

신경회로망을 응용한 현가장치의 폐회로 시스템 규명

김 일 영*, 정 길 도**, 노 태 수***, 홍 동 표****

Empirical Closed Loop Modeling of a Suspension System Using Neural Network

Il Young Kim*, Kil To Chong**, Tae-Soo No***, Dong Pyo Hong****

ABSTRACT

A closed-loop system modeling of an active/semiactive suspension system has been accomplished through an artificial neural network. A 7DOF full model as a system's equation of motion has been derived and an output feedback linear quadratic regulator has been designed for control purpose. A training set of a sample data has been obtained through a computer simulation. A 7DOF full model with LQR controller simulated under several road conditions such as sinusoidal bumps and rectangular bumps. A general multilayer perceptron neural network is used for dynamic modeling and target outputs are fed back to the a layer. A backpropagation method is used as a training algorithm. Model validation for new dataset have been shown through computer simulations.

Key Words : Suspension(현가장치), Neural Network(신경회로망), Closed loop modeling(폐회로 시스템규명)

1. 서 론

자동차 문화가 급속히 진전됨에 따라 이제는 차량이 단순한 운송수단의 역할로 그치지 않고 더욱 편안하고 안전한 운행에 도움을 주는 방향으로 연구되고 있다. 이러한 기대에 따라 현가장치의 개발이 지능화되고 있다. 차량에 현가장치를 부착하는 이유는 여러 가지가 있다. 주행 중, 고르지 못한 노면이나 요철(凹凸)이 있는 곳을 지나게 될 때, 차체의 혼들림을 감소시켜 충돌감을 향상시키고 차륜의 진동을 억제하여 주행시 안정성을 유지할 수 있도록

한다. 또한 차체의 혼들림이 적어지면 차량의 부속품 및 차량 자체의 수명을 연장시킬 수 있고, 선회시 차량의 미끄러짐과 회전을 감소시켜 부드러운 핸들링을 유도할 수 있다. 또한, 트럭과 같은 무거운 차량의 혼들림이나 선회로 인한 도로의 파손을 예방할 수 있다.

현가 장치는 수동형, 능동형과 반능동형으로 나눌 수 있다⁽¹⁾⁽²⁾⁽³⁾. 수동형은 단순히 스프링과 댐퍼만으로 구성된 것으로써, 경제적이고, 신뢰도가 높지만 고유의 물리적 특성으로 인해 현저한 성능향상을 기대하기 어렵다. 이러한 한계점을 해결하는 방법으로 능동형 현가 장치를 개발

* 전북대학교 제어계측공학과

** 전북대학교 제어계측공학과

*** 전북대학교 우주항공공학과

**** 전북대학교 첨밀기계공학과

하기에 이르렀으며, 이는 스프링과 댐퍼가 없고 구동기를 이용하여 차체를 제어하도록 설계되었다. 능동형 현가 장치는 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. 이러한 이유 때문에 실용화되지 못하고 있다. 이러한 문제점들을 해결하는 방법으로 수동형과 능동형의 장점을 이용한 것이 반능동형 현가 장치이다. 반능동형 현가 장치는 수동형에 있는 스프링과 댐퍼를 사용하며, 제어기를 이용하여 스프링의 강도나 댐퍼내 오일 점도를 조절하도록 설계되었다. 경제적이고 성능 향상 면에 있어서도 능동형과 비슷한 결과를 얻을 수 있다. 제어기 설계 관점에서 볼 때 반능동형 현가 장치도 능동형 현가 장치에서처럼 구동기를 제어하는 제어 알고리즘을 필요로 한다.

능동형 현가장치의 연구를 살펴보면, PID 제어기를 이용하여 능동 현가장치의 주파수 응답 특성과 특정 도로 선정에 의한 시간 응답 특성에서 좋은 결과를 얻어 현가장치의 성능을 향상시킨 연구⁽⁴⁾가 보고되었으며, PID 제어이론뿐만 아니라, LQG/LQR 최적제어이론을 적용하여 능동 현가장치의 성능과 안정성을 한층 높이게 되었다⁽⁵⁾⁽⁶⁾⁽⁷⁾. 좋은 성능과 안정성을 보장하는 H_2 제어이론과 시스템의 불확실성이거나 외란에 대해 강인성을 갖는 H_∞ 제어이론의 장점을 취해 H_2 / H_∞ 제어이론이 능동 현가장치에 적용되어 연구되었다⁽⁸⁾. 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⁽⁹⁾. 그밖에, 슬라아딩 모드 제어이론⁽¹⁰⁾, sky_hook 제어이론⁽¹¹⁾, 그리고 예전 제어이론⁽¹²⁾ 등이 현가장치에 적용되고 있다. 현가장치는 자기부상열차에도 부착되어⁽¹³⁾ 균일하지 못한 선로나 불안정한 띠오름 상태에서도 승차감을 향상시킬 수 있도록 하고 있다. 성능이 우수한 현가장치를 개발하기 위해 제어이론뿐만 아니라 하드웨어 분야에서도 많은 연구가 진행되어야 한다. 그 중 댐퍼에 대한 연구가 활발한데 유압식 능동 현가장치에 대한 논문들이 다수 발표되었다⁽¹⁴⁾⁽¹⁵⁾⁽¹⁶⁾. 최근, 전기·전자 기술의 발달에 의해 센서와 컴퓨터를 이용한 전자 제어 방식의 능동 현가장치에 대한 연구도 발표되었다⁽¹⁷⁾.

