

미소-유전 알고리듬을 이용한 오류 역전파 알고리듬의 학습 속도 개선 방법

° 강경운*, 최영길*, 심귀보**, 전홍태*

* 중앙대학교 전자공학과, ** 중앙대학교 제어계측공학과

Speeding-Up for Error Back-Propagation Algorithm Using Micro-Genetic Algorithms

° Kyeng-Woon Kang*, Young-Gil Choi*, Kwee-Bo Sim**, and Hong-Tae Jeon*

* Dept. of Electronics Engineering, Chung-Ang University

** Dept. of Control & Instrumentation Engineering, Chung-Ang University

ABSTRACT

The error back-propagation(BP) algorithm is widely used for finding optimum weights of multi-layer neural networks. However, the critical drawback of the BP algorithm is its slow convergence of error. The major reason for this slow convergence is the premature saturation which is a phenomenon that the error of a neural network stays almost constant for some period time during learning. An inappropriate selections of initial weights cause each neuron to be trapped in the premature saturation state, which brings in slow convergence speed of the multi-layer neural network.

In this paper, to overcome the above problem, Micro-Genetic algorithms(μ -GAs) which can allow to find the near-optimal values, are used to select the proper weights and slopes of activation function of neurons. The effectiveness of the proposed algorithms will be demonstrated by some computer simulations of two d.o.f planar robot manipulator.

1. 서 론

지금까지 발표된 많은 신경회로망 모델이 있지만

제어문제에 적용할 수 있는 적합한 모델은 다층 퍼셉트론(multilayer-perceptron)이다. 이러한 다층 신경회로망에서 원하는 기능을 수행하여 적절한 가중치(weight)를 구하는 방법으로 오류 역전파(error back-propagation)학습이 많이 사용되고 있다. 역전파 학습 알고리듬은 반복적인 기울기 감소 방법(gradient descent method)으로 신경회로망의 실제 출력값(actual output)과 우리가 원하는 출력값(desired output) 사이의 전체 오차를 최소화하도록 구성되어 있으며, 미분 가능한 비선형 함수인 시그모이드 함수(sigmoid function)를 사용한다.

다층 신경회로망의 학습에 오류 역전파 알고리듬이 많이 사용되고 있으나, 단점으로 가중치들이 전체적인 최소치(global minima)가 아닌 지역적인 최소치(local minima)에서 멈출 가능성이 있고, 학습하는데 있어 많은 시간이 걸린다는 점이다.

오류 역전파 알고리듬의 느린 학습 속도는 주로 부적절한 가중치들의 설정으로 인해 발생하는 각 뉴런의 조기 포화상태(premature saturation)에 기인되고 있다. 즉 신경망을 구성하는 어느 한 뉴런이라도 조기 포화상태에 있을 경우에는 가중치의 큰 변화에도 불구하고 실제 오차의 변화량은 미미하게 된다. 따라서 빠른 학습 수렴 속도를 얻기 위해서는 뉴런의 조기 포화상태를 감지하고, 조기 포화상태에서 활성화 함수의 기울기들을 적절히 변화시켜 그

상태를 벗어나게 해야 한다.

본 논문에서는 부적절한 가중치들에 의해 발생하는 초기 포화상태를 미리 감지하고 동시에 포화상태에서 기울기의 적절한 변화를 통하여 다중 신경망의 빠른 수렴성을 얻을 수 있는 한가지 방법을 제안한다. 미소-유전 알고리듬은 생물학적 시스템의 자연선택과 진화를 근간으로 하는 최적화 탐색 알고리듬이다. 이 미소-유전 알고리듬(Micro-Genetic Algorithms)을 이용하여 적절한 뉴런의 활성화 함수의 기울기와 최적 근접 가중치들을 선택하여 오류 역전파 알고리듬의 학습 수렴속도를 개선하는 방법이다.

본 논문의 구성은 다음과 같다. 2 장에서는 미소-유전 알고리듬을 설명하며, 3 장에서는 미소-유전 알고리듬에 의한 신경제어기를 구성하고 그리고 4 장에서는 2 자유도 로보트 매니퓰레이터의 궤적제어에의 적용을, 5 장에서는 컴퓨터 시뮬레이션의 결과를, 6 장에서는 결론을 논한다.

