig. 16과 같은 신경회로망을 사용하였다.

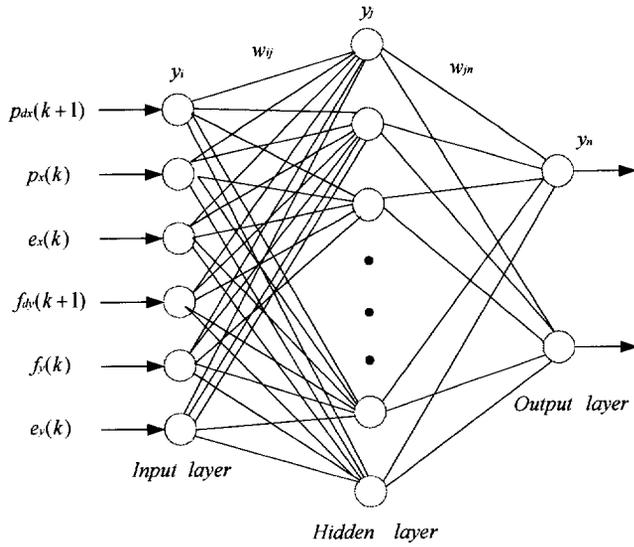
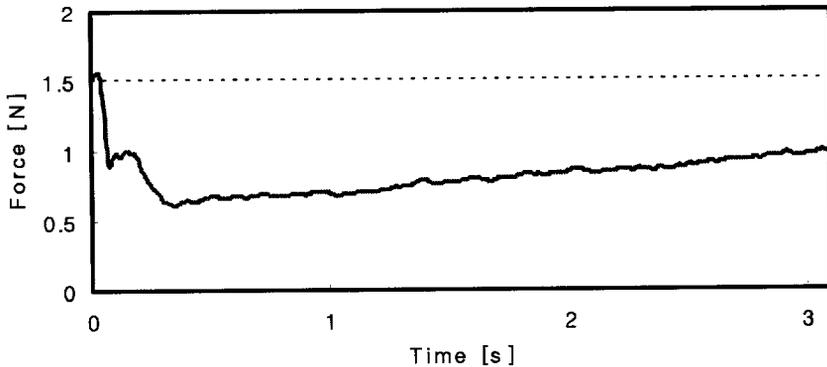


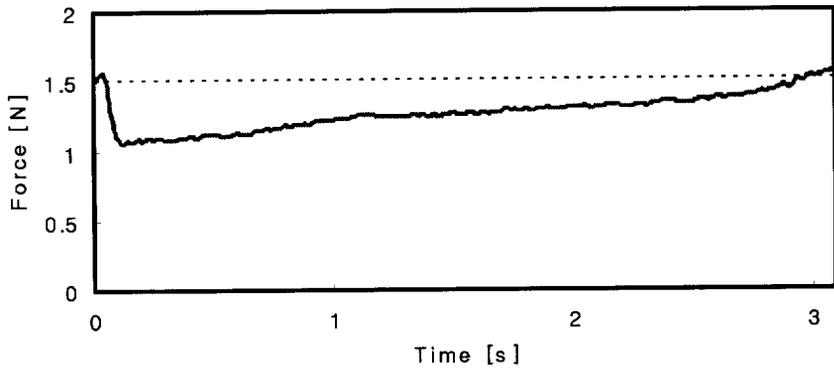
Fig. 16 Neural network

Fig. 16에서 입력층의 입력은 목표위치의 x 성분 p_{dx} , 실제위치의 x 성분 p_x , 위치 오차 e_x , 목표 접촉힘의 y 성분 f_{dy} , 실제 측정된 힘 f_y , 힘 오차 e_y 를 차례로 입력하였다. 중간층수는 10개로 하였으며 출력층수는 모터의 개수인 2로 하였다.

