

동역학 해석을 위한 고무부싱의 실험적 모델링에 대한 연구

손 정 현[†] · 백 윤 경 · 김 동 조

[†]부경대학교 기계공학부

(2004년 4월 21일 접수, 2004년 5월 2일 수정 및 채택)

A Study on the Empirical Modeling of Rubber Bushing for Dynamic Analysis

Jeong Hyun Sohn[†], Woon Kyung Baek, Dong Jo Kim

[†]School of Mechanical Engineering, Pukyong National University

(Received April 21, 2004, Revised and Accepted May 2, 2004)

요 약 : 고무부싱은 차량부품들을 서로 연결하고 차체로 전달되는 진동을 줄여주는 역할을 하는 중요한 요소로써 가진변위와 주파수에 대해서 모두 비선형 특성을 보이며, 특히 주기적인 가진에 대해 히스테리시스 현상을 나타낸다. 본 논문에서는 1축 내구시험기를 이용하여 차량 현가 장치에 사용되는 부싱을 축 방향과 반경 방향에 대해 사인가진과 랜덤가진을 주어 특성을 살펴 보았고 이러한 특성을 반영할 수 있는 동역학적 모델을 인공신경망을 이용하여 개발하였다. 실험결과는 신경망의 입력자료로 활용되었고, 오차역전파 알고리즘을 이용하여 실험적 부싱모델을 개발하였다. 개발된 실험적 부싱모델을 차량 시뮬레이션에 적용하여 유용성을 살펴보았다.

ABSTRACT : A rubber bushing connects the components of the vehicle each other and reduce the vibration transmitted to the chassis frame. A rubber bushing has the nonlinear characteristics for both the amplitude and the frequency and represents the hysteretic responses under the periodic excitation. In this paper, one-axis durability test is performed to describe the mechanical behavior of typical vehicle elastomeric components. The results of the tests are used to develop an empirical bushing model with an artificial neural network. The back propagation algorithm is used to obtain the weighting factor of the neural network. A numerical example is carried out to verify the developed bushing model and the vehicle simulation is performed to show the fidelity of proposed model.

Keywords : rubber bushing, vehicle dynamic analysis, computer simulation, neural network

I. 서 론

고무부싱은 차량부품들을 서로 연결하여주고 차체로 전달되는 진동을 줄여주는 역할을 하는 중요한 요소로써 가진변위와 주파수에 대해서 모두 비선형 특성을 보이며, 특히 주기적인 가진에 대해 히스테리시스 현상을 나타낸다. 현재 차량 설계기

술에서는 전체 차량 모델을 컴퓨터를 이용하여 모델링하여 차량의 거동 특성등을 미리 예측해 봄으로써 개발 기간을 단축시키고 있다. 따라서, 차량을 구성하고 있는 각종 부품들을 역학적으로 적절히 모델링할 수 있는 기술이 요구되고 있으며, 차량동역학 해석을 할 수 있도록 상용 프로그램인 DADS¹와 ADAMS²가 현재 많이 활용되고 있다. 이들 상용 프로그램에서 일반적으로 사용하고 있는 부싱모델은 켈빈-보이트(Kelvin-Voight) 모형으로써

[†]대표저자(e-mail : jhsohn@pknu.ac.kr)

부싱을 세 방향의 선형 스프링-댐퍼와 세 방향의 회전스프링-댐퍼의 선형조합으로 표현하고 있다. 그러나, 이러한 부싱모델에서는 부싱이 가지는 히스테리시스를 재현할 수가 없다. Lee³는 리아니스(Lianis)식으로부터 퓌킨-라저스(Pipkin-Rogers) 모델을 구성하였고 축방향 모드, 비틀림 모드, 반경방향 모드별로 각각 연구하여, 그 결과에 대하여 신뢰성을 검증하였지만, 실제적인 3축이 동시에 가진 되어 커플(couple) 될 때의 결과는 보여주지 못했다. 최근 차량동역학에서는 신경망 알고리즘을 적극 도입하여 해석에 응용하고 있다. Fash⁴는 인공신경망을 구성하여 속 업소바(shock absorber)의 거동을 모델링하였고, Kim⁵은 신경망을 이용하여 현가 시스템을 모델링하였다. Barber⁶는 신경망을 이용하여 부싱 및 속 업소바의 비선형 특성을 반영할 수 있음을 보이고, 다물체 동역학 해석 프로그램에 동적 부싱모델로 구현할 수 있음을 시사하였지만 구체적인 예는 보여주지 않았다.