2. 미소-유전 알고리듬(μ -GAs)

유전 알고리듬은 자연계의 적자 생존(Survival of the fittest)의 원리를 이용하여 1970년대 미국의 홀랜드(J.H.Holland)교수에 의해 정립된 최적화(optimizing) 알고리듬이다. 이 알고리듬은 자연계의 선택과 진화(natural selection and evolution)를 근간으로 하고 있으며 미지의 함수 $Y = G(X)$ 의 해를 발견하는 모의진화(simulated evolution)형의 탐색(search) 알고리듬으로 그 과정은 다음과 같이 요약 할 수 있다.

[단계 1] 10진 인자를 2진 1과 0으로 구성된 문자열(string)로 재표현하기 위한 문자열의 길이와 초기 문자열을 선정한다.

[단계 2] 단계1의 문자열을 이용하여 초기 집단(population)을 구성한다.

[단계 3] 집단의 각 문자열을 10진수 인자로 역 표현하여 함수 $Y=G(X)$ 의 적합도(fitness)를 구한다.

[단계 4] 적합도에 따라 해당 문자열들을 선택한다.

[단계 5] 문자열 간의 교배(crossover)와 돌연변이(mutation) 등의 진화과정을 거쳐 새로운 집단을 구성한다.

[단계 6] 단계 3 이하의 과정을 반복한다.

그림1은 단계1에서의 인자의 문자열 표현과 그 역 표현(즉 문자열 표현으로부터 인자로의 표현)을 보여주고 있으며, 단계3에서의 적합도는 함수에 대한 최적 정도를 의미한다. 그리고 단계4에서의 문자열 선택은 적합도의 높은 정도에 의해서 이루어진다. 그림2는 단계 5에서의 문자열들의 교배를 보여 주고 있다. 이때 교배점(crossing site)은 임의 난수(random)로 선택하게 된다.

인자	문자열
0.750000	↔ 01100000

그림 1. 인자와 문자열
Fig 1. Parameter and String

교배점	
X = 0000	0000 → X' = 00001111
Y = 1111	1111 → Y' = 11110000

그림 2. 문자열의 교배
Fig 2. Crossover

돌연변이(mutation)은 이진 문자열에서 임의 점의 비트(bit)를 1에서 0으로, 0에서 1로 전환하는 연산자이다(그림 3).

X = 00000000	→	X' = 00001000
--------------	---	---------------

그림 3. 돌연변이
Fig 3. Mutation

이와 같은 유전 알고리듬의 특성은 다음과 같다.

1. 유전 알고리듬은 해 공간(solution space)에서

단일 해를 사용하는 것이 아니라 해 집단을 (population of solution space)을 이용한다.

2. 유전이론은 최적화 함수 정보(미분가능성, 연속성 등)를 필요치 않는다.

3. 유전 알고리듬은 전역(global) 최적해의 발견을 가능케 한다.

그러나 유전 알고리듬은 일반적으로 대규모의 유전자 집단을 사용하는데 단순 유전 알고리듬(simple genetic algorithms)의 경우에서도 유전자 집단(gene population)의 크기가 30에서 200개 정도이다. 따라서 유전 알고리듬의 계산을 위한 시간 소비량은 크다고 할 수 있다. 계산시간은 작은 집단의 선택으로 줄일 수 있는데 이를 위하여 제안된 방법이 미소-유전 알고리듬이다.

유전 알고리듬에서 집단 수를 작게 하면 수행능력이 감소하는 경향이 있으므로 집단 수를 작게 하 고도 수행능력에는 영향을 미치지 않는 특성을 갖는 미소-유전 알고리듬(μ -GAs)은 다음과 같은 처리과정을 갖는다.

[단계 1] 집단의 크기는 5개로 임의로 선택하거나 4개는 임의로 선택하고 1개는 이전의 탐색으로부터 나온 우수한 것을 선택한다.

[단계 2] 적합도를 평가하여 제일 우수한 것을 구한 다음 이 문자열을 5번째 문자열로 두고 다음 세대로 넘긴다.(엘리트 규칙)

[단계 3] 남은 4개의 문자열을 재생산(reproduction)하기 위해 임의로 배열하여 짹을 지운다.(이때 같은 문자열끼리의 짹짓기를 피한다)

[단계 4] 교배를 시킨다.

