

## 오차 자기 순환 신경회로망을 이용한 현가시스템 인식과 슬라이딩 모드 제어기 개발

### Identification of Suspension systems using Error Self Recurrent Neural Network and Development of Sliding mode Controller

°송광현\*, 이창구\*\*, 김성중\*\*

\* 전북대학교 전기공학과 (E-mail : peacemkr@koreamail.com)

\*\* 전북대학교 전기·전자·제어 공학부 교수(E-mail : changgoo@moak.chonbuk.ac.kr)

**Abstracts** In this paper the new neural network and sliding mode suspension controller is proposed. That neural network is error self-recurrent neural network. For fast on-line learning, this paper use recursive least squares method. A new neural networks converges considerably faster than the backpropagation algorithm and has advantages of being less affected by the poor initial weights and learning rate. The controller for suspension systems is designed according to sliding mode technique based on new proposed neural network.

**Keywords** error self-recurrent, sliding mode, suspension systems, recursive least squares

#### 1. 서론

최근, 신경회로망에 대한 연구가 활발히 진행되고 있으며 비선형 시스템 인식과 제어를 포함한 다양한 분야에 적용되어 실용화되고 있다[1]-[2]. 일반적으로, 시스템 인식과 제어에 이용하는 신경회로망은 다층망(multilayer) 구조이고, 이를 위한 학습방법은 Rumelhart에 의하여 개발된 역전파(back-propagation :BP) 알고리즘이다[3]. 비록, 이 알고리즘이 다양한 응용분야에 성공적으로 적용되고 있을 지라도 여려가지 단점을 지니고 있다. 특히, 결선강도(weight)에 대한 오차(error)의 기울기를 구하는 방법이기 때문에 local minima에 빠지기 쉽고, 수렴속도가 매우 늦으며 초기 결선강도 값들이나 학습계수(learning rate)에 민감하게 반응한다. 이와같은 단점을 개선하기 위하여 최근 여려 연구들이 활발히 진행되어 왔다. 그 대표적인 예로서, Wasserman은 역전파 알고리즘에 경험적 지식을 결합하는 방법을 제시하였으나 체계적으로 이론화하지 못하였다[4]. 또한, Singhal과 Wu는 확장된 Kalman filtering 기법을 역전파에 결합하였으나 계산상의 복잡성 때문에 망의 크기가 증가하면 실제 적용할 수 없다[5]. 최근, Scalero와 Tepedelenlioglu, Lou와 Perez는 각각 신경회로망을 선형과 비선형 구간으로 구분하고 Kalman 필터링 기법을 도입하여 수렴속도를 빠르게 하고 초기 결선강도값에 크게 영향을 받지 않도록 개선하였으나, 여전히 은닉층(hidden layer)의 선형 오차값을 역전파 알고리즘에 의하여 계산하기 때문에 학습계수에 민감한 단점이 있다[6]-[7].

본 논문에서는 실제적인 응용을 위해서는 제어하고자 하는 시스템에 대한 사전정보를 전혀 요구하지 않아야 하며, 이를 추정(인식)하는데 이용하는 신경회로망 구조와 학습방법은 단순하고 빨라야 한다는 목적을 갖고 연구를 수행하였다. 이러한 목적을 성취하기 위하여 bias대신에 오차가 시간지연되어 캐줄되는 새로운 오차 자기순환(error self-recurrent) 신경모델로 구성된 신경회로망을 제시하고, 앞서 지적한 단점을 개선함과 동시에 새로운 신경회로망에 적용하기 위하여 은닉층의 목표값을 최적기법을 통하여 직접 계산하고 각각의 결선강도값은 반복 최소자승(recursive least square : RLS)법으로 온라인 학습하는 알고리

즘을 개발하였다. 또한 이러한 새로운 신경망 모델을 이용하여 7-DOF 현가 시스템을 실시간 인식하고 이를 바탕으로, 응답이 빠르고 모델링 오차를 고려할 수 있는 슬라이딩 모드 현가 시스템 제어기를 구성하여 좋은 특성을 얻었다.

#### 2. 오차 자기순환 신경망

이 새로운 신경망 구조는 출력과 에러가 시간 지연 되어 순환 입력된다. 보통의 다층 순방향 신경망은 Bias나 Threshold값이 +1이나 -1로 일정한 값을 가지며 이는 각 활성함수의 net출력을 증가하거나 감소하는 기능을 가지고 있다. 하지만 시스템에 따라 어떻게 이값을 결정하는가에 대한 명확한 이론이 없다.

