

## 효율적인 신경망 부싱모델을 위한 신경망 구성 최적화

이 승 규<sup>1)</sup> · 김 광 석<sup>2)</sup> · 손 정 현<sup>3)</sup>

부경대학교 기계공학부 대학원<sup>1)</sup> · 인하공전 자동차과<sup>2)</sup> · 부경대학교 기계공학부<sup>3)</sup>

### Optimization of Neural Network Structure for the Efficient Bushing Model

Seungkyu Lee<sup>1)</sup> · Kwangsuk Kim<sup>2)</sup> · Jeonghyun Sohn<sup>3)</sup>

<sup>1)</sup>Graduate School of Mechanical Engineering, Pukyong National University, Busan 608-739, Korea

<sup>2)</sup>Department of Automotive Engineering, Inha Technical College, Incheon 402-752, Korea

<sup>3)</sup>Department of Mechanical Engineering, Pukyong National University, Busan 608-739, Korea

(Received 25 November 2006 / Accepted 29 January 2007)

**Abstract** : A bushing component of a vehicle suspension system is tested to capture the nonlinear behavior of rubber bushing element using the MTS 3-axes rubber test machine. The results of the tests are used to model the artificial neural network bushing model. The performances from the neural network model usually are dependent on the structure of the neural network. In this paper, maximum error, peak error, root mean square error, and error-to-signal ratio are employed to evaluate the performances of the neural network bushing model. A simple simulation is carried out to show the usefulness of the developed procedure.

**Key words** : Artificial neural network(인공신경망), Bushing(부싱), Hysteresis response(히스테리시스 응답), Vehicle dynamics analysis(차량 동역학 해석), Neural network structure(신경망 구조)

#### 1. 서론

일반적으로 부싱(bushing)은 외부에 금속재질의 실린더(cylinder) 형 슬리브(sleeve)와 내부에 금속 실린더 로드(rod)를 포함하는 탄성 중공 실린더로 구성되어 있다. 금속재질의 관은 현가장치에 연결되어 있고, 휠에서 현가장치에 힘을 전달한다. 고무 부싱은 변위와 주파수에 대해서 비선형적인 특성을 가지며 주기적인 가진에 대해서도 이력반응(hysteretic response)을 나타낸다.

다물체 동역학 해석 프로그램인 ADAMS<sup>1)</sup>에서는 부싱을 세 방향의 병진 스프링-댐퍼(spring-damper)와 세 방향의 회전 스프링-댐퍼의 선형 조합으로 표현되는 켈빈-보이트(Kelvin-Voight) 모형

으로 표현하고 있다. 그러나 이러한 부싱으로는 부싱의 히스테리시스 특성을 제대로 표현할 수 없다. 따라서 차량동역학 해석을 위한 새로운 부싱모델이 요구된다.

최근 널리 이용되고 있는 인공 신경망 알고리즘의 사용이 대안이 될 수 있다. Barber<sup>2)</sup>는 신경망을 이용하여 부싱 및 속 업소마의 비선형 특성을 반영할 수 있음을 보였다. Sohn<sup>3)</sup>은 인공신경망을 이용하여 반경방향 부싱모델을 개발하였고 차량동역학 시뮬레이션에 적용하였다.

하지만, 신경망 모델의 성능은 신경망의 구성과 아주 밀접하게 관련되어 있어서 어떻게 신경망을 구성하느냐에 따라 계산효율성 및 정확성이 좌우된다. 신경망의 특성상 정해진 규칙이 없어서 대부분 시행착오를 거쳐서 적당한 구성을 하게 된다.

<sup>\*</sup>Corresponding author, E-mail: jhsohn@pknu.ac.kr

본 논문에서는 부상의 신경망 구성에 있어서 은닉층(hidden layer)의 개수와 뉴런(neuron)의 개수가 학습(learning) 및 예측(prediction)에 어떠한 영향을 미치는지 파악하여 최적의 부상 신경망을 구축하는데 그 목적이 있으며, 개발된 절차를 이용하면 비슷한 경우에 있어서 시행착오를 줄일 수 있게 된다. 2장에서는 부상 특성을 실험한 장치를 설명하였고, 3장에서는 신경망 모델을 설명하였으며, 4장에서는 신경망 구성에 따른 성능을 분석하였고 결론은 5장에 나타내었다.