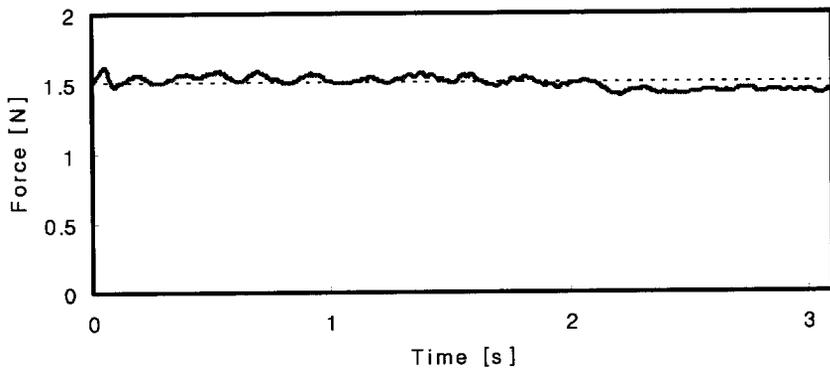
위치 및 힘 제어 실험 대상물체는 패드와 강철에 대하여 각각 실험을 하였다. Fig. 17은 대상물체를 패드일 때의 힘 제어 응답이다.



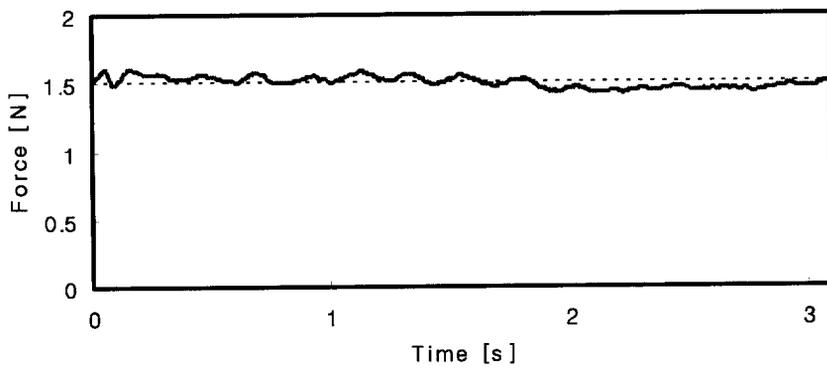
(a) 1st trial



(b) 2st trial



(c) 5th trial

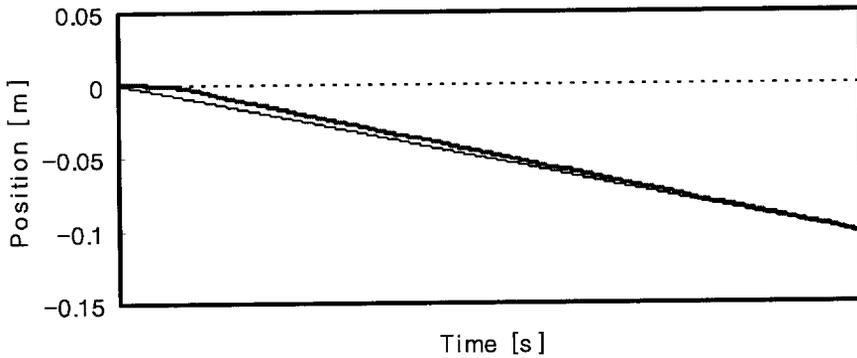


(d) 10th trial

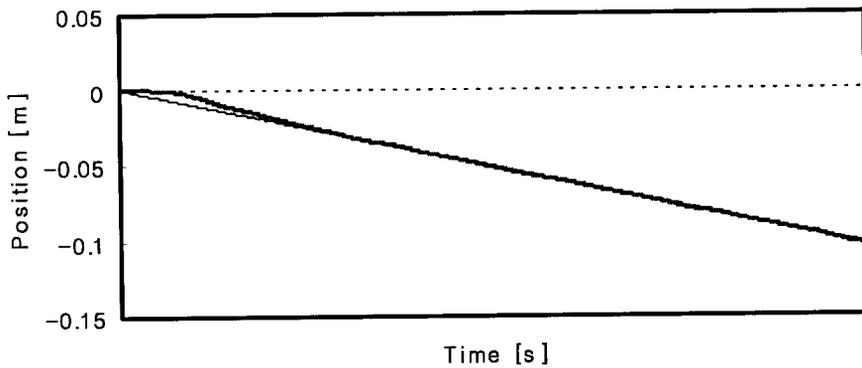
Fig. 17 In case of pad

Fig. 17 의 (a)그림은 첫 번째 힘 제어 실험결과이다. 원하는 목표치와는 많은 차이를 보이고 있다. 그러나 (b), (c)의 결과와 같이 신경회로망을 이용한 학습 후에는 실험값이 목표 값에 상당히 근접하고 있다. 10번째 시도에서 볼 수 있듯이 학습할수록 응답결과가 좋아짐을 알 수 있다.