본 논문에서는 이러한 모호성을 해결하고, 빠르게 변하는 시스템을 인식하고자 그림 1b와 같이 한스텝이전의 출력오차( $e(t-1)$ )를 순환시키고 바이어스는 양의 값으로 한정하는 모델을 제시한다.

그림 1은 각각 기존 신경망 모델과 제안한 신경망 모델을 나타낸다. 그림 1a는 Bias값으로 +1, -1, 0을 가지는 반면 그림 1b는 출력오차를 캐줄함으로써 Bias 설정에 대한 모호성을 해결하고 빠르게 변화하는 시스템을 인식할 수 있다.




그림 1a. 기존의 신경망 모델

Fig. 1a. Conventional Neural Network

그림 1b. 오차 자기순환 신경망

Fig. 1b. Error Self-Recurrent Neural Network

## 2.1 학습 알고리듬

신경망을 그림 2와 같이 선형구간과 비선형구간으로 나누고 선형구간의 은닉층 목표값을 최적 기법으로 구한다. 알고리듬은 다음과 같다.




그림 2. 신경의 구분  
Fig 2. Division of Neural

$$E = \frac{1}{2} \sum_{k=0}^M (d_k - w_k z)^2 \quad (1)$$

$$\frac{\partial E}{\partial z} = 0 \Rightarrow \sum_{k=0}^M d_k w_k = \sum_{k=0}^M w_k w_k^T z \quad (2)$$

$$z^* = W^T (WW^T)^{-1} d \quad (3)$$

각층의 각각의 node에서 이득 벡터  $K_k$ 를 다음과 같이 구하여 weight 벡터를 아래와 같이 추정한다.

$$z_{inj} = \sum_{i=0}^N v_{ji} \chi_i, \quad z_j = f(z_{inj}) \quad (4)$$

$$y_{ink} = \sum_{j=0}^P w_{kj} z_j, \quad y_k = f(y_{ink}) \quad (5)$$

$$K_k = P_k \chi / (\lambda + \chi^T P_k \chi) \quad (6)$$

$$P_k = (I - K_k \chi^T) P_k / \lambda \quad (7)$$

$$w_k = w_k + k_k (d_k - y_{ink}) \quad (8)$$

$$v_j = v_j + k_k (d_{hj} - z_{inj}) \quad (9)$$

위의 과정으로 학습을 반복한다.

## 2.2 다른 비선형 모델 인식

제안한 오차 자기순환 신경회로망과 학습알고리즘을 평가하기 위하여 그림3과 같은 플랜트 출력과 제어 입력을 시간 지연시켜 신경회로망 입력으로 궤환하도록 하였다. 테스트를 위해 플랜트는 비선형 시스템 모델로서 널리 이용되는 식(10)으로 설정하고 입력신호는  $u(t) = 0.5 \sin(2\pi t/50) + 0.5 \sin(2\pi t/120)$ 로 발생하여 수행하였다

$$y(t) = (0.85y(t-1)y(t-2) + 0.16u(t-1) + 0.25u(t-2))/(1+y^2(t-1)) \quad (10)$$

테스트는 초기 결선강도(initial weight)를 0~0.5로 하고 BP와 Scalero에서 학습계수(learning rate)는 0.05로 하였다. 그림 4, 5




그림 3. 시스템 인식을 위한 방법  
Fig. 3. The method of identification of system

는 각각 BP와 Scalero에 의한 학습 방법의 결과이며 그림 6은 제안한 신경망에 의한 결과이다.

그림에서 보는 바와 같이 Scalero 방법은 BP 방법에 의한 신경망보다 나은 결과를 보이지만 200스텝이 지난 후에 수렴함을 알 수 있다. 이에 의해 제안한 신경망의 결과는 기존 방법에 비해 빠른 수렴을 보이고 있다.




그림 4. Network output by BP algorithim (Bias=+1)

Fig. 4. Network output by BP algorithim (Bias=+1)




그림 5. BP에 의한 신경망 출력(Bias=+1)

Fig. 5. Network output by Scalero's algorithm (Bias=+1)




그림 6. Scalero에 의한 신경망 출력(Bias=+1)

Fig. 6. Network output of proposed algorithm (Bias=e(t-1))

## 3. 7-DOF 차량 현가 모델 인식

차량 모델은 그림7과 같은 7자유도를 가지고 있으며 4개의 현가 시스템과 그로 인해 발생하는 Heave, Pitch, Roll 움직임을 고려하고 있다.[11]

신경망의 입력으로는 출력의 1차 2차 지연 궤환값(8개)과 제어입력의 1차 지연 궤환값(4개), Road Disturbance의 1차 지연 궤환값(4개) 총 16개와 출력은 각 바퀴의 서스펜션 스트로크이다.

