

최적제어와 신경회로망을 이용한 능동형 현가장치 제어

김 일 영*, 정 길 도**, 이 창 구***

Active Suspension System Control Using Optimal Control & Neural Network

Il-Young Kim*, Kil To Chong**, Chang Gu Lee***

ABSTRACT

Full car model is needed for investigating as a entire dynamics of vehicle. In this study, 7DOF of full car model's dynamics is selected. This paper proposes the output feedback controller based on optimal control theory. Input data and output data from the optimal controller are used for neural network system identification of the suspension system. To do system identification, neural network which has robustness against nonlinearities and disturbances is adapted. This study uses back-propagation algorithm to train a multilayer neural network. After obtaining a neural network model of a suspension system, a neuro-controller is designed. Neuro-controller controls suspension system with off-line learning method and multi-step ahead prediction model based on the neural network model and a neuro-controller. The optimal controller and the neuro-controller are designed and then, both performances are compared through. For simulation, sinusoidal and rectangular virtual bumps are selected.

Key Words : Full car model(전체 차량 모델), Suspension system(현가장치), Identification neural network(식별 신경 회로망), Optimal controller(최적 제어기), Neuro-controller(뉴로 제어기), Preview control(예견제어)

1. 서 론

차량에 현가장치를 부착하므로써 얻을 수 있는 잇점은 여러 가지가 있다. 우선, 고르지 못한 노면이나 요철(凹凸)을 지나게 될 때, 차체의 흔들림을 감소하여 승차감을 향상시키고 차륜의 진동을 억제하여 주행시 안정성을 유지할 수 있다. 그리고 차체의 흔들림이 적어지면 차량의

부속품 및 차량의 수명을 연장시킬 수 있고, 곡선도로를 선회할 때 부드러운 핸들링을 유도할 수 있다. 또한, 트럭과 같은 무거운 차량의 흔들림이나 선회로 인한 도로의 파손을 예방할 수도 있다.

현가장치는 수동형, 능동형과 반능동형으로 나눌 수 있다.⁽¹⁻⁴⁾ 수동형은 단순히 스프링과 댐퍼만으로 구성된 것으로써, 경제적이고, 신뢰도가 높지만 고유의 물리적 특

* 전북대학교 제어계측공학과 대학원

** 전북대학교 제어계측공학과

*** 전북대학교 제어계측공학과, 자동차 신기술 연구소

성으로 인해 현저한 성능향상을 기대하기 어렵다. 이러한 한계점을 해결하는 방법으로 능동형 현가장치를 개발하기에 이르렀으며, 이는 스프링과 댐퍼가 없고 구동기를 이용하여 차체를 제어하도록 설계되었다. 능동형 현가장치는 수동형에 비해 현저한 성능 향상을 보여 주지만 구동기를 제어하는데 복잡한 알고리즘을 구상해야 하고, 구동기의 동작을 위한 큰 외부 동력이 필요하여 경제적이지 못한 단점을 지니고 있다. 그렇기 때문에 능동형 현가장치는 아직까지 실용화되지 못하고 있다. 이러한 문제점들을 해결하기 위해 수동형과 능동형의 장점을 이용한 반능동형 현가장치에 대한 연구가 활발하다. 반능동형 현가장치는 수동형에 있는 스프링과 댐퍼를 사용하고, 제어기를 이용하여 스프링의 강도나 댐퍼내 오일 점도를 조절하도록 설계된다. 경제적이고 성능 향상 면에 있어서도 능동형과 비슷한 결과를 얻을 수 있다. 제어기 설계 관점에서 볼 때 반능동형 현가장치도 능동형 현가장치에서처럼 구동기를 제어하기 위한 제어 알고리즘을 필요로 한다.

현가장치에 대한 연구를 살펴보면, PID 제어기를 이용하여 능동형 현가장치의 주파수 응답 특성과 특정 도로 선정에 의한 시간 응답 특성에서 좋은 결과를 얻었고,⁽⁵⁾ LQG/LQR 최적제어이론을 현가장치에 적용하여 성능지수를 최소로 하는 제어기를 설계하기도 하였다.⁽⁶⁻⁸⁾ 그리고 좋은 성능과 안정성을 보장하는 H_2 제어이론과 시스템의 불확실성이나 외란에 대해 강인성을 갖는 H_∞ 제어이론의 장점을 이용한 H_2/H_∞ 제어이론이 능동 현가장치에 적용되었다.⁽⁹⁻¹¹⁾ 또한, 1970년대에서 1980년대 중반까지 침체기에 있었던 신경회로망의 연구가 다시 활발해짐에 따라 신경회로망 이론이 현가장치에 적용되고 있다. 신경회로망이 이용되는 이유는, 복잡한 수학적 모델링을 하지 않고도 시스템의 입/출력 값을 이용해 시스템의 특성을 규명하거나 제어기를 설계하는데 우수하다는 것이 증명되고 있기 때문이다.⁽¹²⁻²¹⁾ 최근 들어 가변 구조 제어 중의 하나인 슬라이딩 모드 제어 이론⁽²²⁻²⁵⁾과 적응 제어⁽²⁵⁾⁽²⁶⁾ 등이 현가장치에 이용되고 있다. 이는 불확실한 모델링과 외란에도 강인함을 갖고 있기 때문이다. 그 밖에, 예전 제어이론⁽²⁷⁾ 등이 현가장치에 적용되고 있다. 현가장치는 열차⁽²⁸⁾⁽²⁹⁾ 및 자기부상열차⁽³⁰⁾에도 부착되어 균일하지 못한 선로나 불안정한 떠오름 상태에서도 승차감을 향상시킬 수 있도록 하고 있다.

본 연구에서는 전체 차량의 운동 중에서 7자유도를 선정하여 차량에 대한 수학적 모델링을 하였다. 7자유도는 차체의 수직 운동인 heave, 차체의 앞/뒷솔림 운동인 pitch, 차체의 좌/우솔림 운동인 roll과 4개 차륜의 운동

으로 이루어진다. 반능동형과 능동형 현가장치는 제어 알고리즘을 이용하여 동작하는 제어기를 필요로 한다. 본 논문에서는 성능지수를 최소로 하는 제어값을 구하기 위해 최적 제어 이론을 바탕으로 출력 되먹임 제어기(output feedback controller)를 설계하였다. 그리고 입력 데이터와 최적 제어기에서 얻은 출력 데이터를 이용하여 현가장치에 대한 시스템 규명을 하였다. 시스템 규명을 하기 위해 비선형과 외란에 강인함을 갖고, 다수의 병렬 분산 처리 연산 기능을 가진 신경회로망을 적용하였다. 신경회로망의 구조는 Narendra⁽¹⁵⁾에 의해 제안된 형태를 이용하고 학습 방법으로는 역전파(Back Propagation) 학습 알고리즘을 이용하였다. 역전파 학습 알고리즘은 신경회로망을 통해 얻어진 출력값과 목표 출력값과의 오차를 감소시키는 방향으로 연결강도를 조절한다.

