

로봇 팔의 동력학적제어를 위한 신경제어 구조

문 영 주 · 오 세 영
포항 공대 전자 전기 공학과

Neurocontrol Architecture
for the Dynamic Control of a Robot Arm

Young-Joo Moon and Se-Young Oh
Dept. of EE, Pohang Institute of Science and Technology

Abstract

Neural network control has many innovative potentials for fast, accurate and intelligent adaptive control. In this paper, a learning control architecture for the dynamic control of a robot manipulator is developed using inverse dynamic neurocontroller and linear neurocontroller. The inverse dynamic neurocontroller consists of a MLP (multi-layer perceptron) and the linear neurocontroller consists of SLPs (single layer perceptron). Compared with the previous type of neurocontroller which is using an inverse dynamic neurocontroller and a fixed PD gain controller, proposed architecture shows the superior performance over the previous type of neurocontroller because linear neurocontroller can adapt its gain according to the applied task. This superior performance is tested and verified through the control of PUMA 560.

Without any knowledge on the dynamic model, its parameters of a robot, (The robot is treated as a complete black box), the neurocontroller, through practice, gradually and implicitly learns the robot's dynamic properties which is essential for fast and accurate control.

1. 서론

로봇을 고속, 정확하게 제어하기 위해서는 형태적 구조만을 생각하는 기구학적 제어(Kinematic Control)가 아닌 운동방정식에 의한 동력학적 제어(Dynamic Control)가 필요하다. 그러나 로봇을 동력학적으로 모델하기가 지극히 어렵고 특히 부품의 노후 및 주변환경의 변화 등에서 오는 모델의 시변특성변화 및 마찰등은 예측이 불가능 하며 또 모델이 주어져도 복잡한 계산을 거치므로 동력학적 제어는 주로 실험적으로만 사용되어 왔다. 이러한 제반 문제에 효과적으로 대처하기 위하여 생물체의 신경회로(Neural Network)에서 이루어지는 Sensory Motor Control 을 로봇 제어에 적용하고자 한다. 신경회로를 이용한 제어(신경제어, Neurocontrol)는 종래의 제어방법에서 볼 수 없었던 병렬성 및 학습능력에 의해 그 우월성을 나타낸다. 즉 신경제어는 모든계산이 각 뉴런에서 독립적으로 병렬처리 되므로 실시간 제어가 가능하

고 학습된 제어정보가 분산저장 되므로 몇개의 뉴런이 고장 나거나 입력정보에 잡음이 섞이는 경우에도 출력에 전달되는 영향이 작다. 또한 신경제어는 학습에 의한 제어를 수행하므로 제어하고자하는 시스템의 정확한 모델이 필요하지 않게되어 모델하기 어려운 복잡한 시스템의 제어가 가능하며, 시스템의 변수가 계속 변화 하더라도 학습에 의해 제어 성능을 지속적으로 향상시킬 수 있다[5].

시스템의 동력학에 관한 정보가 전혀없는 경우, 동력학적 제어에 신경회로를 사용한 경우를 살펴보면 주로 신경회로와 보조제어기를 병렬로 연결하여 보조제어기의 출력을 줄이는 방향으로 학습시키는 궤환오차 학습법(Feedback-Error Learning) [3,8] 과 시스템의 동력학을 신경회로를 이용하여 근사화 하고, 근사화된 신경회로로부터 제어에 필요한 학습정보를 추출하여 역동력학 제어를 위한 신경회로를 학습시키는 방식이 있다[9].

본 논문에서는 선형 단층 퍼셉트론을 이용한 선형 신경제어기와 다층 퍼셉트론을 이용한 역동력학 신경제어기를 구성하여 3축 로봇의 동력학적 제어를 시도하였다. 로봇을 완전한 Black Box (Nonlinear Dynamic System) 로 가정하고 다층 퍼셉트론(Multilayer Perceptron)과 선형 단층 퍼셉트론(Linear Single Layer Perceptron)을 병렬로 사용하여, 다층 신경회로는 선형 단층퍼셉트론으로부터의 궤환오차(Feedback Error)를 줄이는 방향으로 신경회로를 학습 시키고 선형 단층 퍼셉트론은 시스템의 출력 오차를 직접 줄이는 방향으로 학습시킨다. 다층 신경회로는 학습에 의해 로봇의 역동력학 모델(Inverse Dynamic Model) 역할을 하며 원하는 관절 각, 각속도와 실제 관절각, 각속도를 받아 운동에 필요한 관절 토크(Joint Torque)를 발생시키도록 한다. 또한 단층 신경회로는 다층 신경회로가 시스템의 역동력학 모델을 충분히 학습하기 이전까지 임시적인 제어역할을 담당하게 한다. 이 신경제어기 구조를 PUMA560의 3축에 적용하여 제어성능을 시험하였다.