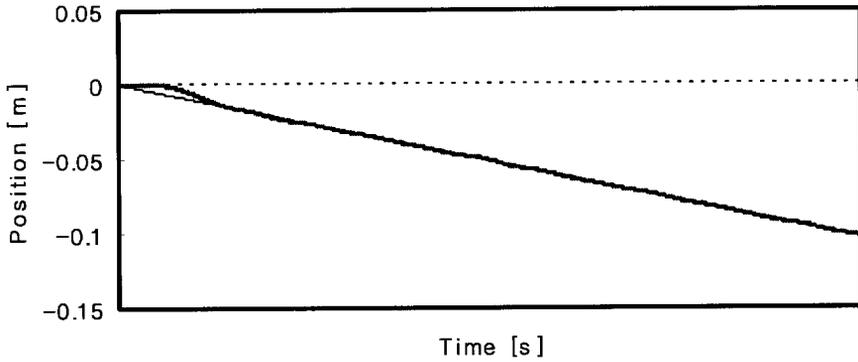
다음 Fig. 18은 패드에 대한 위치 및 힘 제어 실험에서 위치에 관한 응답이다.



(a) 1 trial



(b) 2 trial

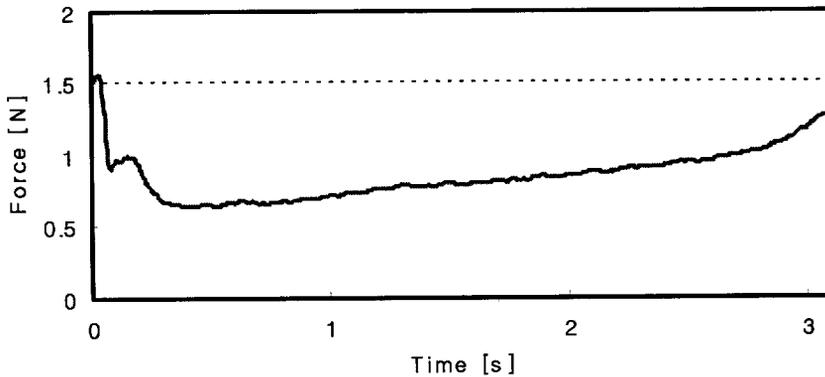


(c) 5 trial

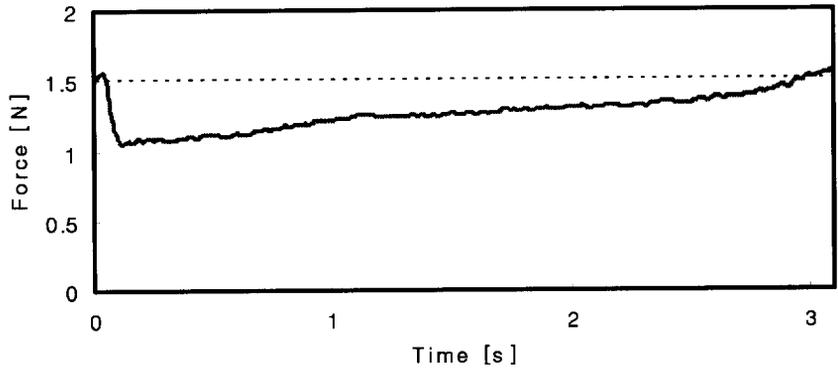
Fig. 18 Response of position

Fig. 18의 그림 (a)와 같이 학습 전에는 목표값과 실제값이 큰 차이를 보이고 있다. 그러나 신경회로망을 이용한 학습이 시작된 후에는 그림 (c)와 같이 목표값과 실제값이 거의 일치하는 응답을 보이고 있다.

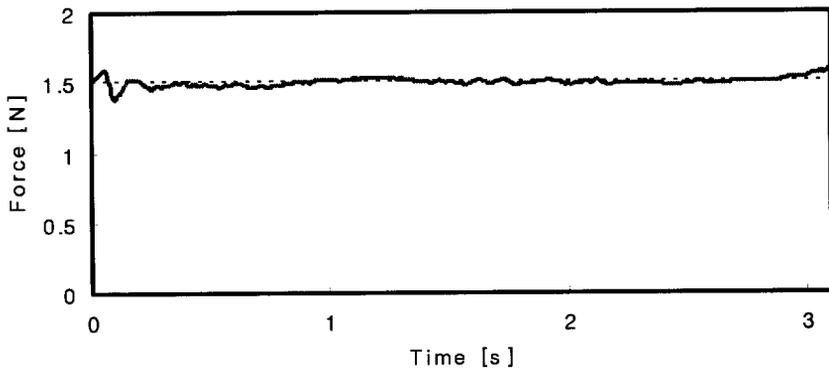
두 번째 위치 및 힘 제어 실험은 대상물체가 강철인 경우이다. 실험 방법은 앞선 실험과 동일하다.



