

# 로봇 매니퓰레이터의 동력학적 신경제어 구조 (Dynamic Neurocontrol Architecture of Robot Manipulators)

文 榮 洲\*, 吳 世 泳\*\*  
(Young Joo Moon and Se Young Oh)

## 要 約

신경회로를 이용한 로봇 팔의 동력학적 제어를 위해 두 가지의 새로운 신경제어구조를 제안하였다. 두 제어구조 모두 제어기는 역동력학 신경제어기와 선형 신경제어기로 이루어져 있으며, 신경제어기를 학습시키는 방법에 있어 하나는 근사화된 시스템 모델로부터 학습신호를 얻는 반면, 다른 하나는 적절한 에너지함수를 정의하여 이 함수를 최소화하도록 학습신호를 추출한다. PUMA 560 로봇의 3축에 대한 컴퓨터 모의제어 실험을 통해 기존의 발표된 신경제어기 구조 및 일반적 제어방식인 PD 제어기에 비해 그 성능이 뛰어난 것을 보였다.

## Abstract

Neural network control has many innovative potentials for fast, accurate and intelligent adaptive control. In this paper, two kinds of neurocontrol architectures for the dynamic control of robot manipulators are developed. One is based on a System Identification and Control scheme and the other is based on the Feedback-Error learning scheme. Both of the proposed architectures use an inverse dynamic neurocontroller in parallel with a linear neurocontroller. The difference is that the first architecture uses the system identifier to get the signals used for training neurocontrollers, while the second architecture uses a properly defined energy function. Compared with the previous types of neurocontrollers which are using an inverse dynamic neurocontroller and a fixed PD gain controller, the proposed architectures not only eliminate the painful process of the fixed gain tuning but also exhibit superior performances because the linear neurocontroller can adapt its gains according to the applied task. This superior performance is tested and verified through computer simulation of the dynamic control of the PUMA 560 arm.

## I. 서 론

로봇트를 고속, 정확하게 제어하기 위해서는 형태적

구조만을 생각하는 기구학적제어(Kinematic Control)가 아닌 운동방정식에 의한 동력학적 제어(Dynamic Control)가 필요하다. 그러나 로봇트를 동력학적으로 모델링하기가 지극히 어렵고 특히 부품의 노후 및 주변환경의 변화 등에서 오는 모델의 특성 변화 및 마찰 등은 예측이 불가능하며 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 Control을 로봇트 제어에 적용하고자 한다. 신경회로를 이용한 신경제어는 센서를 통해 들어오는 플랜트 상태나 환경에서 오는 Feedback을 본 후 과거의 경험에 비추어 제어 신호를 내보내는 지능제어를 한다. 즉 종래

\* 準會員, \*\* 正會員, 浦項工科大学 電子電氣工學科  
(Dept. of Electronic & Electrical Eng., POSTECH)  
産業科學技術研究所 情報電子分野  
(Inform. and Elec. Eng., Group, Research Inst. of  
Industrial Sci. and Techno.)  
接受日字: 1992年 1月 29日  
(※ 본 논문은 한국과학재단, 산업과학기술연구소,  
한국과학재단 지정 서울대 제어계측신기술 연구센터  
의 지원으로 연구되었음.)

의 제어가 단계적 프로그램 계산에 의거한다면 신경회로 방식은 훈련(Training)을 거친 직관, 즉 패턴 인식에 의거하며 이는 생물계에서 대자연이 택한 방식이기도 하다. 따라서 이를 패턴 인식 제어(Pattern Recognizing Control)라 부를 수 있다. 이렇게 훈련된 지능제어 시스템은 실제 운용하며 그때 그때 불완전한 지식을 보강하기가 용이하고 프로그램을 거치지 않으므로 가격이 저렴하다. 더우기 플랜트의 특성이 시간이 지남에 따라 바뀌어도 또 외부에서 교란이 들어와도 학습에 의해 적응하게 된다. 따라서 신경컴퓨터는 인간의 적응, 훈련, 학습기능을 모방하게 된다. 또한 신경제어는 모든 계산이 각 뉴런에서 독립적으로 병렬처럼 되므로 실시간 제어가 가능하고 학습된 제어정보가 분산 저장 되므로 영향이 적다. 또한 신경제어는 학습에 의한 제어를 수행하므로 제어하고자 하는 시스템의 정확한 모델이 필요하지 않게되어 모델하기 어려운 복잡한 시스템의 제어가 가능하며, 시스템의 변수가 계속 변화하더라도 학습에 의해 제어성능을 지속적으로 향상시킬 수 있다.

본 논문에서는 로봇트 팔의 동력학적 제어를 위한 두 가지의 새로운 신경제어 구조를 제안하고 컴퓨터 모의 제어 실험을 통해 기존의 발표된 신경제어 구조 및 일반적 제어방식 PD 제어기와 제어성능을 비교 분석하였다.

본 논문의 구성은 다음과 같다. 2장에서는 신경회로를 이용한 기존의 동력학적 제어 방법에 대해 살펴본다. 3장에서 제안된 신경제어 구조의 알고리즘을 설명하고 4장에서 PUMA560 로봇트에 대한 모의 제어 실험 결과를 보이며 마지막으로 5장에서 본 논문에 대한 결론 및 앞으로의 연구방향을 서술한다.