## 2. 부상 시험

부상의 특성을 시험하기 위해 Fig. 1과 같은 MTS 3축 시험기를 이용하였고, 시험기는 동적 힘  $\pm 25$  kN, 주파수 80 Hz까지 측정 가능하다.




Fig. 1 Jig to test a bush

본 논문에서 사용한 부상은 현가장치를 차체에 고정할 때 사용되는 X/MBR 타입의 부상으로, 실험에 사용된 부상과 제원을 Fig. 2와 Table 1에 각각 나타내었다.




Fig. 2 Bushing configuration

Table 1 Specifications of test bushing (Unit : mm)

Outer steel diameter ( $d_o$ )	50
Inner steel diameter ( $d_i$ )	15
Length ( $l$ )	63
Outer steel thickness ( $t$ )	3

신경망 학습 및 검증에 위해 랜덤 가진 시험을 하였고, 랜덤 입력 데이터는 MTS의 CRPCIII 소프트웨어를 통해 구성하였으며, 진폭은 Fig. 3와 같은 형태로 표현될 수 있는데,  $f$ 는 주파수를 의미하며, 본 연구에서는  $n$ 의 값을 2.5, 3.0, 3.5로 바꾸어가면서 시험하였다. 또한, 최대 진폭(peak value)을 3.0mm로 하였다. Fig. 4에 신경망 학습을 위해 사용된 시험의 가진 변위를 나타내었고, Fig. 5에 부상력을 나타내었다. 학습데이터의 최대 부상력은 3069N이다. 또한, Fig. 6에 검증시 사용된 부상변위를, Fig. 7에 부상력을 각각 도시하였다. 검증데이터의 최대 부상력은 3057N이다.




Fig. 3 Amplitude of the random input




Fig. 4 Bushing displacement for the learning




Fig. 5 Bushing force for the learning




Fig. 6 Bushing displacement for the verification




Fig. 7 Bushing force for the verification

### 3. 신경망 부상 모델

#### 3.1 신경망 구성

신경망 알고리즘은 블랙박스(black-box) 모델링 기법으로써 시스템의 입출력 관계만을 고려하여 모

델링 하게 된다. 일반적으로 신경망은 입력을 받아들이는 입력층과 결과를 내보내는 출력층 그리고 신경망의 학습 능력을 향상시키기 위한 은닉층으로 구성된다. 신경망을 학습시키기 위한 여러 알고리즘들이 개발되어져 있으며, 본 연구에서는 오차 역전파 알고리즘(error back propagation algorithm)을 이용하였다. 부싱은 동적 시스템으로써 과거의 시스템 상태변수가 현재의 출력에 영향을 미치게 된다. 이러한 시스템의 입출력은 식 (2)와 같이 표현될 수 있다.

$$y^t = f(u^t, u^{t-1}, \dots, u^{t-m}, y^{t-1}, \dots, y^{t-n}) \quad (2)$$

따라서 과거의 입력과 출력을 신경망의 입력층에 포함시켰다. 본 논문에서는 신경망의 구조를 크게 2 가지로 나누었다. 첫 번째 구조는 부싱의 변위와 힘의 데이터를 하나의 입력층에 입력하는 구조이고 두 번째 구조는 부싱의 변위의 입력층과 힘의 입력층을 각각 나누어 놓은 구조이다. 신경망 입력층 노드(뉴런)수는 현재의 변위와 과거의 변위 및 출력을 고려하여 11개로 선정하였다.

하나의 입력층 구조로 되어있는 신경망은 은닉층을 최대 3개까지 증가시켜 보았고 은닉층의 뉴런개수는 최소 5개부터 2개씩 증가시켜 최대 21개까지 구성하였다. 은닉층이 2개 이상일 때에는 은닉층의 뉴런개수가 줄어드는 방향으로 은닉층의 노드를 구성하였다. 따라서 은닉층이 하나인 신경망은 총 9가지 구성의 신경망 구조가 사용되었고 은닉층이 2개인 신경망은 36가지, 은닉층이 3개인 신경망은 84가지의 신경망 구조가 사용되었다. 입력층이 두 개가 사용된 신경망의 구조는 변위의 은닉층을 하나에서 세 개 까지 증가 시키면서 각각의 구조마다 힘의 은닉층을 하나에서 세 개 까지 증가 시켜보았다. 그리고 이 경우에서 사용된 은닉층의 뉴런수는 입력층이 하나일 때 사용되었던 뉴런의 수중에 가장 좋은 결과를 보인 뉴런의 수를 사용하였다.