[단계 5] 수렴성 검사한 후 수렴하면 단계 1로 간다

[단계 6] [단계 2]로

3. 미소-유전에 의한 신경제어기의 설계

그림 4는 미소-유전 알고리듬을 이용한 뉴런의 기울기 수정기의 구조를 보여준다.

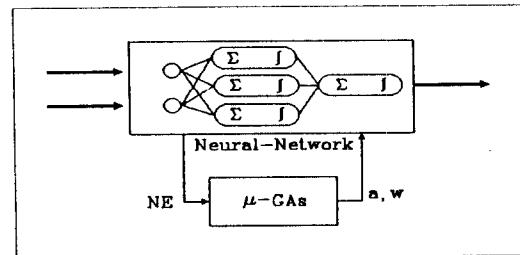


그림 4. μ -GAs에 의한 뉴런의 기울기 수정기
Fig. 4. The slope modifier of neuron by μ -GAs

$$\text{여기서 } NE = \frac{1}{2} (D_k - OUT_k)^2$$

NE(network error)는 신경망 오차이며, D_k 는 k 번째 뉴런의 목표값, OUT_k 는 k 번째 뉴런의 실제 출력값이다. 그리고 a 는 기울기이고 w 는 가중치이다. 또한, 가중치들과 기울기의 값을 구하는 과정은 다음과 같다.

3-1. 문자열과 적합도의 결정

활성화 함수의 기울기와 가중치들은 시스템의 실행에 많은 영향을 미치므로 이 매개변수들을 최적화 대상(objects)으로 선택한다. 미소-유전 알고리듬을 적용하기 위해서 활성화 함수의 기울기와 가중치들을 이진 코드(code)로 나타내야 한다. 이것은 기울기와 가중치들을 비부호 이진(unsigned binary)화으로써 쉽게 할 수 있다. 따라서, 한 문자열은 이진 코드의 두 집합을 결합시킴으로 수식화할 수 있다. 가중치들과 기울기값들은 문자열의 내용을 변화시킴으로 조절한다.

그리고, 적합도의 값은 현재의 가중치들과 기울기값들이 적절한가를 측정하여 결정한다. 적합도는 다음과 같이 정의할 수 있다.

$$\text{적합도} = \frac{K_1}{\text{오차}} + \frac{K_2}{\text{오차의 변화}} + \frac{K_3}{\text{에너지}} \quad (1)$$

여기서 K_1 , K_2 , K_3 는 상수값이고 에너지(energy)는 플랜트(plant)에 대한 입력이다.

식(1)에서 높은 적합도의 문자열에 대응되는 가중치들과 기울기 값들이 제어 목적에 더 적절하고 작은 오차와 에너지를 발생한다.

3-2. 새로운 가중치들과 기울기값들의 생성

문자열과 적합도의 형식을 결정한 후, 가장 높은 적합도 값의 문자열을 구한다. 그 과정은 다음과 같다.

우선, 가중치들과 기울기값들을 포함하고 있는 초기 문자열을 임의로 이진 수(binary number)로 바꾸어 수식화한다. 초기 문자열을 가지고 임의로 생성된 M 개의 문자열들로부터 초기 집단을 구성한다.

그림 5는 초기에 생성된 집단의 예를 보여준다. 집단의 각 행은 가중치들과 기울기 값들의 집합을 나타낸다.

	가중치	기울기
뉴런1	001001000.....100010010100	1010100..1010
뉴런2	001001001.....010010010101	0010010..1101
~	~	~
뉴런M	001001010.....110101000100	1010011..0101

그림 5. 문자열들의 최초 집단
Fig 5. Initial population of strings

최초 집단을 결정한 후, 집단의 각 행들의 적합도는 다음과 같이 얻는다.

[단계1] 문자열을 십진 값(decimal value)으로 바꾸어 가중치들과 기울기를 구한다.

[단계2] 단계1에서 구한 가중치들과 기울기값들을 이용하여 신경체어기를 구성한다.

[단계3] 오차, 오차의 변화량과 에너지를 구하고 적합도 값을 구한다.

모든 문자열들의 적합도 값을 구하면 다음 세대는 초기 집단의 좋은 문자열들(more fitted strings)을 이용하여 구성할 수 있다. 이 과정은 유전자 저장소(gene pool)를 구성하고 더 높은 적합도 값의 문자열에 대한 더 나은 선택 확률을 부여함에 의하여 행하여진다. 유전자 저장소를 이용하여

집단의 다음 세대는 각각의 문자열들 사이의 교배 과정을 통하여 구성된다. 교배(crossover)는 임의의 문자열들을 서로 교환하여 할 수 있다.

