

論文98-35C-6-7

신경 회로망을 이용한 비최소 위상 시스템의 최적 제어기 설계

(Design of an Optimal Controller with Neural Networks
for Nonminimum Phase Systems)

朴相奉*, 朴哲薰*

(Sang-Bong Park and Cheol-Hoon Park)

요약

본 논문은 비최소 위상 시스템을 보다 효율적으로 제어하기 위하여 기존의 PID 타입의 선형 제어기와 병렬적으로 구성된 신경망 제어기의 구성에 대하여 다룬다. 제안된 제어기의 제어 목표는 비최소 위상 시스템의 제어의 경우 흔히 나타나는 언더슛 현상을 최소화하면서 설정된 시스템 응답과의 응답 오차가 최소화하는 것이다. 전체 비용 함수는 고려된 두 가지의 개별 목적 함수간의 선형 합으로 이루어 진다. 신경망 제어기는 주어진 전체 제어 시간 동안의 제어 성능을 광역 평가를 통하여 주어진 전체 비용 함수를 최소화하는 최적 제어기를 구성하도록 진화 프로그래밍을 이용하여 off-line으로 학습된다. 일반적인 컴퓨터 모의 실험으로 계단 신호 응답에서 나타나는 빠른 settling 시간, 작은 언더슛과 오버슛과 같은 제어 성능 향상의 관점에서 기존의 선형 제어 시스템의 성능에 비해 훨씬 효과적이라는 것을 보인다. 또한, 파레토(pareto) 다중 최적화 개념을 도입하여 선형 합으로 이루어진 비용 함수 최적화의 한계성과 문제점을 극복한다.

Abstract

This paper investigates a neuro-controller combined in parallel with a conventional linear controller of PID type in order to control nonminimum phase systems more efficiently. The objective is to minimize overall position errors as well as to maintain small undershooting. A costfunction is proposed with two conflict objectives. The neuro-controller is trained off-line with evolutionary programming(EP) in such a way that it becomes optimal by minimizing the given cost function through global evaluation based on desired control performance during the whole training time interval. However, it is not easy to find an optimal solution which satisfies individual objective simultaneously. With the concept of Pareto optimality and EP, we train the proposed controller more effectively and obtain a valuable set of optimal solutions. Simulation results show the efficacy of the proposed controller in a viewpoint of improvement of performance of a step response like fast settling time and small undershoot or overshoot compared with that of a conventional linear controller.

I. 서론

최소 위상 시스템(minimum phase system)과 달

* 正會員, 韓國 科學技術院 電氣 및 電子工學科
(Dept. of Electrical Engineering KAIST)

接受日字: 1997年3月26日, 수정완료일: 1998年5月25日

리 비최소 위상 시스템(nonminimum phase system)은 그 시스템 자체의 부자연스러운 특성으로 인해 제어기 구성이 이론적으로나 실제 적용 면에서 많은 한계를 가지고 있다고 잘 알려져 있다. 비최소위상 시스템은 선형화된 시스템이 s-평면상의 우반구에서 영점/극점을 가지는 것으로 발전소의 드럼 수위 제어, 미사일/항공기의 수직 상승/하강 등 다양한 분야에서

존재한다. 특히, 비최소 영점은 시스템의 응답 특성에서 언더슛팅(undershooting)과 같은 부자연스러운 현상을 발생시킨다. 이러한 언더슛 현상은 오차가 증가 할수록 제어 입력을 증가시킨다라는 일반적인 제어 개념에 상반된 결과를 초래하여 기존의 제어 기법으로는 만족할 만한 제어 성능을 얻기 어렵게 한다. 비최소 위상시스템에 제어에서 중요한 것은 가급적 빠른 응답 시간하에서 작은 언더슛과 빠른 응답 오차를 유지하는 것이다. 그러나, 작은 언더슛과 빠른 응답 시간 그리고 응답 오차 사이에는 상호 교환 관계(trade-off)가 존재 한다. 이러한 비최소 특성으로 비롯된 비최소 위상 시스템의 제어기 구성의 어려움은 기존의 여러 논문에서 잘 나타난다. 우선, 일반적인 pole-zero 취소 제어 방식의 적용은 내부 안정도 문제 때문에 비최소 시스템에 직접 적용할 수 없다. Elliot^[1]과 Praly^[2] 등은 선형 제어기 구성시 필요한 제어 인자를 효과적으로 얻는 방법을 제안했지만, 여전히 선형 제어기의 한계 성 때문에 언더슛과 같은 비최소 현상을 적절히 해결하지 못했다. 한편 Widrow와 Stearns는 특별한 비최소 위상 시스템 경우에 입력 지연을 통해 이러한 비최소 특성을 상쇄할 수 있는 제어하는 방식을 제안했다^[3].

최근 들어 신경망, 퍼지와 같은 지능 제어 기법이 주목을 받으면서 지능 제어기의 우수성에 대한 인식이 급속히 확산되고 있으며, 많은 제어 분야에 응용되어 성공적인 결과를 얻었다. 이러한 제어 방식은 기존 제어 시스템에서 요구되는 수식 모델링과 복잡한 계산식을 자랑하면서, 인간의 경험과 데이터의 합리적 처리에 바탕을 둔 새로운 계산 기법으로 제어 분야를 접근하는 것이다. 대규모적인 계산의 병렬성(massive parallelism), 학습에 의한 자기 조직화(self-organization) 및 비용 함수의 최적화 등 다양한 신경 회로망의 능력은 그 동안 전통적인 방법으로는 높은 성능을 얻기 힘들었던 문제를 해결하는 도구로 주목 받아 왔다. 신경 회로망의 임의의 연속함수에 대한 근사화 능력이 이론적으로 보장되면서^[4,5,6], 제어 분야에서 그 동안 해결하기 힘들었던 여러 제어 방식에 대한 접근이 활발히 이루어지고 있다^[7,8,9]. 신경망의 학습 방법으로는 크게 최소 경로 경사법에 바탕을 둔 오차 역전파 방법과 오차의 미분 성분이 필요치 않는 확률적인 탐색방법 등이 있다. 특히, 진화 프로그래밍(evolutionary programming, EP)는 확률적인 전역

최적화 기법 중의 하나로써 자연계의 진화와 선택이라는 개념을 이용하여 주어진 비용함수를 최적화하는 해를 찾으며, (준)최적해까지의 빠른 수렴 속도와 적용의 용이함으로 그동안 많은 문제에서 성공적으로 적용되어 왔다.

