
유전알고리즘과 신경망을 결합한 PID 적응제어 시스템의 설계

조용갑*, 박재형**, 박윤명**, 서현재**, 최부귀***

Design of PID adaptive control system combining Genetic Algorithms and Neural Networks

Yong-Gab Cho*, Jae-Hyung Park**, Yoon-Mynug Park**, Hyun-Jae Seo**, Boo-Kwi Choi***

요 약

본 논문은 유전 알고리즘과 신경망을 이용하여 PID 제어기의 최적의 파라미터를 추출하는데 있다. 유전 알고리즘에 의한 제어는 off-line 동작으로서 외란이나 부하변동에 약한 면을 가지고 있다. 따라서 신경망을 제어기에 추가하여 on-line 화 하여 다음과 같이 개선하고자 한다. 첫째, 신경망의 순방향 동작에서 유전 알고리즘에 의해 적합한 PID 파라미터를 찾아 세대수의 증가에 따른 최적의 출력조건을 설정하고 둘째 신경망의 학습능력을 이용하여 역전파 학습에 의한 파라미터를 수정하여 외란이나 다양한 부하 변동에 대한 적응력을 시뮬레이션으로 나타낸다.

Abstract

This paper is about how to decide the best parameter of PID controller, using Genetic Algorithms and Neural Networks. Control by Genetic Algorithms, which is off-line pass, has weakness for disturbance. So we want to improve like followings by adding Neural Network to controller and putting it on line. First we find PID parameter by Genetic Algorithms in forward pass of Neural Network and set the best output condition according to the increasing number of generation. Second, we explain the adaptability for disturbance with simulation by correcting parameter by backpropagation learning rule by using the learning ability of Neural Network.

* 문경대학 정보통신과 교수

** 동아대학교 전자공학과

*** 동아대학교 전자공학과 교수

접수일자 : 1999년 1월 25일

I. 서 론

본 논문에서는 1970년대에 John Holland에 의해 개발된 이래 많은 연구와 관심을 가지고 큰 성과를 이루고 있는 유전 알고리즘 (Genetic Algorithms)과 현재 여러분야에서 응용되고 있는 인공신경망 (Artificial Neural Network)을 PID 제어기 설계의 한 방법으로 사용한다.^{[1][2][3]}

유전 알고리즘은 많은 최적화 문제에서 전역적인 최적의 해를 발견할 높은 가능성을 가진다는 장점과 목적함수에 대한 수학적 제약이 거의 없다는 장점을 가지고 있으며, 신경망은 자기 스스로를 조직화하는 학습의 형태를 가짐으로서 주위환경 변화에 따른 다양한 학습을 통해 적응이 가능하다는 큰 이점을 가지고 있다.

따라서 스스로 시스템에 맞는 파라미터를 찾아내는 자기동조 제어방법을 단순 유전 알고리즘 (Simple GA)에 몇가지 규칙을 더하고, 새로운 목적 함수를 구성한 유전 알고리즘을 사용함으로써 PID 제어기를 기존의 제어기 설계 방법보다 더 간단하고 쉽게 구할 수 있도록 하였다. 또한 유전알고리즘과 PID제어기는 외란이나 다양한 부하 변동과 같은 변화에 대한 적응력이 거의 없으므로 신경망모델의 역전파(Backpropagation) 학습규칙을 통해 이러한 문제점을 해결하고자 한다.

II. 유전알고리즘과 신경망의 결합

2.1 유전 알고리즘(GA)

1) 재생산(Reproduction)

이 과정은 해집단이 진화를 위해 자손집단을 생성하는 과정으로 이는 가장 우수한 개체쪽으로 향하게 하지만 새로운 개체를 생성하지는 못한다. 2) 부호화(Encoding)

10진수의 파라미터를 일정한 길이의 2진 스트링으로 부호화하여 사용한다. 이 때 파라미터의 범위 및 정밀도는 사용자가 지정할 수 있다.

3) 교배(Crossover)

교배점은 확률적으로 지정하도록 하고, 재생산과 함께 사용하여 우수한 개체들 간의 정보를 교환하는 효과적인 방법이 된다.