본 논문에서는 자유도가 7인 전체 차량(Full Car)을 모델링하고 최적제어 이론을 바탕으로 제어 알고리즘을 구상한 후, 신경회로망을 이용하여 현가장치의 폐회로(Closed Loop)시스템을 규명하였다. 복잡한 동적 특성을 갖는 시스템의 경우 적응제어기법은 좋은 결과를 얻을 수 있으나 수학적 모델링을 정확히 알지 못하면 원하는 결과를 얻기가 어렵다. 원래 차량 모델은 비선형이고 시변시스템이므로 제어하는데는 계산이 복잡하고 오랜 처리시간을 필요로 하는 등 많은 어려움이 따른다. 이러한 문제점을 해결하기 위해, 비선형 특성을 잘 규명하고, 학습과 다수의 병렬처리연산의 기능을 가진 신경회로망을 이용하여 폐회로 현가장치의 시스템을 규명하고자 한다. 신경회로망의 구조는 Narendra⁽¹⁸⁾에 의해 제안된 형태를 이용하고 학습방법으로는 역전파(Back Propagation) 학습 알고리즘을 이용하였다. 본 논문의 구성을 살펴보면, 2장에서 차량의 모델링과 제어기를 설계하였고 3장에서 신경회로망에 관해 살펴 보았으며 4장에서는 컴퓨터 시뮬레이션을 통해 시스템규명과 검증을 살펴 보았다.

2. 차량 모델링과 제어기 설계

물체에 힘을 가하면 가속도가 생기는 뉴턴의 제 2 법칙을 이용하여 Fig. 1의 반능동형 현가 장치의 기본적인 운동 방정식을 세우면 다음과 같다.

$$\begin{aligned} \sum F &= Ma = M\ddot{x}, \\ M\ddot{x} &= -k(x - y) - c(\dot{x} - \dot{y}) + u. \end{aligned} \quad (1)$$

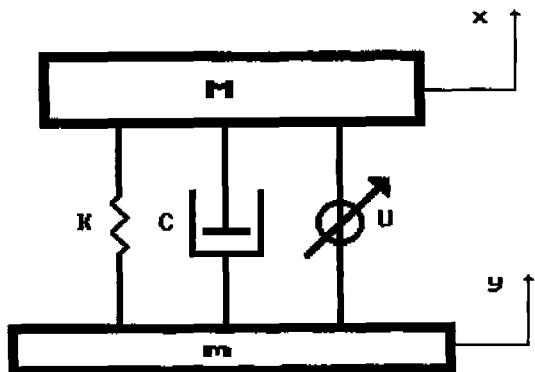


Fig. 1 Basic semi-active suspension system.

이 운동 방정식을 기초로 하여 전체 차량(Full Car)의 수학적 모델링 과정을 살펴보자⁽⁵⁾.

2.1 전체 차량(Full Car)의 모델링

1/4, 1/2 차량 모델은 차량의 부분적인 운동 특성을 파악하는데 유용하지만 차량 전체의 운동 특성을 알기에는 부족하다. Full Car의 자유도는 Fig. 2에서 보는 바와 같이 전·후 차륜 각각 2개씩해서 4 자유도(DOF)와 차체의 Heave 운동, Pitch 운동, 그리고 Roll 운동을 모두 합해 7 자유도를 갖는다. 핸들링과 관계되는 요(Yaw)운동을 비롯해 더 많은 자유도를 고려할 수 있지만, 본 연구에서는 이러한 운동은 고려하지 않고 7 자유도의 경우 정속 전진 운행하는 차량의 운동 방정식을 이용하였다. 모델링에 필요한 시스템의 파라미터는 Table 1에 나타내었다.

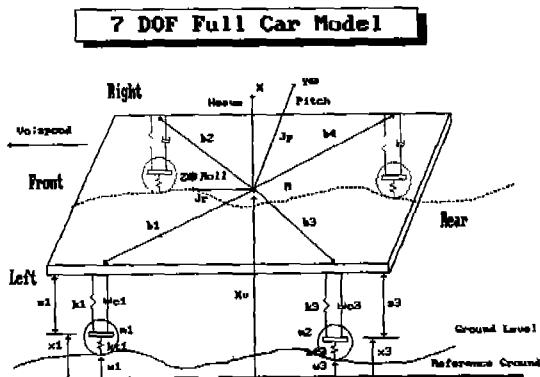


Fig. 2 Full car suspension system model.

Table 1. 7-DOF vehicle model parameters

M	700 kg	Vehicle Mass
J _p	1200 kg · m ²	Vehicle Pitch Moment of Inertia
J _r	1000 kg · m ²	Vehicle Roll Moment of Inertia
k _i	10000 N/m	4's Suspension Stiffness
c _i	250 N · s/m	4's Suspension Damping Coef.
m _i	25 kg	4's Tire Mass
K _i	178000 N/m	4's Tire Stiffness

먼저, 차체의 Heave 운동 방정식은 다음과 같다:

$$M\ddot{X}_v = \sum_{i=1}^4 F_i + \sum_{i=1}^4 U_i \quad (2)$$

여기서 $F_i = -K_i S_i - C_i \dot{S}_i$, ($i = 1, 2, 3, 4$)는 차체 M 에

대한 스프링과 댐퍼의 반발력을 나타내며, K_i 는 스프링 상수를, C_i 는 댐퍼 상수를, 그리고 S_i 는 Suspension Stroke를 의미하며 숫자 1은 전방좌측, 2는 전방우측, 3은 후방좌측, 4는 후방우측을 나타낸다. 그리고 U_i 는 각 현가 장치의 능동 제어력을 나타낸다.