## II. 동력학적 신경제어에 관한 기존연구

최근 수년간 로봇트 팔의 동력학에 대한 신경제어 연구가 활발히 이루어지고 있다. 대표적인 동력학 연구 결과는 다음과 같다. Kawato 등은 3축 로봇트를 Newton-Euler 운동방정식의 비선형 항들을 입력으로 하는 단층 퍼셉트론으로 역동력학을 학습하고 그와 병렬로 PD 제어를 사용하여 PD 출력을 줄이는 방향으로 학습시키는 Feedback-Error Learning을 제안하였다.<sup>[1]</sup> Miller는 퍼셉트론과 역전달 학습을 사용하지 않고 분산 Table Lookup 방식의 CMAC을 이용하여 5축 로봇트를 On-line 지도학습(Supervised Learning) 방식으로 제어하였다.<sup>[2]</sup> oh는 Kawato의 Feedback Error Learning 개념을 이용하여 6축 로봇트의 시뮬레이션과 실제의 3축로봇트의 실험을 통해 고속에서의 정확한 제어, 미지의 부하변화에 대한 적응성, 배우지 않은 궤적으로의

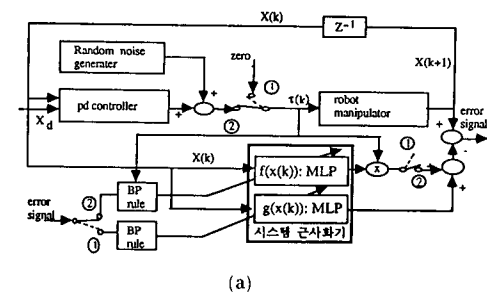
일반화 성능등을 실험적으로 입증하였다.<sup>[3]</sup><sup>[4]</sup> 이상의 제어방식이 신경회로를 제어기에만 사용한 것과는 달리 S.D. Wang은 제어기와 플랜트 모델에 각각 신경회로를 사용하는 Self-Adaptive Neural Controller(SANC) 방식을 제안했다.<sup>[5]</sup> System Identification을 위한 신경회로(플랜트 모델로서의 역할)와 제어용 신경회로를 이용하여 로봇트의 동력학을 근사화(Identification)한 후 신경제어기는 플랜트에 직접 토크를 가하지 않고 근사화된 신경회로 모델에 토크를 인가하여 출력을 얻은 후 이 오차를 근사화된 신경모델을 통해 역전달시켜 최종 역전달된 오차값을 이용하여 최적의 토크를 구하여 제어하는 구조이다. 비교적 간단한 1축 manipulator에 대해 적용하였다. G.J. Wang은 Unsupervising Adaption Control을 제안하였는데 제어 구조는 Self Adaptive Control과 구조적인 면에서 유사하며 근사화를 수행한 후 시스템의 출력 오차를 근사화된 신경회로를 통해 토크오차로 변환하여 신경제어기를 학습시키는 방식을 제안하였다.<sup>[6]</sup> Narendra는 비록 로봇트에 대한 다이나믹 제어를 수행하지는 않았지만 비선형 동력학 제어 시스템을 수학적으로 정의한 후 신경회로를 이용하여 시스템 근사화를 통한 제어방식을 보여주었다.<sup>[7]</sup> 기존의 발표된 신경제어 방식을 크게 분류하여 보면 주로 신경제어기와 보조제어기를 병렬로 연결하여 보조제어기의 출력을 줄이는 방향으로 학습시키는 케환 오차학습법(Feedback-Error Learning)과 시스템의 동력학을 신경회로를 이용하여 근사화하고, 근사화된 신경회로로부터 제어에 필요한 학습정보를 추출하여 역동력학 제어를 위한 신경제어기를 학습시키는 방식으로 구분됨을 알 수 있다.

## III. 제안된 신경제어 구조 및 학습법칙

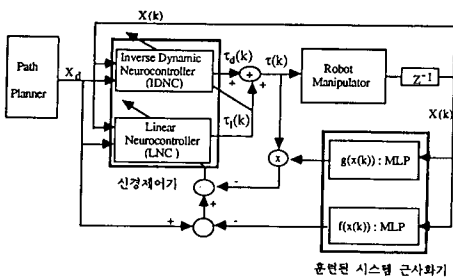
### 1. 신경제어 구조

신경회로를 로봇트 제어에 응용하기 위해 그림 1 및 그림 2와 같은 제어구조를 제안한다. 이하 논문에서는 그림 1의 제어구조를 제안된 구조 I로, 그림 2의 제어구조를 제안된 구조 II로 나타낸다. 두 제어구조 모두 역동력학 신경제어기와 선형 신경제어기로 이루어져 있다. 두 제어구조의 차이점은 선형 신경제어기를 학습시키는 방법에 있어 전자는 근사화된 시스템 모델로부터 학습신호를 찾아내어 학습시키는데 비해 후자는 적절한 에너지 함수를 정의하여 이 함수를 최소화하는 방향으로 학습시키는 방식이 다른 점이다.

