

論文2003-40CI-1-2

퍼지 시스템을 이용한 ADALINE의 학습 방식

(Learning Method of the ADALINE Using the Fuzzy System)

鄭慶權*, 金周雄*, 鄭盛夫**, 嚴基煥*

(Kyung Kwon Jung, Joo Woong Kim, Sung Boo Chung, and Ki Hwan Eom)

요약

본 논문에서는 ADALINE의 학습을 위한 알고리즘을 제안하였다. 제안한 알고리즘은 직접 퍼지 논리 시스템을 이용하여 ADALINE의 연결강도를 조정하는 방식으로 퍼지 논리 시스템의 입력은 오차와 오차의 변화분이고, 출력은 연결강도 변화분이며, 각각의 연결강도는 스케일링 팩터만 다르게 하여 사용하였다. 제안한 알고리즘의 유용성을 확인하기 위하여 노이즈 제거와 인버티드 펜듈럼 제어에 대하여 시뮬레이션과 실험을 수행하였다. Widrow-Hoff의 델타 규칙과 비교하였을 때 제안한 방식은 학습율을 선택할 필요도 없고 성능이 우수함을 확인하였다.

Abstract

In this paper, we proposed a learning algorithm for the ADALINE network. The proposed algorithm exploits fuzzy system for automatic tuning of the weight parameters of the ADALINE network. The inputs of the fuzzy system are error and change of error, and the output is the weight variation. We used different scaling factor for each weights. In order to verify the effectiveness of the proposed algorithm, we performed the simulation and experimentation for the cases of the noise cancellation and the inverted pendulum control. The results show that the proposed algorithm does not need the learning rate and improves the performance compared to the Widrow-Hoff delta rule for ADALINE.

Keywords : Neural network, ADALINE, Fuzzy system, Widrow-Hoff delta rule, Noise cancellation, Inverted pendulum

1. 서론

신경회로망에 대한 연구는 모델의 구성 및 학습 방식 등 여러 가지 다양한 논제로 이루어지고 있으며, 한편으로는 공학뿐만 아니라 의료, 경제 등 사회 여러

분야에 응용되고 있다^[1-4]. 일반적으로 신경회로망은 뉴런, 연결강도 및 학습규칙 등으로 구성되며, 뉴런에는 신호를 처리하기 위한 여러 가지의 활성화 함수가 있으며, 연결강도를 조절하는 학습규칙으로는 퍼셉트론(perceptron)의 퍼셉트론 학습규칙, ADALINE(ADaptive LInear NEuron)의 Widrow-Hoff 델타 규칙(delta rule) 및 다층 신경회로망의 역전파(back-propagation) 알고리즘이 주로 사용되고 있다^[4, 5, 9]. ADALINE은 Widrow-Hoff가 제안한 선형 모델로서 간

* 正會員, 東國大學校 電子工學科
(Dept. of Electronic Eng., Dongguk University)

** 正會員, 瑞逸大學 電子科
(Dept. of Electronic Eng., Seoil College)

接受日字:2002年2月19日, 수정완료일:2002年12月24日

단하여 노이즈 제거(noise cancellation)나 제어 분야 등에 많이 사용되고 있으나 용량은 제한을 받는다. 이것의 학습 알고리즘인 Widrow-Hoff 델타 규칙은 LMS (Least Mean Square) 알고리즘을 이용한 간단하고 학습이 빠른 편으로 μ -LMS 알고리즘 및 α -LMS 알고리즘의 두 가지 버전이 있다. α -LMS 알고리즘은 μ -LMS 알고리즘의 정규화(normalize)한 버전으로 만약 우리가 네트워크에 적용하기 전에 입력을 정규화하면 μ -LMS 알고리즘을 사용한 경우의 결과와 같은 결과를 얻게 된다. 그러나 델타 규칙은 파라미터인 μ 와 α 의 초기 학습율과 초기 연결강도를 정확하게 선택하여야만 우수한 성능을 가질 수 있으며, 수학적으로 1차 미분을 하여야 한다^[4, 5, 8].