그동안 개발된 많은 이론적인 제어 기법에도 불구하고, 현실적으로 거의 대부분의 산업계 제어 시스템은 구조가 간단하면서도 안정된 PID 타입의 선형 제어 방식이 주류를 이루고 있다. 그러나, 양질의 제어 성능을 얻도록 제어 인자들을 설정하는 것은 여전히 소모적인 작업이며, 때로는 시스템과 제어 이론에 대한 상당한 지식과 시스템의 수학적 모델식 등이 요구된다. 더구나, 제어 성능 함수가 상당히 엄격하거나 시스템의 복잡한 특성을 가진 경우에는 원하는 제어 성능을 기존의 선형 제어기만으로는 해결할 수 없는 경우가 종종 발생한다. 따라서, 이러한 제어 환경에 있어서 중요한 것은 기존의 PID 타입의 제어 방식이 가지는 한계성을 효과적 극복함으로써 주어진 비용 함수를 최적화할 수 있는 제어기의 개발이다. 본 논문에서는 기본적으로 시스템 현장에서 가장 많이 적용되는 제어 기법인 선형 PID 타입의 제어기를 사용한다. 그리고 PID 제어기가 갖는 거친 제어 방식과 비최소 위상 시스템이 갖는 여러 문제점을 효과적으로 해결하기 위하여 신경 회로망을 이용한 비선형 제어기를 기존의 선형 제어기에 추가한다. 또한, 언더슛을 감소시키고 시스템의 응답 시간 및 오차를 줄이기 위해서 EP을 이용하여 부가된 신경망 제어기의 가중치를 학습시킨다. 따라서, 제어기의 설계문제는 신경망의 최적화 학습으로 단순화되며, 최적화할 비용 함수는 시스템을 포함한 제어 구조와 신경망 사이의 인터페이스(interface)로써 가중치의 적합도를 제공한다. 실제 많은 문제의 비용 함수는 다양한 성질의 개별 목적 함수로 구성되어지는 것이 일반적이다. 특히, 본 논문에서 다루는 작은 언더슛과 빠른 응답 시간 및 오차의 최소화라는 두 목적함수는 서로 상반된 특성을 지니고 있다. 단순히 두 목적함수를 선형합을 통해 얻은 비용 함수를 최적화할 경우에는 각 목적함수에 가한 가중치의 상대적 크기에 따라 최적해가 상당히 차이가 날 수가 있다. 또한, 가중치에 따라 선형합된 비용 함수의 해공간(landscape)이 복잡하여 최적해를 찾는 데 실패할 수도 있다. 일반적으로 이러한 다중 목적 최적화 문제에는 각 목적 함수간의 최적의 상호 교환관계를 나타

내는 비우위(non-dominated), 패렛도 해들이 존재한다^[10]. 패렛도 해 집합에 속한 각 최적 해들은 동시에 모든 다른 목적 함수를 최소화할 수 없다^[11]. 비록 선형 프로그래밍, 정수 프로그래밍, 그리고 비선형 프로그래밍과 같이 많은 수학적인 최적화 방법이 제시되었지만, EP가 가진 근본적인 병렬 계산 구조는 모집단을 통해서 패렛도 집합을 손쉽게 다룰 수 있는 장점을 지니고 있다. 본 논문에서는 다중 목적 최적화 개념을 EP 방법과 결합하여 제안된 제어 구조의 학습에 적용하여 선형화된 비용 함수 최적화의 문제점과 다중 최적화 기법의 필요성도 알아본다.

다음 장에서는 기존의 오차 역전파 방식을 이용한 비최소 위상 시스템의 신경망 제어 방식의 단점과 새로운 학습 알고리즘의 필요성에 대하여 설명한다. 또한 효과적인 비최소 시스템의 제어를 위해 새롭게 정의된 비용 함수와 전체적인 제어 알고리즘을 기술한다. 3 장에서는 제안된 비용 함수를 바탕으로 진화 알고리즘을 이용한 신경망 학습 방법에 대하여 기술한다. 또한, 다중 목적 최적화 기법의 필요성과 패렛도 집합에 대하여 설명한다. 4 장에서는 컴퓨터 모의 실험을 통하여 제안된 제어구조와 학습 알고리즘을 여러 가지 비최소 위상 모델에 적용한 결과를 보여 준다. 마지막으로 5 장에서 결론과 추후 과제에 대하여 논한다.

II. 신경망 제어기와 진화 알고리즘을 이용한 비최소 위상 시스템 제어기 구성

기존에 제안된 여러 신경망 제어 학습 방법으로는 비최소 위상 시스템에 대한 신경망 제어기의 구성이 일반적으로 상당히 어렵다는 것이 알려져 있다^[12,13]. 신경망 제어기를 가진 전체 제어 시스템은 학습 과정에서 발산하거나, 일정한 학습 횟수 후에도 제어기의 학습이 제대로 이루어지지 못한다. 이렇게 학습이 제대로 이루어지지 못하는 것은 크게 다음과 같은 이유 때문이다^[14]. 우선 기존의 오차 역전파 방식을 이용한 신경망 제어기의 학습은 시스템의 오차를 시스템의 Jacobian이나 그 동정화기를 통해서 역전파 시켜야 한다. 그러나, 비최소 위상 시스템인 경우 시스템의 역함수가 불안정하기 때문에 시스템의 오차의 역전파를 통해 제어기를 학습하기가 어렵게 된다. 또한, 일시적으로 제어 입력이 커짐에 따라 시스템의 출력이 감소하는 비최소 위상 시스템의 특성은 매 제어시간마다

학습에 의해 현재 오차에 대한 적절한 출력 제어값을 결정하기 힘들게 한다. 따라서, 비최소 위상 시스템의 언더슛 효과를 감소시키면서도 출력의 settling 시간을 줄이기 위해서는 새로운 제어 구조를 필요로 하게 된다.

제안된 전체적인 제어기의 구조와 신경망 제어기는 그림 1과 같다. 제안된 제어기는 신경망과 기존의 선형 PI 제어기를 병렬적으로 구성되어 있다. 여기서 신경망 제어기는 선형 제어기의 출력으로는 제어 성능에 한계가 있는 전이(transient) 영역에서 적절한 비선형 출력을 제공함으로써 좋은 제어 성능을 갖도록 하는 것이 중요하다. 이것을 위해 시스템의 계단 응답에 대하여 PI 제어기의 출력의 오차 특성을 파악한 후 적합한 물리적 량을 신경망 제어기의 입력 중에 하나로 선택함으로써 효과적인 제어기를 구성한다. 언더슛은 다음과 같은 부등호가 성립하는 곳에서 일어난다.

$$\frac{de}{dt} \times e > 0. \quad (1)$$

오차와 오차의 미분치의 곱을 신경망의 입력 항으로 사용함으로써 신경망 제어기를 언더슛 영역에 주로 동작시킬 수 있다. 따라서, 신경망 제어기가 제어 입력에 대한 언더슛을 줄이도록 성공적으로 학습된다면 비최소 위상 현상을 효과적으로 줄일 수 있다.