차량의 Y축 방향 페치(pitch) 운동 방정식을 살펴보면 다음과 같다:

$$J_p \ddot{\theta} = \sum_{i=1}^4 (b_i \times F_i) \cdot e_2. \quad (3)$$

여기서 J_p 는 페치 관성 모멘트이고, $e_2 = (0 \ 1 \ 0)^T$ 는 차량 몸체 좌표계의 Y축을 나타내는 단위 벡터를 의미 한다. 그리고 $F_i = R \begin{bmatrix} F_i \\ 0 \\ 0 \end{bmatrix}$ 이다.

유사한 방법으로 Z축 방향 롤(Roll)의 운동을 방정식으로 나타내면,

$$J_r \ddot{\phi} = \sum_{i=1}^4 (b_i \times F_i) \cdot e_3. \quad (4)$$

이며, J_r 은 롤의 관성 모멘트를 의미하고, $e_3 = (0 \ 0 \ 1)^T$ 는 차량 몸체 좌표계의 Z축을 나타내는 단위 벡터이다.

그리고 차륜의 운동 방정식은 다음과 같다:

$$m_i \ddot{X}_i = -F_i - k'_i (X_i - w_i) - \sum_{j=1}^4 U_j \quad (5)$$

여기에서 k'_i 는 타이어의 강성계수(stiffness)이고, w_i 는 각 타이어가 접촉하고 있는 노면의 굴곡 상태를 의미한다. 4개 차륜의 운동 방정식은 현가 장치로 부터의 반발력 F_i 와 노면, 차륜 사이의 반발력 $k'_i(X_i - w_i)$, 그리고 제어력 U_j 로 표현할 수 있다.

식 (2)-(5)를 정리하여 상태방정식으로 표현하면 다음과 같다:

$$\dot{Z} = AZ + BU + GW, \quad (6)$$

상태 방정식에서의 각 상태 변수들은 다음과 같다.

$$z_1 = X_v \quad (\text{Vehicle Heave}),$$

$$z_2 = \theta \quad (\text{Vehicle Pitch}),$$

$$z_3 = \phi \quad (\text{Vehicle Roll}),$$

$$z_4 = X_1 \quad (\text{전방좌측 차륜 절대 변위}),$$

$$z_5 = X_2 \quad (\text{전방우측 차륜 절대 변위}).$$

- $z_6 = X_3$ (후방우측 차륜 절대 변위),
 $z_7 = X_4$ (후방우측 차륜 절대 변위),
 $z_8 = \dot{X}_v$ (Heave Rate),
 $z_9 = \dot{\theta}$ (Pitch Rate),
 $z_{10} = \dot{\phi}$ (Roll Rate),
 $z_{11} = \dot{X}_1$ (전방좌측 차륜 절대 속도),
 $z_{12} = \dot{X}_2$ (전방우측 차륜 절대 속도),
 $z_{13} = \dot{X}_3$ (후방좌측 차륜 절대 속도),
 $z_{14} = \dot{X}_4$ (후방우측 차륜 절대 속도),

$$Z = [z_1 \ z_2 \ z_3 \ z_4 \ z_5 \ z_6 \ z_7 \ z_8 \ z_9 \ z_{10} \ z_{11} \ z_{12} \ z_{13} \ z_{14}]^T$$

$$U = [u_1 \ u_2 \ u_3 \ u_4]^T, \quad W = [w_1 \ w_2 \ w_3 \ w_4]^T$$

을 의미한다.

2.2 제어기 설계

반능동형과 능동형 현가 장치는 제어 알고리즘을 이용하여 동작하는 제어기를 필요로 한다. 본 논문에서는 참 고문헌⁽⁵⁾⁽¹⁹⁾⁽²⁰⁾에 언급되어 있는 최적 제어 이론을 바탕으로 제어기를 설계하였다. 제어하고자 하는 차량 모델의 상태방정식이 식(6)과 같을 때 출력 되먹임 최적 제어 방법을 이용하여 제어기를 설계하였다. 출력 되먹임 최적 제어 방법은 출력을 이용하여 제어기를 설계할 수 있는 장점을 가지고 있다. 제어 입력 $u(t)$ 는 다음과 같다:

$$u(t) = -Ky(t) \quad (7)$$

그리고 LQR(Linear Quadratic Regulator) 제어기의 성능지수는 다음 식과 같다:

$$J = \frac{1}{2} \int_0^\infty (Z^T Q Z + u^T R u) dt. \quad (8)$$

성능지수를 최소로 하는 $u(t)$ 를 얻기 위해 먼저 K (Kalman Gain)를 구한다. K 값은 Riccati Equation과 Lyapunov Equation을 풀기 위한 Matlab software를 이용하였다.

