

무모형 로봇을 위한 신경 회로망 제어 방식

A Non-Model Based Robot Manipulator Control Using Neural Networks

정 슬

캘리포니아 대학 전기 컴퓨터 공학과(Tel:(916)752-3168; Fax:(916)752-8428;

E-mail:jung@ece.ucdavis.edu)

Abstract A novel neural network control scheme is proposed to identify the inverse dynamic model of robot manipulator and to compensate for uncertainties in robot dynamics. The proposed controller is called reference compensation technique(RCT) by compensating at reference input trajectory. The proposed RCT scheme has many benefits due to the differences in compensating position and learning algorithm. Since the compensation is done outside the plant it can be applied to many control systems without modifying the inside controller. It performs well with low controller gain because the operating range of input values is small and the output of the neural network controller is amplified through the controller gain. The back-propagation algorithm is used to train and simulations of three link robot manipulator are carried out to prove the proposed controller's performances.

Keywords Neural network, Reference compensation technique, Robot manipulator

1. 서론

비선형 시스템의 제어는 시스템의 모형을 정확하게 구하기가 어렵고, 수학적 이론의 뒷받침이 부족하기 때문에 그 해결책을 찾기 위한 도전을 주는 문제로 계속 연구가 진행되는 분야이다. 제어할 공정의 정확한 모형을 알 수 없고, 불확실성이 항상 존재하기 때문에 기존의 제어기로는 요구되는 수행을 만족하지 못한다. 이러한 부정확한 모형과 불확실성을 보상하기 위한 방법으로 이론상 잘 정립된 적응 제어와 강건 제어들이 많이 연구되어 왔지만, 아직 확실한 해답을 주지 못하고 있다.

비선형 제어기로서의 신경 회로망은 비선형 근사 능력과 학습 능력 등 비선형 시스템 제어에 유리한 특성들을 갖고 있기 때문에 제어 분야에서 새롭게 각광을 받고 있다. 비선형 공정을 제어하기 위한 정확한 모형을 얻기 어렵고, 불확실성이 항상 존재하기 때문에 기존의 제어기로는 정확한 수행을 기대하기가 어렵다. 이에 대한 해결 방법으로 기존의 논문에서는 불확실성을 내포한 대략적인 동적 방정식이 주어졌을 경우, 신경 회로망을 이용하여 불확실성을 보상하는 방식이 제안되었는데 기본적인 로봇의 모형이 주어지고, 신경 제어기는 제어 대상의 부분적인 모형과 불확실성을 보상하기 때문에 신경 회로망의 능력을 부분적으로 사용하고 있다[1].

하지만, 신경 회로망을 이용하는 참다운 가치는 제어 대상에 대하여 어떤 정보도 필요하지 않다는 데에 있다. 이처럼 제어할 대상의 아무런 지식이 없이 그 공정을 제어할 수 있다면 신경 회로망의 잠재적인 능력을 완전히 사용하는 것이다.

이러한 기본 태두리 안에서 기존의 신경 제어 방식들을 살펴 보면 가장 기본적인 방식으로 역모형을 직접 인식하는 방법이 있다 [2]. 이 경우에 back-propagation 알고리즘을 사용하려면 입력과 출력의 관계를 나타내는 자코비안(Jacobian)정보가 필요한데 이 자코비안 정보를 얻기 위한 여러 방식들이 제안되었다.

예컨대, finite difference 방법을 이용하는 방식, 다른 신경 회로망을 이용하여 구하는 방식, 그리고 대략적인 자코비안을 사용하거나, 전혀 자코비안을 사용하지 않는 방법 등이 있다 [2,3]. 그 중에서도 그림 1에 보여지는 역모형 인식을 모태로 한 귀환 오차 학습 방식(FEL)이 주류를 이루는데 이 경우에는 자코비안이 필요가 없다 [4].

이 논문에서 제안하는 방식도 궁극적으로 역모형 인식과 불확실성을 보상한다는 점에서 FEL 방식과 같지만, 보상하는 방법

과 학습 방법이 달라서 다음과 같은 추가적인 이득을 얻을 수 있다.