본 연구에서는 뉴런의 비선형 활성화 함수(activation function)로 식 (3)과 같이 표현되는 하이퍼볼릭 탄젠트 시그모이드 함수(hyperbolic tangent sigmoid function)를 사용하였다.

$$y = \tanh ax \quad (3)$$

부싱의 변형량과 부싱력을 실제 크기의 입력으로 줄 경우, 값의 크기(scale)차이로 인해 활성화 함수의 포화영역에서 작동할 가능성이 높아진다. 따라서 입력 값과 출력 값을 정규화(normalizing) 시켜주어야 한다. 본 연구에서는 부싱의 변위 및 부싱력을 최대 값(maximum value)으로 나누어 준 후 데이터들을 하이퍼볼릭 탄젠트 시그모이드 함수를 통과시켜서 정규화를 해주었다.

### 3.2 신경망 성능평가 지표

신경망 성능평가를 위한 지표로써 최대오차비(maximum error ratio), 피크오차비(peak error ratio), 최소제곱오차비(root mean square error ratio, RMS)를 사용하였다.

최대오차비는 실험값의 부싱력과 신경망을 통하여 얻은 부싱력의 차가 가장 큰 지점에서의 오차의 비를 말하는 것이고, 피크오차비는 부싱력 중 비선형성이 가장 강하다고 말할 수 있는 최대의 부싱력이 발생하는 부분에서의 부싱력의 실험값과 신경망을 통해 얻은 부싱력의 오차의 비이다. 최소제곱오차비는 실험을 통하여 얻은 부싱력의 RMS와 그 부싱력과 신경망을 통해 얻은 부싱력의 오차의 RMS의 비이며 식 (4)와 같이 표현된다.

$$RMS\ ratio(\%) = \frac{\sqrt{\frac{1}{T} \sum_{t=1}^T (F_{exp}(t) - F_{pre}(t))^2}}{\sqrt{\frac{1}{T} \sum_{t=1}^T (F_{exp}(t))^2}} \times 100 \quad (4)$$

최대오차비와 피크오차비는 한 점에 대한 오차를 나타내는 반면, 식 (4)의 최소제곱오차비는 실험데이터의 실효치에 대한 오차의 실효치를 백분율로 나타낸 것으로서 전체적인 오차를 나타내는 것이다. 이 식에서  $F_{exp}$ 는 실험을 통하여 얻은 부싱력을 말하고  $F_{pre}$ 는 신경망을 통해서 구한 부싱력을 의미한다. 그리고 T는 데이터 개수를 뜻한다.

## 4. 신경망 구성에 따른 부싱모델의 성능

### 4.1 입력층이 하나일 때의 성능

Fig. 8에 입력층이 하나일 때의 신경망 구성을 나타내었다. 신경망 학습에서 사용되는 학습종료 조건은 보통 학습횟수제한과 오차제한으로 볼 수 있

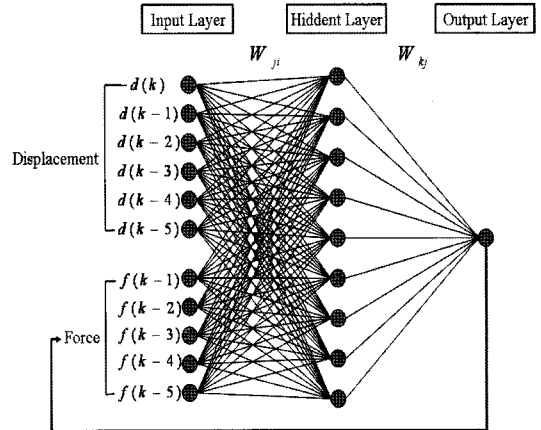


Fig. 8 Neural network structure with one input layer

는데 본 논문에서 사용한 신경망 학습 종료 조건은 오차제한으로 식 (5)에 나타내었다. 부싱의 실험데이터와 시뮬레이션데이터의 RMS 오차의 근 값이 26이하가 되면 학습을 종료하도록 하였다.

$$\sqrt{\frac{1}{T} \sum_{t=1}^T (F_{exp}(t) - F_{pre}(t))^2} \leq 26 \quad (5)$$

Fig. 9와 Fig. 10은 각각 은닉층이 한 개일 때의 뉴런개수에 따른 최대오차비와 피크오차비를 보여주고 있다. X축은 각각의 경우(case)를 나타내고 있는데 case1의 경우에는 뉴런의 개수가 5개이며 이후로는 case별로 뉴런의 개수가 2개씩 증가하여 case 9는 뉴런의 개수가 21개가 된다.