2. 사용된 신경회로

2-1. 동역학적 신경제어를 위한 다층신경회로

로봇팔의 역동력학적 모델을 수행하기 위해서는 Nonlinear Mapping 에 적합한 모델이 사용되어야 하는데, 지금까지 많은 신경회로 모델이 발표되었지만 제어 문제에 적용할 수 있도록 Nonlinear, Continuous Mapping에 적합한 모델은 다층 퍼셉트론(Multilayer Perceptron)이다[5]. 이 다층 신경회로망은 뉴런(Neuron)을 수학적으로 모델하여 이 뉴런을 여러층으로 쌓은 구조로 되어 있다. 3축 로봇팔의 제어를 위한 신경회로의 구조는 입력 뉴런수가 12 (각축의 현재 각 및 각속도, 원하는 각 및 각속도), 첫째 은닉층이 30, 두번째 은닉층이 10, 출력층이 3 (각축에 인가될 토크)의 뉴런층으로 이루어져 있으며 사용된 활성화함수는 은닉층에는 Sigmoid 함수를 사용하였으며, 출력층에는 기울기가 0.1인 선형함수를 사용하였다. 사용된 신경회로의 구조는 < 그림 1 > 과 같으며, 학습법칙은 Generalized Delta Rule 을 사용하였다[5].

2-2. 선형 신경제어를 위한 단층신경회로

신경회로가 로봇팔의 각 축의 오차에 대한 선형이득에 빨리 접근해 갈 수 있도록 하기 위해서는 복잡한 구조의 다층 신경회로를 사용할 수 없으며, 각 축에 각각의 독립된 단층 신경회로를 이용하여 각 축의 현재 오차 및 이전 오차에 대한 선형 이득을 구하도록 하였다. 각 단층 신경회로의 입력은 각 축에 해당하는 현재 위치오차 및 속도오차 그리고 이전 n 번째 까지의 위치오차 및 속도오차가 입력으로 주어지도록 설계되었고, 출력층은 기울기가 1인 하나의 뉴런으로 이루어져 있다. 즉 현재의 각오차, 각속도오차와 저장시켜둔 이전오차로부터 적절한 이득을 곱하여 제어에 필요한 토크를 발생시키도록 하는 선형 제어기이다. 사용된 신경회로의 구조는 < 그림 2 > 와 같으며 학습법칙은 Delta Rule 을 사용하였다.

3. 신경제어 구조

신경회로를 로봇 제어에 응용하기 위해 < 그림 3 > 과 같은 제어 구조를 제안한다. 처음 역동력학 신경제어기의 Weight 는 Random 하게 초기화 하고 선형 신경제어기의 Weight 는 0으로 초기화한다. 원하는 경로가 주어지면 역기구학 해를 풀어 각도와 각속도가 주어지고 현재 로봇의 각도와 각속도의 차이 및 이전오차에 의해 선형 신경제어기가 동작하여 선형회환토크 $\tau_1(t)$ 가 발생하고 역동력학 신경제어기는 원하는 각도와 각속도, 현재 각도와 각속도를 입력으로 하여 역동력학 제어 토크 $\tau_d(t)$ 를 발생하며 로봇에 인가되는 토크는 두 토크의 합

$$\tau(t) = \tau_1(t) + \tau_d(t)$$

$\tau(t)$: 로봇에 인가되는 토크 벡터 (3 x 1)

으로 구성된다.