첫째로, 불확실성을 보상하는 위치가 제어하는 대상 외부에 있기 때문에 기존에 설치되어 있는 실제 시스템들의 제어기들을 수정할 필요 없이 그 대상에 적용하기가 쉬운 잇점이 있다. 이러한 특성은 제안된 제어 방식의 보편성을 나타낸다. 둘째, 보상된 값이 제어기를 통해 증폭되기 때문에 낮은 제어기의 이득을 가지고도 높은 이득을 사용한 것과 같은 수행 능력으로 증진시킬 수 있다는 점이다. 따라서 제어기의 높은 이득을 취하는데 따르는 비용을 절감하고 안정성을 높일 수 있다. 이러한 특성들은 제안된 제어 방식의 경제성 또는 생산성과 결부되기 때문에 높은 가치가 있다.

2. PD 제어 방식

일반적인 n 관절(joint) 로봇 동적 모형은 다음과 같다.

$$D(q)\ddot{q} + h(q, \dot{q})\dot{q} + g(q) + f_f(\dot{q}) = \tau \quad (1)$$

$D(q)$ 는 $n \times n$ 관성 행렬, $h(q, \dot{q})\dot{q}$ 는 $n \times 1$ 벡터의 Coriolis와 원심력, $g(q)$ 는 $n \times 1$ 벡터의 중력, $f_f(\dot{q})$ 는 $n \times 1$ 벡터의 마찰력이고, τ 는 $n \times 1$ 벡터의 토크가 된다. q 는 $n \times 1$ 벡터의 각(角)위치이고 \dot{q} 는 $n \times 1$ 벡터의 각(角)속력, \ddot{q} 는 $n \times 1$ 벡터의 각(角)가속력이다.

로봇의 안정성을 보장하는 가장 간단한 제어 법칙은 PD제어 방법으로 다음과 같이 표현한다(ϕ_r 가 제로일 경우 그림 1을 참고).

$$\tau = K_D(\dot{q}_r - \dot{q}) + K_F(q_r - q) \quad (2)$$

q_r 은 $n \times 1$ 벡터의 지시된 기준 경로이고, K_D 와 K_F 는 $n \times n$ 제어기 이득 행렬이다.

(1)식과 (2)식을 연립하면 다음과 같은 페루프 방정식을 얻을 수 있다.

$$\ddot{e} + D^{-1}K_D\dot{e} + D^{-1}K_F e = D^{-1}(D\ddot{q}_d + h + g + f_f) \quad (3)$$

$$e = q_r - q, \dot{e} = \dot{q}_r - \dot{q}$$

오차 방정식(3)을 보면 위치 오차가 로봇 팔의 위치에 따라 달라지므로 제어하기가 어렵기 때문에 로봇의 동적 방정식을 정확하게 제어할 방법이 없다. 보통 PD제어에서는 안정성이 보장되는 한도 안에서 높은 이득을 사용하면 성능이 향상된다. 하지만, 제어기 이득이 높을 경우에 성능을 어느 한도에서 향상시킬 수는 있으나 비선형 불확실성은 보상하기 어려울 뿐만 아니라 시스템의 안정성에 영향을 끼칠 수 있다.

그러므로, 낮은 이득을 가지고 역모형 인식과 비선형 불확실성을 보상할 수 있는 방식이 필요한데, 그 방식을 본 논문에서 소개하고자 한다.

3. 새로운 경로 보상 방식(RCT)의 제어 구조

그림 2에는 제안한 구조 방식이 잘 나타나 있다. 신경 회로망은 선(先)보상기(precompensator)로서 보상을 제어 루프 밖에서 실행한다. 신경 제어기로부터의 출력인 보상 신호 ϕ_p 는 주어진 입력 신호 q_d 에 더해져서 새로운 입력 q_r 로 되고 이는 다시 실제 출력 신호 q 와 비교되어서 오차 신호 e 를 만든다. 이 오차 신호는 제어기의 이득을 통하게 되므로 증폭되어 직접 공정을 제어할 입력 신호(예를 들면 토크)를 형성한다.

보상하는 신호(ϕ_p)를 입력 신호에 더하고, 제어기를 통하기 때문에 보상 신호가 제어기의 이득만큼 증폭한다. 신경 제어기의 출력은 ϕ_p 로 한정되기 때문에 ϕ_p 는 유한 차분법을 사용해서 다음과 같이 얻을 수 있다.

$$\phi_p = \frac{\phi_p(t) - \phi_p(t-1)}{T} \quad (4)$$

여기서 T 는 추출률(sampling rate)이다.