본 논문에서는 ADALINE의 학습 방식으로 퍼지 논리 시스템(FLS: Fuzzy Logic System)을 이용하는 방식을 제안한다. 제안하는 방식은 ADALINE 모델이 입력과 출력층 하나로서 구성이 간단하여 연결강도를 직접 퍼지 논리 시스템으로 조절할 수 있어 Widrow-Hoff 델타 규칙과 같이 1차 미분을 하거나 최적의 학습율을 선택하지 않아도 되는 방식이다. 퍼지 논리 시스템은 하나로 구성하여 여러 개의 연결강도를 스케일링 팩터(scaling factor)만 다르게 하여 조절하며, 퍼지 논리 시스템의 입력으로는 오차와 오차의 변화분을 이용하고, 출력은 연결강도의 변화분을 이용한다. 제안한 방식의 유용성을 확인하기 위하여 노이즈제거(noise cancellation)와 인버티드 펜듈럼(inverted pendulum) 제어 등에 대하여 Widrow-Hoff 델타 규칙과 시뮬레이션 및 실험을 통하여 성능을 비교 검토한다.

II. ADALINE

ADALINE은 단층 신경회로망의 간단한 구조로 여러 개의 유닛(unit)들로부터 입력을 받는 단일 뉴런으로 구성된다. <그림 1>은 일반적인 ADALINE구조로서 여기서는 각각 4개의 입력 벡터와 4개의 연결강도 벡터 그리고 단일 출력 y 로 구성한다^[4, 5, 8].

ADALINE의 출력은 식 (1)과 같이 나타낼 수 있다.

$$y = \sum_{i=1}^4 x(i)w(i) = \mathbf{x}^T \mathbf{w} \quad (1)$$

여기서 $\mathbf{x} = [x_1 \ x_2 \ x_3 \ x_4]^T$ 인 입력이고, $\mathbf{w} = [w_1 \ w_2 \ w_3 \ w_4]^T$ 인 연결강도이다.

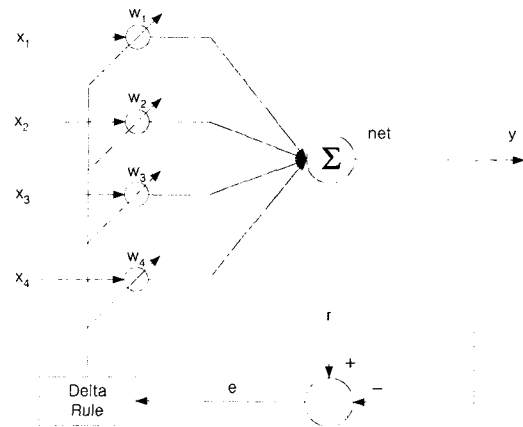


그림 1. ADALINE의 구조
Fig. 1. A structure of ADALINE.

ADALINE은 지도 학습을 수행하며, 목표 출력값을 y 이라 하면 오차를 식 (2)와 같이 정의할 수 있다.

$$e = r - y = r - \mathbf{x}^T \mathbf{w} \quad (2)$$

Widrow는 ADALINE의 학습을 위해 α -LMS 알고리즘과 μ -LMS 알고리즘을 제안하였다^[4, 5, 8].

μ -LMS 알고리즘은 식 (3)과 같이 연결강도 조정량 $\Delta \mathbf{w}$ 를 계산하며

$$\Delta \mathbf{w} = \mu e \mathbf{x} \quad (3)$$

여기서 μ 는 학습율이다. 이 방식은 간단하고, 연결강도 조정량이 오차에 비례하는 관계를 가진다.

α -LMS 알고리즘은 식 (4)와 같이 연결강도 조정량 $\Delta \mathbf{w}$ 를 계산하며

$$\Delta \mathbf{w} = \alpha \frac{e \mathbf{x}}{\|\mathbf{x}\|^2} \quad (4)$$

여기서 α 는 학습율이다. α -LMS 알고리즘은 정규화된 μ -LMS 알고리즘이다.

III. 제안한 학습 방식

본 논문에서는 ADALINE의 학습 방식으로 퍼지 논리 시스템을 이용하여 직접 연결강도를 자동 조정한다. 퍼지 논리 시스템은 한 개를 구성하여 각각의 스케일링 팩터만 다르게 하여 여러 개의 출력을 얻어낼 수 있다. 퍼지 논리 시스템의 입력으로는 오차와 오차의

표 1. 퍼지 제어 규칙
Table 1. Fuzzy control rules.

de \ e	N	Z	P
N	P	P	Z
Z	P	Z	N
P	Z	N	N




그림 2. 오차의 소속 함수
Fig. 2. The membership functions of error.