역동력학 신경제어기는 로봇트 팔의 역동력학 모델, 즉 로봇트 팔의 현재상태(각도, 각속도)로부터 원하는 상태로 가게 하는데 필요한 토크를 계산하는 역할을 하며



(a)



(b)

그림 1. 제안된 신경제어구조 I

- (a) 신경회로를 이용한 로봇트 팔의 동력학 근사화
- (b) 시스템 근사화기를 이용한 신경제어기의 학습

Fig. 1. The proposed neurocontrol architecture I.

- (a) identification of dynamics for a robot arm using neural networks,
- (b) training the neurocontroller using system identifier.

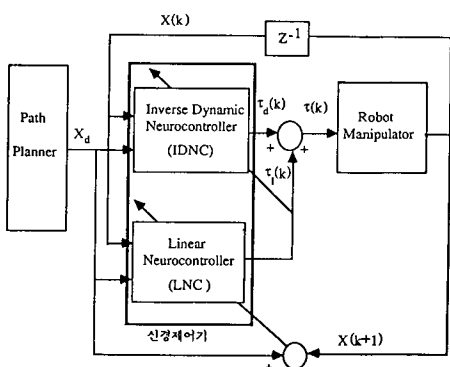


그림 2. 제안된 제어구조 II

Fig. 2. The proposed neurocontrol architecture II.

다층 신경회로를 이용하여 구현하였다. 신경회로망의 학습에 의해 이러한 역할을 점진적으로 수행하도록 한다.

선형 신경제어기는 각 축의 현재 상태오차(각도 및 각속도) 그리고 이전  $m$  번째까지의 상태오차에 선형이득을 곱하여 각축의 제한 오차 토크를 발생하도록 하며, 이 계산에 적합한 다층신경회로를 사용하였다. 즉  $i$  번째 축의 제한 토크는  $i$  번째 축의 현재 오차와 이전 오차에 적절한 이득을 곱하여 계산하며 다른축의 오차정보들은 사용하지 않는다.

제한된 신경제어기의 개략적인 동작원리는 다음과 같다. 원하는 경로가 주어지면 역기구학해를 풀어 각도와 각속도가 주어지고 현재 로봇트의 각도와 각속도와의 차이 및 이전오차에 의해 선형 신경제어기가 동작하여 선형 제한토크가 발생하고 역동력학 신경제어기는 원하는 각도와 각속도, 현재 각도와 각속도를 입력으로 하여 역동력학 제어 토크를 발생하며 로봇트에 인가되는 토크는 두 토크의 합으로 구성된다. 처음 역동력학 신경제어기의 Weight는 Random 하게 초기화 하고 선형 신경제어기의 Weight는 zero로 초기화한다. 따라서 학습을 시작하는 순간 두 제어기의 출력 토크는 모두 zero이다. 처음 학습시 선형 신경제어기는 적절히 정의된 에너지 함수나 근사화된 시스템 모델로부터 학습신호를 얻어, 빠른 학습 능력에 의해 오차에 대한 이득이 급격히 변화하면서 제어에 필요한 대략의 토크를 발생하게 된다. 그러나 학습이 진행될수록 선형 신경제어기에 의한 제한 오차를 줄이는 방향으로 역동력학 신경제어기의 Weight를 학습하게되어 대부분의 제어역할을 역동력학 신경제어기가 담당하게 된다. 즉 급격한 변화에서는 다층 신경회로로 이루어진 역동력학 신경제어기가 학습할 시간이 없기 때문에 선형 신경제어기를 병렬로 사용하여 선형 신경제어기가 주로 동작하게 되고 평상시에는 역동력학 신경제어기가 제어를 주로 담당하게 된다.

2. 학습법칙

1) 신경제어 구조 1의 학습법칙

가) 로봇트 팔의 동력학 근사화

다층 신경회로망은 일반적으로 식 (1)로 표현되는 로봇트 시스템의 동력학 함수를 학습에 의해 근사화시킬 수 있다.

$$X(k+1) = F(X(k), \tau(k)) \tag{1}$$

여기서  $X(k)$ 는  $k$ 번째 시간에서의 로봇트 팔의 조인트 각도와 각속도로 이루어진  $2n$ 차원 상태 벡터이며  $\tau(k)$ 는  $k$ 번째 시간에 로봇트 팔에 인가되는  $n$ 차원의 토크 벡터이다. 그러나 이 함수를 완전히 근사화하였다고 가정해도 시스템을 동력학적으로 제어하기 위해서는 현재상태와 원하는 상태가 주어졌을때 다음 식 (2)를 만족하는

최적토크  $\tau^*(k)$ 를 다층 신경회로에서 추출하여야 한다. 다층 신경회로에서 이 정보를 직접 추출할 수는 없다. Wang은 반복적으로 토크를 근사화된 신경회로에 주고 다시 오차를 역전달 시키는 방법을 이용하여 최적 토크를 추출하였으나 비교적 간단한 1축 로봇에 적용하였다. 축수가 증가할수록 복잡한 신경회로에서 이 정보를 추출하는 것이 어려워진다.

$$X_d = F(X(k), \tau^*(k)) \quad (2)$$

본 논문에서는 이러한 어려움을 극복하기 위해 로봇 팔의 동력학 함수를 짧은 sampling time 동안 시변 선형 시스템(Linear Time-Varying System)으로 가정하였다.

$$X(k+1) = A(k)X(k) + B(k)\tau(k) \quad (3)$$

이 식을 신경회로망을 이용하여 근사화하기 적합한 형태인 다음 식(4)로 수정하였다.

$$X(k+1) = F_1(X(k)) + F_2(X(k))\tau(k) \quad (4)$$

식 (4)를 근사화하기 위해  $F_1(X(k))$ 의 근사화를 위한 다층 신경회로망  $f(X(k), w)$ 과  $F_2(X(k))$ 의 근사화를 위한 다층 신경회로망  $g(X(k), w)$ 을 사용하였다.