4) 적합도(Fitness)

유전 알고리즘에서는 우수한 개체를 선별하는데 목적함수에 의해 계산된 적합도 값을 사용한다.

5) 돌연변이

재생산과 교배과정은 집단의 개체들이 현재 가지고 있는 정보들을 이용하여 결합하고 탐색하지만 돌연변이 과정은 현재 집단이 가지고 있지 않는 정보를 만들 수 있다.

2.2 신경망(NN)

다층 퍼셉트론(MLP)은 신경망 모델중 가장 범용적으로 사용되고 있으며 지금도 다층 퍼셉트론에 대한 보다 효율적인 학습방법의 연구가 계속되고 있다. 다층 퍼셉트론은 Fig.1과 같이 단층의 퍼셉트론이 두 개 이상의 층으로 구성된 구조이다. Fig.1과 같은 다층 퍼셉트론은 역전파 학습 방법(Back-propagation learning rule)은 교사(Supervised)신호에 의한 학습 방법으로 설정치와 실제출력치의 차이에 의한 오차항을 역전파시켜서 신경망의 가중치를 수정하는 방법이다. 학습은 온라인 학습으로서 실제출력을 얻는 순방향 부분과 실제출력과 교사신호의 오차를 구하여 역전파시켜 델타규칙(Delta rule)으로 가중치를 수정하는 역전파 부분으로 나누어져서 이루어진다.




그림 1. 다층퍼셉트론의 구성도
Fig. 1. Schematic of MLP

역전과 학습부분은 먼저 평가함수를 최소오차 자승법으로 구한다. 그리고 델타규칙으로 출력층과 중간층 뉴런에 연결된 가중치를 수정하고, 다음으로 일반화된 델타규칙을 이용하여 중간층 뉴런과 입력들에 연결된 가중치를 수정한다. 식 (1)은 최소오차 자승법을 나타낸다.

$$E = \frac{1}{2} \sum_{k=1}^n (R_k - y_k)^2 \dots\dots\dots (1)$$

여기서, R_k 는 교사신호이고, y_k 는 출력층 뉴런의 출력값이다.

출력층 뉴런과 중간층 뉴런사이의 가중치 수정계산을 식(2)와 식(3)에 나타내었다. 가중치의 수정은 음의 gradient 하강법에 의한다.

$$W_{kj}(n) = W_{kj}(n-1) + \Delta W_{kj}(n) \dots\dots\dots (2)$$

$$\begin{aligned} \Delta W_{kj}(n) &= -\eta \frac{\partial E}{\partial W_{kj}} + \alpha \Delta W_{kj}(n-1) \\ &= \eta \delta_k h_j + \alpha \Delta W_{kj}(n-1) \\ &= \eta (R_k - y_k) g'(NET_k) h_j + \alpha \Delta W_{kj}(n-1) \end{aligned} \dots\dots\dots (3)$$

여기서, η 는 학습율,
 α 는 모멘트 계수,
 δ_k 는 출력층의 오차항이고,

$$NET_k = \sum_{n=1}^N W_{kn} \cdot h_n \text{이다.}$$

그리고, 중간층 뉴런과 입력들 사이의 가중치 수정은 식(4), 식(5)와 같이 계산되어진다.

$$W_{ji}(n) = W_{ji}(n-1) + \Delta W_{ji}(n) \dots\dots\dots (4)$$

$$\begin{aligned} \Delta W_{ji}(n) &= -\eta \frac{\partial E}{\partial W_{ji}} + \alpha \Delta W_{ji}(n-1) \\ &= \eta \delta_j x_i + \alpha \Delta W_{ji}(n-1) \\ &= \eta f'(NET_j) \sum_{k=1}^K (\delta_k W_{kj}) x_i + \alpha \Delta W_{ji}(n-1) \end{aligned} \dots\dots\dots (5)$$

여기서, η 는 학습율,
 α 는 모멘트 계수,
 δ_j 는 출력층의 오차항이고,

$$NET_j = \sum_{n=1}^N W_{jn} \cdot x_n \text{이다.}$$

신경망의 기본 구조와 델타규칙에 의한 학습방법을 알아보았다. 이렇게 구성된 신경망이 어떻게 PID 제어기와 연결되어 적응하는가는 다음에 다루기로 한다.