Fig. 3은 차량이 일정한 속도(20 km/h)로 전진 운행하고 있을 때, 전방좌측 차륜에 전달되는 노면의 입력 상태를 나타낸 것이다. 노면 입력에 대한 실험 결과로써 Fig. 4는 제어기가 없는 상태의 차체의 Heave 운동을 의미하는데 많은 진동이 있음을 알 수 있다. 반면에, Fig. 5는 출력 되먹임 제어기에 의해 얻어진 결과를 나타낸 것

으로 진동수가 많이 감소하여 승차감이 월등히 좋아졌음을 알 수 있다.

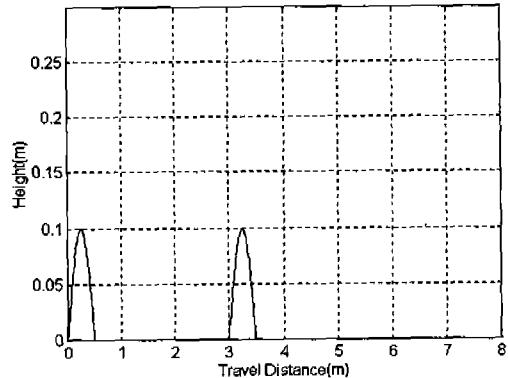


Fig. 3 Bump input with constant speed.

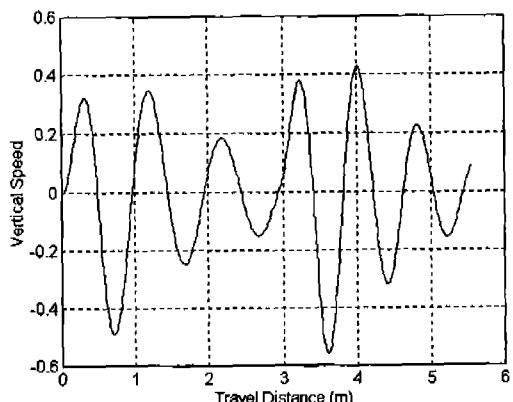


Fig. 4 Heave motion without controller.

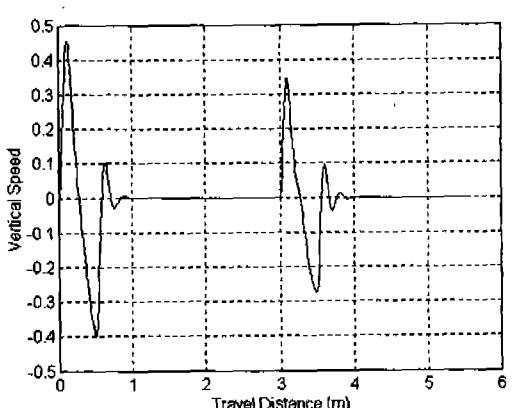


Fig. 5 Heave motion with controller.

3. 신경회로망

지금까지 전체 차량을 모델링하고 최적 제어기를 설계하여 그에 대한 응답을 살펴 보았다. 이제, 입력값과 제어기에서 얻은 결과를 이용하여 실시한 신경회로망 폐회로 시스템의 모델링을 살펴보자.

3.1 신경회로망 설계

기본적인 신경회로망 구조는 Narendra에 의해 소개된 것으로 Fig. 6에 나타나 있다. 신경회로망의 입력층은 모두 19개의 입력값들을 가진다. 4개의 차륜에 접촉되는 불규칙한 노면에 의한 입력값 $w_1(k) \sim w_4(k)$, 노면 입력시 최적 제어로직에서 얻은 Suspension 제어력 $u_1(k) \sim u_4(k)$, 노면 입력의 전단계 값 $w_1(k-1) \sim w_4(k-1)$ 제어력의 전단계 값 $u_1(k-1) \sim u_4(k-1)$ 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, 은닉층 1에서는 편차를 포함하여 19개의 입력노드와 15개의 출력노드로 구성되어 있고, 은닉층 2에서는 16개의 입력노드와 10개의 출력노드로 되어 있다. 출력층은 11개의 입력노드와 1개의 출력노드로 구성되어 있다.

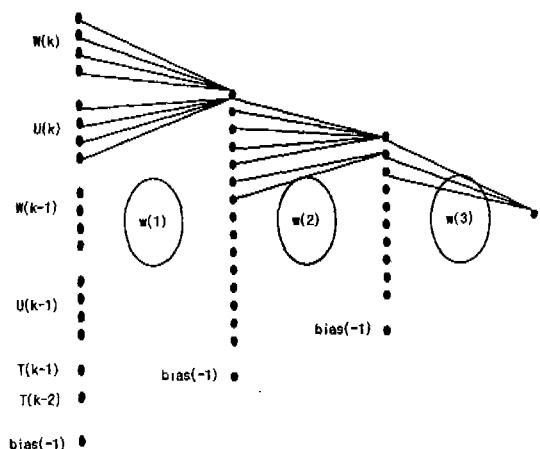


Fig. 6 Neural network introduced by Narendra.