A)  $F_1(X(k))$ 의 학습

실제 로봇의 제어를 가정하여  $\tau(k)=0$ 일때의 학습 데이터를 얻기 위해 그림 1-(a)에 도시한 방법을 이용한다. 간단한 PD 제어를 이용하여 제어하고자 하는 경로를 따라 로봇 팔을 움직인다. 이때 좀더 다양한 학습 데이터를 얻기 위해 약간의 노이즈(PD 제어에 의해 로봇의 제어가 가능한 정도의 uniform pseudo random 값)를 PD 토크에 더하여 로봇 팔에 인가한다. 주어진 경로를 따라 움직이는 동안 불규칙적으로 1 Sampling Time 동안 로봇의 토크 입력을 zero로 인가하고(그림 1-(a)에서 스위치가 1에 있을때) 이때 얻어지는 학습 데이터  $X(k), X(k+1)$ 을 얻어 신경회로  $f(X(k), w) = F_1(X(k))$ 가 되도록 BP(Back Propagation) rule을 이용하여 학습시킨다.

B)  $F_2(X(k))$ 의 학습

이 함수의 학습은  $F_1(X(k))$ 의 학습에 비해 matrix곱이 있어 다소 복잡하다. 이 함수를 학습시키기 위한 데이터, 즉  $X(k), \tau(k), X(k+1)$ 를 얻는 방법은 A)에서 언급한 방식과 동일하며 그림 1-(a)에서 스위치가 2의 위치에 있을때 측정된 데이터이다.  $X(k), \tau(k), X(k+1)$ 의 관계는 식(4)로 표현되며 이미 A)의 과정을 통해  $F_1$

$(X(k)) = f(X(k), w)$ 가 되도록 학습하였으므로  $X(k)$ 가 주어지면  $F_1(X(k))$ 를 구할 수 있다. 따라서 식 (4)로부터

$$F_2(X(k))\tau(k) = X(k+1) - f(X(k), w) \quad (5)$$

가 되며  $g(X(k), w)$ 가  $F_2(X(k))$ 를 근사화 하여야 하므로  $g(X(k), w) \tau(k)$ 가  $X(k+1) - f(X(k), w)$ 가 되도록  $g(X(k), w)$ 의 weight를 조절하면 된다. 그러나 이 오차 신호 즉

$$e = [X(k+1) - f(X(k), w)] - g(X(k), w)\tau(k) \quad (6)$$

는 다층 신경회로망의 출력단의 오차가 아니다. 여기서  $g(X(k), w)$ 와  $\tau(k)$ 의 matrix 곱은 그림 3과 같이  $g(X(k), w)$ 을 입력으로 하며  $\tau(k)$ 의 weight를 가지는 가상적인 선형 신경회로로 표시할 수 있다. 따라서 모든 학습데이터에 대해 오차신호  $e$ 를 선형신경회로를 따라 다층 신경회로망까지 역전달시킨 다음,  $g(X(k), w)$ 의 weight를 조절하여 오차신호  $e$ 를 zero로 가게함으로써  $g(X(k), w)$ 가  $F_2(X(k))$ 를 근사화 하도록 한다.




그림 3. Matrix 곱의 신경회로 모델  
Fig. 3. Neural network model for matrix multiplication.

나) 신경제어기의 학습법칙

A) 선형 신경제어기의 학습법칙

현재의 상태  $X(k)$ 에서 원하는 상태  $X_d$ 로 가게하는 최적 토크를  $\tau^*(k)$ 라 하자. 어떤 순간  $k$ 에서 역동력학 신경제어기가 발생하는 토크를  $\tau_d(k)$ 라 하면

$$\tau^*(k) = \tau_d(k) + \tau_1^*(k) \quad (7)$$

로 표현할 수 있다. 따라서 현재의 선형 신경제어기의 출력  $\tau_1(k)$ 가  $\tau_1^*(k)$ 로 되도록 선형 신경제어기의 weight를 조절하면된다. 선형화시킨 로봇 팔의 동력학 식 (4)로부터 현재상태  $X(k)$ 와 원하는 상태  $X_d$  그리고 그때의 최적 토크  $\tau^*(k)$  사이에 다음의 관계가 성립한다.

$$X_d = F_1(X(k)) + F_2(X(k)) \tau^*(k) = f(X(k), w) + g(X(k), w) \tau^*(k) \quad (8)$$

$$(\because f(x(k), w) = F_1(X(k)), g(X(k), w) = F_2(X(k)))$$

따라서 식 (7)을 식 (8)에 대입하면 다음 식이 된다.