2.3. 유전알고리즘과 신경망의 결합

앞절에서 설명되었듯이 역전과 알고리즘을 이용하여 신경망 제어를 설계할 수 있다. 이는 오차에 의해 신경망 제어가 스스로 학습하여 플랜트에 적합한 제어기로 이루어질 수 있다. 하지만 이 경우 신경망이 학습하기까지 많은 시간이 필요하게 되고 지역최소치에 빠질 가능성도 있다. 이를 보완하기 위해 유전 알고리즘을 사용하여 신경망의 가중치들의 적합한 값을 찾아내도록 하였다. 즉 이렇게 이루어진 신경망은 이미 학습이 이루어진 것과 같다.

우선 유전알고리즘의 유전자로서 신경망의 입력층과 출력층의 모든 가중치들을 부호화하여 사용하였다. 부호화 방법으로는 보다 정밀한 값을 추정하기 위하여 부동소수점의 사용을 채택하였다. 이를 Fig. 2에 나타내었다. 각 가중치들에 부호비트, 지수부의 부호비트, 지수부 3비트, 실수부 5비트로 총 10비트 유전자 구조를 형성하였다




그림 2. 규칙화된 NN의 염색체
 Fig. 2. Chromosome of refined NN

또 유전알고리즘에서 개체수와 교배확률, 돌연변이 확률은 다음과 같이 설정하였다.

표 1. 유전알고리즘의 파라미터

Table 1. Parameters of genetic algorithm

파라미터	설정치
개체 size	60
교배확률	60%
돌연변이 확률	0.33%

이렇게 구성된 유전자의 적합도를 구하기 위하여 일반적으로 오차제곱의 합을 목적함수로 많이 사용하나 이는 지역적 극값을 가질 수 있으므로 본 논문에서는 단위 계단 응답에 대한 최고 진동폭, overshoot, 상승시간(rising time) 및 정착 시간 등을 성능평가 기준으로 한다.

$$Fitness(K_P, K_I, K_D) = \left(\frac{1}{1 + \sum_i W_i e_i} \right) \dots\dots (6)$$

식(6)은 이러한 적합도를 구하기 위한 목적함수를 나타내었다. 여기서 e_i 는 위에서 언급한 overshoot, 상승시간 등과 같은 성능지수이고 이들은 성능평가에 미치는 영향을 다르게 가져야 함으로서 W_i 와 같이 이에 대한 가중치를 다르게 부가함으로써 정규화하였다.




그림 3. PID 제어를 위한 신경망모델의 구조
Fig. 3. The structure of the NN model for PID controller

Ⅲ. 신경망을 이용한 PID 제어기 구현

본 논문에서 사용되는 PID 제어기가 어떻게 신경망과 결합되었는지를 Fig. 3에 나타내었다.

이는 신경망을 이용한 자기동조 PID 제어기의 구조를 나타내고 있으며 PID 파라미터 수정을 위해서 신경망은 역전파 학습을 하도록 하였다.

Ⅳ. 적응제어 시스템의 설계

지금까지 본 논문에서 구성된 제어기에 대해서 살펴보면 크게 2가지 동작으로 나누어 볼 수 있다. 우선 임의의 플랜트에 적합한 파라미터를 찾기 위한 off-line 동작과 다음으로 플랜트 변동이나 외란




그림 4. off-line system에서의 GA-FNN-PID 제어기의 학습구성도

Fig. 4. The learning scheme of the GA-FNN-PID controller in off-line system.