더해진 입력값 $q_r = q_d + \phi_p$, $\dot{q}_r = \dot{q}_d + \dot{\phi}_p$ 를 (2)식에 대입하고, (1)식과 연립하면

$$K_D(\dot{q}_d + \dot{\phi}_p - \dot{q}) + K_P(q_d + \phi_p - q) = D\dot{q} + h\dot{q} + g + f, \quad (5)$$

(5)식을 정리해 보면 다음과 같다.

$$K_D\dot{\epsilon} + K_P\epsilon = D\dot{q} + h\dot{q} + g + f - \dot{\phi} \quad (6)$$

$$\epsilon = q_d - q, \quad \dot{\epsilon} = \dot{q}_d - \dot{q}$$

ϵ 는 출력 오차이고, $\dot{\phi} = K_D\dot{\phi}_p + K_P\phi_p$, ψ 는 보상 신호인데, 신경 제어기의 순수 출력 신호는 제어기의 이득 값들이 각각 곱해져서 증폭됨을 볼 수 있다.

여기서 $v = K_D\dot{\epsilon} + K_P\epsilon$ 를 학습 신호로 정의하자. 이상적으로 수렴이 되었을 때 즉, $v=0$ 일 때 $\dot{\phi}$ 는 (6)식으로부터

$$\dot{\phi} = D\dot{q} + h\dot{q} + g + f, \quad (7)$$

따라서 신경 회로망은 로봇의 역모형이 된다. 이러한 특징 때문에 제안한 구조 방식은 역 제어의 한 방식이라 할 수 있다.

RCT와 FEL의 구조를 비교해 보면, RCT 방식에서는 보상 신호 또한 제어기 이득을 통해 증폭되기 때문에 작은 보상값, 즉 신경 제어기의 작은 출력(ϕ_p)을 가지고도 증폭된 큰 보상 효과($\dot{\phi}$)를 얻을 수 있다. 또한 신경 회로망은 그 내부에서 진행되는 가중값과 비선형 영역(e.g. -1, +1 또는 0, 1)에 따라서 그 성능이 좌우되는 특성이 있는데, 본 제어기는 입력과 출력의 작동 영역이 작기 때문에 입력값의 정규화 과정과 비정규화 과정이 필요하지 않다. 무엇보다도 RCT의 가장 큰 잇점은 공정 내부의 제어기를 변경할 필요가 없이 외부에서 보상이 가능하다는 것이다. 그림 다음 장에서는 신경 제어기의 구조에 대하여 소개하도록 한다.

4. 신경 제어기 구조와 학습 방법

신경 제어기는 이단 선형식(two layer feedforward)의 표준 신경 회로망이 쓰인다. 준비기(Buffer)로 작용하는 입력층, 비선형인 잠재층, 그리고 선형인 출력층으로 구성된 제어기는 N_I 가 입력의 수, N_H 가 잠재 신경의 수, 그리고 N_O 가 출력의 수일 경우 편향 가중치까지 고려한다면, 전체의 가중(weight)수는 $W_T = (N_I + 1)N_H + (N_H + 1)N_O$ 가 된다. 입력값은 입력층과 잠재층 사이에 있는 가중값(w_{ij})과 곱하여지고 잠재층에서 다시 더해져서 활성화 함수(activation function)를 통하게 된다. 이 활성화 함수는 비선형으로 S자 함수라고도 불리는데, 그 값이 -1 부터 1 사이에 존재한다.

$$f(x) = \frac{1 - \exp(-x)}{1 + \exp(-x)} \quad (8)$$

이 활성화 함수(activation function)를 통한 값들은 다시 잠재층과 출력층 사이에 있는 가중(w_{jk})과 곱해져서 각 출력층에서 더해짐으로 마지막 신경 회로망의 출력(ϕ)이 된다. 그러므로 출력층의 k 번째 출력 ϕ_k 는 다음과 같이 나타난다.

$$\phi_k = \left[\sum_{j=1}^{N_H} w_{jk} \frac{1 - \exp(-\sum_{i=1}^{N_I} x_i w_{ij} + b_j)}{1 + \exp(-\sum_{i=1}^{N_I} x_i w_{ij} + b_j)} \right] + b_k \quad (9)$$

b_j 는 j 번째 잠재층 신경의 편향 가중(biased weight)이고, b_k 는 k 번째 출력층 신경의 편향 가중이 되는데, 다른 가중들과 마찬가지로 매번 새롭게 된다. 신경 제어기는 이단 선형식(two layer feedforward)의 표준 신경 회로망이 쓰인다. 신경 회로망의 가중값들을 새롭게 하기 위해서는 학습 신호 v 로 구성된 이차 함수인 목적함수 J 를 최소화하면 된다.