역동력학 신경제어기의 학습법칙은 주어진 로봇팔의 상태로부터 적절한 제어입력을 계산하기 어려우므로, 선형

신경제어기의 궤환오차를 줄이는 방향으로 역동력학 신경제어기의 Weight 를 학습시킨다. 즉 선형 신경제어기의 출력을 에너지 함수(Energy Function) 로 하여 그 출력을 최소화하도록 역동력학 제어기의 Weight 를 학습시킴으로서 신경제어기가 로봇의 역동력학 모델을 수행하도록 하는 것이다. 선형제어기의 출력은 제어오차에 비례하므로 에너지 함수(Energy Function) 를 최소화하는 것은 결국 제어오차를 최소화하는 것이 된다. 즉 에너지 함수를 다음과 같이 다시 정의하고, Generalized Delta Rule 로부터 다음 학습법칙이 유도된다 [5].

$$\text{에너지 함수} : E_d = \frac{1}{2} \sum_k \tau_{ik}(t)^2 \quad [k: 1,2,3 \text{ 축}]$$

$$\text{학습법칙} : \Delta W_{ij}(t) = \eta \delta_j(t) o_i(t) + \alpha \Delta W_{ij}(t-\Delta t)$$

[i,j: 인접 층의 뉴런 표시]

$$\text{은닉층 델타 값} : \delta_j(t) = o_j(t) [1 - o_j(t)] \sum_i \delta_i W_{ij}$$

$$\text{출력층 델타 값} : \delta_k(t) = \tau_{ik}(t)$$

선형 신경제어기의 학습법칙은 역동력학 신경제어기의 출력과 선형 신경제어기의 출력을 합한 토크를 로봇팔에 인가한 뒤 Δt 후의 측정된 제어오차 (속도오차 + 위치오차)를 줄이는 방향으로 Delta Rule 을 사용하여 신경회로의 Weight 를 학습시킨다. 즉 에너지 함수를 다음과 같이 다시 정의하고 Delta Rule 로부터 다음식의 학습법칙이 유도된다.

$$\text{에너지 함수} : E_1 = \frac{1}{2} \sum_i E_{1i}^2 \quad [i: 1,2,3 \text{ 축}]$$

$$E_{1i} = (\theta_{di}(t) - \theta_i(t+\Delta t)) + (\dot{\theta}_{di}(t) - \dot{\theta}_i(t+\Delta t))$$

$$\text{학습법칙} : \Delta W_{ikp}(t) = \eta \theta_{ei}(t-k\Delta t) E_{1i} + \alpha \Delta W_{ikp}(t-\Delta t)$$

$$\Delta W_{ikv}(t) = \eta \dot{\theta}_{ei}(t-k\Delta t) E_{1i} + \alpha \Delta W_{ikv}(t-\Delta t)$$

[그림 2. 참조]

처음 학습시 선형 신경제어기의 빠른 학습에 의해 오차에 대한 이득이 급격히 변화하면서 대부분의 토크를 발생하게 된다. 그러나 학습이 진행될수록 대부분의 제어역할을 역동력학 신경제어기가 담당하게 된다. 즉 순간적인 변화에서는 선형 신경제어기가 주로 동작하게 되고 평상시에는 역동력학 신경제어기가 제어를 주로 담당하게 된다. 즉 급격한 변화에서는 다층신경회로로 이루어진 역동력학 신경제어기가 학습할 시간이 없기 때문에 선형 신경제어기를 병렬로 사용하게 된다. 제안된 구조는 학습에 필요한 Torque 샘플을 제시할 필요가 전혀 없는 Unsupervised Learning 방식으로 로봇의 Dynamic Model 없이 단지 오차만으로 제어가 가능하며 고정이득을 가진 보조제어기 (ex: PD ...) 대신 선형 신경제어기를 사용하여, 주어진 일에 따라 선형 신경제어기가 스스로 적절한 이득을 찾으므로서 전체 제어성능이 향상된다.

4. 실험결과

모의실험은 PUMA 560 로봇의 3축을 제어하여 제안된 구조의 제어성능을 시험하고 일반적인 제어방법인 PD 제어, PD 제어기와 역동력학 신경제어기를 병렬로 이용한 제어, 선형 신경제어기만 이용한 제어, 제안된 선형 신경제어기와 역동력학 신경제어기를 병렬로 이용한 제어에 대해, 제어성능을 비교하는 것으로 하였다. 이하 본 논문에서 선형 신경제어기 (Linear Neurocontroller)의 영문약자는 LNC 로, 역동력학 신경제어기 (Inverse Dynamic Neurocontroller)의 영문약자는 IDNC 로, PD 제어기 (PD Controller)의 영문약자는 PDC 로 표기한다.