신경회로망을 충분히 학습시켜 시스템에 대한 규명을 한 후, 뉴로 제어기를 설계하였다. 뉴로 제어기의 구조와 학습 알고리즘은 식별 신경회로망과 유사하게 하였다. 뉴로 제어기는 오프라인 학습 방법에 의해 현가장치를 제어하게 된다. 본 연구에서의 오프라인 제어란, 차량이 정속 전진 운행하는 동안, 매 샘플링 시간마다 센서로 부터 정보를 얻지 않고, 이전에 정보를 이용하여 제어기를 설계하는 방식을 말한다. 오프라인으로 설계된 제어기는 주어진 상황에 대해, 시스템의 동작상태를 미리 예측할 수 있으므로 예견제어에 이용할 수 있으며, 또한 시스템 제어의 보조장치로도 사용할 수 있는 장점이 있다.

본 논문의 구성은, 2장에서 차량의 모델링과 최적 제어기의 설계에 대해 논하고 3장에서는 시스템을 규명하기 위해 신경회로망에 관해 살펴 볼 것이며 4장에서는 뉴로 제어기 설계와 5장에서 컴퓨터 시뮬레이션을 통해 최적 제어기와 뉴로 제어기의 성능을 비교, 분석하고자 한다.

2. 차량 모델링과 제어기 설계

2.1 전체 차량(full car)의 모델링

차량의 부분적인 운동 특성을 알기위해 1/4, 1/2 차량 모델이 적용되곤 한다. 그러나 차량 전체의 운동 특성을 연구하기 위해서는 전체 차량 모델이 필요하다. 본 연구에서는 전체 차량의 운동중 7자유도(DOF)를 선정하여 차량에 대한 모델링을 하였다. 7자유도는 차체의 수직 운동인 heave, 차체의 앞/뒷솔림 운동인 pitch, 차체의 좌/우솔림 운동인 roll과 4개 차륜의 운동으로 이루어진다.

Fig. 1은 전체 차량 모델의 계략도이고, 파라미터는 Table 1에 나타나 있다. 본 연구에서는 heave motion의 방향을 X축, pitch motion의 방향을 Y축, 그리고 roll motion의 방향을 Z축으로 정하였다.

우선 X축 방향으로 운동하는 차체의 heave motion에 관한 운동 방정식을 살펴보면 다음과 같다.

$$M\ddot{x}_v = \sum_{i=1}^4 F_i + \sum_{i=1}^4 F_i. \quad (1)$$

여기서 M 은 차체의 질량이고, F_i 는 차체에 대해 스프링과 댐퍼의 반발력을 나타내며 $F_i = -k_i s_i - c_i \dot{s}_i$ ($i = 1, 2, 3, 4$)이다. 침자 i 는 4개의 차륜번호로 숫자 1은 전방좌측, 2는 전방우측, 3은 후방좌측, 4는 후방우측을 나타낸다. k_i 는 스프링 상수를, c_i 는 댐퍼 상수를, 그리고 s_i , \dot{s}_i 는 suspension stroke의 변위로써 좀 더 자세히 나타내면 다음과 같다.

$$\begin{aligned} s_i &= x_v - b_i^y \phi + b_i^z \theta - x_i, \\ \dot{s}_i &= \dot{x}_v - b_i^y \dot{\phi} + b_i^z \dot{\theta} - \dot{x}_i. \end{aligned} \quad (2)$$

x_v 는 차체의 수직 운동을 나타내는 변위이고, b_i^y 는 차체의 중심점에서 i번째 현가장치까지의 y축 거리를, b_i^z 는 차체의 중심점에서 i번째 현가장치까지의 z축 거

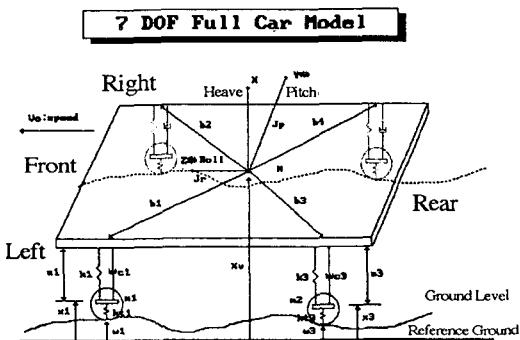


Fig. 1 Full car suspension system model

Table 1. Parameter of full car model

M	700 kg	$b_{FL}(y\text{-축}), b_{FR}(z\text{-축})$	- 0.75 m(y축), 1 m(z축)
J_p	$1200 \text{ kg} \cdot \text{m}^2$	$b_{FL}(y\text{-축}), b_{FR}(z\text{-축})$	0.75 m(y축), 1 m(z축)
J_r	$1000 \text{ kg} \cdot \text{m}^2$	$b_{RL}(y\text{-축}), b_{RR}(z\text{-축})$	- 0.75 m(y축), - 1.5 m(z축)
k_i	10000 N/m	$b_{RL}(y\text{-축}), b_{RR}(z\text{-축})$	0.75 m(y축), - 1.5 m(z축)
c_i	$250 \text{ N} \cdot \text{s/m}$		
m_i	25 kg		
K_i	178000 N/m		

리를 의미하고, x_i 는 i번째 차륜의 수직 변위를 나타낸다. 그리고 U_i 는 각 현가 장치의 능동 제어력을 나타낸다.

Y축 방향의 앞/뒷슬립 운동인 pitch motion의 운동 방정식은,

$$J_p \ddot{\theta} = \sum_{i=1}^4 b_i^z (F_i + U_i) \quad (3)$$

로써 J_p 는 Y축에 대한 관성 모멘트이다.

Z축 방향의 좌/우슬립 운동인 roll motion의 운동 방정식은 다음과 같다.

$$J_r \ddot{\phi} = \sum_{i=1}^4 (-b_i^z) (F_i + U_i). \quad (4)$$

여기서, J_r 는 Z축에 대한 관성 모멘트이다.

그리고 차륜의 운동 방정식은 다음과 같다.

$$m_i \ddot{x}_i = -F_i - U_i - K'_i (x_i - w_i). \quad (5)$$

m_i 은 i번째 차륜의 질량을 나타내고, K'_i 는 i번째 차륜의 스프링 상수를 의미한다. 그리고 외란인 w_i 는 i번째 차륜에 접하는 노면의 입력을 나타낸다.

2.2 최적 제어기 설계

반능동형과 능동형 현가 장치는 제어 알고리즘을 이용하여 동작하는 제어기를 필요로 한다. 본 논문에서는 최적 제어 이론을 이용한 출력 되먹임 제어기(output feedback controller)를 설계하였다. 출력 되먹임 제어기는 전상태 되먹임 제어기(full state feedback controller)와는 다르게 모든 출력 상태 중 일부분의 출력만을 가지고도 제어할 수 있어 경제적이다. 본 연구에서는 각 현가장치의 서스펜션 스트로크(suspension stroke) 변위와 속도를 출력으로 하여 제어기를 설계하였으며, 서스펜션 스트로크란 차체와 차륜사이의 거리 변위를 의미한다. 출력 되먹임 제어 $u(t)$ 를 정의하면 다음과 같다.

$$u(t) = -K y(t). \quad (6)$$

그리고 성능지수는 다음 식과 같다.

$$J = \frac{1}{2} \int_0^\infty (X^T Q X + u^T R u) dt. \quad (7)$$

X 는 서스펜션 스트로크의 위치와 속도인 8개의 상태변수이고 Q, R 은 가중치 벡터이다. 성능지수를 최소로 하는 $u(t)$ 를 얻기 위해 먼저 K (Kalman Gain)를 구한다. K 값

은 Riccati Equation 과 Lyapunov Equation을 풀기 위한 Matlab soft-ware를 이용하였다.