신경회로망을 학습시키기 위해서는 입력데이터와 목표 출력데이터가 필요하다. 입력데이터는 Fig. 3에서 보는 것처럼 노면의 입력 상태(W)와 노면의 입력시 제어로직을 통해 얻어진 제어력(U)이다. 1개의 입력 패턴은 19개

의 입력값이고 1개의 로드는 500개의 패턴으로 되어 있다. 전체 로드의 종류는 Table 2에서처럼 10가지의 샘플링 로드와 2가지의 테스트 로드이며 10개의 샘플링 로드는 신경회로망을 학습하는데 이용되고 2개의 테스트 로드는 최종적으로 학습된 신경회로망의 성능을 검증하는데 사용된다. 목표 출력 데이터는 Fig. 5에서처럼 최적 제어기를 통해 얻어진 차체의 Heave 운동을 나타내는 값들이다. 전체 10개의 로드는 각각 500개의 입/출력 패턴을 가지고 있다.

Table 2. Bumps used in simulation.

(단위 : m)

종류 (ROAD)	왼쪽 차륜에 끊는 범프		오른쪽 차륜에 끊는 범프	
	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.)	0.5	0.15	0.5	0.15
Test 2 (rec.)	0.5	0.15	0.5	0.15

3.2 신경회로망 학습

신경회로망의 학습 알고리즘으로 역전파 알고리즘을 이용하였다. 활성화 함수로서 출력의 범위가 -1.0에서 1.0 까지인 bipolar sigmoid 함수를 사용하였고, 입력층에 제시된 데이터는 은닉층의 각 노드의 활성화 함수, 즉 시그모이드 함수에 의해 계산되었다. 역전파 알고리즘은 신경회로망을 통해 얻어진 출력값과 목표 출력값을 비교하여 그 차이를 감소하는 방향으로 연결 강도(weight)를 조절하게 되는데 이러한 학습을 계속하여 원하는 결과를 얻을 때까지 반복한다. 또는 지정된 학습 횟수만큼 학습을 한다. 본 연구에서는 학습 횟수를 3,000번 하여 결과를 얻었다.

학습 과정을 살펴보면 다음과 같다⁽²¹⁾. 먼저, 연결강도와 학습률(learning rate)을 초기화시키는데, 연결강도의 초기화 범위는 -1.0 ~ 1.0이고, 학습률은 0.01, 0.1, 그리고 0.5의 3가지로 고려하여 학습시켰다. 초기화가 끝나면 학습 패턴을 정하는데 이미 현가장치 플랜트를 통

해 의해 얻어진 입/출력값으로, 그 중 하나의 예가 Fig. 3과 Fig. 5에서 보는 것처럼 각각 입력 패턴과 목표 출력 패턴이다.

$$\begin{array}{ll} \text{입력 패턴} & : z_1 \ z_2 \ z_3, \dots, z_{500} \\ \text{목표 출력 패턴} & : d_1 \ d_2 \ d_3, \dots, d_{500} \end{array}$$

입력 패턴이 제시된 후, 은닉층1에서 연결강도 $w(1)$ 와 입력값 z_i 에 의해 출력 식(9)와 같이 $y(1)$ 이 계산되고,

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

은닉층2에서는 연결강도 $w(2)$ 와 은닉층1의 출력값 $y(1)$ 에 의해 식(10)을 이용하여 $y(2)$ 값을 얻는다.

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

출력층에서는 연결강도 $w(3)$ 과 은닉층2의 출력값 $y(2)$ 를 가지고 최종 출력값 o_l 을 식(11)과 같이 계산한다.

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

각 뉴런의 특성을 나타내는 활성화 함수 f 는 bipolar 시그모이드 함수로서 식(12)로 표현되며,

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

함수 f 의 기울기 λ 의 값을 1로 정했다. 그리고 net 는 연결강도와 입력값의 합을 의미한다.

출력층으로부터 결과값 (o_l)이 계산되면 목표 출력 (d_l)과의 오차를 계산하게 된다. 오차 E 는 식(13)으로부터 계산된다:

$$\begin{aligned} E &= \frac{1}{2} \sum_{l=1}^L (d_l - o_l)^2 \\ &= \frac{1}{2} \sum_{l=1}^L (d_l - f(net))^2 \quad , \text{for } l = 1, 2, \dots, L \quad (13) \end{aligned}$$

오차를 줄이기 위해 식(14)의 델타 규칙[21]을 사용하여 연결강도를 조정하게 된다.

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

출력층에서의 δ 값은 식(14)로부터 다음과 같이 얻을 수 있다.

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

은닉층2에서의 δ 값은,

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

이고, 은닉층1에서의 δ 값은,

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

이다.

은닉층과 출력층에서 δ 값을 얻게 되면, 오차를 줄이는 방향으로 연결강도를 조절하며, 식(18), (19), (20)에 의해 연결강도가 갱신된다.

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

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

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

하나의 패턴이 학습을 마치게 되면 또 다른 학습 패턴이 앞에서 설명한 알고리즘을 통해 학습하게 된다. 하나의 로드는 모두 500개의 패턴으로 되어 있고 10개의 셈플링 로드를 학습하였을 때, 이를 1 Try라 하였다. 본 연구에서는 모두 3,000 Try하였다.