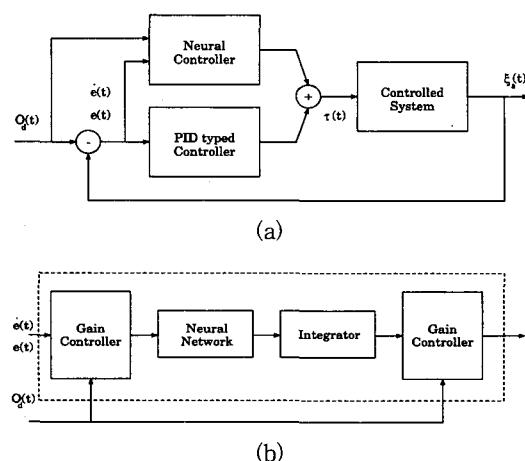


그림 1. 제안된 제어 시스템의 (a) 전체 블록 다이아그램과 (b) 신경망 제어기의 블록 다이아그램
Fig. 1. (a) Overall block diagram of the proposed controller and (b) Structure of the neuro controller

전형적인 비최소 위상 시스템의 출력 특성이 그림 2

와 같을 때, 비용 함수에 고려해야 할 중요한 것은 빠른 상승시간과 settling 시간에 비해 작은 언더슛과 오버슛을 가지는 제어기를 구성하는 것이다. 따라서, 다음과 같이 서로 교환관계가 있는 다중 비용 함수를 정의할 수 있다.

$$E_1 = \int_0^T (O_d(t) - \xi_a(t))^2 dt \quad (2)$$

$$E_2 = E_{21} + E_{22} \quad (3)$$

$$\begin{cases} E_{21} = |\min(\min \xi_a(t), 0)| & \text{when } O_d(t) = 1 \\ E_{22} = |\max(\max \xi_a(t) - 1, 0)| & \text{when } O_d(t) = 1 \\ 0 \leq t \leq T \end{cases}$$

$$E_3 = E_{31} + E_{32} \quad (4)$$

$$\begin{cases} E_{31} = |\max(\max \xi_a(t), -1, 0)| & \text{when } O_d(t) = 0 \\ E_{32} = |\min(\max \xi_a(t) - 0)| & \text{when } O_d(t) = 0 \\ 0 \leq t \leq T \end{cases}$$

$$E_4 = \alpha \times E_1 + \beta \times (E_2 + E_3) \quad (5)$$

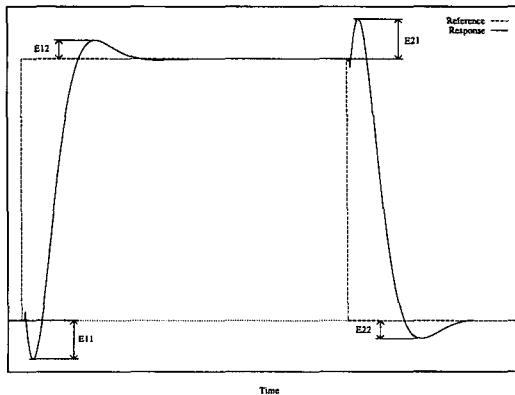


그림 2. 전형적인 비최소 위상 시스템의 계단 응답
Fig. 2. A step response of a nonminimum phase system.

여기서 $O_d(t)$ 와 $\xi_a(t)$ 는 각각 목적 계단 출력과 실제 출력 값이며, T 는 학습 대상 구간이며, α 와 β 는 기중 계수이다. 식 (5)은 두개의 목적 함수가 기중된 선형 조합이다. E_1 , E_2 와 E_3 는 계단 입력의 상승과 하강 시점에서 나타나는 각기 전체 제곱 오차의 합, 언더슛(E_{11} , E_{21})과 오버슛(E_{12} , E_{22})의 크기이다. 비위상 최소 시스템은 그 특성상 빠른 상승 시간을 얻기 위해서는 큰 언더슛을 동반해야 하기 때문에 제어기의 성능은 최적화를 위한 두 목적 함수간의 기중치에 큰

영향을 받는다^[13]. 기중치 계수 α 와 β 값은 시행착오를 통해 최적으로 결정되었다. 제안된 비용 함수를 통해서 학습과정에서 얻어지는 신경망 가중치들의 적합도를 평가할 수 있다.

III. 신경망 제어기의 최적화 기법

본 장에서는 제안된 제어구조에서 목적 함수간의 선형합된 비용함수에 대한 EP를 통한 최적화 기법과 다른 목적 최적화 개념을 도입한 최적화 방법을 이용한 신경망 제어기 학습 방법에 대해 알아본다.

1. EP를 이용한 신경망 가중치 학습 방법

기존의 결정론적(deterministic) 최적화 기법들은 비용 함수의 경사도나 고차 특성을 이용한다. 비록 이런 기법들이 지역적인 최적화 해로의 수렴을 보장할 수 있지만, 고려된 비용 함수가 대단히 복잡하거나 최적화해야될 변수들이 서로간에 비선형적 연관성을 가질 경우에는 상당히 나쁜 성능을 보일 수도 있다. 최근에 이러한 문제를 해결할 한 방법으로 확률적인 탐색 방법에 바탕을 둔 진화 알고리즘이 주목을 끌고 있다. 진화 알고리즘은 기본적으로 자연계의 적자 생존과 자연 선택설 이론을 바탕을 둔 유전 알고리즘(genetic algorithm, GA), 진화 프로그래밍(EP) 등이 있다. GA는 실제 실변수 대신에 이진법처럼 부호화된 인자들에 대하여 일정한 크기의 string을 한다^[15,16]. EP나 GA와 달리 실제 실변수를 그대로 사용한다. 따라서, 함수의 극사화나 변수의 최적화 문제는 이진수 기법을 사용하는 GA에 비해 분해도 문제가 없고 빠른 수렴 성능을 가진 EP가 훨씬 효과적이다. 또한, 신경 회로망 분야에서도 주어진 비용 함수를 최적화하는 가중치를 찾는 데 EP가 좋은 학습 알고리즘이 확인되었다^[17,18].