본 논문에서는 부싱의 히스테리시스를 잘 반영하고 주파수 및 변위의 비선형성을 모두 고려할 수 있는 인공신경망 부싱모델을 현재 차량동역학 분야에서 가장 많이 사용되고 있는 프로그램인 ADAMS에서 사용가능하도록 개발하였다. MATLAB⁷을 이용하여 신경망 알고리즘을 구성하고 학습시켰으며, Simulink를 이용하여 ADAMS와 연결시켰다. 신경망 학습을 위해 오류역전파 알고리즘을 이용하고, 나렌드라 알고리즘(Narendra algorithm)⁸을 도입하였다. MTS 1축 내구시험기를 이용하여 진폭과 주파수에 따른 부싱력을 측정하였고, 랜덤(random) 입력에 대한 부싱의 전달력 또한 측정하였다. 시험결과는 본 연구에서 개발한 신경망 프로그램의 입력자료로 활용되었으며, 학습된 가중치를 이용하여 차량동역학 해석 시에 동적 부싱모델이 될 수 있도록 차량동역학 해석 모듈로 구현하였다. 2장에서는 부싱의 특성시험 장치 및 시험 결과를 도시하였고, 3장에는 신경망을 이용한 부싱의 모델링에 대해 기술하였으며, 4장에 수치예제를 보였고, 결론을 5장에 나타내었다.

II. 부싱의 특성 시험

차량동역학 해석에 사용할 부싱의 거동을 정확하게 모델링하기 위하여 본 연구에서는 부싱의 특성 시험을 하였다. 본 연구에서는 부싱의 특성을 시험하기 위하여 MTS 1축 내구시험기를 이용하였다. 시험은 반경방향(radial direction)과 축방향(axial direction)으로 나누어 실시하였다. 반경방향에서는 고무의 전단, 압축, 팽창의 조합 때문에 부싱의 강성이 크고 비선형으로 나타난다. 축방향에서는 전단변형만 생기기 때문에 더 낮은 선형적인 강성을 보인다. Figure 1에 부싱의 축방향 특성을 시험하기 위해 자체 제작한 지그(JIG)를 도시하였고, Figure 2에 부싱의 반경방향 특성을 시험하기 위해 제작한 지그를 나타내었다.

삼각과 가진 시험은 MTS 장비의 계수 값을 튜




Figure 1. Axial JIG for a bushing test.



Figure 2. Radial JIG for a bushing test.

닝하기 위한 예비 시험으로써 행해졌으며, 주어진 입력가진을 부싱 변형이 얼마나 잘 따라가는 가를 알아보기 위해 행하였다. 삼각파 가진을 주었을 때 시간에 따른 축방향 힘을 Figure 3에 도시하였으며, 부싱변위에 대한 축방향 부싱력을 Figure 4에 도시하였다. 삼각파 입력이 주어졌을 때 부싱의 변형이 삼각파 형태로 따라감을 볼 수 있으므로 현재 축 방향의 튜닝 작업은 잘 된 것으로 판단하고, 이때의 계수 값을 사인파 가진 시험에 적용하였다. Figure 4에서 부싱의 히스테리시스 특성이 나타남을 관찰할 수 있으며, 진폭이 커질수록 면적이 넓어짐을 알 수 있다. 삼각파 가진을 주었을 때 시간에 따른 반경방향 힘을 Figure 5에 도시하였으며, Figure 6에 부싱변위에 대한 반경방향 부싱력을 도시하였다. 축 방향과는 달리 기울기가 일정하지 않




Figure 3. Bushing forces under triangular input(axial).

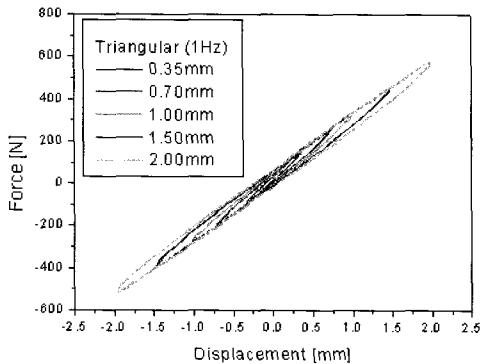


Figure 4. Bushing displacement vs forces(axial, 1Hz triangular input).




Figure 5. Bushing forces under triangular input(radial).




Figure 6. Bushing displacement vs forces(radial, 1Hz triangular input).

고 비선형임을 알 수 있으며, 이는 반경방향의 강성이 비선형 특성이 많이 나타남을 의미한다.