은닉층이 하나일 때는 뉴런의 개수가 9개일 때(case3) 최대오차비와 피크오차비가 가장 작게 나왔다




Fig. 9 Maximum errors in case one hidden layer




Fig. 10 Peak errors in case one hidden layer

Table 2 Case classification with two-hidden layers

	5	7	9	11	13	15	17	19
7	1							
9	3	2						
11	6	5	4					
13	10	9	8	7				
15	15	14	13	12	11			
17	21	20	19	18	17	16		
19	28	27	26	25	24	23	22	
21	36	35	34	33	32	31	30	29

으며 최대오차비는 실험을 통하여 얻은 부싱력이 -2326N일 때 신경망을 통해 얻은 부싱력이 -2582N이었다. 피크오차비는 실험을 통해 얻은 부싱력이 3059N일 때 신경망을 통해 얻은 부싱력은 2971N이었다. Fig. 11과 Fig. 12에 은닉층이 두 개일 때의 최대오차비비와 피크오차비를 도시하였다. Table 2에 경우를 나타내었다. Table 2에서 가로축은 은닉층1의 뉴런의 개수를 말하며 세로축은 은닉층2의 뉴런의 개수를 말한다.

은닉층이 두 개일 때, 최대오차비와 피크오차비를 모두 따져보면 case1, 즉 은닉층1의 뉴런의 개수가 7개, 은닉층2의 뉴런의 개수가 5개 일 때 가장 좋은 결과를 보이고 있다. 이 경우 실험을 통해 얻은 최대 부싱력이 3059N일 때에 신경망을 통해 얻은 최대 부싱력이 2882N이 나왔다.

은닉층이 세 개일 때에는 총 84가지의 경우가 사용되었다. 최소 뉴런의 개수 5개부터 최대 뉴런의 개




Fig. 11 Maximum errors in case two-hidden layers




Fig. 12 Peak errors in case two-hidden layers

Table 3 Case classification with three-hidden layers

7	15	13	11	9	7				
13	19	17	15	13	11	9	7		
11	15	21	19	17	15	13	11	9	
9	13	17	57						
7	11	15	56	54					
5	9	13	59	65	70				
	7	11	60	66	71	75			
	5	9	61	67	72	76	79		
		7	62	68	73	77	80	82	
			5	63	69	74	78	81	84

수 21개까지 사용하였다. case를 Table 3에 나타내었다. Table 3의 각각의 표는 은닉층1의 뉴런의 개수를 말하고 각 표의 가로축은 은닉층2의 뉴런의 개수를 말하며 세로축은 은닉층3의 뉴런에 개수를 말한다. Fig. 13~15에 최대오차비, 피크오차비, RMS비를 각




Fig. 13 Maximum errors in case three-hidden layers




Fig. 14 Peak errors in case three-hidden layers




Fig. 15 RMS errors in case two-hidden layers

Table 4 Best results in case three-hidden layers

	Max error (%)	Peak error (%)
1	12.3 (13-11-5)	1.9 (17-13-5)
2	13.6 (19-17-5)	2.2 (19-17-7)
3	13.9 (19-11-9)	2.4 (19-11-5)

각 도시 하였다. case1은 은닉층1,2,3의 뉴런의 개수가 각각 9개, 7개, 5개 이고 case84는 뉴런의 개수가 각각 21개, 7개, 5개이다. Table 4에서 은닉층이 세 개일 때의 최대오차비와 피크오차비의 상위 3경우를 보여 주고 있다.

최대오차비가 가장 작게 나온 세 가지의 경우에는 피크오차비가 다소 높게 나왔기 때문에 피크오차비가 작게 나온 세 가지의 경우 중 가장 좋은 최대오차비와 RMS를 고려하여 case53(19-11-5)이 가장 좋은 결과를 보여준 것을 확인하였다. Table 5는 피크오차비가 가장 작게 나온 세 가지 경우에 대한 최대오차비, 피크오차비, RMS비이다.

Case53의 경우 최대오차비는 실험 부상력이 -2109N일 때에 신경망을 통해 얻은 부상력은 -2448N이 나왔다. 피크오차비는 실험 부상력이 3058N일 때에 2984N이 나왔다. 은닉층의 개수가 늘어날수록 좋은 결과를 보이는 구성도 있었지만 좋지 못한 결과를 보이는 구성도 많이 있었다. 또한, 은닉층의 개수가 늘어날수록 계산시간도 그 만큼 증가하였다. 따라서 은닉층의 개수가 많다고 해서 좋은 결과를 보이는 신경망 구조라고 말하기는 힘들다.