EP는 염색체(chromosome), 변이(mutation) 그리고 모집단(population)과 같은 생물계의 용어를 이용한다. 유전 인자로써 최적화 대상인 변수들로 이루어진 염색체는 모집단의 구성 요소이다. 초기 모집단은 문제에 따라 랜덤 또는 적절히 설정된 염색체 집단으로 결정된다. 모집단에서 선택된 염색체들은 부모 세대로써의 염색체 군을 이루고 변이 방법을 통해 자식 세대의 염색체 군을 새로 생성한다. 생성된 부모와 자식 세대의 염색체 군은 유전 인자 집단을 구성하고 그

집단에서 우수한 염색체 집단들이 이미 정의된 선택 방법(selection scheme)을 통해 다음 세대의 모집단이 추출된다. 이러한 과정이 종료 조건이 만족될 때까지 반복됨으로써 모집단 내의 염색체군이 우수한 성능을 가지도록 진화되는 것이다. EP에서는 일반적으로 두 가지의 선택 방법, 즉 $(\mu + \lambda)$ 와 (μ, λ) 방법이 있다. 전자는 μ 개의 부모 염색체군과 그로부터 생성된 λ 개의 자식 염색체군이 합쳐진 $(\mu + \lambda)$ 개의 유전 인자 집단에서 우수한 μ 개의 다음 부모 세대를 선택하는 방법이며, 후자는 단지 λ 개의 자식 염색체군에서 μ 개의 다음 부모 세대를 선택하는 방법이다. 또한, 새로운 염색체군의 우수성과 다양성을 유지하기 위하여 각 염색체의 성능 지수를 서로간의 비교 우위를 통해 결정하는 토너먼트(tournament) 방법, 절대적으로 일정개의 최고 성능 염색체군을 유지하는 최고 보유(best keeping) 방법, 확률적으로 우수한 성능의 염색체군을 유지하는 룰렛 ���(roulette wheel)방법 등이 있다. 그림 3과 4는 기본적인 EP 알고리즘과 흐름도이다. 초기 모집단내의 염색체들은 랜덤하게 형성하여 가급적 넓은 해공간을 탐색 가능하도록 한다. 학습이 진행되면서 모집단의 부모 세대로부터 변이 방법을 통해 생성된 자식 세대의 염색체들은 부모 세대의 유전 인자 주위에서 변형된 새로운 인자를 보유한다. 따라서 변이 방법을 통해 어느 정도 부모 세대의 우수한 인자를 유지하면서도 새롭게 생성된 유전 인자에 의하여 더욱 우수한 성능 지수를 가질 가능성을 갖게 된다. 각 염색체는 다음과 같은 변이 방법에 의하여 진화된다.

$$\sigma_i^{n+1} = \sigma_i^n + N(0, \epsilon \sigma_i^n) \quad (6-1)$$

$$x_i^{n+1} = x_i^n + N(0, \sigma_i^n) \quad (6-2)$$

```

Begin
  make first  $\mu$  parents
  evaluate cost functions of parents
  while (not termination condition) do
    begin
      make  $\lambda$  offsprings
      evaluate cost functions of offsprings
      select  $\mu$  chromosomes as next parents
      and
    End
  
```

그림 3. 기본적인 EP 알고리즘

Fig. 3. Basic Algorithm of EP.

여기서 x_i^n 은 염색체내의 i 번째 인자이며, $N(\cdot, \cdot)$ 와 σ_i^n 은 각각 표준 가우시안 랜덤 분포와 n 번째 진화에서 i 번째 인자에 대한 분산값이다. ϵ 는 양의 상수값으로써 분산값의 변화폭을 결정한다. 변이는 염색체뿐만 아니라 그자체에 대해서도 진화를 허용한다.

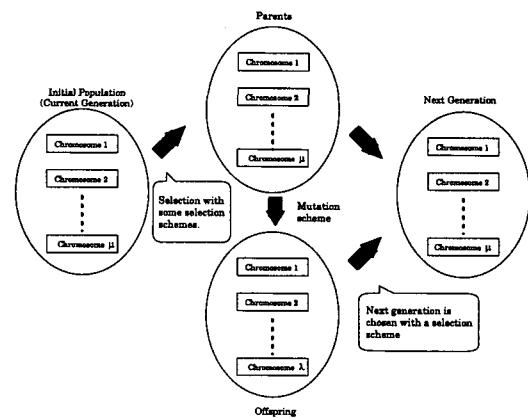


그림 4. EP 알고리즘의 흐름도

Fig. 4. Flowchart of EP Algorithm.

2. EP를 이용한 다중 목적 최적화 방법

염색체를 실변수로 표현하는 EP는 대상 시스템에 대한 구체적인 수학적 계산식이나 미분 정보없이도 비교적 빠른 수렴 속도하에서 최적해 또는 준 최적해를 보장한다. 그러나, 비용 함수가 다중 목적함수로 이루어진 경우에는 단지 EP 알고리즘만(original EP, OEP)으로는 실제 최적해를 보장하기가 상당히 어렵다. 현실 세계의 많은 문제들은 성능 평가에 있어 다양한 성능 지수(목적) 함수를 포함한다. 따라서, 진정한 의미의 최적화라는 것은 다중 목적 함수의 최적화 개념의 관점에서 그러한 문제를 다루어야 한다. 특히, 각 목적 함수가 서로간에 강한 교환관계를 유지하는 경우 단순한 최적화 방법만으로는 최적해를 얻기가 힘들다. 일반적으로 다중 목적 함수 문제는 함수들간의 가중치에 의한 선형 조합이나 제약 조건 방법을 통해서 최적화될 수도 있다. 그러나, 최적의 해를 얻기 위한 가중치의 상대적인 크기를 실제 결정하기는 상당히 힘들뿐만 아니라 모든 가능한 경우에 대하여 실험을 해야하는 어려움이 따르게 된다. 다중 목적 최적화의 기본 목적은 비용 함수를 구성하는 각 목적 함수를 독립적으로 최적화 되도록 하여 동시에 모든 목적 함수를 감소시킬 수 없는 합리적인 최적해들을 제공하는 것이다. 이러한 최적해들을 비우위화되었다고 하며, 모

두 파레토 집합(Pareto optimal set 또는 Pareto optimal surface)을 이루는 구성요소가 된다. 파레토 집합내에 있는 해들은 각 목적 함수들이 서로 상충되어 있다. 반드시 하나 이상의 목적 함수에 대해서는 다른 파레토 집합내 해들에 비해 우수한 값을 유지하지만, 모든 목적 함수값이 우수하지는 않다. 해공간 내에서 자신의 각 목적 함수들 값에 대하여 모두 우수한 값을 가진 해가 존재하는 경우 그해는 우위화되었다고 한다. 그림 5에서는 목적 함수의 공간에 대하여 모든 해집합을 표현하였다. 이때 목적 함수 공간은 3 영역으로 나뉘어지며, 가능 영역(feasible), 불가능(infeasible) 그리고 파레토 최적 해가 그것이다. 가능 영역의 해는 모두 파레토 최적 해집합내의 어느 한 해에 대하여 우위화되었다는 것을 알 수 있으며, 파레토 집합내 각해들은 서로 비우위화되어있다. 따라서, 파레토 최적 집합을 통해서 모든 목적 함수의 최적 영역과 상대적인 관계를 알수있다. 다중 목적 최적화 방법과 연관된 많은 방법이 연구되어 왔으나, EP를 이용한 다중 목적 최적화 방법(multiobjective optimization using EP, MOEP)은 몇가지 유용한 장점을 가지고 있다.