$$J = \frac{1}{2} v^T v \quad (10)$$

J 를 미분하면 J 의 기울기를 (6)과 (10)식으로부터 다음과 같이 얻을 수 있다.

$$\frac{\partial J}{\partial w} = \frac{\partial v^T}{\partial w} v = - \frac{\partial \phi^T}{\partial w} v \quad (11)$$

이 기울기는 back-propagation 알고리즘에 쓰이는데 가중값들은 다음과 같이 새롭게 된다.

$$\Delta w(t) = \eta \frac{\partial \phi^T}{\partial w} v + \alpha \Delta w(t-1) \quad (12)$$

여기서 η 값은 학습률이고 α 는 운동량(momentum) 상수이다.

5. 제어기의 간편화 디자인

그림 2의 제어 구조(구조 I)에서 신경 회로망 제어기의 입력의 수를 줄임으로써 그림 3과 같이 간단해질 수 있다. 구조 II에서는 보상하는 곳이 위치만으로 국한되는데, $\dot{q}_r(t)$ 를 구하기 위해 아래와 같이 유한차분법을 쓰면 구조 I과 같은 효과를 얻을 수 있다.

$$\dot{q}_r(t) = \frac{q_r(t) - q_r(t-1)}{T} \quad (13)$$

(13)식 안에는 \dot{q}_a 와 ϕ_a 가 내포되어 있으므로, (13)식에 $q_r(t) = q_d(t) + \phi_p(t)$ 와 $q_r(t-1) = q_d(t-1) + \phi_p(t-1)$ 를 대입하면

$$\dot{q}_r(t) = \frac{q_d(t) - q_d(t-1) + \phi_p(t) - \phi_p(t-1)}{T} \approx \dot{q}_d + \phi_a \quad (14)$$

(14)식을 (2)식에 대입하고 (1)식과 연결한 뒤, 정리하면

$$\phi = D\dot{q} + h + g + f_j \quad (15)$$

(15)식은 구조 I의 결과 (7)식과 같다.

6. 모의 실험 결과

세 링크(three-link)로 구성된 로봇 팔이 모의 실험에 실행되었는데 그 기본적인 동적 모형 방정식은 PUMA 560 로봇 팔의 처음 세 링크로부터 얻어 졌다. 임의적인 불확실성을 주기 위해서 각 관절(joint)마다 마찰력이 더해졌는데 마찰력의 모형은 다음과 같다.

$$f(\dot{q}) = 5.0 \operatorname{sgn}(\dot{q}) + 8.0 \dot{q} \quad (16)$$

또한 무거운 10Kg의 물체가 팔 끝에 달려 있다고 가정한다.

기존의 PD 제어기 이득 값으로는 임계 감폭(critically-damped)의 경우를 고려해서 높은 이득값으로는 $K_D = \operatorname{diag}[50, 50, 50]$, $K_F = \operatorname{diag}[625, 625, 625]$ 그리고 낮은 이득값으로는 $K_D = \operatorname{diag}[10, 10, 10]$, $K_F = \operatorname{diag}[25, 25, 25]$ 가 선택되었다. 신경 제어기 변수들로서 잠재 신경의 수는 6, $\alpha = 0.9$, 초기 가중값은 -0.5 와 0.5 사이에서 무작위로 정해졌다. 학습률 η 는 시행 오차 과정을 통해 최적값으로 선택된다. 로봇의 작업 수행 능력은 두 번째 주기 동안의 경로 오차의 합으로 평가가 된다. T 는 추출률로서 0.005초이고 F 는 한 주기인데, 원형 경로에서는 $F = 4$ 초, 복합 경로에서는 $F = 12$ 초가 사용된다.

로봇의 첫 번째 작업은 주어진 경로, 즉 지름이 30cm이고 45도 경사가 진 원형 경로를 따라 가는 것이다. 표 1에서는 높은 이득을 사용했을 경우를 나타내고 표 3에서는 낮은 이득을 사용했을 경우이다. 오차를 보면 구조 I, II의 성능이 FEL의 성능보다 훨씬 우수함을 알 수 있다.