차량이 일정한 속도(20 km/h)로 Fig. 2(a)와 같은 범프를 지나게 될 때, 차륜에 전달되는 노면의 입력 상태를 나타낸 것이 Fig. 2(b)이다. Fig. 3은 노면 입력시 제어기가 없는 상태의 차체의 heave motion을 의미하는데 많은 진동이 있음을 알 수 있다. 반면에, Fig. 4는 출력 되며 임 제어기에 의해 얻어진 결과를 나타낸 것으로 진동 수가 많이 감소하여 차량의 운동이 안정해졌음을 알 수 있다.

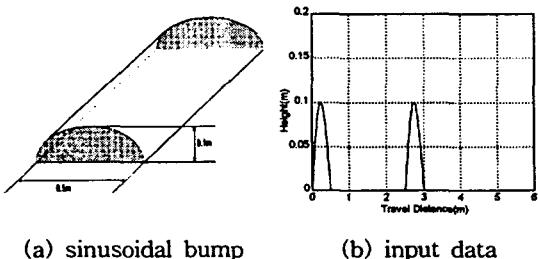


Fig. 2 Bump & input data

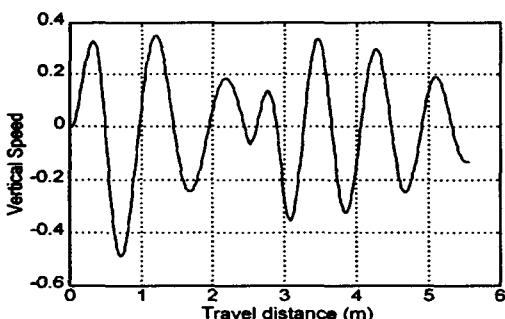


Fig. 3 Heave motion without controller

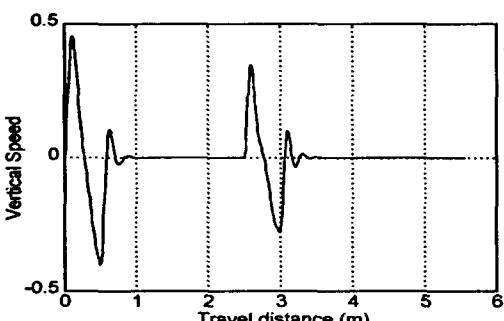


Fig. 4 Heave motion with optimal controller

3. 시스템 규명

지금까지 전체 차량을 모델링하고 최적 제어기를 설계하여 그에 대한 응답을 살펴 보았다. 이제, 노면의 입력값과 제어기에서 얻은 결과를 이용하여 시스템 규명을 하자. 시스템을 규명하기 위해 신경회로망을 이용하였다.

3.1 신경회로망 설계

기본적인 신경회로망 구조는 Narendra에 의해 소개된 것으로 Fig. 5에서 보는 것과 같이 1개의 입력층과 2개의 은닉층, 그리고 하나의 출력층으로 구성된다. 입력층은 모두 19개의 입력값들로써, 4개의 차륜에 접촉되는 불규칙한 노면에 의한 입력값 $w_1(k) \sim w_4(k)$, 노면 입력시 최적 제어로직에서 얻은 제어력 $u_1(k) \sim u_4(k)$, 노면 입력의 전단계 값 $w_{(k-1)} \sim w_{(k-1)}$, 제어력의 전단계 값 $u_{(k-1)} \sim u_{(k-1)}$, 전단계의 목표 출력값 $t(k-1)$ 과 전전단계의 목표 출력값 $t(k-2)$, 그리고 편차(-1)로 구성된 입력들이 하나의 패턴을 이룬다. 은닉층은 2개를 사용하였는데, 첫 번째 은닉층은 편차를 포함하여 19개의 입력노드와 15개의 출력 노드로 구성되어 있고, 두 번째 은닉층은 16개의 입력노드와 10개의 출력노드로 되어 있다. 출력층은 11개의 입력 노드와 1개의 출력노드로 구성되어 있다.

신경회로망을 학습시키기 위해서는 입력데이터와 목표 출력데이터가 필요하다. 입력데이터는 Fig. 2에서 보는 것처럼 노면의 입력 상태(w_i)와 노면의 입력시 제어로직을 통해 얻어진 제어력(u_i)이다. 1개의 입력 패턴은 19개의 입력값을 가지고, 1개의 로드는 500개의 패턴으로 되어 있다. 전체 로드의 종류는 Table 2에서 보여지는 것처럼 10가지의 학습 로드와 2가지의 테스트 로드이며 10개의 학습 로드는 신경회로망을 학습하는데 이용되고 2개의 테스트 로드는 최종적으로 학습된 신경회로망의 성능

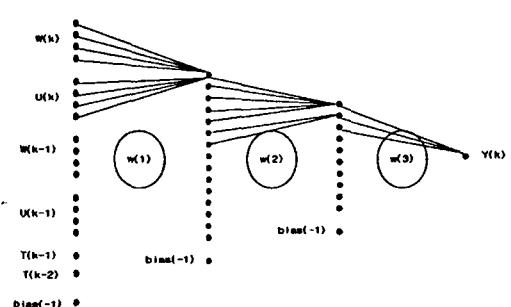


Fig. 5 Neural network introduced by Narendra

Table 2. Various bumps used in simulation

종류 (ROAD)	왼쪽 차륜에 닿는 범프 (m)		오른쪽 차륜에 닿는 범프 (m)	
	길이(폭)	높이	길이(폭)	높이
1 (sin.)	0.5	0.1	0.5	0.1
2 (sin.)	0.5	0.2	0.5	0.2
3 (sin.)	1.0	0.1	1.0	0.1
4 (sin.)	0.5	0.1	0.5	0.2
5 (sin.)	0.5	0.1	1.0	0.1
6 (rec.)	0.5	0.1	0.5	0.1
7 (rec.)	0.5	0.2	0.5	0.2
8 (rec.)	1.0	0.1	1.0	0.1
9 (rec.)	0.5	0.1	0.5	0.2
10 (rec.)	0.5	0.1	1.0	0.1
Test 1 (sin.)	0.75	0.1	0.75	0.1
Test 2 (rec.)	0.75	0.1	0.75	0.1

을 테스트하는데 사용된다. 목표 출력 데이터는 최적 제어기를 통해 얻어진 Fig. 4의 차체의 heave motion을 나타내는 값들이다. 전체 10개의 로드는 각각 500개의 입/출력 패턴을 가지고 있다.