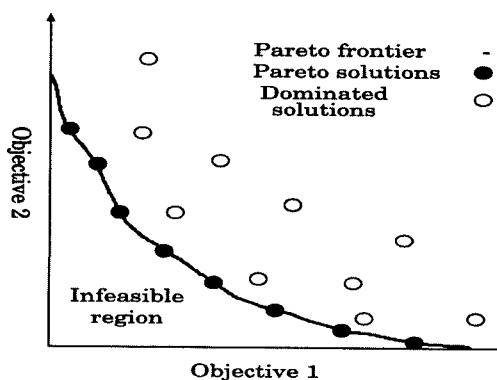


그림 5. 각 목적 함수를 최소화할 경우 목적 함수 공간에서 나타나는 파레토 최적 해

Fig. 5. Pareto optimal set(frontier) when minimizing each objective.

우선 EP 자체가 가지는 근본적인 병렬 구조와 단 한번의 시행으로 모집단내의 각 염색체 군들이 손쉽게 파레토 집합을 이룰 수 있다는 것이다. EP와 MOEP의 차이점은 현재의 모집단에서 다음의 부모 세대를 뽑는 선택 방법의 차이이다. 즉, EP가 하나의 최적해를 얻기위해 빠른 속도로 수렴하는 반면에 MOEP는

모집단에서 높은 확률로 비우위된 염색체군들을 뽑으면서 가급적 넓은 해공간에 최적해를 분산시킨다. 본 논문에서 다중 목적 최적화를 수행하기 위하여 EP 알고리즘에 파레토 개념을 바탕으로한 니세(niche)와 공유(sharing) 방법을 도입하였다. 파레토 방법은 각 목적 함수의 적합도를 순위(rank) 관점에서 정의된다. 모든 비우위된 해집합에 대하여 새로운 변이에 있어 같은 확률값을 제공함으로써 Goldberg에 의해 제안된 파레토 최적화 개념을 이용한다^[15]. 공유 기법은 모집단내의 염색체군들이 이미 정의된 니세 크기내로 집중되는 것을 막음으로써 전체 최적 해집단이 파레토 최적 해면에 균일하게 분포되게 한다.

다중 목적 최적화 개념을 도입하기 위하여 2 장에서 정의된 비용 함수 (5)를 2차원의 목적 함수 공간에서 다음과 같이 재정의 하였다.

$$f(w) = (f_1(w), f_2(w)) \quad (7)$$

여기서 w 는 신경망 제어기의 가중치이며 $f_1(w) = E_2 + E_3$, $f_2(w) = E_1$ 이다. E_2 와 E_3 은 모두 전이 영역에서의 언더슛과 오버슛을 크기를 표현하기 때문에 같은 비용함수로 취급하였다.

IV. 모의 실험

제안된 제어 구조를 이용한 컴퓨터 모의 실험은 다음과 같은 세가지 비최소 위상 모델들에 대하여 이루어졌다.

$$\frac{s - 1}{s^2 + 7s + 12} = \frac{s - 1}{(s + 3)(s + 4)} \quad (8)$$

$$\frac{s - 1}{s^2 + 1.72s - 0.256} = \frac{s - 1}{(s + 2)(s - 0.128)} \quad (9)$$

$$\frac{0.005(0.1877s^2 - 0.0292s + 0.001)}{s^4 + 0.6121s^3 + 0.0581s^2 + 0.001s} \quad (10)$$

식 (8)은 비최소 영점만을 가진 그리고 식 (9)은 비최소 영점과 극점을 모두 가진 비최소 위상 시스템 모델이다. 식 (10)는 울진 원자력 발전소의 저출력시 실제 드럼 보일러 시스템에서 입력에 대하여 출력 수위의 반응을 근사화한 전형적인 선형 4차 비최소 위상 시스템이며^[19], 두 개의 비최소 영점을 가지고 있다. 급수량 조절에 의한 수위 응답에는 어느 정도의 시간 지연이 있고 수축 및 팽창의 비최소 효과로 인한 수위

변동이 급속하기 때문에 선형 제어기로는 근본적인 문제 해결이 곤란하다. 따라서, 시스템 모델 (10)에서 중요한 제어 목적은 새로운 제어 방식을 통해 일시적인 수축 및 팽창에 의한 요동폭을 어느정도 허용하되 가급적 빠른 시간 내에 원하는 수위 설정치에 제어가 이루어지도록 제어되어야 한다. 각 시스템의 샘플링 간격은 0.05, 0.2, 그리고 1초이다. 시스템 모델 (9)과 (10)에서는 전체 안정도를 유지할 선형 제어기의 이득(gain)의 크기가 너무 제한되어 있기 때문에 만족할만한 제어 성능을 얻기 위한 제어 인자를 구하기가 힘들었다. 제안된 제어 시스템 구조에서 적용된 신경망 제어기의 내부 구조는 2 장에서 언급한 것처럼 계단 출력 오차의 물리량을 분석하여 $e(t)$, $e(t)-e(t-1)$, $e(t)^*$ ($e(t)-e(t-1)$)와 각 입력의 자연 성분등 모두 6개의 입력을 사용했다. 각 가중치의 동적 영역을 제한함으로써 신경망 제어기의 출력값을 일정 범위로 제한할 수 있으며, 전체 제어 시스템의 안정도를 해치지 않는 범위 내에서 신경망을 최적으로 학습할 수 있었다^[20].