각 세대를 거듭함으로서 가장 높은 적합도 값을 가진 문자열은 증가하고 고정된 값으로 지정된다. 가장 높은 적합도 값의 문자열이 신경회로망의 가중치들과 기울기들로 선택되어지며 플랜트에 대한 최소, 오차와 오차의 변화, 에너지를 발생한다.

4. 로보트 매니퓰레이터의 궤적제어

제안한 방법의 성능을 검증하기 위해 2 자유도 로보트 매니퓰레이터의 궤적제어를 위한 미소-유전 알고리듬에 의한 신경체어기를 구성한다. 표 1은 로보트 매니퓰레이터의 기계적 매개변수를 나타내고 그림 6은 2 자유도 로보트 매니퓰레이터를 보여준다. 시뮬레이션에 사용된 다층 신경망의 입력층에 4 개의 뉴런, 2개의 중간층(각 6개, 6개) 및 출력층에 2개의 뉴런을 갖는 4-6-6-2의 구조를 갖는다.

로보트 팔의 궤적은 카르테시안 평면(cartesian x-z plane) 안에서 하나의 원으로 주어진다.

제안한 신경체어기의 효용성을 증명하기 위한 원 궤적(circle trajectory)은 다음과 같이 주어진다.

$$\text{위치 } X = 0.6 + 0.20 \cos(\theta t) \quad (2a)$$

$$\text{위치 } Y = 0.3 + 0.15 \sin(\theta t) \quad (2b)$$

$$\text{위치 } Z = 0.0 \quad (2c)$$

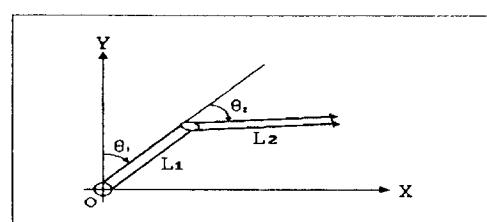


그림 6. 2 자유도 평면 로보트 매니퓰레이터
Fig 6. Two-link planar Manipulator

표 1. 2 자유도 로보트 매니퓰레이터의 재원

	Link 1	Link 2
길이	0.53m	0.47m
질량	2.5Kg	2.0Kg

5. 컴퓨터 시뮬레이션

제안한 방법의 성능을 검증하기 위해 2 자유도 로보트 매니퓰레이터의 궤적제어를 위한 미소-유전 알고리듬에 의한 신경제어기는 그림 7에 보여준다.

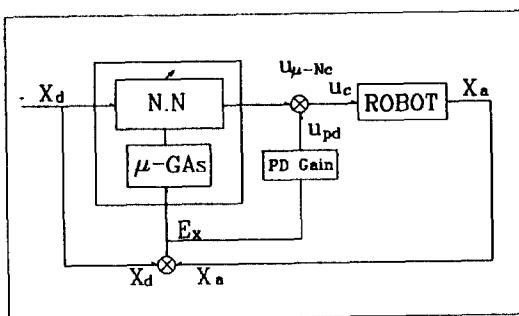


그림 7. μ -GAs에 의한 신경제어기
Fig 7. Neural Controller by μ -GAs

그림 7에서 E_x 는 오차, X_a 는 실제 출력값이고 X_d 는 목표 출력값이다.