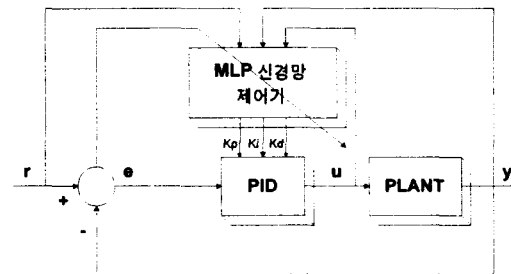


그림 5. on-line system에서 GA-BPNN-PID 제어기의 학습구성도

Fig. 5. The learning scheme of the GA-BPNN-PID controller in on-line system.

에 대한 적응제어를 위한 on-line 동작이다. 첫째로 off-line 동작에서는 유전 알고리즘에 의해 적합한 파라미터를 찾도록 하였으며, 이를 GA-FNN-PID로 나타냈으며 GA-FNN-PID 제어기는 유전알고리즘과 신경망의 순방향 동작과 PID제어기의 결합을 의미한다. 이를 Fig. 4에 블록도로 나타내었다.

둘째로 on-line 동작에서 적응제어를 위해 신경망의 학습능력을 이용하여 역전파학습에 의한 파라미터 수정을 이루도록 하였다. 이것을 여기에서는 GA-BPNN-PID 제어기로 나타내었으며 이 제어기는

유전알고리즘과 신경망의 역전파학습 동작과 PID 제어기의 결합을 나타내며 블록도는 Fig. 5에 나타내었다.

V. 시뮬레이션 및 고찰

앞에서 제안된 제어기와 일차지연함수인 $y(t) = 0.9y(t-1) + 0.23u(t-1)$ 인 PLANT를 설정하여 시뮬레이션한 결과를 다음에 나타내었다.

제안된 제어기의 출력 응답 특성을 보기 위해 설




그림 6. 최대 적합도와 평균 적합도의 진화과정
Fig. 6. Evolution of average fitness and of maximum fitness

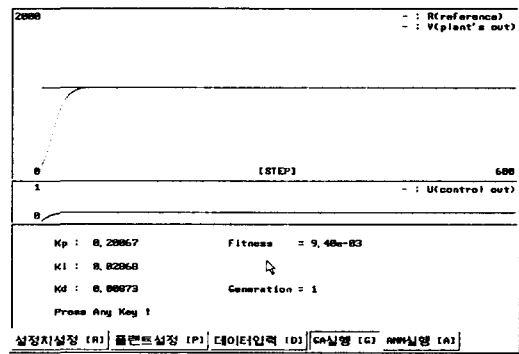


그림 7. 초기 1세대의 응답 결과
Fig. 7. Output response at evolution of initialize generation




그림 8. 9세대의 진화 응답 결과
Fig. 8. Output response at evolution of 9 generation




그림 9. 38세대의 진화 응답 결과
Fig. 9. Output response at evolution of 38 generation




그림 10. 49 세대의 진화 응답 결과
Fig. 10. Output response at evolution of 49 generation




그림 11. 외란시 GA-FNN-PID 제어기의 응답 결과
Fig. 6. Output response of GA-FNN-PID controller at disturbance




그림 12. 외란시 GA-BPNN-PID 제어기의 응답 결과
Fig. 12. Output response GA-BPNN-PID controller at disturbance

정치는 1000[rpm]의 구형 응답으로 하고, 샘플링 주기 T는 1.635[ms]로 하였다. 우선 Fig. 6에서 평균 적합도와 최대 적합도의 진화과정을 나타내었다. 그리고 Fig. 7에서 Fig. 10까지는 세대별 시뮬레이션 결과를 나타내었다. 앞서 나타난 결과로서 유전 알고리즘에 의한 진화로서 PID 제어기의 파라미터를 조정하기 위한 신경망을 안정화 시켰음을 알 수 있다.

이에 $t=300[nT] \sim 320[nT]$ 일 때 설정치의 10%를 외란으로 인가하였을 경우 GA-FNN-PID 제어기와 GA-BPNN-PID 제어기의 출력응답과형을 Fig. 11와 Fig. 12을 비교하여 나타내었다.