본 논문에서는 제안된 제어 구조의 성능을 OEP와 MOEP의 관점에서 그 결과를 서로 비교해 보고, 제안된 제어 구조의 우수성을 보인다. 각 최적화 기법에서 200개의 모집단이 이용되었으며, 선택 방법으로 $(\mu + \lambda)$ 과 토너먼트 방법이 이용되었다. 그림 6은 시스템 모델 (9)에 대하여 EP에 의해 5500 번 동안 진화되는 동안 각 학습 횟수에서 최적해가 변화하는 모습을 보여준다.

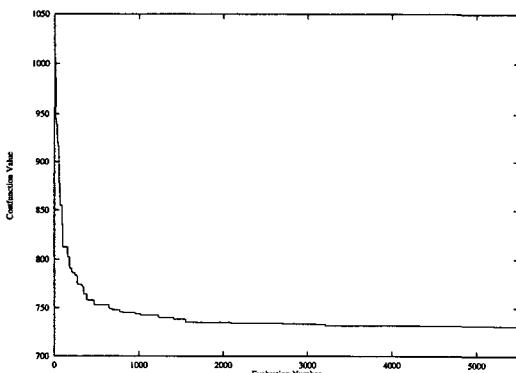
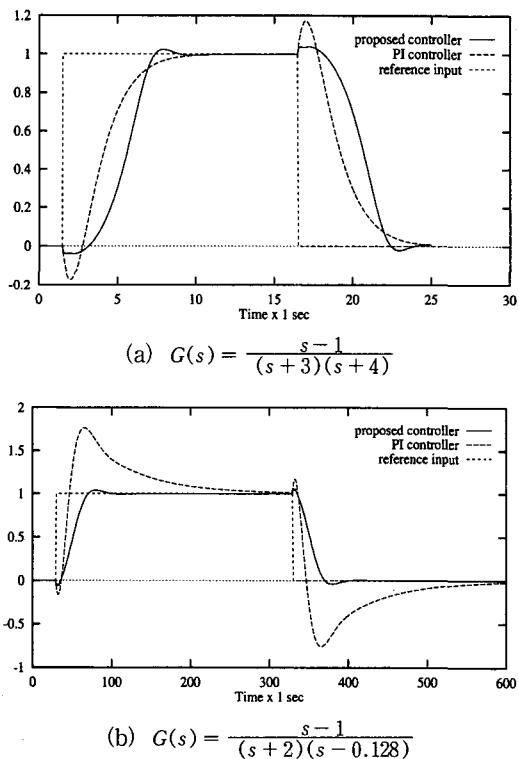
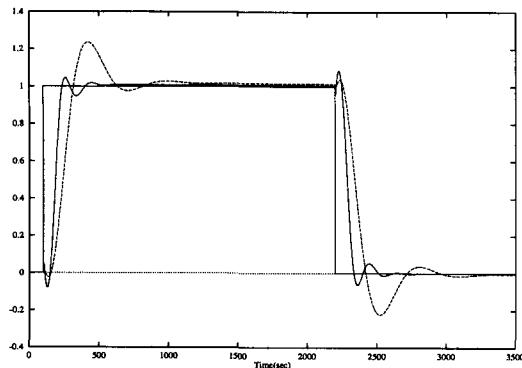


그림 6. EP의 학습에 따른 최적 해의 변화
Fig. 6. A learning curve of the optimal solution using EP.

주어진 비최소 위상 시스템을 기준의 선형 제어기와 제안된 신경망 제어기를 이용하여 최적해를 구했을 때,

원하는 계단입력에 대한 실제 시스템의 출력을 비교하여 그림 7에 나타내었다. 이때 PI 구조에 적용된 PI 제어 인자는 EP를 통하여 주어진 모델에 대하여 안정화 범위 내에서 최적화하여 얻은 것이다. 그림 8은 각 시스템에 대하여 근궤적기(root locus)을 통해 얻은 PI 제어기만의 제어 성능(점선)과 제안된 제어 시스템에 의한 결과(실선)를 보여준다. 그림 8 (a)는 시스템 모델 (8)에 대하여 제안된 제어 구조에서 신경망 제어기의 출력값(실선)과 PI 제어기의 출력값(점선)을 보여주며, (b)는 시스템 입력 제어값이다. 표 1은 제안된 제어 구조의 우수성을 정의된 선형 조합으로 구성된 비용 함수의 관점에서 수치적으로 비교되었다. 제안된 제어구조의 다양한 계단 입력에 대한 일반화 응답 특성은 그림 9에서 보여 준다. 모의 실험 결과로부터 신경망 제어기는 주로 언더슛을 포함한 전이상태에서 주로 효과적으로 동작한다는 것과 제안된 알고리즘이 초기의 제어 목적인 작은 언더슛과 오버슛 그리고 빠른 settling 시간을 효과적으로 제공한다는 것을 알 수 있다. 전체적으로 제안된 제어 시스템 구조에서는 정상상태의 오차는 PI 선형 제어기에 의해 감소되며, 전이 구간내 제어 성능은 신경망 제어기에 의해 향상된다는 것을 알 수 있다.





$$(c) G(s) = \frac{0.005(0.1877s^2 - 0.0292s + 0.001)}{s^4 + 0.6121s^3 + 0.0581s^2 + 0.001s}$$

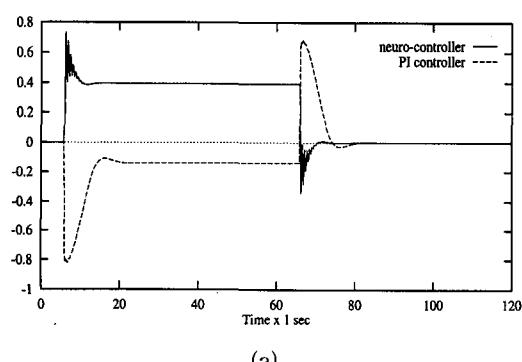
그림 7. 계단 입력에 대한 제안된 제어 시스템(실선)과 기존의 선형 제어기만(점선)의 제어 성능 비교

Fig. 7. Performance comparison between the proposed controller(solid) and PI controller (dotted).

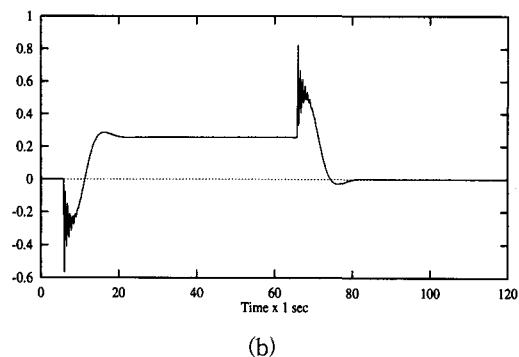
표 1. 시스템 모델 (7)과 (8)에 대하여 각각 (α, β)가 (0.1, 60)와 (1, 60)일 때, 계단 입력에 대한 비용 함수 $\alpha E_1 + \beta E_2$ 의 값 비교

Table 1. Comparison of performance in terms of values of the cost function $\alpha E_1 + \beta E_2$ for a step input with $\alpha = 0.1$, $\beta = 60$ for the first system(8) and $\alpha = 1$, $\beta = 60$ for the second system(9).