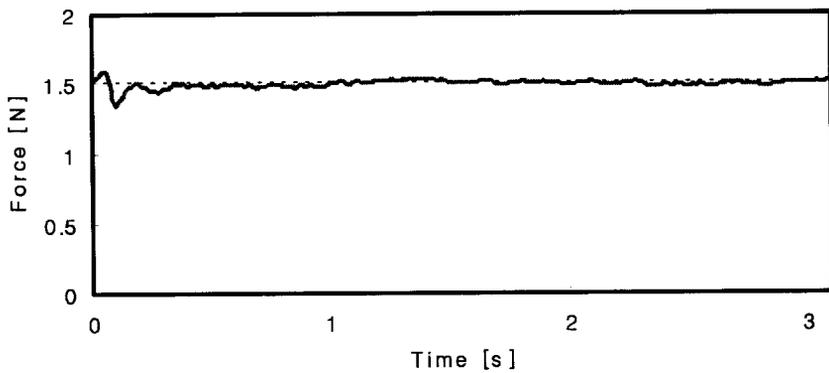
(a) 1st trial



(b) 2st trial



(c) 5th trial

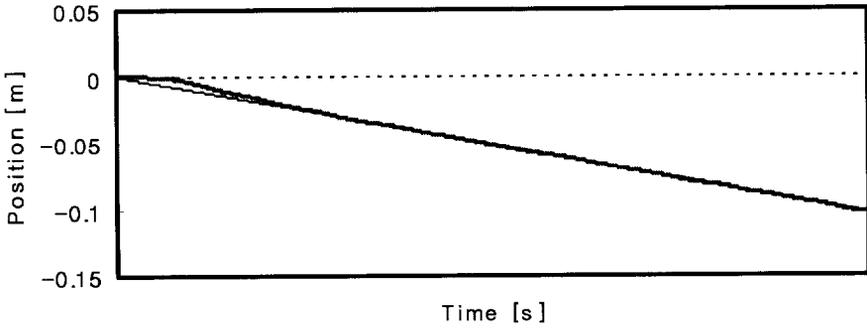


(d) 10th trial

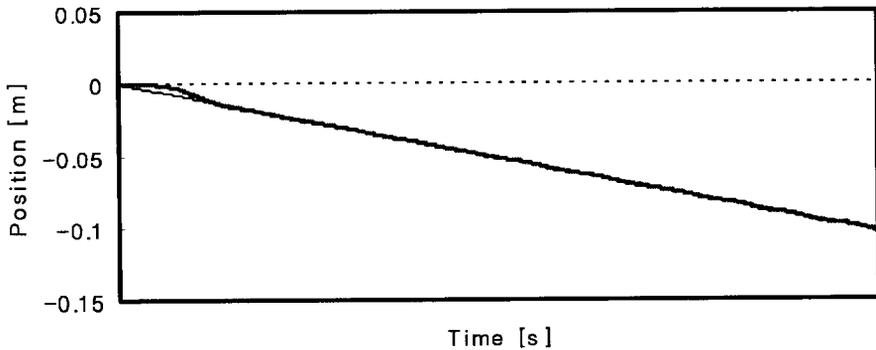
Fig. 19 In case of steel

Fig. 19 의 (a)는 대상물이 강철일 경우의 첫 번째 힘 제어 실험결과이다. 원하는 목표치와는 많은 차이를 보이고 있다. 그러나 (d)의 결과와 같이 신경회로망을 이용한 학습 후에는 실험값이 목표값에 상당히 근접하고 있다. 이 실험 역시 학습할수록 응답결과가 좋아짐을 알 수 있다.