부싱의 히스테리시스 특성을 관찰하기 위하여 조화가진 시험을 시행하였다. 가진은 식(1)과 같은 함수로 주었으며, Kuo⁹가 시행한 시험방법을 참고하여 실시하였다.

$$\delta(t) = \delta_0 \sin 2\pi ft \tag{1}$$

식(1)에서 주파수(f)를 2, 5, 10, 15, 20 Hz의 5종류로 바꾸면서 실험하였으며, 축 방향 가진 진폭은 0.35, 0.7, 1.0, 1.35, 1.7, 2.0 mm의 6종류로, 반경 방향 가진 진폭은 0.35, 0.7, 1.0, 1.35, 1.7, 2.0, 2.5, 3.0 mm의 8종류로 바꾸면서 실험하였다. 10Hz 가진을 주었을 때 가진 진폭에 따른 축 방향 힘을 Figure 7에 도시하였고, 4 mm 가진 진폭에 주파수

에 따른 축 방향 힘을 Figure 8에 각각 도시하였다. 또한, 10Hz 가진을 주었을 때 가진 진폭에 따른




Figure 7. Axial forces due to amplitude.




Figure 8. Axial forces due to frequency.




Figure 9. Radial forces due to amplitude.




Figure 10. Radial forces due to frequency.




Figure 11. Amplitude of the random input.

반경 방향 힘을 Figure 9에 도시하였고, 4 mm 가진 진폭에 주파수에 따른 반경 방향 힘을 Figure 10에 각각 도시하였다. Figure 9에서 진폭이 커질수록 부상강성의 비선형성이 커짐을 알 수 있다. 또한, Figure 10에서와 같이 주파수가 증가할수록 비선형성이 증가함을 볼 수 있다.

랜덤 입력 데이터는 MTS의 CRPCIII 소프트웨어를 통해 구성하였으며, 샘플링율(sampling rate)을 204.8Hz로 두었고, 진폭은 Figure 11과 같은 형태로 표현될 수 있는데, 본 연구에서는 n의 값을 1.4, 1.6, 1.8, 2.0, 2.4, 3.0으로 바꾸어가면서 시험하였다. 또한, 최대 진폭(peak value)을 2 mm로 하였다.

Figure 8에 피크치가 2 mm 일 때 n의 값의 변화에 따른 반경방향 부상력을 도시하였고, Figure 9에 n의 값이 2일 때 피크치의 변화에 따른 반경방향 부상력을 도시하였다.




Figure 12. Radial forces due to n value changes.




Figure 13. Radial forces due to peak changes.

III. 실험적 부상모델링

신경망 알고리즘은 블랙박스 모델링 기법으로써 시스템의 입출력 관계만을 고려하여 모델링 하게 된다. 즉, 시험결과를 학습하여 새로운 입력에 대하여 시스템의 비선형성을 반영한 결과를 예측하는 이론이며, 일반적으로 신경망은 입력을 받아들이는 입력층과 결과를 내보내는 출력층 그리고 은닉층으로 구성된다. 각 층은 외부의 자극에 반응하는 뉴런이라는 세포체로 이루어지며, 생물학적으로 시냅스(synapse)에 해당되는 연결강도에 의해 새로운 정보를 학습하고 이를 경험이나 지식으로 기억하게 된다. Figure 14에 신경망을 도시하였다.

신경망을 학습시키기 위한 여러 알고리즘들이 개발되어져 있으며, 본 연구에서는 오차 역전파 알고리즘(error back propagation algorithm)을 이용하였다.¹⁰ 이 알고리즘은 학습 도중 발생하는 오차를




Figure 14. Structure of the neural network.

최소화하기 위하여 연결강도(weighting factor)를 조절한다. 출력층에서 계산되는 실제 출력값과 요구되는 출력값 사이의 오차는 식(3)을 통해 구할 수 있다.

$$E_p = \frac{1}{2} \sum_j (t_{pj} - O_{pj})^2 \quad (2)$$

$$E = \frac{\sum E_p}{P} \quad (3)$$

식(2)는 학습되는 출력층에서 발생하는 P번째 패턴의 오류값을 나타내고, 식(3)은 각 패턴의 오류를 합산한 전체 오류를 패턴의 개수로 나눈 것이다. t_{pj} 는 출력층에서 P번째 패턴의 j번째 뉴런의 목표 값이며, O_{pj} 는 실제 출력이다. 계산된 전체 오차가 정의된 오차, 예를 들면 10^{-4} 이나 10^{-5} 보다 작을 때까지 학습을 반복하게 된다. 연결강도의 변화량은 전체 오차가 감소하는 방향으로 최급하강법을 적용하여 연결강도의 변화량을 결정지며, 최종적인 연결강도의 변화량은 식(4)와 같이 표현된다.