4. 컴퓨터 시뮬레이션

신경회로망을 학습시키는데 필요한 데이터는 차량이 시속 20km/h의 정속 전진 운동을 하며 범프를 지난다고 가정한 상태에서 얻은 값들이다. 가상범프는 Fig. 7에서처럼 사인파형과 구형파형으로 높이와 길이가 다른 10가지의 샘플링 로드와 2가지의 테스트 로드이며 Table 2에

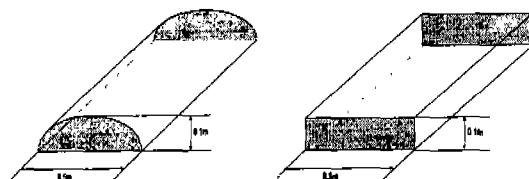
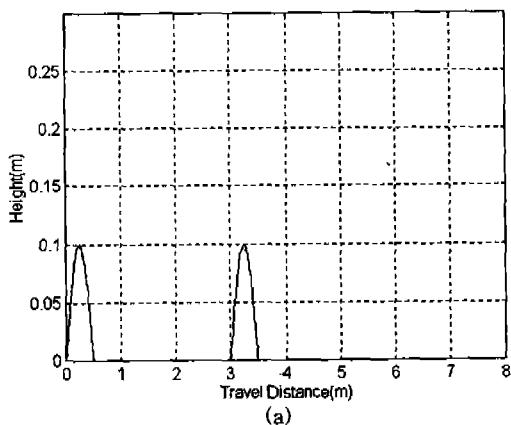
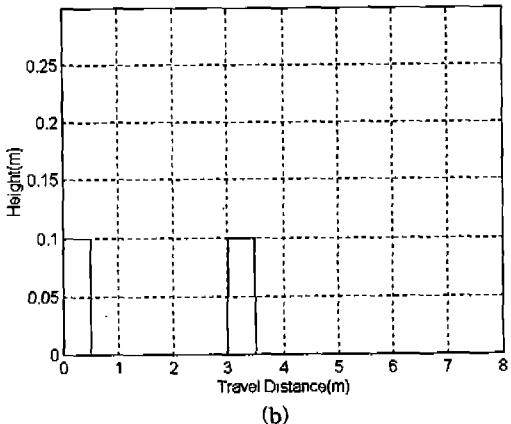


Fig. 7 Sinusoidal & rectangular bumps



(a)

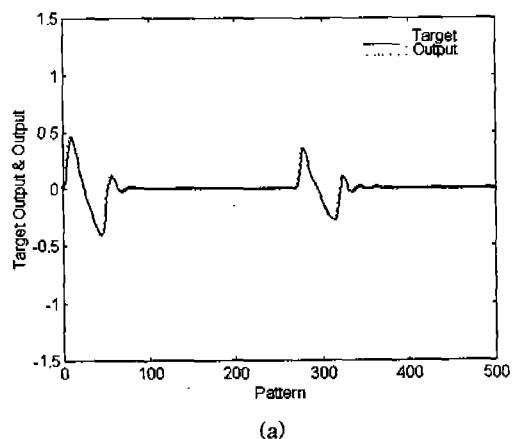


(b)

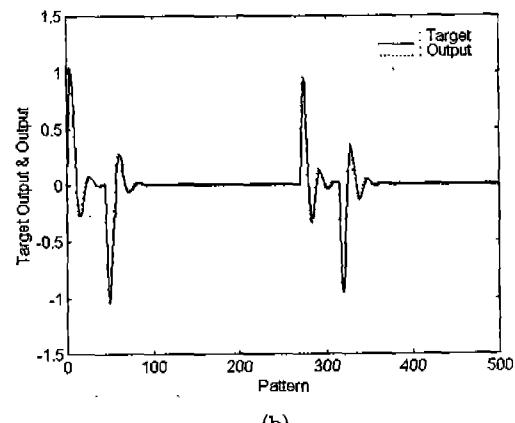
Fig. 8 Inputs of the sampling roads:
(a) road1, (b) road6

서 보는 것과 같다. 앞바퀴가 범프에 닿은 순간부터 1초의 시간이 흐르는 동안 데이터를 얻으며 샘플링 주기는 0.002 sec로 하였다. Fig. 8은 전체 10개의 샘플링 로드 중에서 road 1과 road 6, 2개만을 선정한 것으로써 (a)는 범프의 폭이 0.5m 높이는 0.1m인 사인파형의 가상범프 입력이고, (b)는 폭이 0.5m 높이가 0.1m의 구형파형의 가상범프 입력을 나타낸다. Fig. 9은 학습된 신경회로망을 통해 얻은 차체 heave 운동의 과도 반응으로 실선은 목표 출력을 나타내고 점선은 신경회로망의 출력을 나타낸다. (a)는 road 1의 결과를 (b)는 road 6의 결과를 나타낸 것으로 목표출력과 신경회로망의 출력이 거의 일치함을 볼 수 있고 이로써 학습이 잘 되었음을 알 수 있다.