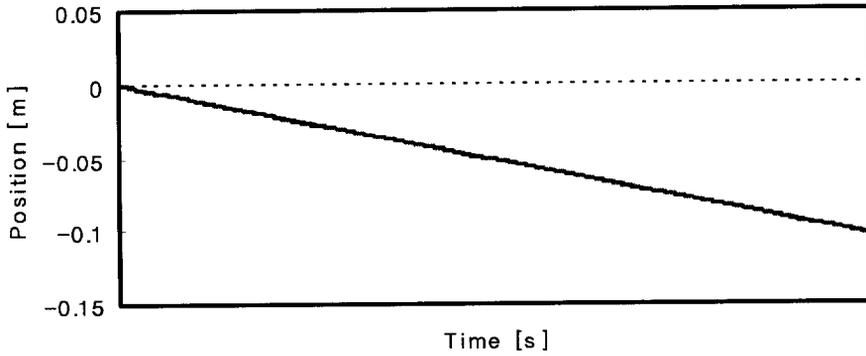
Fig. 20은 앞선 강철에 대한 위치 및 힘 제어 실험에서 위치에 관한 응답이다..



(a) 1 trial



(b) 2 trial



(c) 5 trial

Fig. 20 Response of position

Fig. 20의 그림 (a)와 같이 학습 전에는 목표값과 실제값이 큰 차이를 보이고 있다. 그러나 신경회로망을 이용한 학습이 시작된 후에는 그림 (c)와 같이 목표값과 실제값이 거의 일치하는 응답을 보이고 있다.

대상물체의 변화에 의한 위치 및 힘 제어 실험에서도 신경회로망을 이용한 제어기는 좋은 응답을 보이고 있다.

6장 결론

최근 산업용 로봇에 의하여 많은 작업의 신속화와 정밀화가 이루어졌다. 특히 자동생산, 자동조립, 자동측정 등 부품을 생산, 조립, 분류 평가하는데 있어서 산업용 로봇의 역할은 그 중요성을 더해 가고 있다. 그러나 단순 조립, 가공 작업에서 발전하여 정확한 위치제어와 힘 제어를 통한 정밀 가공이 가능한 산업용 로봇의 요구가 높아지고 있으며 이런 로봇들의 모델링은 쉽지가 않다. 따라서 본 논문에서는 신경회로망을 이용한 로봇의 제어를 통해서 신경회로망의 이점 및 적용성에 대하여 실험을 통하여 증명하였다.

본 논문에서는 매니퓰레이터의 기구학과 동력학식을 설명하였다. 또한 시스템에 대한 다른 파라미터나 수학적 모델을 모르더라도 정밀한 제어가 가능한 하이브리드 제어 시스템을 구현하였고, PD제어기와 신경 회로망 제어기를 병렬로 연결하여 제어기를 구성 하였다. 이때 신경 회로망의 가중치들이 안정하게 학습되도록 오류역전파 알고리즘을 제안하였다. 이와 같이 구현된 하이브리드 제어 시스템은 시간이 지남에 따라 신경 회로망의 가중치들이 안정하게 학습하여 플랜트의 동특성을 파악하게 되고 수정된 PD제어기 출력은 점점 작아져 신경 회로망 제어기가 주 제어기로써 제어를 담당하게 된다. 즉, 신경회로망으로 학습이 진행되면서 일정 시간의 학습 후에 정상 상태 오차가 작아져 정밀한 제어가 가능하고, 특히 실험 대상물체가 변할지라도 강인한 제어 특성을 보였다. 위치 및 힘 제어 실험은 대상물체를 패드와 강철에 대하여 실험하였으며, 대상물체의 변화에도 불구하고 신경회로망에 의한 응답은 양호하였다.

추후 과제로는 선박 용접용 로봇, 선박 가공용 로봇과 같은 실제 산업용 로봇으로의 적용 등을 제안할 수 있으며, 다양한 작업환경에 대해 더욱 적절히 대응할 수 있는 제어 알고리즘의 개발이 요구된다.