표 1. 높은 이득 사용시 원형 경로 오차

Table 1. Circular trajectory error under high gain

	구조 I	구조 II	FEL
η	0.0008	0.0002	0.0008
α	0.9	0.9	0.9
$E_p(\text{rad}^2)$	0.000002	0.000003	0.023981
$E_v(\text{rad/s})^2$	0.00444	0.00343	1.790924
$E_c(\text{m})$	0.0000001	0.0000001	0.00605

그림 4에서는 높은 이득을 사용했을 경우에 세 가지 제어기들의 첫 번째 원형 주기의 경로 수행을 나타내는데, 구조 I의 성능이 가장 좋음을 알 수 있다. 낮은 이득을 사용할 경우에 FEL과 보상하지 않았을 때의 경로 오차가 너무 크기 때문에 표 3에서는 구조 I, II의 수행 결과만 나타나 있다.

로봇의 두 번째 작업은 그림 6에서 보여 지는 것처럼 복합 경로를 수행하는 것이다. 경로 수행 결과는 표 2에 잘 나타나 있다. 원형 경로 수행의 경우와 같은 현상으로 구조 I의 제어기

의 경로 오차가 가장 작음을 알 수 있다.

그림 6은 높은 이득의 제어를 사용했을 때의 결과인데, 그림에서 보면 구조 I, II의 성능이 FEL 제어기의 성능보다 우수함을 알 수 있다. 또 낮은 이득의 제어를 사용했을 경우 구조 I, II 제어기들의 수행 결과가 표 3에 나타나 있다.

표 2. 높은 이득 사용할 때 복합 경로 오차

Table 2. Composite Trajectory error under high gains

	구조 I	구조 II	FEL
η	0.0005	0.0001	0.0005
$E_p(\text{rad}^2)$	0.011361	0.018119	2.006162
$E_v(\text{rad/s})^2$	112.8616	100.6445	173.321945

표 3. 낮은 이득 사용시 경로 오차

Table 3. Trajectory error under low gains

	원형 경로		복합 경로	
	구조 I	구조 II	구조 I	구조 II
η	0.01	0.005	0.015	0.005
α	0.9	0.9	0.9	0.9
$E_p(\text{rad}^2)$	0.000339	0.000229	0.009719	0.009503
$E_v(\text{rad/s})^2$	0.004881	0.003760	60.050266	37.12189
$E_c(\text{m}^2)$	0.000085	0.000061	N/A	N/A

7. 결론

본 논문에서 우리는 신경 회로망을 이용하여 제어할 대상의 모형에 대한 지식이 없을 경우에 불확실성을 보상하는 적응 제어 방식을 보였다. 이 제어 방식은 경로를 보상하는 구조적 특성과 출력 오차를 학습 신호로 사용하는 학습 방법에 따라 그 성능이 우수하다는 것이 모의 실험을 통해 증명되었다. 구조상 다른 세 가지 신경 제어기들을 모의 실험을 통해 비교해 보았는데, 그 중에서 구조 I의 성능이 제일 좋았다.

본 제어 방식의 큰 잇점은 보상이 기존에 설치되어 있는 제어 시스템의 밖에서 이루어지기 때문에 기존의 선형 제어기로 제어되는 다양한 공정 등의 제어기들을 수정할 필요 없이 쉽게 응용이 가능하다는 것이다. 또한 기존의 신경 회로망 제어 방식(FEL)과 비교해 낮은 이득 제어가 가능하기 때문에 높은 이득을 사용해야 하는데 따르는 비용을 감소하고, 안전성을 향상시킬 수 있다.

참고문헌

- [1] A. Ishiguro, T. Furuhashi, S. Okuma, and Y. Uchikawa, "A neural network compensator for uncertainties of robot manipulator", IEEE Trans. on Industrial Electronics, vol. 39, pp. 61-66, December, 1992
- [2] D. Psaltis, A. Sideris, and A. Yamamura, "A multilayered neural network controllers", IEEE Control Systems Magazine, pp. 17-21, 1986.
- [3] K. Narendra and K. Parthasarathy, "Identification and control of dynamical system using neural networks", IEEE Trans. on Neural Networks, vol. 1, pp. 4-27, 1990
- [4] M. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback error learning", IEEE Trans. on Neural Networks, vol. 1, pp. 251-265, 1988