시뮬레이션의 초기 연결강도는 0~0.5로 하고 오차에 대한 weight는 0.05로 하였다. 그림 8, 9, 10, 11은 크기 0.1m의 Bump입력에 따른 각각 바퀴의 서스펜션 스트로크 추정결과를 보여준다.

그림에서 보는 바와 같이 0.5m 주행후에는 추정 오차가 거의 없다는 것을 알 수 있다.




그림 7. 7-DOF 차량 모델  
Fig. 7. 7-DOF vehicle model




그림 8. 도로 주행 조건 (Left:0.2, Right:0.1)  
Fig. 8. Road Disturbance (Left:0.2, Right:0.1)




그림 9. 앞 왼쪽 휠의 서스펜션 변위  
Fig. 9. suspension stroke of front left wheel




그림 10. 앞 오른쪽 휠의 서스펜션 변위  
Fig. 10. suspension stroke of front right wheel

#### 4. 슬라이딩 모드 현가시스템 제어기

신경망 모델을 이용한 제어기 설계에 대한 연구는 A.J. Morris[9], Keyser[10]등에 의하여 최근 많은 연구결과들이 발표되었다. 그러나, 대부분의 제어결과들이 신경회로망 모델에 민감하고, 빠른 학습능력을 갖지 못하는 신경망모델을 이용하기 때문




그림 11. 뒤 왼쪽 휠의 서스펜션 변위  
Fig. 11. suspension stroke of rear left wheel




그림 12. 뒤 오른쪽 휠의 서스펜션 변위  
Fig. 12. suspension stroke of rear right wheel

에 실시간 제어에 이용하지 못하는 실정이다.[8]-[10]

본 논문에서는 제안한 신경망 모델을 바탕으로 하여 슬라이딩 모드 현가 시스템 제어기를 개발하였다.

슬라이딩 모드 제어 기법은 강인제어의 한 분야로서 임의의 모델 부정확성(uncertainty)에도 불구하고 높은 제어 성능이 보장되며 빠른 응답 특성과 제어기 안에 비선형 식을 포함할 수 있다는 장점을 지니고 있다. 슬라이딩 모드 제어 기법에 대한 자세한 설명은 생략한다.

슬라이딩 모드 제어기법은  $x^{(n)} = f(x) + b(x)u$  과 같은 모델을 사용한다. 그러나 본 연구에서는 인식된 신경망을 기초로 하기 때문에 슬라이딩 모드 제어 기법을 응용하여 구성하였다. 시스템을 묘사하는 신경망 출력은 식 (11)과 같다.

$$y_j^{nn}(t) = F[\hat{A}y^p(t-1) + \hat{B}y^p(t-2) + \hat{C}u(t-1) + \hat{D}w(t-1) + \hat{E}e(t-1)] \quad (11)$$

현가시스템은 2차로 가정하고 제어 입력은 식 (12)에서 구한다.

$$u = -\hat{f} + \lambda \hat{x} - k \text{sat}(s/\phi) \quad (12)$$

$$\hat{f} = F[\hat{A}y^p(t-1) + \hat{B}y^p(t-2) + \hat{E}e(t-1)] \quad (13)$$

$\ddot{x}_d = x_d = 0$ ,  $\lambda = 7$ ,  $k = F + \eta = 10 \times |y(t)| + 0.1$ ,  $\phi = 15^\circ$ 이다.

여기에서  $\dot{x}$ 는 직접 측정이 불가능하며 식 (14)으로 구하면 제어기는 예측제어기로 작동한다.

$$\dot{\hat{x}}(t+1) = \frac{y(t+1) - y(t)}{h} = \frac{y^{nn}(t+1) - y(t)}{h} \quad (14)$$

$$y^{nn}(t+1) = F[\hat{A}y^p(t) + \hat{B}y^p(t-1) + \hat{C}u(t) + \hat{D}w(t) + \hat{E}e(t)] \quad (15)$$

시뮬레이션은 각 바퀴의 서스펜션 스트로크를 신경망으로 인식하고 그에 따른 제어 입력 4개를 구성하여 수행하였다. 제어 대상은 서스펜션 스트로크이고 제어 성능을 평가하기 위하여 각 바퀴의 서스펜션 스트로크대신에 시스템의 Heave, Pitch, Roll 움직임을 출력하였다.