3.2 신경회로망 학습

신경회로망을 학습시키기 위한 방법으로 역전파 학습 알고리즘을 이용하였다. 각 뉴런의 특성을 결정짓는 활성화 함수로는 출력의 범위가 -1.0에서 1.0 까지인 bipolar sigmoid 함수를 사용하였고, 입력층에 제시된 데이터는 은닉층의 각 노드의 활성화 함수, 즉 시그모이드 함수에 의해 계산된다. 역전파 학습 알고리즘은 신경회로망을 통해 얻어진 출력값과 목표 출력값을 비교하여 그 차 이를 감소하는 방향으로 연결 강도(weight)를 조절하게 되는데 이러한 학습을 계속하여 원하는 결과를 얻을 때까지 반복하거나 지정된 학습 횟수만큼 학습을 한다. 본 연구에서는 학습 횟수를 5,000번 하여 결과를 얻었다.

학습 과정을 살펴보면 다음과 같다⁽³¹⁾. 먼저, 연결강도와 학습률(learning rate)을 초기화시키는데, 연결강도의 초기화 범위는 -1.0~1.0으로 하였고, 학습률은 0.1로 하였다. 초기화가 끝나면 학습 패턴을 정하는데 그 중 하나의 예를 들어 보면, 노면의 입력을 나타내는 Fig. 2(b), 최적 제어기에서 얻은 제어력, 그리고 목표 출력값을 나타내는 Fig. 4이다. 노면 입력값과 제어력은 입력 패턴이고, 목표 출력값은 출력 패턴이다.

$$\begin{aligned} \text{입력 패턴} &: z_1, z_2, z_3, \dots, z_{500}, \\ \text{목표 출력 패턴} &: d_1, d_2, d_3, \dots, d_{500}. \end{aligned} \quad (8)$$

입력 패턴과 목표 출력 패턴이 제시된 후, 첫 번째 은닉층에서는 연결강도 $w(1)$ 과 입력값 z_i 에 의해 출력값 $y(1)$ 이 식 (9)와 같이 계산된다.

$$\begin{aligned} z &\leftarrow z_i, \quad d \leftarrow d_i, \\ y(1)_j &= f(w(1)_j^t z), \quad \text{for } j = 1, 2, 3, \dots, 15. \end{aligned} \quad (9)$$

두 번째 은닉층에서는 식 (10)과 같이 연결강도 $w(2)$ 와 첫 번째 은닉층의 출력값 $y(1)$ 에 의해 $y(2)$ 값을 얻게 된다.

$$y(1)_k = f(w(2)_k^t y(1)), \quad \text{for } k = 1, 2, 3, \dots, 10. \quad (10)$$

출력층에서는 연결강도 $w(3)$ 과 두 번째 은닉층의 출력값 $y(2)$ 를 가지고 최종 출력값 o_l 을 식 (11)과 같이 얻게 된다.

$$o_l = f(w(3)_l^t y(2)), \quad \text{for } l = 1. \quad (11)$$

각 뉴런의 특성을 나타내는 활성화 함수 f 는 Fig. 6에서 보는 것처럼 bipolar sigmoid 함수로써 식 (12)와 같다.

$$f = \frac{2}{1 + \exp(-\lambda net)} - 1. \quad (12)$$

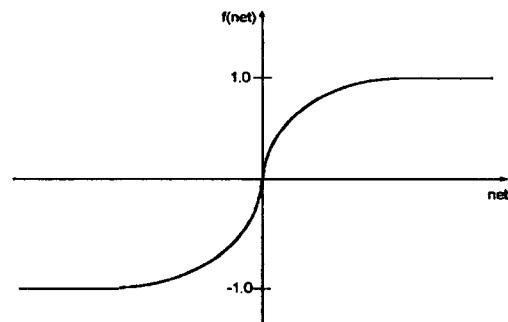


Fig. 6 Bipolar sigmoid function

여기서, λ 는 함수의 기울기를 의미하며 1로 가정하였다. 그리고 net 는 연결강도와 입력값의 곱을 의미한다.

출력층으로부터 결과값(o_l)이 계산되면 목표 출력(d_l)과의 오차를 계산하게 된다. 오차 E 를 구하기 위한 식은 다음과 같다.

$$E = \frac{1}{2} \sum_{l=1}^L (d_l - o_l)^2$$

$$= \frac{1}{2} \sum_{l=1}^L (d_l - f(\text{net}))^2, \quad \text{for } L = 1. \quad (13)$$

식 (14)에서 보는 바와 같이 텔타규칙⁽³¹⁾을 사용하여 오차를 줄이고, 오차가 줄어드는 방향으로 연결강도는 조절된다.

$$\begin{aligned} \delta &= -\frac{\partial E}{\partial(\text{net})} \\ &= -(d - f(\text{net}))f'(\text{net}). \end{aligned} \quad (14)$$

출력층에서의 δ 값은 식 (14)로부터 다음과 같이 얻을 수 있다.

$$\delta_{ol} = \frac{1}{2}(d_l - o_l)(1 - o_l^2), \quad \text{for } l = 1. \quad (15)$$

두 번째 은닉층에서의 δ 값은,

$$\begin{aligned} \delta_{y(2)k} &= \frac{1}{2}(1 - y_k^2) \sum_{l=1}^L \delta_{ol} w(3)_{lk}, \\ \text{for } k &= 1, 2, 3, \dots, 10. \end{aligned} \quad (16)$$

이고, 첫 번째 은닉층에서의 δ 값은 식 (17)과 같다.

$$\begin{aligned} \delta_{y(1)j} &= \frac{1}{2}(1 - y_j^2) \sum_{k=1}^K \delta_{y(2)k} w(2)_{kj}, \\ \text{for } j &= 1, 2, 3, \dots, 15. \end{aligned} \quad (17)$$

연결강도는 식 (18), 식 (19), 그리고 식 (20)에서와 같이 은닉층과 출력층에서 얻어진 δ 값을 이용하여 갱신된다.

$$\begin{aligned} w(3)_{lk}^{new} &= w(3)_{lk}^{old} + \eta \delta_{ol} y(2)_k, \\ \text{for } l &= 1 \\ k &= 1, 2, 3, \dots, 11 \end{aligned} \quad (18)$$

$$\begin{aligned} w(2)_{kj}^{new} &= w(2)_{kj}^{old} + \eta \delta_{y(2)k} y(1)_j, \\ \text{for } k &= 1, 2, 3, \dots, 10 \\ j &= 1, 2, 3, \dots, 16 \end{aligned} \quad (19)$$

$$\begin{aligned} w(1)_{ji}^{new} &= w(1)_{ji}^{old} + \eta \delta_{y(1)j} z_i, \\ \text{for } j &= 1, 2, 3, \dots, 15 \\ i &= 1, 2, 3, \dots, 19 \end{aligned} \quad (20)$$

식 (8)에서 식 (20)까지의 과정을 학습이라 하고, 하나

의 패턴이 학습을 마치게 되면 다른 패턴이 학습된다. 본 연구에서는, 하나의 로드가 500개의 패턴으로 되어 있고 10개의 로드를 모두 5,000번 학습하였다.