4.1 제안된 신경제어 구조의 제어성능

제안된 제어구조 <그림 3> 에의해 원형궤적 (둘레: 1.256m)을 평균 0.41m/sec 의 속도로 따라가도록 하였다. 한번 반복하는데 소요된 시간은 3초이며 Sampling Time 은 3ms 로 하였다.

(1) 학습에 따른 토크출력의 변화

<그림 4> 는 처음 시도에서 PUMA 560 로봇의 두번째 축에 인가되는 선형 신경제어기의 출력과 역동력학 신경제어기의 출력을 나타낸다. 선형 신경제어기의 빠른 학습에 의해 오차에 대한 이득이 급격히 증가하면서 대부분의 토크를 발생하나 곧 역동력학 신경제어기가 학습에 의해 곧 대부분의 제어역활을 수행함을 알 수 있다.

(2) 제어성능

<그림 5> 는 추적 (Tracking) 하고자하는 궤적에 대해 통상의 PD제어기와 신경제어기의 제어성능을 직교좌표계에 표시한 것이다. 신경제어에 의한 제어성능의 향상을 알 수 있다.

(3) 일반화 특성

<그림 6> 은 미리 신경제어기를 직사각형 궤적에 대해 학습시킨후 (30 회 반복학습후) 다시 원형궤적에 대해 학습 제어한 경우와, 처음부터 원형궤적에 대해 학습제어한 경우의 평균 RMS 오차를 나타낸것이다. 직사각형궤적에 대한 학습효과가 새로운 궤적에 대한 학습제어에 어느정도 반영됨을 알 수 있다.

(4) Sampling Time 변화에 따른 제어성능

<그림 7> 은 Sampling Time 의 변화에 따른 제안된 구조의 제어성능을 나타낸다. Sampling Time 이 작을수록 전체 제어성능이 향상됨을 알 수 있다.

4.2 제어성능비교

PD 제어 <그림 8>, 선형 제어기만 사용한 제어 <그림 9>, PD 제어기와 역동력학 신경제어기를 병렬로 구성한 제어 <그림 10>, 제안된 선형 신경제어기와 역동력학

신경제어기를 병렬로 사용한 제어 <그림 3> 의 제어성능을 비교하였다.

(1) 저속 운동에서의 제어성능 비교

원형궤적(둘레: 1.256m)을 평균 0.41m/s 의 속도로 추적(Tracking)하도록 하였다. 한번 반복하는데 소요된 시간은 3초이며 Sampling Time 은 3ms 로 하였다. <그림 11> 에 나타나있듯이 PD 제어에 비해 다른 3 가지의 제어구조는 신경회로의 학습으로 성능이 향상됨을 알 수 있다. 역동력학 신경제어기와 PD제어기를 병렬로 사용한 구조에 비해 제안된 구조의 제어가 선형 신경회로의 학습에 의한 제어능력의 도움을 받아 더 나은 성능을 보여준다.

(2) 고속 운동에서의 제어성능 비교

원형궤적(둘레: 1.256m)을 평균 1.256m/s 의 속도로 추적하도록 하였다. 한번 반복하는데 소요된시간은 1초이며 Sampling Time 은 3ms 로 하였다. <그림 11> 와 <그림 12> 을 비교하면 고속운동에서 PD 제어의 경우, 저속 운동에 비해 오차가 다른 3 가지 학습제어 방식에 비해 크게 증대함을 알 수 있다. 역동력학 신경제어기와 PD제어기를 병렬로 사용한 구조의 경우 보조제어기인 PD 제어기의 성능저하로 전체제어 성능이 나빠짐을 알 수 있다.

(3) 부하에 대한 적응능력 비교

<그림 13> 는 중속운동에서 20번째 반복학습에서부터 3 kg 의 부하를 로봇팔 끝에 인가하였다. PD 제어기의 제어오차가 크게 증가 하는데 비해, 다른 3가지 방식의 학습제어는 오차가 증가 하였다가 학습에 의한 적응제어 (Adaptive Control) 로 오차가 감소함을 알수있다. 고속 운동 제어의 경우와 같이 역동력학 신경제어기와 PD 제어기를 병렬로 사용한 구조에서는, 보조제어기인 PD 제어기의 성능저하로 전체제어 성능이 나빠짐을 알 수 있다.