	System I(7)	System II(8)
PI controller	13.10	89.52
Proposed controller	10.57	23.50



(a)



(b)

그림 8. $G(s) = \frac{s-1}{(s+2)(s-0.128)}$ 에 대하여 (a) 제안된 제어 시스템내의 PI 제어기(점선)와 신경망 제어기(실선)의 출력과 (b) 전체 제어기의 출력

Fig. 8. Controller output of (a) the PI controller (dotted line), and the neuro-controller (solid line). (b) the proposed controller with $G(s) = \frac{s-1}{(s+2)(s-0.128)}$

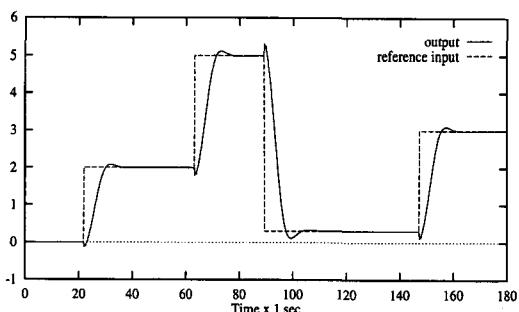


그림 9. 시스템 모델 $G(s) = \frac{s-1}{(s+2)(s-0.128)}$ 에 대하여 제안된 제어 시스템의 일반화 성능

Fig. 9. Generalization behavior of the proposed controller with model $G(s) = \frac{s-1}{(s+2)(s-0.128)}$.

그림 10과 11은 MOEP 기법에 의해 얻어진 파렛토 최적해 집합과 선형 조합의 비용 함수에 대하여 OEP 기법으로 구한 최적해를 목적 함수 공간에서 서로 비교하였다. 그림 12는 모델식 (9)에 대하여 MOEP로 새롭게 구한 신경망 제어기의 의한 제어 입력의 형태를 보여준다. 파렛토 해집합 중의 한 최적해가 그림 8의 OEP에 의해 얻어진 것보다 낮은 채팅링 특성을 가지면서도 작은 언더슛과 오차 크기를 유지한다. 비록 OEP 기법(5,000 epoch)이 다양한 최적해를 동시에 구하는 MOEP 기법(40,000 epoch)에 비해 빠른 수렴 속도를 보이지만, 다중 목적 최적화 관점에서

볼 때 진정한 최적해를 제공하지 못하였다. 주어진 가중치에 의해 구성된 비용함수를 최적화하는 OEP 방법은 가중치된 해공간의 복잡도와 EP 자체가 갖는 초기 포화(premature convergence)에 의해 준 최적해를 제공하는 경우가 종종 발생하기 때문이다. 또한, 실질적으로 설계자가 요구하는 제어 성능을 만족하기 위한 기중치 결정은 상당한 시행 속도를 요구하며, 요구된 제어 성능이 목적 함수 공간내에서 실제 성립하는지도 알 수가 없다. MOEP는 이러한 문제점을 쉽게 해결해 주며, 설계자에게 다양한 최적해와 목적 함수간의 상호 관계를 손쉽게 알게 하여 설계자의 기호에 따라 최종 결정에 가장 적합한 최적해를 쉽게 선택하게 한다.

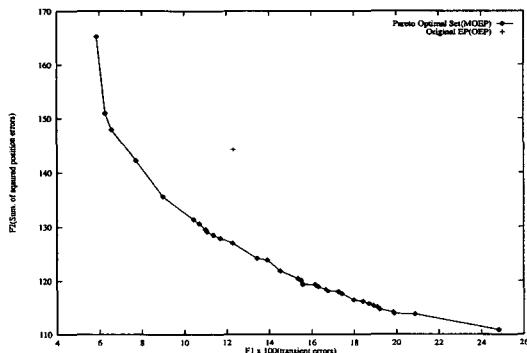


그림 10. 모델식 $\frac{s-1}{s^2 + 7s + 12}$ 에 대하여 MOEP의 페레토 집합과 OEP의 최적해 비교

Fig. 10. Pareto optimal frontier found by MOEP and a solution of OEP for $\frac{s-1}{s^2 + 7s + 12}$.

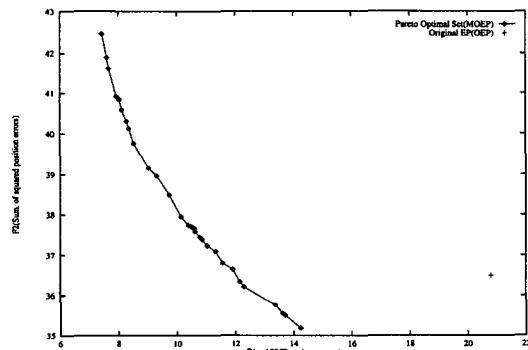


그림 11. 모델식 $\frac{s-1}{s^2 + 1.7s + 0.256}$ 에 대하여 MOEP의 페레토 집합과 OEP의 최적해

Fig. 11. Pareto optimal frontier found by MOEP and a solution of OEP for $\frac{s-1}{s^2 + 1.7s + 0.256}$.

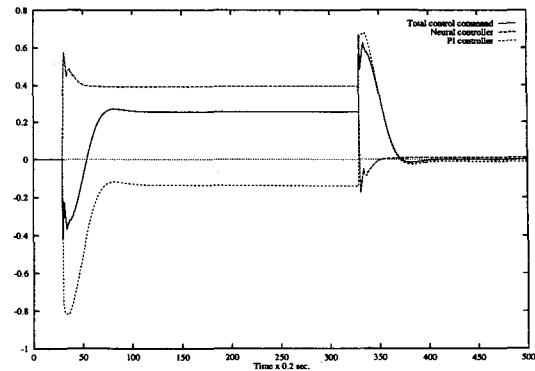


그림 12. 모델식 $\frac{s-1}{s^2 + 1.7s + 0.256}$ 에서 MOEP의 한 최적해를 인가할 때 얻어진 제어 입력 형태

Fig. 12. Torque profiles of the proposed controller when an optimal solution of Pareto set is applied to $\frac{s-1}{s^2 + 1.7s + 0.256}$.