4. 뉴로 제어기 설계

뉴로 제어기의 구조와 학습 알고리즘은 시스템 규명에서 이용된 신경회로망 식별기의 것과 유사하다. Fig. 7은 뉴로 제어기의 신경회로망 구조를 나타내며, 입력층과 2개의 은닉층, 그리고 출력층으로 구성되어 있다. 입력층은 19개의 입력값들로 되어 있는데, 외란에 해당하는 노면의 입력 $w_1(k) \sim w_4(k)$, 최적 제어기로 부터 얻은 제어값 $u_1(k) \sim u_4(k)$, 그리고 플랜트의 출력값 중에서 heave motion인 vertical speed $v(k)$ 와 전단계의 노면 입력값 $w_1(k-1) \sim w_4(k-1)$, 전단계의 제어값 $u_1(k-1) \sim u_4(k-1)$, 전단계의 vertical speed $v(k)$, 그리고 편차(-1)이다. 첫 번째 은닉층은 편차가 포함된 19개의 입력노드와 15개의 출력노드를 가진다. 두 번째 은닉층은 16개의 입력노드와 10개의 출력노드로 되어 있다. 그리고 출력층에서는 11개의 입력노드와 4개의 출력노드로 구성되어 있다. 식별 신경회로망에서는 목표 출력값을 heave motion인 vertical speed $v(k)$,로 하였지만 뉴로 제어기에서의 목표 출력값은 최적 제어기로 부터 얻은 4개의 제어값 $u_1(k) \sim u_4(k)$ 이다.

뉴로 제어기는 오프라인 학습 방법에 의해 현장장치 제어기의 파라미터를 구하게 된다. 플랜트의 출력과 식별 신경회로망의 출력값과의 오차가 최소가 되도록 식별 신경회로망의 연결강도를 조절한 후, 이미 설정된 플랜트의 출력과 목표 출력값 사이의 오차가 최소가 되도록 뉴로 제어기를 학습시킨다. 뉴로 제어기의 학습 알고리즘으로는 신경회로망 식별기의 경우와 같이 역전파 학습 알고리

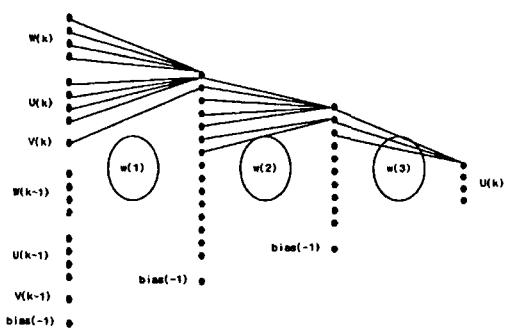


Fig. 7 Neuro-controller

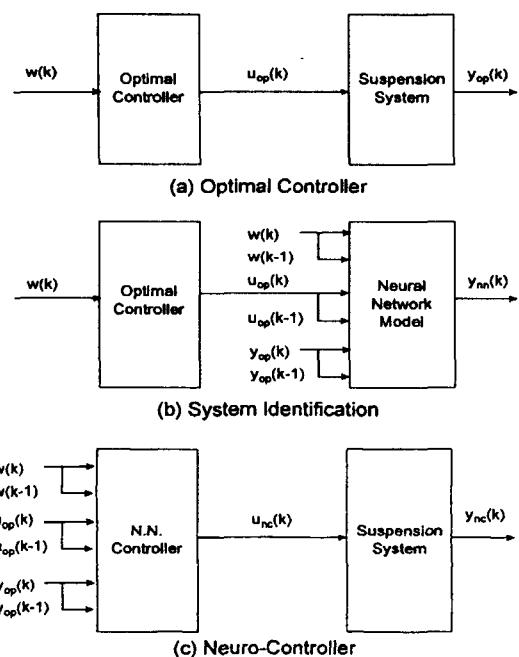


Fig. 8 Optimal controller, system identification, and neuro-controller

즘을 사용하여 뉴로 제어기의 출력값과 목표 출력값과의 오차를 감소시키는 방향으로 연결강도가 조정된다. 뉴로 제어기의 학습 과정을 이미 3장에서 설명하였던 신경회로망 식별기의 학습 과정과 비교하여 볼 때, 출력값이 1 개인 신경회로망 식별기와는 다르게 뉴로 제어기의 경우에는 출력값이 4개이기 때문에 $i=1, 2, 3, 4$ 인 것만이 다를 뿐, 학습 알고리즘은 신경회로망식별기와 거의 유사하다. 본 연구에서는 뉴로 제어기의 학습을 신경회로망 식별기에서 처럼 5,000번 실시하였다.

지금까지, 최적 제어기 설계와 신경회로망을 이용한 시스템 규명, 그리고 뉴로 제어기 설계에 대해 설명하였다. Fig. 8은 2, 3, 4장에서 설명하였던 내용을 간략하게 블록 다이어그램으로 나타낸 것이다. Fig. 8(a)는 노면 입력시 최적 제어기를 통해 얻어진 제어력이 현가장치를 제어하는 것을 보여주고, Fig. 8(b)는 노면 입력, 최적 제어기의 제어력, 그리고 플랜트의 결과값을 이용하여 신경회로망 식별기의 학습하는 과정을 보여준다. Fig. 8(c)는 신경회로망 식별기와 비슷한 방법으로 뉴로 제어기의 학습과정과 학습된 제어기에 의한 현가장치의 제어 과정을 보여준다.

5. 시뮬레이션

설계된 최적 제어기와 신경회로망 식별기 그리고 뉴로 제어기의 성능을 확인하기 위해 컴퓨터 시뮬레이션을 하였다. 본 연구에서는 Fig. 9와 같이 사인파형과 구형파형의 가상 범프를 선정하고 Table 2에서와 같이 크기와 모양을 다르게 하여 10개의 학습 로드와 2개의 테스트 로드를 선정하였다. Fig. 10은 높이가 0.1 m이고 폭이 0.5 m인 사인파형과 구형파형의 범프를 차량이 일정한 속도 20 km/h로 통과할 때, 1초 동안의 노면 입력 데이터를 의미한다. 샘플링 시간은 0.002 sec로 하였다.

Fig. 11은 Fig. 10과 같은 사인파형 노면 1과 구형파형 노면 6이 입력되었을 때, 최적 제어기와 학습된 신경회로망의 결과를 나타낸 것으로써, 실선은 최적 제어기를 통해 얻어진 차량의 7가지 출력 중 차체의 수직 속도인 heave motion을 의미한다. 점선은 학습된 식별 신경회로망의 결과를 나타낸다. Fig. 11에서 실선과 점선이 거의 일치함을 보이는데 이것은 신경회로망 식별기의 학습이 잘 되었음을 의미한다.