(4) Sampling Time 변화에 따른 제어성능 비교

중속운동 (0.456m/sec)에서 Sampling Time 을 3ms, 10ms, 15ms, 20ms 로하여 제어한 경우, 제안된구조는 Sampling Time 을 20 ms 까지 크게해도 안정된 제어를 수행한 반면 <그림 7>, 선형 신경제어기 만을 사용한경와 역동력학 신경제어기와 PD제어기를 병렬로 사용한 구조의 경우에는 Sampling Time 이 10 ms 를 넘는경우 불안정하여 제어를 할 수 없었다.

5. 결론

위에서 로봇트 팔의 역동력학적 제어를 위한 신경제어 구조를 제안하였다. 제안된 구조는 신경회로의 병렬성에 의해 실시간 처리가 가능하며 또한 on line 제어방식으로 로봇트 팔의 동력학에 대한 아무런 사전지식 없이도 학습에 의해 작업을 습득하고, 부하의 변화등에 적응할 수 있으며,

지속적인 제어능력의 향상을 가져올 수 있다. 또한 제안된 구조(역동력학 신경제어기와 선형 신경제어기를 병렬로 사용한 구조)는 PD제어기와 같이 고정된 이득을 사용하는 기존의 제안된 신경제어 구조(역동력학 신경제어기와 PD제어기를 병렬로 사용한 구조)에 비해, 선형 신경제어기를 사용하여 주어진 일에 따라 선형 신경제어기가 스스로 적절한 이득을 찾으므로서 전체 제어능력이 향상됨을 보였다.

참고 문헌

[1] 오세영, "신경회로의 로봇틱스 및 산업 자동화 응용", *전자공학회지*, vol. 17, no. 3, 1990, 6월, pp. 28-36.

[2] W. T. Müller, R. P. Hewes, F. H. Glanz, and L. G. Kraft, "Real time dynamic control of an industrial manipulator using a neural-network-based learning controller," *IEEE Trans. Robotics Automat.*, vol. 6, no. 1, Feb. 1990, pp 1-8.

[3] M. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback-error learning neural network for trajectory control of a robotic manipulation," *Neural Networks*, vol. 1, 1988, pp. 251-265.

[4] A. Guez and J. Selinsky, "Neurocontroller design via supervised and unsupervised learning," *J. Intelligent and Robotics Systems*, 1989, pp. 307-335.

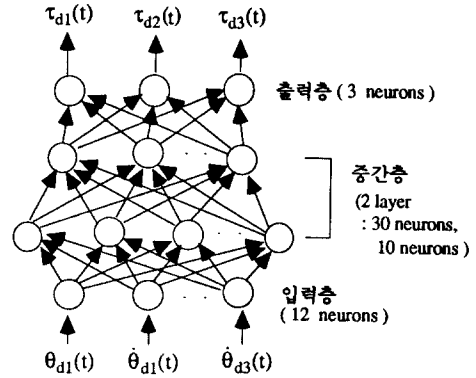
[5] D. E. Rumelhart, J. L. McClelland, and the PDP Reserch Group, *Parallel Distributed Processing*. MIT Press, vol. 1, 1986.

[6] M. Kawato, Y. Maeda, Y. Uno, and R. Suzuki, "Trajectory formation of arm movement by cascade neural network network model based on minimum torque-change criterion," *Biological Cybernetics*, vol. 62, 1990, pp. 275-288.

[7] R. G. Hoptroff, T. J. Hall, and R. E. Burge, "Experiments with a neural controller", *Int. Joint Conf. on Neural Networks*, vol. 2, June, 1990, pp. 735-740.