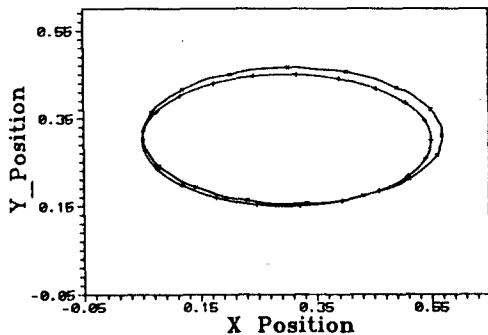


그림 9. 30세대에서의 궤적
Fig 9. Trajectory at 30 generations

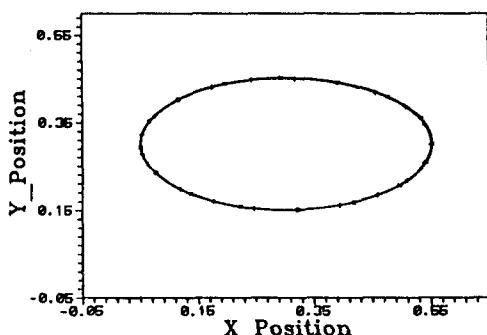


그림 10. 200세대에서의 궤적
Fig 10. Trajectory at 200 generations

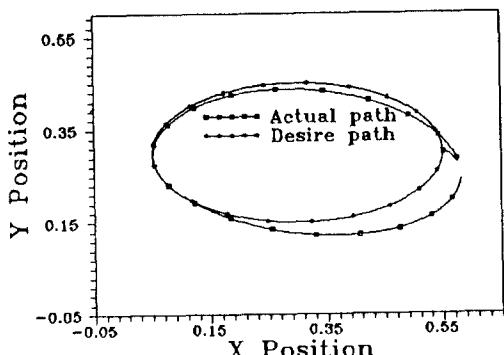


그림 8. 초기 값에서의 궤적
Fig 8. Trajectory at initial values

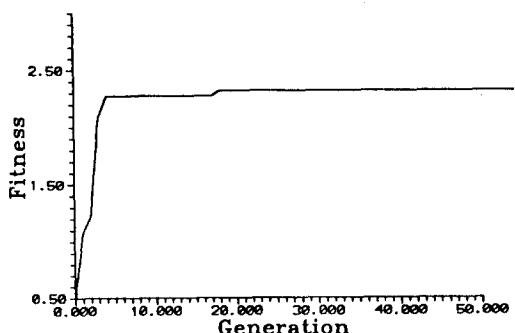


그림 11. 각 세대의 적합도 값
Fig 11. Fitness value at each generation

그림 8은 임의의 초기 가중치들과 기울기들로 구성된 신경제어기를 걸친 시스템의 출력 궤적이다. 그림 9은 약 30세대 후의 출력 궤적을 보여준다. 그림 10은 200세대 후에 얻어진 최적 근접 가중치들과 기울기들에 의하여 얻어진 출력궤적을 보여준다. 그림 11는 적합도 함수값들의 변이(transition)를 보여준다. 결과로부터 알 수 있는 것 같이 제안한 방법은 초기 포화상태를 미리 감지하여 포화상태를 벗어나게 하여 빠른 학습 수렴속도를 갖게 한다.

6. 결 론

본 논문에서 제안한 미소-유전 알고리듬(μ -GAs)을 이용한 신경제어기는 지역적 최소치에 빠지는 것을 극복하고, 뉴런의 초기 포화상태를 회피하여 고도의 시변 비선형 시스템인 로보트 매니퓰레이터의 궤적을 효율적으로 제어함을 시뮬레이션을 통하여 입증하였다.

참고문헌(REFERENCES)

- [1] K.S.Krishnakumar, "Micro genetic algorithms for stationary and nonstationary funtion optimization", Proc. of SPIE Intelligent Control and Adaptive Systems Conf., 1989
- [2] Joey K.Paker, Ahmad R. Khoogar, David E. Goldberg, "Inverse Kinematics of Redundant Robots using Genetic Algorithms", "Proceedings 1989 IEEE International Conference on Robotics And Automation, pp.271-276, 1989
- [3] D.E.Gordberg, Genetic algorithms in Search Optimization and Machine Learning, Addison Wesley, 1989
- [4] Lawrence Davis, Handbook of Genetic algorithm, Van Nostrand Reinhold, 1991
- [5] S.H.Park, H.C.Cho, H.G.Lee, H.T.Jeon, "Application of Genetic algorithm to Hybrid Fuzzy Inference Engine", Proc. of Korea-Japan Joint Conf. of Fuzzy Systems and Engineering, 1992, pp.296-301
- [6] Yuval Davidor, Genetic algorithms and Robotics, World Scientific, 1991
- [7] Y.Lee, S.H.Oh, M.W.Kim, "The effect of initial weights on premature satuation in Back-Propagation Learning", IEEE, 1991, Vol 1,pp.765-770
- [8] A.Rezgui, et al., "The effect of the slope of the Activation Function on the Back-Propagation Algorithm", Proc. IJCNN, 1990, pp.707-710
- [9] K.S. Fu, R.C. Gonzalez, C.S.G. Lee , Robotics control, Sensing, Vision and Intelligence, McGraw-Hill