역전파 학습 알고리즘은 에러가 감소하는 방향으로 연결강도가 조절되는데, Fig. 12는 학습이 반복됨에 따라 에러가 점차 줄어드는 것을 보여 준다. 신경회로망을 학습시키는데 있어서 학습률은 중요한 변수가 될 수 있다. 학

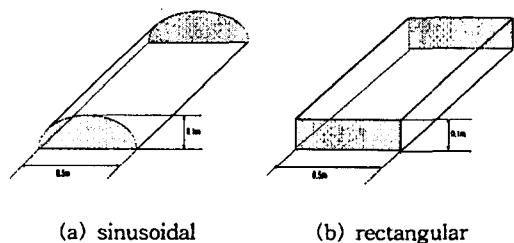


Fig. 9 Virtual bumps

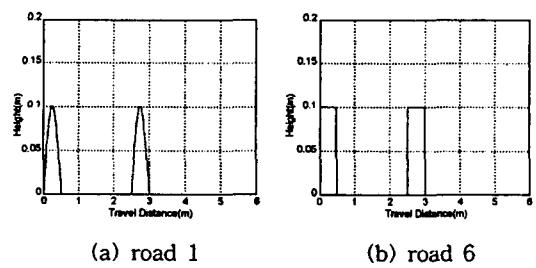
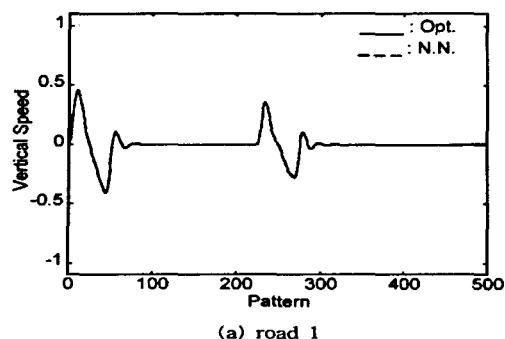
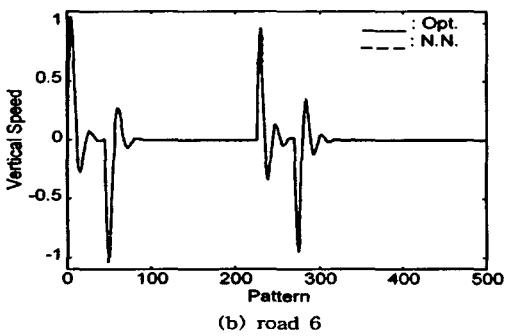


Fig. 10 Input data of the learning roads



(a) road 1



(b) road 6

Fig. 11 Response of trained neural network

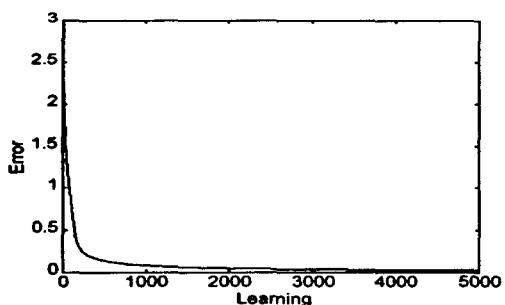
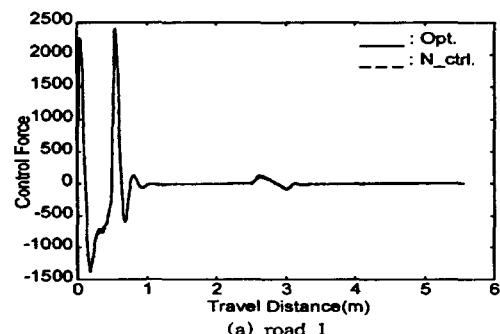


Fig. 12 Decreasing error of N.N. identifier

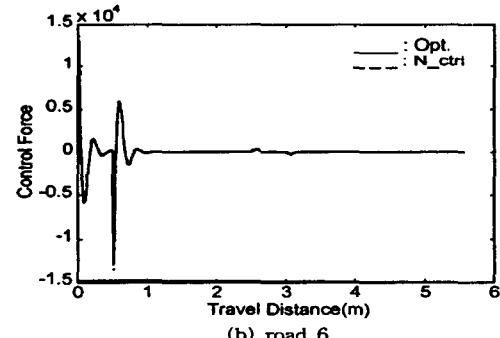
습률이 작으면 에러가 천천히 감소하여 학습 시간이 길어지게 되고 학습률이 크면 에러가 빨리 감소하지만 학습과정에서 불안정한 상태가 발생될 수 있다. 본 연구에서는 학습률을 0.1로 하여 신경회로망 식별기를 학습시켰다.

뉴로 제어기의 학습 결과를 살펴보기 위해 Fig 10과 같은 학습 데이터가 입력되되면, 뉴로 제어기는 4개 제어값을 출력하게된다. Fig. 13은 최적 제어기로 부터 얻은 제어값과 뉴로 제어기로부터 얻은 제어값을 비교한 것으로 4개의 제어값 중, front-left의 제어값을 나타낸다. 실선

은 최적 제어기의 결과이고 점선은 뉴로 제어기의 결과로 써 거의 일치함을 알 수 있다. Fig. 13 (a)는 차량이 사인파형의 범프를 통과할 때 최적 제어기와 뉴로 제어기로부터의 제어력을 나타내는 것이고, Fig. 13 (b)는 구형파형을 통과할 때 제어력을 나타내는 것으로, 구형파형을 지날 때 더 큰 제어력을 필요로 함을 알 수 있다. 뉴로 제어기의 학습 구조와 알고리즘은 신경회로망 식별기와 유사하여 에러가 감소하는 방향으로 연결강도가 조절된다. Fig. 14는 학습률을 0.1로 한 후, 학습이 진행됨에 따라 뉴로 제어기의 에러가 감소되는 것을 보여준다.



(a) road 1



(b) road 6

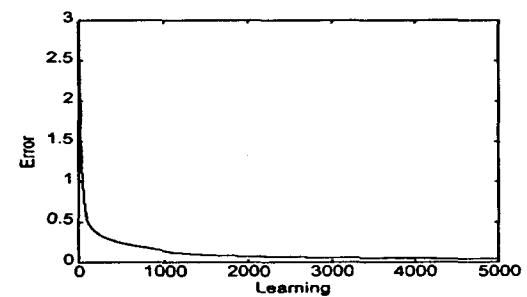
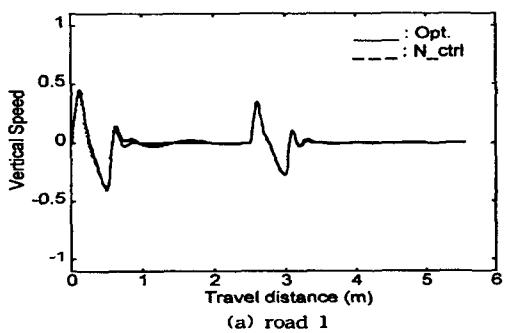
Fig. 13 Control force(u_{FL}) of optimal controller & neuro-controller

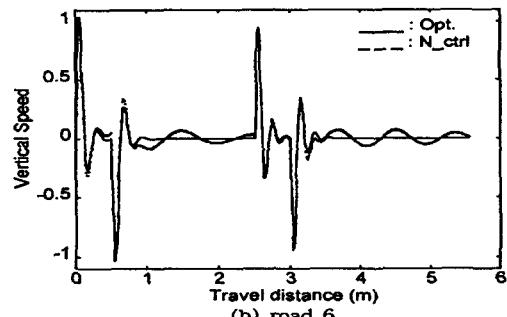
Fig. 14 Decreasing error of neuro-controller

뉴로 제어기에서 얻은 제어값을 플랜트에 적용하였을 경우, 그 때의 결과를 살펴보자. Fig. 15는 플랜트의 7가지 출력 중 차체의 수직 운동인 heave motion을 나타내면 실선은 최적 제어기의 제어값을 플랜트에 적용하였을 경우, 점선은 뉴로 제어기에서 얻어진 제어값을 플랜트에 적용하였을 경우 그 출력을 의미한다. 학습이 잘 된 뉴로 제어기는 최적 제어기를 사용하였을 경우와 비교하여 유사한 결과를 낼 수 있음을 알 수 있다.