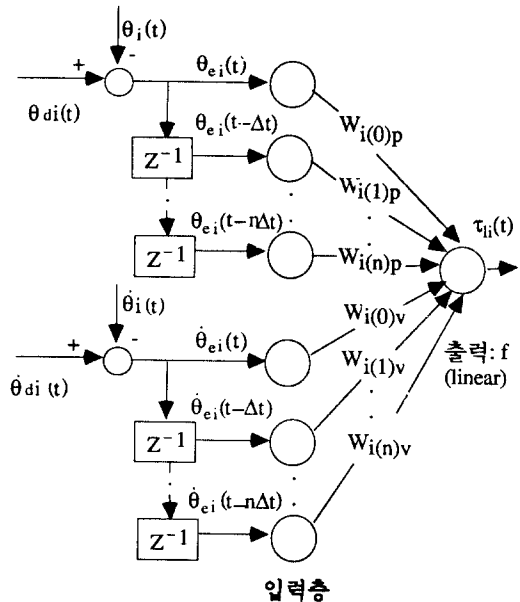
[8] Yeon-Sik Ryu and Se-Young Oh, "A neural network architecture for dynamic control of robot manipulators", *Korean Auto. Control Conf.*, vol. 2, 1989, pp. 1113-1119

[9] S. D. Wang and H. M. S. Yeh, "Self-Adaptive Neural Architectures for Control Application", *Int. Joint Conf. on Neural Networks*, vol. 3, pp. 309-314, June 1990.



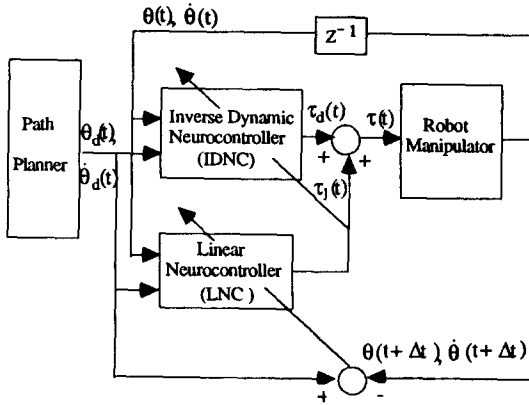
$\tau_d(t)$: 역동력학 토크 벡터 (3 x 1)
 $\theta_d(t), \hat{\theta}_d(t)$: 원하는 각, 각속도 벡터 (3 x 1, 3 x 1)
 $\theta(t), \hat{\theta}(t)$: 현재 각, 각속도 벡터 (3 x 1, 3 x 1)
 W : Weight 벡터
 $\tau_d(t) = f(\theta_d(t), \hat{\theta}_d(t), \theta(t), \hat{\theta}(t), W)$

<그림 1.> 역동력학 신경제어기 구조
 <Fig. 1.> Inverse Dynamic Neurocontroller Architecture

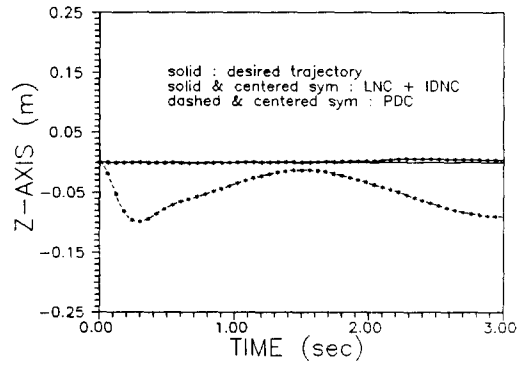


$W_{ikp}(t)$: i 번째 조인트의 k 만큼 시간지연된 각 오차에 대한 이득
 $W_{ikv}(t)$: i 번째 조인트의 k 만큼 시간지연된 각속도 오차에 대한 이득
 $\tau_i(t)$: 선형제어 토크 벡터 (3 x 1)
 $\tau_{ii}(t)$: i 번째 조인트에 인가되는 선형 제어 토크
 $net_i(t) = \sum_{k=0}^n (W_{ikp}\theta_{ei}(t-k\Delta t) + W_{ikv}\hat{\theta}_{ei}(t-k\Delta t))$
 $\tau_{ii}(t) = f(net_i(t)) \quad [i=1,2,3 \text{ 축}]$

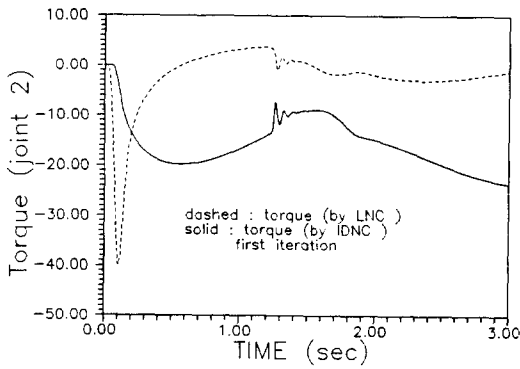
<그림 2.> 선형 신경 제어기 구조
 <Fig. 2.> Linear Neurocontroller Architecture