참고문헌

- [1] Howard R Nicholls, "Advanced tactile sensing for robotics", World Scientific Series(vol. 5), (1992).
- [2] Russel, RA, "Robot tactile sensing", prentice Hall, (1990).
- [3] Kensuke Hasegawa, "Role of Tactile Sensor in the Robot", Journal of the Robotics Society of Japan vol. 2. No 5, pp.42-45, 1984.
- [4] N. Hogan, "Impedance control : An approach to manipulator, part I, ii, iii" ASME journal of Dynamics Systems, Measurements, and Control, vol. 3, pp. 1-24, 1985
- [5] M. Raibert and J. Craig, " Hybrid position/force control of manipulator", ASME Journal of Dynamic. Systems, Measurements", and Control, vol. 102, pp. 126-133, 1981
- [6] G. J. Wang and D. K. Miu, "Unsupervising Adaptation Neural-Network Control", Proc. IEEE Int. Conf. Neural Networks, vol.3, pp.421-428, 1990.
- [7] 황용연, " 학습제어기를 이용한 직접구동형 로봇의 하이브리드 위치/힘 제어", 대한기계학회논문집 Vol.24A, No.3, pp.74-83, 2000.
- [8] 양오, 양해원, "수정된 PD 제어기와 신경 회로망을 이용한 하이브리드 제어 시스템의 구현", Trans. KIEE. Vol.45, No.5, pp.764-771, 1996.
- [9] 주진원, 나기수, 김갑순, "힘제어 로봇용 6축 힘/토크 센서의 설계 및 제작", 대한기계학회 1997년도 추계학술대회논문집 A, pp.436-441. 1997.
- [10] 이정문, "신경회로망의 개괄적 이해", 제어 · 자동화 · 시스템공학회지 제1권 제3호, pp.22-38, 1995.
- [11] 김대수, "신경망 이론과 응용(I)", 하이테크정보, (1992).

- [12] 오성권, “프로그래밍에 의한 컴퓨터 지능”, 내하출판사, (2002).
- [13] 김상희, 최한고, 박원우, “신경회로망을 이용한 스폿용접의 용접상태검사 시스템의 개발”, Trans. KIEE. vol. 46, No.10, pp.1534-1541, 1997.
- [14] 이창구, “신경회로망 보상기를 갖는 비선형 PID 제어기”, 전기학회지, Vol.49D, No.5, pp.225-233, 2000.
- [15] 손준혁, 박성욱, 서보혁, 이상철, “신경망을 이용한 직류 스텝모터의 속도제어”, Trans. KIEE. Vol.53D, No.4, pp212-220, 2004.
- [16] 박종현, 송재복, 한창수, “로봇工學” 도서출판 기술, (1994).

감사의 글

미흡한 저의 논문이 완성되기까지 애정 어린 격려와 따끔한 충고로 지도해주신 황용연 지도교수님께 진심으로 감사드립니다.

바쁘신 와중에도 부족한 저의 논문에 성심성의껏 지도와 조언을 해주신 변기식 교수님, 안영주 교수님께 감사드립니다. 아울러 대학원 과정에서 많은 것을 배우고 보다 더 큰 안목을 길러주신 이형기 교수님, 최연욱 교수님, 김남호 교수님, 김만고 교수님, 이정창 교수님, 신춘식 선생님께도 진심으로 감사의 말씀을 드립니다.

학부과정, 대학원과정 뿐만 아니라 학과 조교 업무를 담당할 때 항상 따뜻하게 조언을 해주신 문인석 선생님, 강의와 연구로 항상 바쁘신 김관형 선배, 배상범 선배, 더 깊은 공부를 위해 진학하는 김동원 선배, 지금도 열차 운행 중인 서재현 선배와 사회생활 열심히 하고 있는 정광덕 선배, 김성훈 선배, 문홍득 선배에게도 감사드립니다. 짧지 않은 시간동안 생활을 같이한 제어제측공학과 최강 '로봇제어 연구실'의 문선호, 김병기, 최광호, 김진승 후배에게 우선 감사의 말을 전하고, 시스템제어연구실의 류나이 후배, 제측 및 신호처리연구실의 서현수, 노현용 후배, 신호처리 연구실의 김봉주 후배, 전력전자연구실의 조대원, 윤정환 후배에게도 감사의 말을 전합니다. 또한 학과사무실의 김성진, 신혜숙 조교와 전기정보공학과와의 강경숙, 박정민 조교선생님, 제가 이끄는 많은 선·후배, 동기들에게도 감사의 마음을 전합니다.

세상의 그 무엇보다도 소중한 사랑하는 부모님과 평생친구인 사랑하는 동생 지홍이와, 언제나 저의 이야기를 들어주시는 존경하는 외할머니와 큰 이모, 글로 다 적어드리지 못한 많은 친지 분들에게도 감사의 말씀을 드리고, 항상 옆에서 힘이 되는 그녀에게도 감사의 말을 전합니다. 모든 분들의 기대에 어긋남 없이 어디서나 최선을 다해서 열심히 살아가는 모습을 보여드리겠습니다. 감사합니다.

2006년 2월
김 태 곤 올림