$$X_d = f(X(k), w) + g(X(k), w) (\tau_d(k) + \tau_1^*(k)) \quad (9)$$

따라서 선형 신경제어기의 출력  $\tau_1(k)$ 가  $\tau_1^*(k)$ 이기 위해서는 모든 학습데이터에 대해

$$e = [X_d - f(X(k), w)] - [g(X(k), w) (\tau_d(k) + \tau_1(k))] = 0 \quad (10)$$

이어야 한다. 앞의 근사화 모델의 학습경우와 같이 이 오차는 선형 신경제어기의 출력단 오차가 아니다. 여기서  $g(X(k))(\tau_d(k) + \tau_1(k))$ 는 그림 4와 같이 역동력학 신경제어기의 출력과 선형 신경제어기의 출력의 합을 입력으로 하는 가상적인 선형 신경회로의 구조로 생각할 수 있으며, 따라서 이 신경회로를 따라 오차를 역전달 시킨 다음 Gradient descent rule을 이용하여 선형 신경제어기의 weight를 조절한다.

트의 역동력학 모델을 수행하도록 한다. 선형 신경제어기의 출력은 제어오차에 비례하므로 에너지 함수(Energy Function)를 최소화하는 것은 결국 제어오차를 최소화하게된다. 즉 에너지 함수를 다음과 같이 정의하고, Generalized Delta Rule을 이용하여 역동력학 신경제어기를 학습시킨다.

$$\text{에너지 함수} : E = \frac{1}{2} \sum_{i=1}^n \tau_i^2 [i=1 \dots n \text{축}] \quad (11)$$

2) 신경제어 구조 II의 학습법칙

가) 선형 신경제어기의 학습법칙

로봇팔의 동력학 함수를 짧은 Sampling time 동안 선형 시스템으로 가정하고 현재 역동력학 토크와 최적의 선형 제어 토크를 더한 최적 토크를 로봇트 팔에 가한 경우 다음 식이 성립한다.

$$X_d = A(k)X(k) + B(k)(\tau_d(k) + \tau_1^*(k)) \quad (12)$$

또한 역동력학 토크와 현재 계산된 선형 제어토크의 합을 로봇트 팔에 인가한 경우 다음식이 성립하게 된다.

$$X(k+1) = A(k)X(k) + B(k)(\tau_d(k) + \tau_1(k)) \quad (13)$$

(12)식에서 (13)식을 빼면 상태 오차와 토크 입력오차 사이의 관계를 나타내는 다음 식이 된다.

$$X_d - X(k+1) = B(k)(\tau_1^*(k) - \tau_1(k)) \quad (14)$$

여기서 각 축에 대한 오차(각도오차, 각속도오차)를 생각해보면 i 축의 시스템 오차는 다음 식으로 표현할 수 있다.

$$X_{d1p} - X_{1p}(k+1) = B_{1p}(\tau_{11}^*(k) - \tau_{11}(k)) + \dots + B_{1p}(\tau_{1n}^*(k) - \tau_{1n}(k)) + \dots + B_{np}(\tau_{in}^*(k) - \tau_{in}(k)) \quad (15)$$

$$X_{d1v} - X_{1v}(k+1) = B_{1v}(\tau_{11}^*(k) - \tau_{11}(k)) + \dots + B_{1v}(\tau_{1n}^*(k) - \tau_{1n}(k)) + \dots + B_{nv}(\tau_{in}^*(k) - \tau_{in}(k)) \quad (16)$$

그림 4. 선형 신경제어기의 학습(제안된 구조 I)

Fig. 4. Training the linear neurocontroller (The proposed architecture I).

B) 역동력학 신경제어기의 학습법칙

선형 신경제어기의 출력을 에너지 함수(Energy Function)로 하여 그 출력을 최소화하도록 역동력학 제어기의 Weight를 학습시킴으로써 신경제어기가 로봇

(위 식에서 p는 joint position을 v는 joint velocity를 나타냄)

여기서 한가지 가정을 하였다. 즉 i축에 대해 생각했을때 그 축에 대한 오차계수  $B_{1p}, B_{1v}$ 의 크기가 다른 축으로부터 영향을 받는 계수  $B_{jp}, B_{jv}(j \neq i)$ 에 비해 훨씬 크고 이 계수는 양의 부호를 가진다고 가정하자. 이 경우 식 (15)와 식 (16)은 다음과 같이 쓸 수 있다.

$$X_{dIP} - X_{IP}(k+1) \cong B_{IP}(\tau_{II}^*(k) - \tau_{II}(k)) \quad (17)$$

$$X_{dIV} - X_{IV}(k+1) \cong B_{IV}(\tau_{II}^*(k) - \tau_{II}(k)) \quad (18)$$

이 두 식을 더하면 다음 식이 된다.

$$[X_{dIP} - X_{IP}(k+1)] + [X_{dIV} - X_{IV}(k+1)] \cong (B_{IP} + B_{IV})(\tau_{II}^*(k) - \tau_{II}(k)) \quad (19)$$