그림 3. 오차의 변화분의 소속 함수
Fig. 3. The membership functions of change of error.

변화분($de = e(t) - e(t-1)$)을 사용하고, 출력으로는 연결 강도의 변화분을 사용하며 식 (5)와 같다.

$$w(t+1) = w(t) + \text{Fuzzy}(e, de) \quad (5)$$

퍼지 논리 시스템의 퍼지 제어 규칙과 소속함수에 대한 구성은 전문가의 의견으로 하지 않고, 델타 규칙




그림 4. 출력 Δw 의 소속 함수
Fig. 4. The membership functions of Δw .




그림 5. 퍼지 논리 시스템의 입출력 평면
Fig. 5. Input-output surface of fuzzy logic system.

을 이용하여 노이즈 제거와 인버티드 펜들럼 제어에 대한 시뮬레이션 결과에 대한 데이터를 바탕으로 하였다. <표 1>은 시뮬레이션 결과에 대한 데이터를 바탕으로 구성된 9개의 간단한 퍼지 제어 규칙이며, 여기서 N(Negative), Z(Zero), P(Positive)는 퍼지 소속 함수이다. 퍼지 제어 규칙은 시스템의 출력 경향을 분석하여 결정하였다.

e 와 de 의 소속 함수는 <그림 2, 3>과 같으며 출력인 Δw 의 소속함수는 <그림 4>와 같다.

퍼지 제어 규칙을 이용하여 퍼지 추론은 최소-최대 연산을 사용하고, 비퍼지화는 무게 중심법을 사용한다^[6-7]. <그림 5>는 퍼지 논리 시스템의 입출력 관계를 나타낸 것이다.

IV. 시뮬레이션

1. 노이즈 제거

<그림 6>은 ADALINE을 사용한 노이즈 제거 시스템

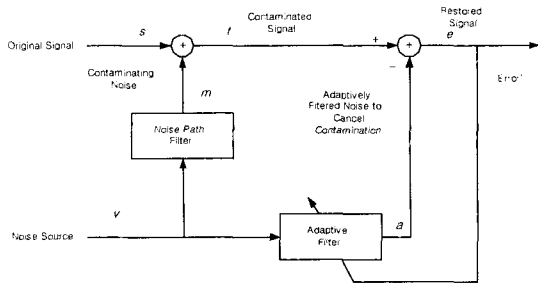


그림 6. 노이즈 제거 시스템의 블록선도
Fig. 6. The block diagram for noise cancellation.




그림 7. 원신호
Fig. 7. Original signal.

표 2. 스케일링 팩터
Table 2. Scaling factor.

연결강도	오차	오차의 변화분
w_1	1.5	1.5
w_2	1.0	1.0
w_3	0.5	0.5
w_4	0.1	0.1




그림 9. 델타 방식의 노이즈 제거
Fig. 9. Noise cancellation by the Delta method.




그림 8. 노이즈를 첨가한 신호
Fig. 8. Noise plus original signal.




그림 10. 제안한 방식의 노이즈 제거
Fig. 10. Noise cancellation by the proposed method.

템의 블록 선도이다^[9].

원신호는 식 (6)과 같다.

$$x = \sin\left(\frac{80}{t+0.1}\right) \quad (6)$$

<그림 7>은 원신호이고, <그림 8>은 노이즈가 첨가된 신호이다.

노이즈 제거를 위한 ADALINE의 구조는 입력을 4개로 하였다. 시뮬레이션 조건으로 델타 규칙에서 초기 연결강도는 [-1,1] 사이에서 랜덤하게 선택하였고, 학습율은 시행착오를 통해 0.1로 선택하였다. 제안한 방식에서 초기 연결강도는 델타 규칙과 동일하게 선택하였고, 연결강도 조정량을 구하기 위해 오차와 오차의 변화분을 퍼지 논리 시스템의 입력으로 사용할 때 각각의 스

케일링 팩터를 <표 2>와 같이 하였다. 단 퍼지 논리 시스템의 출력 스케일링 팩터는 1로 하였다.

델타 규칙을 사용한 경우의 시뮬레이션은 <그림 9>이고, 제안한 퍼지 논리 시스템을 사용한 학습 방식의 시뮬레이션은 <그림 10>이다.