Fig. 10은 학습률을 0.01, 0.1 그리고 0.5 각각의 경우에 따른 신경회로망의 출력값과 목표출력값의 차이인



(a)



(b)

Fig. 9 Responses of trained heave motion:
(a) road1, (b) road6

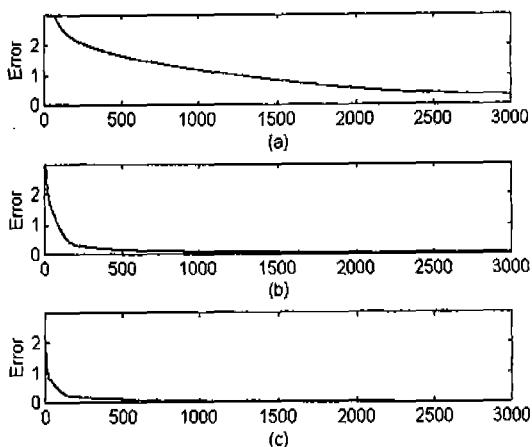


Fig. 10 Training errors:
(a) $\eta = 0.01$, (b) $\eta = 0.1$, (c) $\eta = 0.5$

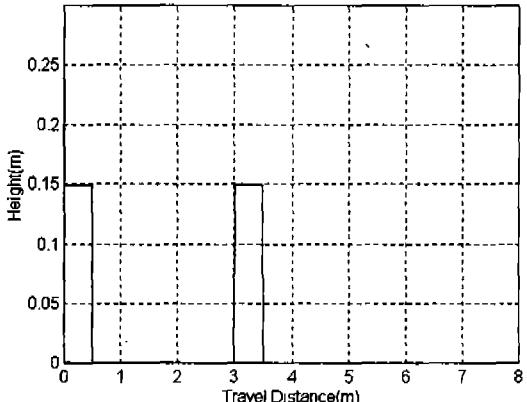
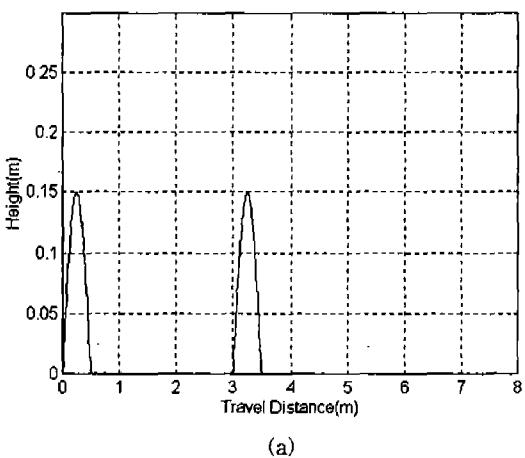


Fig. 11 Inputs of the test roads:
(a) test road1, (b) test road2

에러의 감소 곡선을 나타낸다. 학습의 횟수가 증가함에 따라 점차 에러가 감소함을 볼 수 있으며 학습률이 0.01의 경우는 0.1의 경우보다 에러의 감소율이 작아 에러가 수렴하기까지는 오랜 시간을 필요로 한다. 그리고 학습률이 $\eta=0.5$ 경우엔 수렴속도는 빠르지만 에러 수렴 근처에서는 $\eta=0.1$ 의 경우보다 채터링(chattering) 현상이 크게 일어난다. 따라서 학습시간과 학습 정확성의 상충조건을 trade off하여 적절한 학습률의 선택이 필요하다. 본 연구에서는 학습률을 0.1로 하여, 3,000 Try 학습시킴으로써 현가장치의 폐회로 시스템을 규명하였다.

위에서 얻은 신경회로망 모델이 시스템을 적절히 규명하였는지 검증하기 위해 Table 2의 테스트 로드 2개 즉, 폭이 0.5m 높이가 0.15m인 사인파형 가상범프와 구형파의 가상범프를 선정하여 학습된 신경회로망의 성능을 검증해 보았다. 물론 이 테스트 로드의 데이터는 학습되

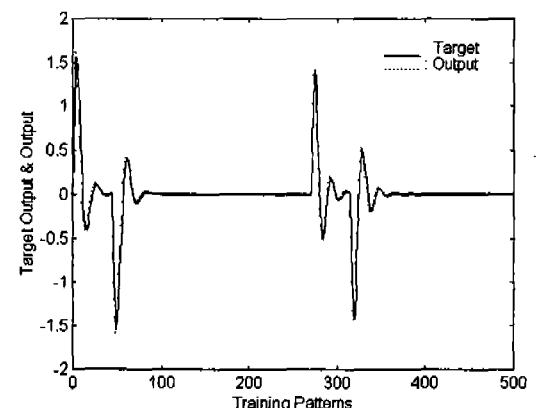
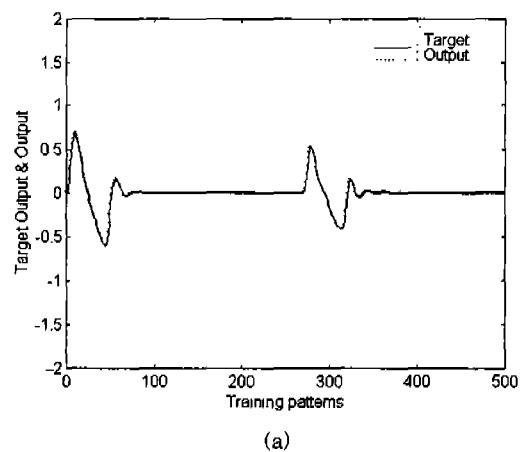


Fig. 12 Responses of heave motion:
(a) test road1, (b) test road2.