선형 신경제어기의 weight 학습은 gradient descent rule을 사용하므로 따라서 이 계수의 정확한 값보다 그 부호가 중요한 정보가 된다. 두 오차계수 모두 양의 부호를 가진다고 가정하였으므로 1축의 선형 신경제어기의 오차는 다음과 같이 정의 된다.

$$e_1 = [X_{dIP} - X_{IP}(k+1)] = [X_{dIV} - X_{IV}(k+1)] \quad (20)$$

이 식은 다음과 같이 에너지함수를 정의할 때와 동일한 학습 신호를 얻는다. (이 함수가 최소화되면 시스템 오차가 최소화되므로 적절한 에너지함수이다.)

$$E = \frac{1}{2} \sum_{i=1}^n E_{II}^2 \quad [i=1 \dots n \text{축}] \quad (21)$$

$$E_{II} = [X_{dIP} - X_{IP}(k+1)] + [X_{dIV} - X_{IV}(k+1)] \quad (22)$$

즉 제어구조 II의 선형 신경제어기의 학습방법은 선형 신경제어기의 출력과 역동력학 제어기의 출력을 합하여 로봇트 팔에 인가한뒤 측정된 각오차와 각속도 오차를 더하여 이 신호를 학습신호로 하여 학습시킨다.

나) 역동력학 신경제어기의 학습법칙

제안된 구조 I과 동일하다. 즉 선형 신경제어기의 제한오차를 줄이는 방향으로 역동력학 신경제어기의 Weight를 학습시킨다. 즉 선형 신경제어기의 출력을 에너지 함수(Energy Function)로하여 그 출력을 최소화하도록 역동력학 제어기의 Weight를 학습시킴으로서 역동력학 신경제어기가 로봇트의 역동력학 모델을 수행하도록 한다.

#### IV. 모의실험 결과

모의 실험은 PUMA560 로봇트의 3축을 제어하여 PD 제어 그림 5-(a), 제안된 구조의 일부인 선형 신경제어기 그림 5-(b), PD 제어기와 역동력학 신경제어기를 병렬로 구성한 제어기 그림 5-(c), 제안된 제어기(구조 I, II)의 제어성능을 비교하였다. 제어성능 비교는 중속운동에서의 추적 성능과 적응제어 성능을 비교하는 것으로 하였으며 적응제어 성능의 비교실험은 중속운동에서 고속운

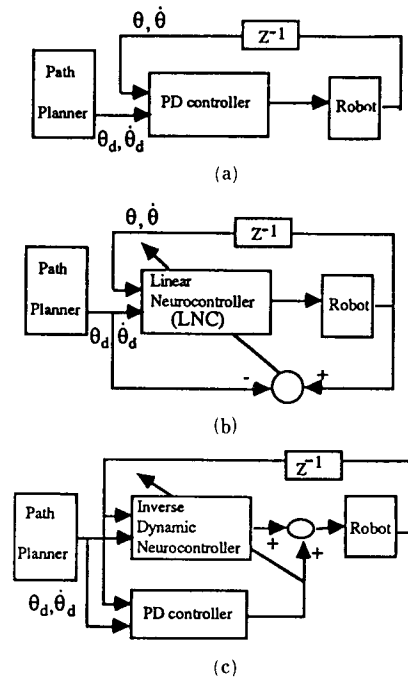


그림 5. 제어성능 비교에 사용된 제어기

- (a) PD 제어기
- (b) 선형 신경제어기
- (c) PD 제어기와 역동력학 신경제어기를 병렬로 사용한 신경제어기

Fig. 5. Controller used in comparing the control performances.

- (a) PD Controller,
- (b) Linear Neurocontroller,
- (c) The neurocontroller using PD controller and inverse dynamic neurocontroller.

동으로의 속도변화에 따른 제어성능의 변화와 부하의 첨가에 따른 제어성능의 변화를 시험하였다.

##### 1. 중속 운동에서의 추적성능 비교

원형궤적(둘레 : 1.256 m)을 평균 0.41 m/sec의 속도로 따라가도록 하였다. 한번 반복하는데 소요된 시간은 3 초이며 Sampling Time은 3ms로 하였다. 그림 6에 학습에 따른 직교좌표에서의 평균 RMS 오차의 변화를 나타내었다. 표 1에 PD 제어, PD 제어기와 역동력학 신경제어기를 병렬로 구성한 제어기, 제안된 제어기(구조 I, II)의 100번 학습하는 동안, 오차가 가장 적었을 때의 평균 RMS 오차값을 나타내었다. PD 제어기에 비해 다른 세가지의 신경제어 구조는 학습에 의해 제어성능이 향상됨을 알수있다. 또한 제안된 두가지의 신경제어 구조가 기존의 신경제어 방식에 비해 안정적인 제어를 수행함을 알 수 있다. 근사화된 동력학 모델(10000개의 학습 데이


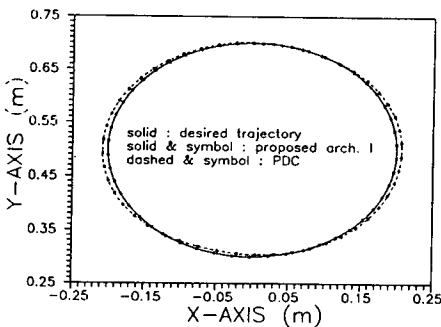


그림 6. 추적 성능 비교  
Fig. 6. Comparison of tracking Performance.