시뮬레이션 결과 제안한 방식이 노이즈 제거에서 초기에는 유사하나 그 이후에는 우수함을 확인할 수 있었다.

2. 인버티드 펜듈럼 제어

ADALINE을 이용한 인버티드 펜듈럼 제어 시스템의 블록 선도는 <그림 11>과 같다. <그림 11>은 간접 제어 방식으로 제어기와 플랜트를 동정하는 부분으로 구성되었다. 앞쪽의 Adaline과 퍼지 논리 시스템은 제어기이고, 플랜트 아래에 있는 퍼지 논리 시스템은 동정기이다. 제어기의 입력은 기준 신호 r_i 와 출력 y_i 의 오차 e_i 를 입력으로 하여 플랜트의 입력인 u 를 출력한다. 동정기의 입력은 출력 y_i 와 y_i 의 과거의 값인 $y_{i-1}, y_{i-2}, y_{i-3}$ 을 입력으로 동정된 입력 신호 \hat{u} 를 출력한다. u 와 \hat{u} 의 차이인 e_u 는 퍼지 논리 시스템의 입력으로 들어가 제어기와 동정기의 연결강도를 조정한다. 또한 그림에서 FLS는 Fuzzy Logic System의 약자이다.

제안한 방식의 유용성을 확인하기 위하여 식 (7)로 표현되는 인버티드 펜듈럼에 대하여 시뮬레이션을 하였다.

$$ml^2\ddot{\theta} + B\dot{\theta} = mgl\cos(\theta) = \tau \tag{7}$$

$\theta, \dot{\theta}, \ddot{\theta}$ 는 각각 인버티드 펜듈럼의 각변위, 각속도, 각가속도를 나타내고, τ 는 입력, m, l, B, g 는 각각 펜듈럼의 질량, 길이, 마찰계수, 중력가속도를 나타내며 값은 각각 $m=0.1[\text{kg}], l=0.1[\text{m}], B=0.4[\text{kg}\cdot\text{m}^2/\text{s}], g=9.8[\text{m}/\text{s}^2]$ 이다.

식 (7)을 상태공간 모델로 표현하면 식 (8)과 같다.

$$\begin{aligned} \dot{x}_1 &= x_2 \\ \dot{x}_2 &= -\frac{g}{l}\cos x_1 - \frac{B}{ml^2}x_2 + \frac{1}{ml^2}\tau \end{aligned} \tag{8}$$

목표 신호를 식 (9)와 같이 주고 시뮬레이션 하였다.

$$r_i = \sin(t) \tag{9}$$

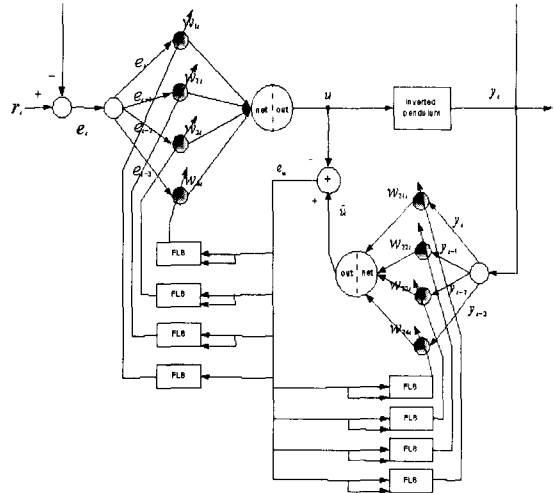


그림 11. 제어 시스템의 블록 선도
Fig. 11. The block diagram of control system.

표 3. 제어기의 스케일링 팩터
Table 3. Scaling factor of controller.

연결강도	오차	오차의 변화분
w_1	0.1	0.1
w_2	0.1	0.1
w_3	8	8
w_4	8	8

표 4. 동정기의 스케일링 팩터
Table 4. Scaling factor of identifier.