$$\Delta_p W_{ji}(n+1) = \eta \delta_{pj} O_{pj} + \alpha \cdot \Delta_p W_{ji}(n) \quad (4)$$

여기서 n 은 학습 횟수이며, α 는 상수, $\alpha \cdot \Delta_p W_{ji}(n)$ 은 모멘텀 항으로써 오차 진동을 적게 하여 수렴 속도를 빨리 하기 위해 사용된다. 연결강도의 변화는 패턴 제시 때마다 변경하는 방법과 일괄 변경하는 방법이 있다. 기본적으로 역전파 알고리즘은 기울기 감소(gradient descent) 기법을 이용하여 식(3)의 전체 오차를 최소화하는 학습기법이다. 이때

가중치는 식(4)에 의하여 변화되며, 아주 작은 양만큼씩 변화하면서 오류평면의 전역 최소치로 수렴해 가게 된다. 이 변화량을 제어하는 매개변수의 역할을 학습율이 담당한다. 실제로 학습율은 클수록 빠른 학습이 가능하나, 너무 크게 되면 전역 최소치들 사이에 두고 진동이 일어날 수도 있다. 모멘텀은 학습속도를 향상시키기 위하여 사용되는데, 이전에 가중치가 변화하였던 양을 현재 가중치 수정시 얼마만큼 고려할 것인가를 결정하는 매개변수이다. 보편적으로 학습율과 모멘텀은 0과 1 사이의 실수를 사용한다.

부싱은 동적 시스템으로써 과거의 시스템 상태 변수가 현재의 출력에 영향을 미치게 된다. 이러한 시스템의 입출력은 식(5)와 같이 표현될 수 있다.

$$y^t = f(u^t, u^{t-1}, \dots, u^{t-m}, y^{t-1}, \dots, y^{t-n}) \quad (5)$$

따라서 과거의 입력과 출력을 신경망의 입력층에 포함시켰다. 신경망 입력층 노드수는 현재의 변위와 과거의 변위 및 출력을 고려하여 11개로 선정하였다. 신경망의 은닉층은 1개의 층으로 구성하였고, 은닉층 노드수는 9개, 출력층 노드수는 1개로 선정하였으며 출력은 부싱력을 의미한다. 이는 여러 번의 테스트 결과 가장 우수한 결과를 보이는 개수로 선정된 것이다. 본 연구에서는 은닉층 뉴런의 비선형 활성화 함수(activation function)로 식(6)과 같이 표현되는 하이퍼볼릭 탄젠트 시그모이드 함수(hyperbolic tangent sigmoid function)를 사용하였다. 출력층 활성화 함수는 선형함수(linear function)를 사용하였다.

$$y = \tanh ax \quad (6)$$

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 해 주었다. Figure 15에

본 연구에서 사용한 인공신경망의 구성도를 도시하였다.

신경망을 구성하고 학습시키기 위해 MATLAB을 이용하여 m-file을 작성하였다. Figure 16은 신경망을 학습시키기 위해 사용했던 랜덤 가진 데이터이며, Figure 17은 랜덤 가진 했을 때의 부싱력이다.




Figure 15. Structure of the artificial neural network.




Figure 16. Input data of the neural network.




Figure 17. Bushing forces of the neural network.

개발한 신경망 부상모델을 범용 다물체 동역학 해석 프로그램인 ADAMS에서 사용할 수 있도록 모듈을 구성하였다. 본 연구에서는 Figure 18에서 처럼 Simulink를 이용하여 ADAMS와의 인터페이스를 구현하였다.

Figure 18에서 'input' 블록은 1개의 현재의 변위와 10개의 과거의 결과로부터 신경망 부상모델의 입력을 생성한다. 'Bushing model'블록은 S-function 블록으로 신경망 알고리즘을 S-function으로 내장하고 있다. 'ADAMS'블록은 ADAMS와의 인터페이스를 담당하고 있는 블록이다. 부상력을 계산하는 절차는 Figure 19와 같다.




Figure 18. Structure in the Simulink.