Table 5 Comparisons of errors in case of minimum peak errors

	Max error(%)	Peak error(%)
19-17-7	20.1	2.2
19-11-5	16.1	2.4
17-13-5	15.2	1.9
	RMS ratio	
19-17-7	0.7750	
19-11-5	0.7829	
17-13-5	1.1087	

#### 4.2 입력층이 두 개일 때

입력층을 변위의 입력층과 부상력의 입력층으로 나누어 보았다. 앞의 신경망 시뮬레이션 결과를 토대로 은닉층이 하나일 때에는 뉴런의 개수를 각각 9개, 은닉층이 두 개일 때에는 은닉층1,2의 뉴런의 개수를 각각 7개, 5개로 하였고 은닉층이 세 개일 때에는 은닉층 1,2,3의 뉴런의 개수를 각각 19개, 11개, 5개로 하였다. 입력층을 두 개로 나누었을 때에는 총

9가지의 경우가 만들어지는데 Table 6에서 각 경우 마다의 오차의 비가 아닌 실제값의 최대오차와 피크오차, 그리고 최소제곱오차비를 나타내었다.

Table 6에서 D와 F는 각각 변위 입력층의 은닉층의 개수와 부싱력 입력의 은닉층의 개수를 나타내는 것이다. 입력층의 개수에 따른 신경망의 성능비교를 쉽게 보여주기 위하여 Table 7에 입력층이 한 개일 때의 신경망의 구성중에서 각 오차가 가장 작은 구성들의 오차를 나타내었다.

Table 7의 괄호 속에 숫자는 뉴런의 개수를 뜻한다. 입력층이 한 개인 경우, 최대오차는 은닉층이 한 개이고 뉴런의 개수가 9개인 경우에 가장 적은 오차를 보였고, 피크오차의 경우는 은닉층이 세 개이고 각각의 은닉층의 개수가 17개, 13개, 5개인 경우, 최소제곱오차는 은닉층이 두 개이고 그 뉴런의 개수가 7개, 5개인 경우에 가장 좋은 결과를 보이고 있다. Table 6의 case5와 Table 7을 비교해보면 입력층이 한 개일 때의 모든 경우보다 입력층이 두 개일 때의 case5가 더 좋은 결과를 보여줄을 알 수 있다. 따라서, 본 연구에 사용한 부싱의 경우에는 Table6의 case5가 최적의 신경망구조라고 볼 수 있다.

아래의 Table 8은 이전의 신경망 연구<sup>3)</sup>에서 많이 사용한 입력층이 하나이고 은닉층 뉴런의 개수가 각각 10개, 9개인 신경망구조(reference case)와 이번

Table 6 Comparisons of errors in case of two input layers

case	D	F	Max error (%)	Peak error (%)	RMS ratio (%)
1	1	1	51.5	12.8	1.426
2	1	2	23.5	2.1	2.089
3	1	3	27.1	2.7	2.046
4	2	1	19.5	2.4	0.958
5	2	2	6.8	1.9	0.209
6	2	3	15.1	2.6	1.268
7	3	1	19.4	3.3	0.978
8	3	2	11.3	7.2	0.560
9	3	3	24.6	18.8	3.397

Table 7 Structure with minimum errors in case of one input layer

Max error (%)	Peak error (%)	RMS ratio (%)
11.6	1.9	0.37
(9)	(17-13-5)	(7-5)

Table 8 Comparisons of errors between optimum case and reference case

	Max error (%)	Peak error (%)	RMS ratio (%)
Optimum case	6.8	1.9	0.209
Reference case	20.1	2.8	0.38

연구에서 최적화한 신경망구조(optimum case)의 오차를 비교한 것이다.

Table 8에서 알 수 있듯이, 본 연구에서 제안한 신경망 구조가 이전의 경우보다 오차의 크기가 작은 것을 알 수 있다.