연결강도	오차	오차의 변화분
w_1	0.001	0.001
w_2	0.001	0.001
w_3	1	1
w_4	1	1

델타 규칙에서 두개의 ADALINE 모두 동일하게 4개의 입력을 사용하고, 연결강도의 초기값은 $[-0.01, 0.01]$ 사이에서 임의로 설정하였고, 학습율은 0.2로 하였다. 샘플링 시간은 0.01초이고, Runge-Kutta 4th order 적분 알고리즘을 사용하였다. 제안한 방식에서 제어기로 사용한 ADALINE의 퍼지시스템 입력 스케일링 팩터는 <표 3>과 같고, 동정기로 사용한 ADALINE의 퍼지 논

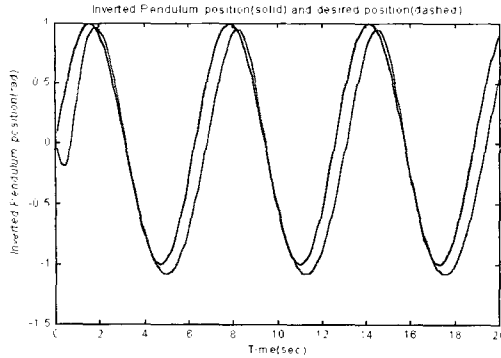


그림 12. 델타 방식의 응답 곡선
Fig. 12. The response curve by the Delta method.

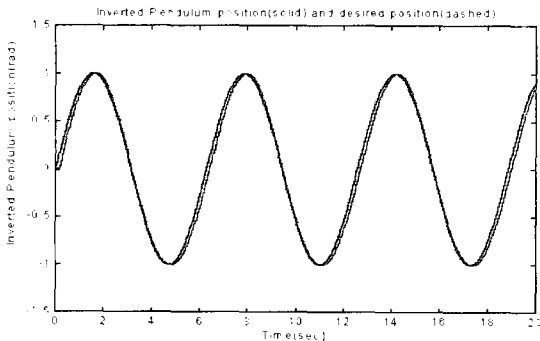


그림 13. 제안한 방식의 응답 곡선
Fig. 13. The response curve by the proposed method.

리 시스템 입력 스케일링 팩터는 모두 <표 4>와 같다. 단 제어기와 동정기로 사용한 퍼지 논리 시스템 출력의 스케일링 팩터는 각각 1로 하였다.

Widrow-Hoff 델타 규칙을 사용한 경우의 시뮬레이션 응답 곡선은 <그림 12>이고, <그림 13>은 제안한 방식의 응답 곡선이다.

인버티드 펜듈럼 제어에서도 제안한 방식의 제어 성능이 우수함을 확인하였다.

V. 실험 및 검토

1. 근전도 신호의 노이즈 제거

근전도 신호 측정을 위한 실험 장치 블록 선도는 <그림 14>와 같으며, 전원 노이즈가 들어있는 각 전극의 입력 신호를 증폭하여 필터를 거치지 않고 바로 A/D 변환을 한 후 제안한 알고리즘을 이용하여 전원 노이즈를 제어하였다.




그림 14. 실험 장치의 블록 선도
Fig. 14. The block diagram of experiment device.




그림 15. 실험 장치와 측정 사진
Fig. 15. The picture of experiment device and EMG signal measurement.

<그림 15>는 실험 장치와 근전도 신호 측정 사진이다. 각 채널의 근전도 신호 측정은 각 채널의 차동 증폭기를 위한 4쌍의 전극과 하나의 공통접지 전극을 사용한 총 9개의 전극으로 4개 채널을 구성하여 신호를 측정하였다. 측정은 왼팔에 대하여 실행하였으며, 측정시 손목과 팔꿈치, 어깨를 움직이도록 팔의 비틀림에 대한 움직임을 최대한 억제하였으며, 반복되는 측정에서도 같은 자세를 유지하였다. <그림 15>의 오른쪽 사진은 어깨, 팔꿈치, 손목 등으로부터 근전도 신호를 측정하고 있는 사진이며, 측정시 사용한 1회용 Ag/Cl 표면전극으로 피검자에게 고통이 없고 성능도 뒤지지 않는 전극용 전도젤이 발려져 있다.

실험에서 A/D 변환기는 8비트 4채널 방식인 Analog Device사의 AD7824를 사용하였으며 변환된 데이터는 인터페이스 카드를 이용하여 저장하였다. 신호의 측정을 위하여 19~58dB 까지의 이득을 갖는 증폭기와 5~1,200[Hz]의 신호를 통과시키는 필터를 계수 OP-Amp INA101HP와 OP-Amp LF412CN을 사용하여 구성하였다. 또한 최종 출력이 A/D 변환기의 입력 범위(-5V~+5V)를 초과하지 않도록 주 증폭기의 이득을 조정하였다.