지 않은 데이터이다. Fig. 11은 테스트 로드의 입력 상태를 나타내고 Fig. 12은 신경회로망을 통해 얻은 결과로써, heave 운동을 나타낸다. 학습되지 않은 데이터라 할지라도 이미 학습된 데이터와 유사하거나 또는 학습 범위 내의 값이라면 신경회로망은 잘 적용할 수 있음을 알 수 있다. 이는 시스템을 모델링하는 과정에서 모델의 불확실성과 잡음에 대해 신경회로망이 강인함을 갖는다는 것을 의미한다.

5. 결 론

7 자유도를 갖는 전체차량에 대해 수학적 운동방정식을 유도하였다. 출력 되먹임 제어기를 설계한 후, 제어기가 부착되지 않은 상태와 최적 제어기를 이용하였을 때와의 결과를 과도 시간 응답에서 살펴보고 최적 제어기 성능의 우수함을 확인하였다. 범프 모양을 사인파형과 구형파형으로 정하였고 범프의 종류로는 학습에 사용되는 샘플링 로드 10가지와 학습된 신경회로망의 성능을 테스트하기 위해 테스트 로드 2가지를 선정하였다.

신경회로망을 학습시키기 위한 데이터는 샘플링 로드의 입력값과 최적 제어기에서 얻은 출력값, 즉 목표 출력값으로 하였다. 신경회로망은 Narendra에 의해 소개된 것으로 동적 시스템을 모델링하는데 유용한 teacher forcing 방법이었고, 학습 방법은 오차 역전파 학습 알고리즘으로 엘타규칙에 의해 에러를 최소화하도록 연결강도를 조절하였다. 학습률을 달리하여 에러의 감소 특성을 살펴보았다. 학습된 데이터와 학습되지 않은 데이터를 가지고 학습된 신경회로망에 적용해 보아 학습하지 않았던 데이터도 잘 적용하여 폐회로 현가장치에 대한 시스템 모델링이 잘 되었음을 알 수 있었다.

참 고 문 헌

- 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.
- 이경수, "능동/반능동 현가시스템 기술", 제어·자동화·시스템공학회 학회지 제2권 제2호, pp. 41-56, 1996.
- 허승진, "자동차의 능동형 현가시스템 개발동향", 제어·자동화·시스템공학회 학회지 제2권, 제2호, pp. 57-65, 1996.
- 안세영, 양상식, "전체 차량 능동 현가 시스템을 위한 PID제어기의 설계," 한국자동차공학회, 1994년 추계학술대회 논문집, pp. 36-42, 1994.
- 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.
- 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.
- Ray, L. R., "Robust Linear-Optimal Control Laws for Active Suspension Systems", Transactions of the ASME, Vol. 114, pp. 529-598, Dec. 1992.
- 정우영, 김상우, 원상철, "능동 현가 시스템을 위한 H^2 / H^∞ 제어기 설계," KACC, Preceedings of the 11th KACC, pp. 888-891, Oct. 1996.
- 정길도, 윤광수, 김도균, "인공 신경망을 이용한 비선형 시스템의 규명," KACC, 한국자동차제어학술회의 논문집, pp. 836-842, Sep. 1994.
- 박재석, 박혁성, 김효준, 박영필, 양현석, "차량 현가계의 슬라이딩 모드 제어," 한국자동차공학회, 1995년 추계학술대회 논문집, pp. 302-307, 1995.
- 배준영, 심재진, 김영범, 이두형, "승차감 개선을 위한 반능동형 현가시스템의 제어," 한국자동차공학회, 1995년 추계학술대회 논문집, pp. 495-500, 1995.
- 윤일종, "Jerk를 고려한 능동과 반능동현가장치의 예견제어," 한국자동차공학회, 1994년 추계학술대회 논문집, pp. 43-49, 1995.
- 강정식, 강이석, "자기부상열차 현가장치의 능동진동제어," KACC, Proceedings of the 11th KACC, pp. 876-879, 1996.
- 손영준, 이광희, 박성환, 이진걸, "능동 현가시스템의 성능평가를 위한 유압식 시험기의 설계 및 제어에 관한 연구," KACC, Proceedings of the 11th KACC, pp. 1445-1449, 1996.

15. 장성욱, 박성환, 이진걸, "유압식 능동 현가시스템의 개발에 관한 연구," KACC, Preceedings of the 11th KACC, pp. 1459-1464, 1996.
16. Kim, W., Lee, B. Y., Kim, S. W., Won, S. C., "Force Control of an Asymmetric Hydraulic Cylinder for Active Suspensions", KACC, Preceedings of the 11th KACC, pp. 1124-1127, Oct. 1996.
17. 신현정, 조성호, 이상권, 두민수, "전자제어 현가장치용 차고센서," 한국자동차공학회, 1994년 추계 학술대회 논문집, pp. 249-254, 1994.
18. Narendra, K. S. and Parthasarathy, K., "Identification and Control of Dynamic System Using Neural Networks," IEEE Transactions on Neural Networks, Vol. 1, No. 1, pp. 4-27, 1990.
19. 노태수, "다몸체 시스템의 운동방정식 형성 방법," 한국항공우주학회지, 제22권, 제6호, 1994.
20. 노태수, "다몸체 시스템 운동 해석 소프트웨어의 개발과 무궁화위성 자세 동력학 시뮬레이션에 관한 연구," 한국항공우주학회, 춘계학술발표회 논문 초록집, 1996.
21. Zurada, J. M., "Introduction to Artificial Neural System," West Info Access, pp. 185-190, 1992.