### 5. 반경방향 시뮬레이션

본 연구에서 제안한 신경망의 구조를 범용 다물체 동역학 해석 프로그램인 ADAMS에서 사용할 수 있도록 Simulink를 이용하여 ADAMS와의 인터페이




Fig. 16 Bushing forces

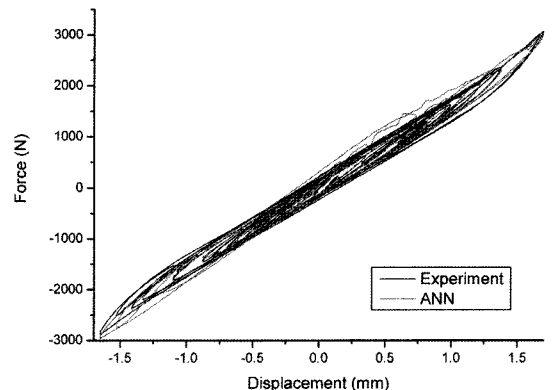


Fig. 17 Bushing displacement vs bushing forces

스를 구현하였다. Fig. 16에 부상력을, Fig. 17에 부상변위 대 부상력을 각각 도시하였다. 그림에서 ‘Experiment’는 시험결과를 ‘ANN’은 신경망부싱모델의 결과를 각각 나타낸다.

## 6. 결론

본 논문에서는 신경망 부상모델 구성을 위한 학습데이터를 얻기 위해 MTS 3축 고무시험기를 이용하여 부싱의 반경방향의 힘과 변위와의 관계를 주파수 및 진폭별로 시험하였고, 랜덤 가진에 대한 시험도 행하였다. 차량동역학 해석에 이용할 수 있도록 인공신경망을 이용하여 부상모델을 구성하였다. 인공신경망은 수식의 형태로 정형화 할 수 없어서 일반적인 최적화 알고리즘을 사용하는 데에는 무리가 있다. 따라서 입력층과 은닉층의 개수와 뉴런의 개수를 변수로 두고 경우의 수를 따져봐야 한다. 신경망 구성에 따른 성능을 비교하여 다음과 같은 결론을 얻었다.

- 1) 본 연구에 사용된 부싱의 예에서는 입력층을 변위의 입력층, 부상력의 입력층으로 나누고 은닉층은 두 개로 구성하는 것이 최적의 결과를 보여주었다.
- 2) 은닉층이 늘어날수록 학습의 시간이 길어지는 반면 더 좋은 결과를 보이지는 못했다.
- 3) 은닉층1과 은닉층2의 뉴런의 개수의 비가 3:1이 넘으면 신뢰성이 떨어지는 결과를 보일 수도 있음을 확인하였다.
- 4) 신뢰성이 떨어지는 신경망구성의 오차를 보면 최소제곱오차비의 경우에는 3.5%이하의 오차를 보이지만 최대오차비와 피크오차비는 각각 수백에서 수십퍼센트의 오차를 보이고 있는데, 이것은 신경망 모델이 전체적으로 실험값과 비슷한 부상력을 내고 있지만 낮은 부상력이 작용할

때 한번 씩 잘못된 부상력을 계산해내기 때문인 것으로 사료된다.

그러므로, 부싱의 종류에 따라 신경망 모델을 만들 때에는 입력층을 변위의 입력층과 부상력의 입력층으로 나누고, 은닉층의 개수를 2개로 구성한 후, 충분한 경우의 수를 구성하여 최적설계를 수행하여야 바람직한 결과를 얻을 수 있을 것으로 사료된다.

본 연구의 경우, 은닉층1과 2에 각각 7개의 뉴런과 5개의 뉴런을 사용한 것이 최적의 결과를 보여주었으며, 최대오차는 6.8%, 피크오차는 1.9%, RMS오차는 0.2%를 보여주어 일반적인 시스템규명의 경우 10%오차 이내이면 만족할 만한 것으로 받아들여지므로 괜찮은 결과를 보여주었다고 사료된다.

## 후 기

이 논문은 2007년도 부경대학교 누리사업에 의하여 일부 지원되었음.

## References

- 1) ADAMS User's Guide, MSC Software Corporation, 2003.
- 2) A. J. Barber, "Accurate Models for Complex Vehicle Components using Empirical Methods," SAE 2000-01-1625, 2000.
- 3) J. H. Sohn, W. S. Yoo and D. W. Park, "Empirical Bushing Model Using Artificial Neural Network," Transactions of KSAE, Vol. 11, No.4, pp.151-157, 2003.
- 4) S. M. Savaresi, S. Bittanti and M. Montiglio, "Identification of Semi-physical and Black-box Non-linear Models: The Case of MR-dampers for Vehicles Control," Automatica, Vol.41, pp.113-127, 2005.