<그림 16>은 어깨의 전극에서 측정된 어깨의 굴곡의 근전도 신호로 필터를 거치지 않고 측정된 근전도 신호이다.




그림 16. 직접 측정된 근전도 신호
Fig. 16. Direct-measured EMG signal.




그림 18. 델타 방식의 노이즈 제거
Fig. 18. Noise cancellation by the Delta method.




그림 17. 아날로그 필터로 노이즈를 제거한 근전도 신호
Fig. 17. Noise cancelled EMG signal using analog filters.




그림 19. 제안한 방식의 노이즈 제거
Fig. 19. Noise cancellation by the proposed method.

<그림 17>은 어깨의 전극에서 측정된 어깨의 굴곡의 근전도 신호를 OP-Amp로 설계한 High-Pass 필터, Low-Pass 필터, 60Hz notch 필터 등의 아날로그 필터로 노이즈를 제거하여 측정된 근전도 신호로, 델타 규칙과 제안한 방식의 결과와 비교하기 위한 성능지표로 사용한다.

<그림 14>에서, 전원 노이즈가 들어있는 각 전극의 입력 신호를 증폭하여 필터를 거치지 않고 바로 A/D 변환을 한 신호로 델타 규칙과 제안한 방식의 노이즈 제거 실험을 한다. 실험 조건은 시뮬레이션과 같고, 델타 규칙을 이용한 방식의 노이즈 제거 실험 결과는 <그림 18>이며, <그림 19>는 제안한 방식의 노이즈 제거 실험 결과이다.

<그림 17>과 비교하여 제안한 방식은 델타 규칙 보다 노이즈 제거 성능이 우수함을 실험을 통하여서도

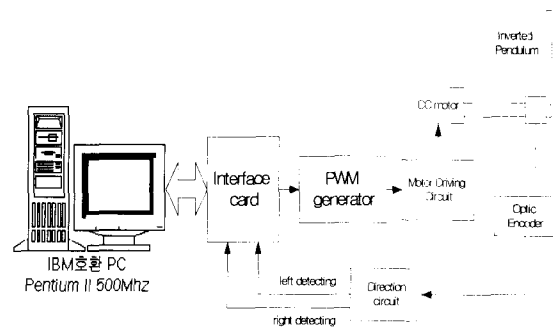


그림 20. 실험 시스템의 블록 선도
Fig. 20. The block diagram of experimental system.

확인하였다.

2. 인버티드 펜들럼 제어

인버티드 펜들럼 제어를 위한 실험 시스템의 블록 선도는 <그림 20>과 같다.

그림에서 인터페이스 카드는 1개의 8255를 사용하여 8비트 병렬 입출력 포트가 최대 3개, 어드레스 디코딩에 변화를 줄 수 있도록 설계하였다. 전력 증폭기에서 모터 구동시 생길 수 있는 노이즈가 전체회로에 전달되는 것을 방지하고 D/A 변환기의 부하를 감소시키기 위하여 D/A 변환기와 전력 증폭기 회로는 포토커플러로 연결하였다. PWM 방식의 D/A 변환기의 입력펄스 주파수는 4 [MHz], 데이터는 8bit, 변환전압범위는 0~10 [V], 변환시간은 64[μ s], 정밀도는 39.0625 [mV]로 설계하였다. 모터 구동 전력증폭기 회로는 FET(IRFP064)를 사용하여 설계하였고, 프리휠링 다이오드를 사용하여 역기전력을 방지할 수 있도록 하였다. 매니플레이터의 각변위를 측정하기 위한 센서로는 1회전당 1000 [pulse]의 출력을 갖는 로타리 엔코더를 사용하였다. 제안된 방식의 제어알고리즘은 시뮬레이션을 위해 사용되었던 MATLAB 루틴을 모듈화 하여 C언어로 IBM PC 상에서 구현하였으며, Runge-Kutta 4th order 알고리즘으로 해석하는 루틴대신에 인터페이스 카드를 통하여 제작된 실험 장치에 연결하였다. 따라서 PC 내의 C언어 상에서 계산된 제어 입력 신호는 인터페이스카드, 구동회로를 거쳐 DC 서보 모터로 가고 DC 서보 모터는 기준궤적을 따라 이동한다. 모터에 부착된 엔코더로부터 발생된 펄스를 펄스방향 판별회로와 8253 카운터를 통하여 각변위를 펄스로 계산하고 인터페이스 카드를 통하여 PC로 입력받아서 각변위를 라디안 값으로 환산하고 검출된 각변위를 이용하여 각속도를 구한다. 실제 제어에 있어 실시간 구현을 위해 PC내부의 timer interrupt를 이용하여 정확한 샘플링 주파수를 구현하였다. <그림 21>은 실험 장치 사진이다.