V. 결 론

본 논문에서는 비최소 위상 시스템에 대하여 신경회로망과 기존의 PI 선형 제어기를 이용한 새로운 제어 시스템을 제안하였다. 제안된 알고리즘은 비선형 제어기를 선형 제어기가 주어진 제어 성능을 효과적으로 수행하지 못하는 부분 동자 영역에서 동작시킴으로써 좋은 제어 성능을 얻을 수 있다는 가정에 바탕을 두었다. 전체적인 제어의 목적은 전이영역에서 언더슛 현상을 억제하면서도 빠른 응답시간과 응답 오차를 줄이는 것이었다. 본 논문에서는 이러한 목적을 효과적으로 달성하기 위하여 다중 목적 함수를 제안하고, 이를 바탕으로 제안된 제어 구조기에 대하여 off-line 학습으로 전역적 계산 능력을 지닌 EP를 이용한 학습 방법을 제시하였다. 또한, 다중 목적 함수의 최적화시 나타나는 문제점을 해결하기 위하여 페레토를 이용한 다중 목적 최적화 개념을 도입하였다. 시뮬레이션 결과는 제안된 제어 알고리즘을 통하여 시스템에 대한 전문가적인 지식이나 복잡한 이론 계산 없이도 작은 언더슛과 오버슛 그리고 빠른 상승 시간과 settling 시간과 같은 제어 성능 향상을 얻을 수 있다는 것을 보여준다. 또한, 다중 최적화 개념을 통해 설계자의 요구에 부응하는 다양한 최적해를 제공하였다. 현재 선형 근사화시 비최소 위상 특성을 가지는 비선형 시스템에 대하여 제안된 알고리즘을 이용한 안정된 제어와 강건 제어가 연구 중에 있다.

감사의 글

* 본 연구는 기초 전력 공학 공동 연구소의 지원(관리 번호 95-21)으로 수행되었습니다.

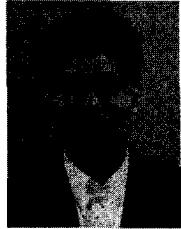
참 고 문 헌

- [1] H. Elliott, "Direct adaptive pole placement with application to nonminimum phase systems," *IEEE Trans. on Automat. Contr.*, vol. AC-27, no. 3, pp. 720-721, 1982.
- [2] L. Praly, "Towards a globally stable direct adaptive control scheme for not necessarily minimum phase systems," *IEEE Trans. on Automat. Contr.*, vol. AC-29, no. 10, pp. 946-949, 1984.
- [3] B. Widrow, and S.D. Stearns, *Adaptive Signal Processing*, Englewood Cliffs, NJ: Prentice-Hall, 1992.
- [4] Hornik, M. Stinchcombe, and H. White, Multilayer feedforward networks are universal approximators, *Neural Networks*, vol. 2, pp. 359-366, 1989.
- [5] Cybenko, Approximation by superpositions of a sigmoidal function, *Mathematics of Controls, Signals and Systems*, vol. 2, no. 4, pp. 303-314, 1989.
- [6] A. Barron, "Neural net approximation", Procs. of 7th Yale Workshop on Adaptive and Learning Systems, pp. 69-72, 1992.
- [7] K. S. 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.
- [8] W.T. Miller, R.S. Sutton, and P.J. Werbos, *Neural Networks for Control*, Cambridge, MA : MIT Press, 1990.
- [9] J. Hunt, D. Sbarbaro, R. Zbikowski, and P.J. Gawthrop, Neural networks for control systems - A survey, *Automatica*, vol. 28, no. 6, pp. 1083-1112, 1992.
- [10] D.H. Loughlin and S.R. Ranjithan, The neighborhood constraint method : A genetic algorithm-based multiobjective optimization technique, *International Conference on Genetic Algorithm*, pp. 665-673, 1997.
- [11] C.M. Fonseca and P.J. Fleming, An overview of evolutionary algorithms in multiobjective optimization, *Evolutionary Computation*, vol. 3, pp. 1-16, 1995.
- [12] Y.M. Park, S.H. Hyun, and J.H. Lee, An inverse dynamics controller for power system stabilizing using artificial neural networks, *International Conference on Power System Technics.*, vol. 2, pp. 1326-1329, Beijing, China, 1994.
- [13] S. Park, L.J. Park, and C.H. Park, A novel neuro-controller for nonminimum phase systems, *International Conference on Soft Computing(Iizuka)*, pp. 127-128, Iizuka, 1994.
- [14] S. Park, L.J. Park, and C.H. Park, A neuro-genetic controller for nonminimum phase system, *IEEE Trans. Neural Networks*, vol. 6, pp. 1297-1300, 1995.
- [15] D. Goldberg, *Genetic Algorithm in Search, Optimization, and Machine Learning*, Reading, MA: Addison Wesley, 1989.
- [16] D.B. Fogel, "An introduction to simulated evolutionary optimization," *IEEE Trans. Neural Networks*, vol. 5, pp. 3-14, 1994.
- [17] S. Park, J. Yu, and C.H. Park, Path planning using evolutionary programming for a robot manipulator, *Asia-Pacific Conference on Simulated Evolution and Learning(SEAL)*, pp. -, 1996.
- [18] J.D. Schaffer, D. Whitley, and L.J. Eshelman, Combination of genetic algorithms and neural networks: A survey of the state of art, *Proc.of COGANN-92*, pp. 1-37, 1992.
- [19] 원전 증기 발생기 수위 제어를 위한 퍼지 제어기 및 콘솔 소프트웨어 개발, 기초전력공학공동연구소 연구 보고서, 1993
- [20] S. Park, and C.H. Park, Network Complexity and Generalization to appear in *Procs. of ICNN*, Houston, 1997.

저자 소개

朴相奉(正會員)

1969년 1월 29일생. 1991년 2월 서울대학교 전기공학과 (학사). 1994년 8월 한국 과학기술원 전기 및 전자공학과(석사). 1994년 9월 한국 과학기술원 대학원 ~ 현재 전기 및 전자공학과(박사과정). 주관심분야는 Neural-based control, Nonlinear control, Evolutionary Algorithms, Multiobjective optimization



朴哲薰(正會員)

1961년 4월 14일생. 1984년 2월 서울대학교 전자공학과 졸업. 1990년 미국 California Institute of Technology 공학 석사 및 공학 박사 취득. 1997년 현재 한국 과학기술원 전기 및 전자공학과 부교수. 관심 분야는 패턴 인식, 퍼지 논리, 신경망 제어, 유전 알고리즘 등임