표 1. 제안된 제어기의 성능 비교 (직각좌표계에서의 평균 RMS 오차 값)  
Table 1. Performance comparison of proposed controllers. (Average RMS error Value in cartesian space)

제어 구조	제안된 구조 I의 성능	제안된 구조 II의 성능	역동력학 신경제어기와 PD제어기의 병렬구조	PD제어기의 성능
오차				
평균 RMS 오차 값	0.014	0.02	0.031	0.705

터블 얻은 뒤 1000번 off line으로 학습시켰음)로부터 얻은 학습신호를 이용한 제안된 구조 I이 가장 정확한 제어를 수행함을 알 수 있다.



(a) X-Y축



(b) Z-Time축

그림 7. 제안된 신경제어구조 I에 의한 추적성능  
Fig. 7. Tracking performance of the proposed neurocontrol architecture I.

그림 7에 추적하고자하는 궤적에 대해 통상의 PD제어기와 제안된 신경제어 구조 I의 제어성능을 직교좌표에 표시하였으며 그림 8에 추적하고자하는 궤적에 대해 통상의 PD제어기와 제안된 신경제어 구조 II의 제어성능을 직교좌표계에 표시하였다.

2. 적응제어 성능비교


1) 추적속도 변화에 따른 적응제어 실험

원형궤적(원둘레길이 : 1.256 m)를 평균 0.416 m/s의 속도로 추적하도록 하다가 20번째 학습부터 1.256 m/s의 속도로 추적하도록 하였다. 그림 9에 속도변화에 따른 제어성능 변화를 도시하였다. PD제어기의 경우 제어오차가 크게 증가하는데 비해, 다른 3가지 방식의 학습제어는 오차가 증가하였다가 학습에 의한 적응제어(Adaptive Control)로 오차가 감소함을 알 수 있다. 또한 제안된 신경제어구조(II)의 경우 선형 신경제어기의 이득이 적절히 조절되므로 고정된 이득의 선형제어기와 역동력학 신경제어기를 사용한 경우보다 전체 제어성능이 향상됨을 알 수 있다.

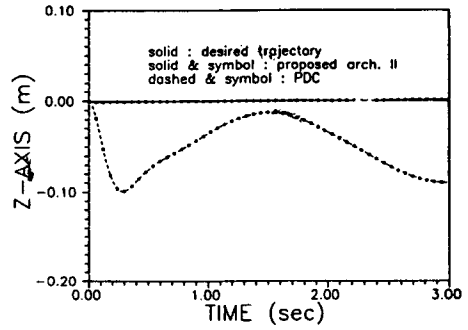
2) 부하를 첨가하였을때의 적응제어 실험

중속운동에서 20번째 학습에서부터 3kg의 부하를 로봇 팔 끝에 인가하였다. 그림 10에 부하첨가에 따른 제어성능 변화를 도시하였다. PD제어기의 제어오차가 크게 증가하는데 비해, 다른 3가지 방식의 학습제어는 오차가 증가하였다가 학습에 의한 적응제어(Adaptive Control)로 오차가 감소함을 알 수 있다.

V. 결론 및 과제



(a) X-Y축



(b) Z-Time축

그림 8. 제안된 신경제어구조 II에 의한 추적성능

Fig. 8. Tracking performance of the proposed neurocontrol architecture II.

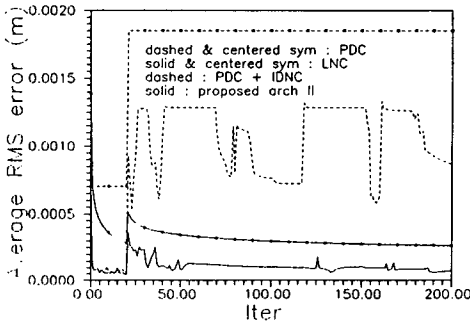


그림 9. 추적 속도 변화에 따른 적응제어 실험

Fig. 9. Adaptive control experiment with varying tracking velocity.

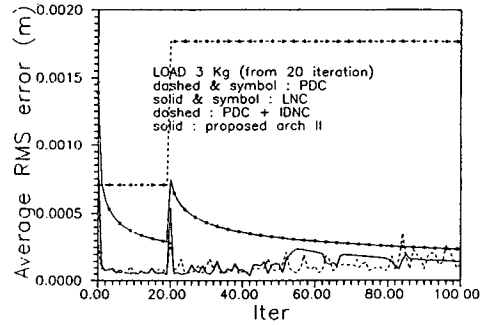


그림 10. 부하의 변화에 따른 적응제어 실험

Fig. 10. Adaptive control experiment with a load change.

본 논문에서는 로봇트 팔의 동력학적 제어를 위한 두가지의 신경제어 구조를 제안하였다.