그림 13, 14, 15, 16은 각 바퀴의 서스펜션 스트로크를 보여준다. 그림 16과 그림 17은  $\emptyset$ (Boundary Layer)의 유무에 따른 채터링 현상을 보여주고 있다. 그림 17에서 4m 이후 일정 크기로 채터링하는 것을 볼 수 있다.




그림 14. Pitch 움직임  
Fig. 14. Pitch motion




그림 13. Heave 움직임  
Fig. 13. Heave Motion




그림 15. Roll 움직임  
Fig. 15. Roll Motion




그림 16. 서스펜션 변위, sat(s/∅)  
Fig. 16. Suspension Stroke, sat(s/∅)

#### 4. 결론

본 논문에서는 학습속도를 개선하기 위한 신경모델로서 bias로 +1대신에 오차가 시간지연되어 자기 궤환되는 새로운 recurrent 신경회로망을 제시하고 그 성능을 실험하였다. 이를 위해, 은닉층의 목표값을 역전파 알고리즘에 의하여 전달하지 않




그림 17. 서스펜션 변위, sgn(s)  
Fig. 17. Suspension stroke, sgn(s)

고 최적기법을 이용하여 직접 계산하고 각각의 결선강도값을 RLS에 의하여 온라인으로 추정하는 알고리즘을 개발하였다. 여러가지 실험결과에 의하면 제안한 방법이 초기 결선강도에 크게 영향을 받지 아니하고, 기존의 학습계수 설정에 따른 문제를 해결하므로써 신경망 모델에 기초한 실시간 제어기 설계를 용이하게 하였다. 제시한 신경회로망 모델을 이용하여 현가시스템에 슬라이딩 모드 기법을 이용한 제어기를 사용하여 제어 가능성을 보였으며  $\emptyset$ (Boundary Layer)에 따른 채터링 현상도 고려하였다. 인식 초기의 과도현상으로 인한 정확한 제어 입력 발생이 어려워 차후 초기에는 일반 제어기를 사용하면서 학습을 병행하고, 학습이 이루어진 뒤에는 신경망 슬라이딩 모드 제어기를 적용하는 것이 필요할것으로 생각된다.

#### 참고문헌

- 1) Narendra, K. S. and Patthasarathy, "Identification and control of dynamical systems using neural networks," IEEE Trans. Neural Networks, Vol. 1, pp. 4-27, 1990
- 2) Wabgaonkar, H. and Stubberud, A., "A system identification technique based on neural networks," Proc. IEEE Int. Conf. Systems Engineering, Kobe, Japen, pp.352-356, Sept. 1992
- 3) Rumelhart, D. E. and McClelland, J. L., "Parallel Distributed Processing," Vol. 1, MIT Press, Cambridge, MA, 1986
- 4) Wasserman, P. D., Neural Computing, Theory and Practice, Van Nostrand Reinhold, NY, 1989
- 5) Singhal, S. and Wu, L., "Traning feedforward networks with the extended Kalman algorithm," Proc. IEEE Int. Conf. Acoustic, Speech, Signal Processing, pp.1187-1190, May 1989
- 6) Scalero, R. S. and Tepedelenlioglu, N., "A fast new algorithm for traning feedforward neural networks," IEEE Trans. Signal Processing, Vol. 40, pp. 202-210, 1992
- 7) Haykin, S., Neural Networks : A Comprehensive Foundation, Macmillan College Publishing Company Inc., NY, 1994
- 8) G.A.Montague, M.J.Willis and Morris, "Artificial neural network model based control," ACC'94, pp. 2134-2138, 1994
- 9) R. D. Keyser and Yonghong Tan, "Adaptive PID control with neural network based predictor", CONTROL'94, pp.1490-1494, 1994
- 10) A.Draeger, S.Engell, and H.Ranke, "Model predictive control using neural networks, IEEE Control society, October 1995, pp.61-66
- 11) 노태수, 정길도, 홍동표, "7DOF 차량 모델을 이용한 자동차 혼가장치 동력학 해석 및 시뮬레이션에 관한 연구," 한국자동차공학회 96년 춘계학술대회 논문집, pp.212-216