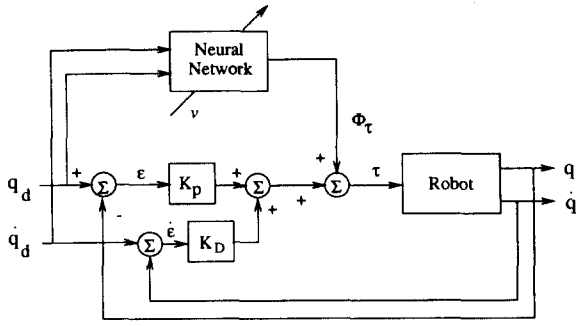


Figure 1: Feedback error learning control structure(FEL I)

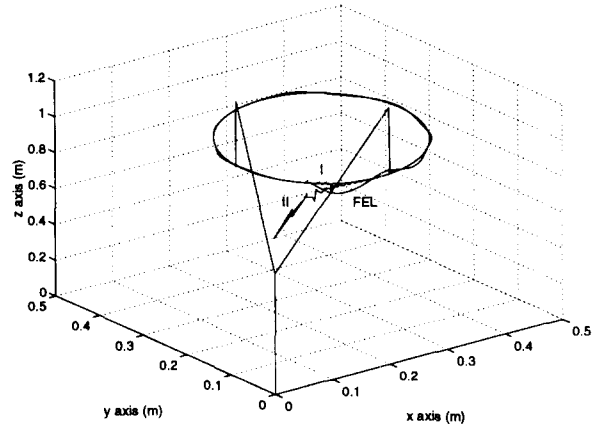


Figure 4: End Point Circular Trajectory : (I) RCT Scheme 1 (II) RCT Scheme II (FEL) FEL Scheme

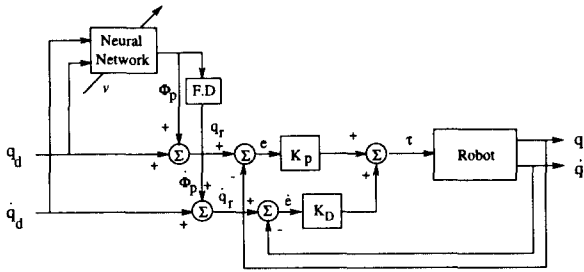


Figure 2: Reference compensation technique : Scheme I

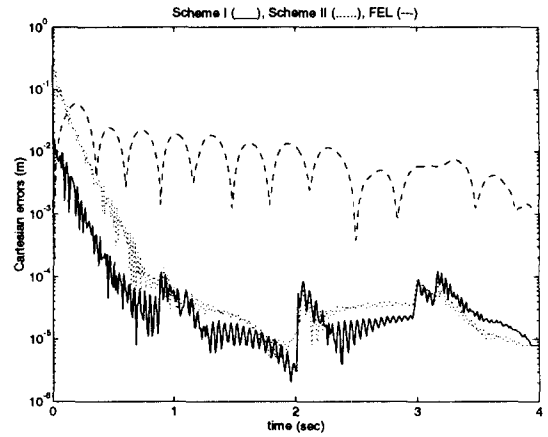


Figure 5: Cartesian errors of End Point Circular Trajectory

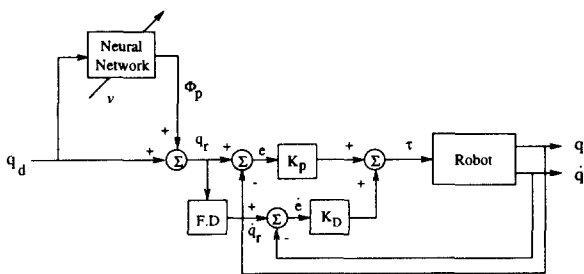


Figure 3: Reference compensation technique : Scheme II

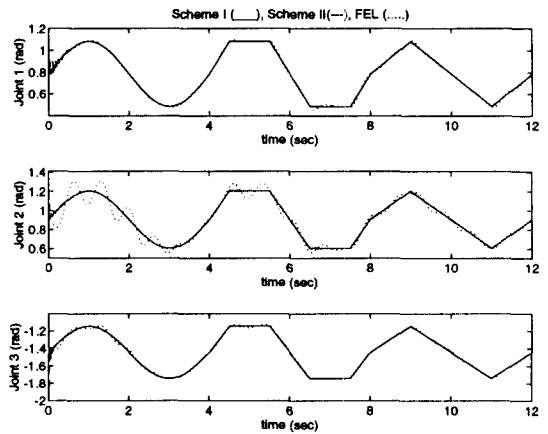


Figure 6: Composite Trajectory Tracking