이로서 GA-FNN-PID 제어기를 사용한 시스템에

서는 약 20%의 최대 편차가 발생하였으나, 본 논문에서 제안된 GA-BPNN-PID 제어기를 사용한 제어기를 사용하였을 때는 11%의 최대 편차가 발생하였다.

VI. 결 론

본 논문에서는 제안된 제어기가 외란에 강인함을 확인하였다. 이로서 목적하였던 유전알고리즘에 의한 최적화와 신경회로망의 학습능력을 가진 제어기를 구성하여 그 성능의 우수함을 시뮬레이션을 통해 알아보았다.

향후 연구과제로는 유전 알고리즘의 세대 변화에 따른 최적화 정도가 세대수가 증가함에 따라 완전히 비례하도록 설계하고 이를 바탕으로 실제 PLANT에 적용하여 검증해 보는 것이다.

참고문헌

- [1] L. Davis, Handbook of Genetic Algorithms., Van Nostrand Reinhold, 1991.
- [2] J. E. Lansberry, L. Wozniak, and D. E. Goldberg, "Optimal hydrogenerator governor tuning with a genetic algorithm.", IEE Trans. Energy Conversion, Vol. 7, No. 4, pp. 623-628, 1992.
- [3] Vittorio Maniezzo, "Genetic Evolution of the Network", IEEE Transactions on Neural

- Networks, Vol.5, No.1, pp.39-53, January
Topology and Weight Distribution of Neural
1994.
- [4] K. J. Aström and T. Hägglund, Automatic
Tuning of PID Controllers., Instrument Society
of America, 1988.
- [5] K. Krishnakumar, David E. Goldberg, "Control
System Optimization Using Genetic Algorithms",
Journal of Guidance. Control. and Dynamics
Vol. 15. NO.3. May~June 1992.
- [6] J. J. Grefenstette, "Optimization of control
parameters for genetic algorithms.", IEEE
Trans. Syst. Man Cybern., vol. SMC-16, pp.
122-128, Jan./Feb. 1986.
- [7] 임 영도, 이 상부 "퍼지 신경망 유전진화" 도
서 출판 영과 일, pp.107-216, 1992
- [8] 정 연우 "유전알고리즘과 PID 제어기를 이용
한 DC Moter 의 속도 제어에 관한 연구" 동아
대학교 석사 학위 논문, 1996
- 조 옹 갑(Yong-Gab Cho)
1988년 부경대학교 전자공학과 졸업(학사)
1992년 동아대학교 대학원 전자공학과 졸업(석사)
1993년~현재 동아대학교 대학원 전자공학과 박사과정
1996년~현재 문경대학 정보통신과 조교수
* 관심분야 : 적응제어, 비선형제어, 다변수강인 및
예측제어
- 박 재 형(Jae-Hyung Park)
1987년 동아대학교 전자공학과 졸업(학사)
1990년 동아대학교 대학원 전자공학과 졸업(석사)
1996년~현재 동아대학교 대학원 전자공학과 박사
과정
* 관심분야 : 퍼지 및 신경망 제어, 로봇틱스
- 박 윤 명(Yoon-Mynug Park)
1992년 동아대학교 전자공학과 졸업(학사)
1992년~1997년 LG전자 조리기기설계실 주임연구원
1999년 동아대학교 대학원 전자공학과 졸업(석사)
1999년~현재 동아대학교 대학원 전자공학과 박사
과정
* 관심분야 : 지능형 제어, 비선형 제어, 이동로보
트 제어
- 서 현 재(Hyun-Jae Seo)
1998년 동아대학교 전자공학과 졸업(학사)
1998년~현재 동아대학교 대학원 전자공학과 석사
과정
1999년~현재 부산자동차고등학교 교사
* 관심분야 : 퍼지, 신경망 및 유전알고리즘 제어
- 최 부 귀(Boo-Kwi Choi)
1960년 연세대학교 전기공학과 졸업(학사)
1980년 경희대학교 대학원 전자공학과 졸업(석사)
1970년~현재 동아대학교 전자공학과 교수
* 관심분야 : 지능형제어, 최적제어