시스템 Identifier와 제어기로 구성된 신경제어 구조 I은 Identifier가 로봇트 팔의 동력학을 학습(off-line)에 의해 근사화하여, 신경제어기를 학습시키는데 필요한 정확한 학습신호를 제공함으로써, 기존의 시스템 오차를 학습신호로 하는 제어구조에 비해 그 제어성능이 우수함을 3축 로봇트의 모의 실험을 통해 실험적으로 보였다. (근사화 방법을 이용한 로봇트 팔의 동력학 제어의 경우 현재까지 발표된 논문의 대부분은 간단한 1축 로봇트에 적용하였을 뿐임) 근사화를 이용한 제어방식의 가장 큰 문제는 시스템의 실시간 근사화가 어렵다는 점이며, 이로 인한 신경제어의 일반적인 장점인 적응제어 능력이 약하다는 단점을 가진다. 시스템의 근사화를 통한 제어는 산업공정 제어에도 적용 가능한 구조로 이 분야에 관한 연구가 활발히 이루어져야할 것으로 생각되며 특히 실시

간으로 시스템을 근사화할 수 있는 방법에 대한 연구가 있어야 하겠다.

제안된 신경제어 구조 II의 경우 로봇트 팔의 동력학에 대한 아무런 사전지식 없이도 오차의 궤환을 통한 학습에 의해 작업을 습득하고, 부하의 변화 등에 적응할 수 있으며, 지속적인 제어능력의 향상을 가져올 수 있는 장점을 가진다. 또한 이 제어구조는 PD 제어기와 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 찾음으로써 전체 제어성능이 향상됨을 보였다.

수행해야할 과제로는 앞에서 밝힌 시스템의 실시간 근사화에 대한 연구와 신경회로 Chip 또는 고속 DSP Chip을 이용한 신경제어기를 개발하여 실제 산업용 로봇트에 적용하는 과제 등이 있다. 또한 본 논문에서 로봇트



의 상태변수를 Joint Space에서 정의하였는데 앞으로 Cartesian Space와 Image Space로 확장 적용하는 과제도 남아있다.

### 參 考 文 獻

- [1] 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, no. 3, 1988.
- [2] T. Miller, R.P. Hews, F.H. Glanz, and L.G. Kraft, "Real-time dynamic control of an industrial manipulator using a neural-network-based learning controller," *IEEE Trans. on Robotics and Automation*, vol. 6, no. 1, 1990.
- [3] 조문증, 오세영, "신경회로를 이용한 6축 로봇의 역동력학적 토크제어," 한국자동제어학술회의 논문집, pp. 1-6, (1990).
- [4] 오세영, 문영주, "신경회로를 이용한 로봇 팔의 동력학적 제어," 제2차 신경회로 연구회 학술대회 논문집, 1991.
- [5] S.D. Wang, H.M.S. Yeh, "Self-adaptive neural architecture for control applications," *Int. Joint Conf. on Neural Networks*, June, 1990.
- [6] G.J. Wang, H.M.S. Yeh, "Unsupervised adaption neural network control", *Int. Joint Conf. on Neural Networks*, June, 1990.
- [7] K.S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks", *IEEE Transactions on Neural Networks*, vol. 1, no. 1, pp. 4-27, 1990.
- [8] Y.H. Pao, "Adaptive pattern recognition and neural networks," Addison-Wesley, 1989.
- [9] D. Psaltis, A. sideris, and A.A. Yamamura, "A multilayered neural network controller," *IEEE Control Systems Magazine*, pp. 17-21, April 1988.
- [10] A.G. Barto, R.S. Sutton, and C.W. Anderson, "Neuronlike adaptive elements that can solve difficult deaming control problems," *IEEE Trans. Syustems, Man, and Cybernetics*, vol. SMC-13, no. 5, September 1983.
- [11] A. Guez and J. Selinsky, "A neuromorphic controller with a human teacher," *Proc. of the IEEE International Conference on Neural Networks*, pp. 595-602, July 1988.
- [12] A. Guez, J.L. Eilbert, and M. Kam, "Neural network architecture for control," *IEEE Control Systems Magazine*, pp. 22-24, April 1988.
- [13] R.K. Elsley, "A learning architecture for control based on back-propagation neural networks," *Proc. of the IEEE Conference on Neural Networks*, pp. 587-594, 1988.
- [14] W.T. Miller, "Sensor-based control of robotic manipulators using a general learning algorithm," *IEEE J. of Robotics and Automation*, pp. 157-165, vol. RA-3, no. 2, 1987.
- [15] T. Miller, "Real-time application of neural networks for sensor-based control of robots of vision," *IEEE Trans. on System, Man, and Cybemetics*, vol. 19, no. 4, 1989.

### 著 者 紹 介

#### 文 榮 洲 (準會員)

1985년 2월 부산대학교 공과대학 전자공학과 졸업.  
1985년~1990년 금성전기 연구소 연구원. 1992년 2월 포항공대 전자전기공학과 졸업(석사). 현재 포항공대 전자전기공학과 박사과정. 주관심분야는 신경회로의 로봇트 제어 및 자동화 응용. Neural-Fuzzy 제어분야 등임.

#### 吳 世 泳 (正會員)

第28卷 第B編 第9號 參照  
현재 포항공대 전자전기학과 부교수. 주관심분야는 신경회로의 로봇트 제어 및 자동화 응용로봇트 공학, 패턴인식 등임.