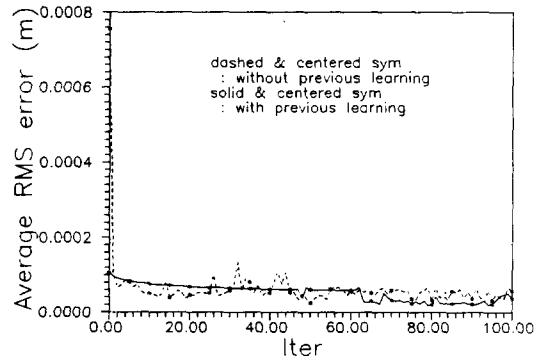
<그림 3.> 제안된 신경 제어 구조
 <Fig. 3.> Proposed Neurocontroller Architecture



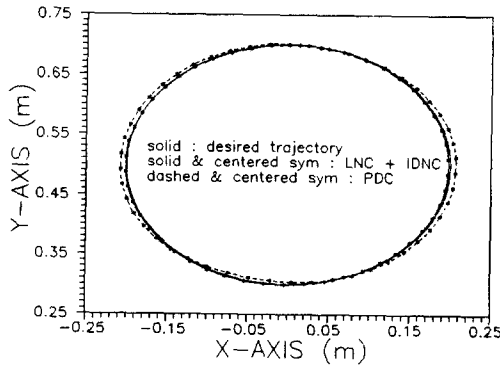
b) Z-Time 축
 b) Z-Time Axis
 <그림 5> 원궤적에 대한 제어성능
 <Fig. 5> Control Performance over a Circular Trajectory



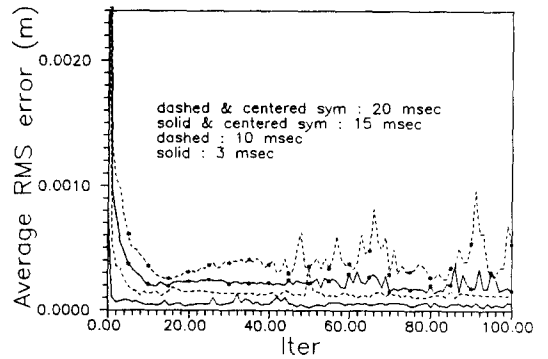
<그림 4> 학습에 따른 관절 2의 토크변화 (처음시도시)
 <Fig. 4.> The Evolution of Joint 2 Torque with Learning (at the first attempt)




<그림 6> 일반화 성능
 <Fig. 6.> Generalization Performance




a) X-Y 축
 a) X-Y Axis




<그림 7> 샘플링 타임 변화에 따른 제어성능
 <Fig. 7.> Control Performance for Varying Sampling Times




<그림 8.> PD 제어기
<Fig. 8.> PD controller




<그림9> PD 제어기와 역동력학 신경제어기를
이용한 신경제어기
<Fig. 9.> Neurocontroller using PD controller
Inverse Dynamic Neurocontroller



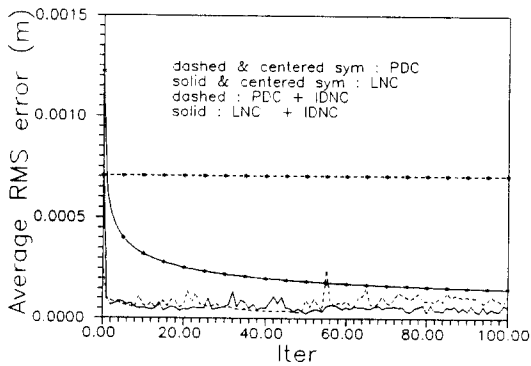
<그림10> 선형 신경제어기
<Fig. 10.> Linear Neurocontroller



<그림 12.> 고속운동에서의 제어성능
<Fig 12.> Control Performance for a High Speed Movement



<그림 13.> 부하 변화에 따른 적응실험
<Fig 13.> Adaptability Experiment for a Varying Payload



<그림 11.> 저속운동에서의 제어성능
<Fig 11.> Control Performance for a Low Speed Movement