이제, 학습되지 않은 데이터를 입력하였을 경우, 신경회로망 식별기와 뉴로 제어기의 성능을 확인하여 보자.

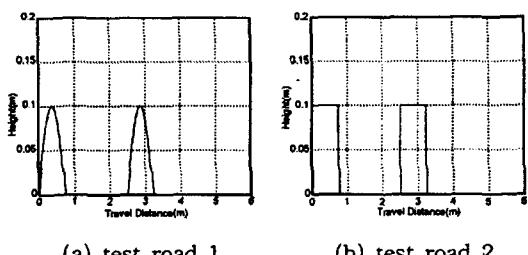


(a) road 1



(b) road 6

Fig. 15 Response of optimal controller & neuro-controller



(a) test road 1

(b) test road 2

Fig. 16 Input data of test roads

Fig. 16은 학습되지 않은 테스트 로드의 입력 데이터로 써 범프의 높이가 0.1 m이고 폭이 0.75 m인 사인파형과 구형파형의 가상범프이다. Fig. 16의 데이터가 신경회로망 식별기에 입력되었을 때, Fig. 17과 같은 응답을 얻을 수 있다. 실선은 목표 출력인 최적 제어기의 결과이고 점선은 신경회로망 식별기의 결과로써, 학습되지 않은 데이터라 할지라도 학습했던 데이터와 유사한 데이터라면 신경회로망은 좋은 결과를 낼 수 있다는 것을 알 수 있다. Fig. 16의 테스트 입력 데이터를 뉴로 제어기에 적용하였을 경우 Fig. 18과 같은 결과를 얻을 수 있다. 실선은 front-left 현가장치의 최적 제어기 제어값이고 점선은 뉴로 제어기에서 얻은 제어값이다. 신경회로망 식별기에서와 같이 뉴로 제어기는 학습되지 않은 데이터가 입력되어도 좋은 결과를 낼 수 있다.

계속하여 학습되지 않은 데이터를 통해 얻어진 Fig. 18의 최적 제어기와 뉴로 제어기의 제어값을 플랜트에 입력하였을 경우, 플랜트의 출력 중 heave motion은 Fig. 19와 같다. 최적 제어기와 비슷한 결과를 보여주고 있다. 컴퓨터 시뮬레이션 결과, 신경회로망은 학습했던 환경과 유사하거나 학습환경의 범위 안에서 좋은 결과를 낼 수 있음을 알 수 있다.

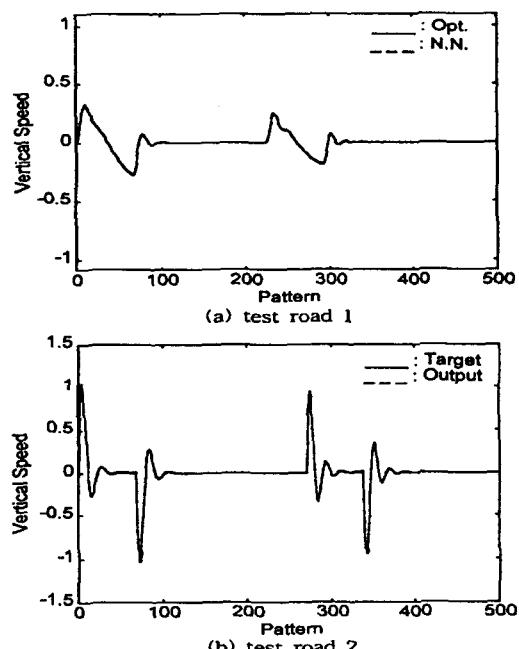


Fig. 17 Response of optimal controller & N.N. identifier

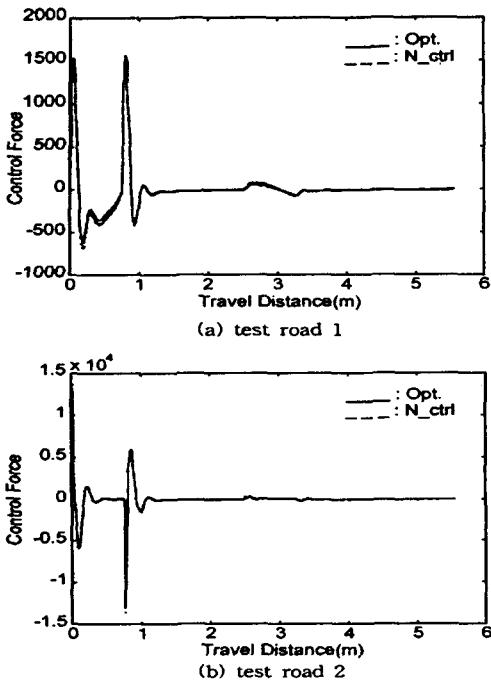


Fig. 18 Control force(u_{Fz}) of optimal controller & neuro-controller

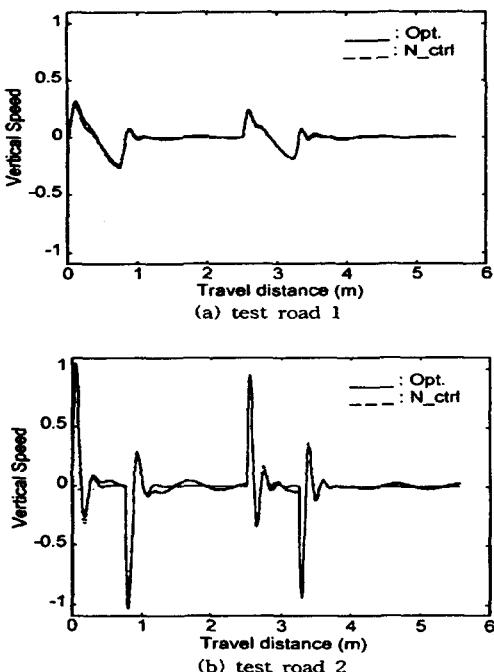


Fig. 19 Response of optimal controller & neuro-controller

6. 결 론

본 연구에서는 전체 차량을 대상으로 7자유도를 선정하여 각 운동에 대한 운동 방적식을 구하였다. 최적 제어 이론을 바탕으로 제어기를 설계한 후, 제어기가 부착되지 않은 수동형 현가장치와 성능을 비교하여 최적 제어기가 부착된 능동형 현가장치의 성능이 우수함을 보였다.

노면의 입력 데이터와 최적 제어기에서 얻은 데이터를 이용하여 현가장치에 대한 시스템 규명을 하였다. 신경회로망은 다수의 간단한 처리소자들로 구성되어 병렬 분산 처리가 가능하고 비선형이나 불확실한 시스템에 대한 모델링이 우수하다. 본 연구에서는 역전파 학습 알고리즘을 이용한 신경회로망을 능동형 현가장치의 모델링에 적용하였다. 학습이 잘 된 신경회로망 식별기는 이미 학습했던 데이터는 물론, 학습되지 않은 데이터라 할지라도 유사한 데이터라면 잘 적응할 수 있음을 알 수 있었다.