실험 조건은 시뮬레이션과 같이 하여 델타 규칙을




그림 21. 실험 장치 사진
Fig. 21. The picture of experimental set up.




그림 22. 델타 방식의 응답 곡선
Fig. 22. The response curve by the Delta method.




그림 23. 제안한 방식의 응답 곡선
Fig. 23. The response curve by the proposed method.

사용한 경우의 실험 결과는 <그림 22>이고, <그림 23>은 제안한 방식의 실험 결과이다.

실험 결과에서도 제안한 방식의 제어 성능이 우수함을 확인하였다.

VI. 결 론

ADALINE의 학습을 위해 퍼지 논리 시스템을 이용하는 방식을 제안하였다. 제안한 방식은 퍼지 논리 시스템을 구성하여 직접 연결강도를 조절하는 방식으로, 퍼지 논리 시스템의 입력으로는 오차와 오차의 변화분을 사용하고 출력으로는 연결강도의 변화분을 사용하였다. 한 개의 퍼지 논리 시스템으로 각각의 스케일링 팩터만 조절하여 여러 개의 연결강도를 조절할 수 있었다. 제안한 방식의 유용성을 확인하기 위하여 노이즈 제거 와 인버티드 팬들럼 제어 등에 대하여 Widrow-Hoff 델타 규칙과 시뮬레이션 및 실험을 통하여 다음

과 같은 결과를 얻었다.

- ▶ 델타 규칙에서의 적절한 학습을 파라미터를 선택하지 않아도 되고 1차 미분을 하지 않아도 된다.
- ▶ 퍼지 논리 시스템의 구성이 9개의 규칙으로 간단하다.
- ▶ 노이즈 제거 및 인버티드 펜들럼 제어에서 Widrow-Hoff 델타 학습 규칙 보다 성능이 우수하다.

참 고 문 헌

- [1] Ling Zhang, Bo Zhang, "A geometrical representation of McCulloch-Pitts neural model and its applications," IEEE Transactions on Neural Networks, vol. 10, pp. 925~929, 1999.
- [2] Simon Haykin, Neural network a comprehensive foundation, second edition, Prentice-Hall, 1999.
- [3] Hayman. S, "The McCulloch-Pitts model," IJCNN '99. International Joint Conference on Neural Networks, vol. 6, pp. 4438~4439, 1999.
- [4] Bernard Widrow, Michael A. Lehr, "30 Years of adaptive Neural Networks: Perceptron, Madaline, Backpropagation," Proceedings of the IEEE, vol. 78, no. 9, pp. 1415~1442, 1990.
- [5] Zi-Qin, Michael T. Manry, Jeffrey L. Schiano, "LMS Learning Algorithms: Misconceptions and New Results on Convergence," IEEE Transactions on Neural Networks, vol. 11, no. 1, 2000.
- [6] Li-Xin Wang, A course in fuzzy systems and control, Prentice Hall PTR Prentice-Hall Inc., 1997.
- [7] Kevin M. Passino, Stephen Yurkovich, Fuzzy control, Addison-Wesley, 1997.
- [8] Rodney Winter, Bernard Widrow, "Madaline Rule II: A Training Algorithm for Neural Networks", IEEE International Conference on Neural Networks, pp. 401~408, vol. 1, 1988.
- [9] Hagan, Demuth, Beale, NEURAL NETWORK DESIGN, PWS Publishing Company, 1996.

저 자 소 개

鄭慶權(正會員) 第39卷 CI編 第4號 參照

鄭盛夫(正會員) 第38卷 CI編 第6號 參照

金周雄(正會員) 第39卷 CI編 第4號 參照

嚴基煥(正會員) 第38卷 SC編 第4號 參照