신경회로망 식별기의 구조와 학습 알고리즘이 유사한 뉴로 제어기를 설계한 후, 오프라인 제어 방법을 이용하여 실제 주어진 환경이 학습하였던 환경의 범위 안에 있다면, 결과를 미리 예측할 수 있어 예견제어의 기능을 할 수 있도록 하였다. 최적 제어기와 뉴로 제어기의 성능을 확인하기 위해 다양한 사인파형과 구형파형의 가상범프를 선정하여 컴퓨터 시뮬레이션을 하였다. 뉴로 제어기와 최적 제어기를 플랜트에 적용하였을 경우, 그 결과를 비교하였고 뉴로 제어기는 성능 면에서 최적 제어기와 유사함을 확인할 수 있었다. 뉴로 제어기 역시, 학습되지 않은 데이터라 할지라도 좋은 결과를 낼 수 있었다.

참 고 문 헌

1. M. Appleyard and P.E. Wellstead, "Active suspensions: some background," IEE Proc. Control Theory, vol. 142, no. 2, 1995.
2. Oueslati, F., and Sankar, S., "A Class of Semi-Active Suspension Schemes for Vehicle Vibration Control," Journal of Sound and Vibration, Vol. 172, No. 3, pp. 391~411, 1994.
3. 이경수, "능동/반능동 현가시스템 기술", 제어·자동화·시스템공학회 학회지 제2권 제2호, pp. 41~56, 1996.
4. 허승진, "자동차의 능동형 샤시시스템 개발동향".

- 제어·자동화·시스템공학회 학회지 제2권, 제2호, pp. 57~65, 1996.
5. 안세영, 양상식, “전체 차량 능동 현가 시스템을 위한 PID제어기의 설계,” 한국자동차공학회, 1994년 추계학술대회 논문집, pp. 36~42, 1994.
 6. 노태수, 정길도, 홍동표, “7 자유도 차량 모델과 출력 되먹임을 이용한 자동차 능동 현가장치 설계에 관한 연구,” KACC, Preceedings of the 11th KACC, pp. 871~875, 1996.
 7. Hac, A., Youn, I., “Optimal Semi-Active Suspension with Preview Based on a Quarter Car Model”, Transactions of the ASME, Vol. 114, pp. 84~92, Jan. 1992.
 8. Ray, L. R., “Robust Linear-Optimal Control Laws for Active Suspension Systems”, Transactions of the ASME, Vol. 114, pp. 529~598, Dec. 1992.
 9. 정우영, 김상우, 원상철, “능동 현가 시스템을 위한 H_2/H_∞ 제어기 설계,” KACC, Preceedings of the 11th KACC, pp. 888~891, Oct. 1996.
 10. C. Doyle, K. Glover, P. Khargonekar and B. Francis, “State Space Solution to Standard H^2 and H^∞ Control Problems,” IEEE Trnas. on Automatic Control, Vol. 34, No. 8, pp. 831~847, August 1989.
 11. P. Khargonekar and M. Rotea, “Mixed H_2/H_∞ control : A convex optimization approach,” IEEE Trans. on Automatic Control, vol 36, no. 7, pp. 824~837, 1991.
 12. 정길도, 윤광수, 김도균, “인공 신경망을 이용한 비선형 시스템의 규명”, KACC, 한국자동차제어학술회의 논문집, pp. 836~842, Sep. 1994.
 13. 김일영, 정길도, 노태수, 홍동표, “신경회로망을 이용한 현가장치의 폐회로 시스템 규명”, 한국정밀공학회, Vol. 14, No. 7, pp. 29~38, 1997.
 14. 성홍석, 이쾌희, “리아프노브 안정성이 보장되는 신경회로망을 이용한 비선형 시스템 제어,” 제어·자동화·시스템공학회 학회지 제2권, 제 3호, pp. 142~147, 1996.
 15. K. S. Narendra and K. Parthasarathy, “Identification and Control of Dynamic System Using Neural Networks,” IEEE Trans- actions on Neural Networks, vol. 1, no. 1, pp. 4~27, 1990.
 16. Si-Zhao Qin, Hong-Te Su, and Thomas J. McAvoy, “Comparison of Four Neural Net Learning Methods for Dynamic System Identification,” IEEE Transactions on Neural Networks, vol. 3, no. 1, pp. 122~130, 1992.
 17. Fu-Chang Chen and Hassan K. Khalil, “Adaptive Control of nonlinear systems using neural networks,” Int. J. Control, vol. 55, no. 6, pp. 1299~1317, 1992.
 18. Fu-Chuang Chen and Hassan K. Khalil, “Adaptive Control of Class of Nonlinear Discrete-Time Systems Using Neural Networks,” IEEE Transactions on Automatic Control, vol. 40, no. 5, pp. 791~801, 1995.
 19. A. U. Levin and K. S. Narendra, “Control of Nonlinear Dynamical Systems Using Neural Networks: Controllability and Stabilization”, IEEE Transactions on Neural Networks, vol. 4, no. 2, pp 192~206, 1993.
 20. A. U. Levin and K. S. Narendra, “Control of Nonlinear Dynamical Systems Using Neural Networks-Part II: Observability, Identification, and Control”, IEEE Transactions on Neural Networks, vol. 7, no. 1, pp 30~42, 1996.
 21. D. Psaltis, A. Sideris, and A.A. Yamamura, “A Multilayer Neural Network Controller”, IEEE Control System Magazine, vol. 8, pp. 17~21, 1988.
 22. 박재석, 박혁성, 김효준, 박영필, 양현석, “차량 현가제의 슬라이딩 모드 제어,” 한국자동차공학회, 1995년 추계학술대회 논문집, pp. 302~307, 1995.
 23. J.J.E. Slotine, “Sliding controller design for nonlinear systems,” Int. J. Contr., vol. 40, no. 2, pp. 421~434, 1984.
 24. Fengxi Zhou and D. Grant Fisher, “Continuous sliding mode control,” Int. J. Contr., vol. 55, no. 2, 313~327, 1992.

25. A. Alleyne and J.K. Hedrick, "Nonlinear Adaptive Control of Active Suspensions", IEEE Trans. on Control System Technology, vol. 3, pp. 94~101, 1995.
26. 배준영, 심재진, 김영범, 이두형, "승차감 개선을 위한 반능동형 현가시스템의 제어," 한국자동차공학회, 1995년 추계학술대회 논문집, pp. 495~500, 1995.
27. 윤일중, "Jerk를 고려한 능동과 반능동현가장치의 예견제어", 한국자동차공학회, 1994년 추계학술대회 논문집, pp. 43~49, 1995.
28. J. Karl Hedrick and A. V. Arslan, " Nonlinear Analysis of Rail Vehicle Forced Lateral Response and Stability", Transactions of the ASME, vol. 101, 1979.
29. G. W. Celniker and J. K. Hedrick, "Rail Vehicle Active Suspensions for lateral ride and stability improvement", Transactions of the ASME, vol. 104, 1982.
30. 강정식, 강이석, "자기부상열차 현가장치의 능동진동제어," KACC, Preceedings of the 11th KACC, pp. 876~879, 1996.
31. Zurada, J. M., "Introduction to Artificial Neural System," West Info Acess, pp. 185~190, 1922.