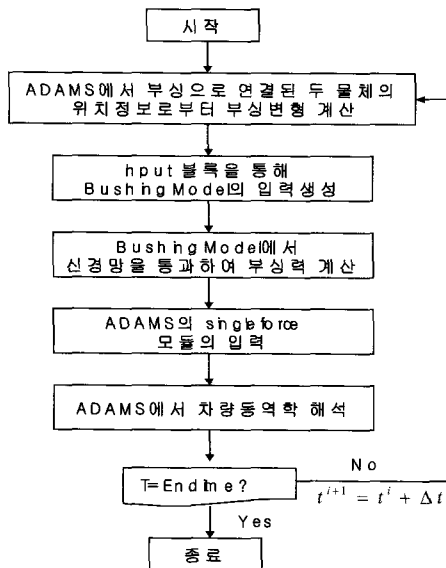


Figure 19. Flow chart for bushing forces calculation.

IV. 수치예제

본 연구에서 개발한 부상모델을 차량 예제에 적용하여 유용성을 보이고자 한다. Figure 20은 본 논문에서 사용한 전체 차량모델을 보여주고 있다. 전륜현가장치는 맥퍼슨 스트럿(McPherson strut)이고 후륜현가장치는 토션빔(torsion beam)이 적용된 다목적 차량(MPV)이다. 타이어는 ADAMS에서 제공하는 UA 타이어모델을 사용하였으며 전체차량의 자유도는 31이다. 인공신경망 부상모델은 트레일링 암(trailing arm)과 차체(chassis)사이에 연결된 부상에 적용되어있다. 차량의 초기속도를 5 m/s로 주고 Figure 21과 같은 범프를 통과하도록 시뮬레이션 하였다. 범프의 폭을 변경시킴으로써 가진 주파수가 달라지므로 여러 주파수대의 입력이 들어올 때 캘빈보이트 모형과의 차이점을 살펴볼 수 있다. 캘빈보이트 모형에서의 스프링 강성과 댐핑 계수를 추출하기 위하여 Figure 22와 같은 전형적인 히스테리시스 루프 그래프를 작성하였다. 식(7)에서 F_{max} , F_{min} 은 각각 최대변형시의 힘과 최소변형시의 힘을 나타내며, 식(8)에서 δ_{max} , δ_{min} 은 각각 최대변형량과 최소변형량을 나타낸다. 히스테리시스 면적으로부터 식(8)을 이용하여 손실각을 계산하며, 동적강성은 식(10)을 이용하여 계산되고 스프링상수는 식(11)을 이용하여 계산한다.




Figure 20. ADAMS full car model.




Figure 21. Bump shape.




Figure 22. Force deflection curve with a hysteresis loop.

Table 1. Spring stiffness and damping coefficient of a bushing

| Bushing | Spring stiffness k [N/m] | Damping coefficient c [N · m/sec] |
|--------------------|--------------------------|-----------------------------------|
| Radial (3mm, 10Hz) | 2048822.9 | 1144.168 |
| Axial (2mm, 10Hz) | 278482.9 | 115.878 |

댐핑계수는 식(12)를 이용하여 계산하며, 본 연구에서 대상으로 한 부싱의 경우 Table 1과 같이 요약된다. Table 1의 데이터는 실험적 부싱모델의 신뢰성 검증을 위한 선형 부싱모델의 입력자료로 활용된다.

$$F = (F_{max} - F_{min})/2 \tag{7}$$

$$\delta = (\delta_{max} - \delta_{min})/2 \tag{8}$$

$$\sin \phi = \frac{(loop\ area)}{\pi f \delta} \tag{9}$$

여기서 ϕ 는 손실각(loss angle) 또는 위상각(phase angle)을 의미한다.

$$\text{Dynamic stiffness } k_D = \frac{F}{\delta} \tag{10}$$

$$\text{Elastic spring constant } k = k_D \cos \phi \tag{11}$$

$$\text{Damping coefficient } c = \frac{k_D \sin \phi}{2\pi f} \tag{12}$$

Figure 23에는 차체의 수직변위를, Figure 24에는 차체의 수직가속도를 각각 나타내었으며, 부상력을 Figure 25에 각각 도시하였다. 부상력이 다소 차이가 나는 것은 고주파수 영역에서 차이가 나기 때문이며, Figure 26에 도시한 부상력의 FFT(Fast Fourier Transform)를 보면 알 수 있다. 20Hz 미만에서는 선형모델과 잘 일치하는 것을 볼 수 있으나, 고주파수가 될 수록 차이가 남을 확인할 수 있다. 실험과 비교한 것이 아니므로 신경망 모델이 정확히 맞다고 할 수는 없으나, 선형모델을 대체할 수 있는 대안으로는 받아들여질 수 있으리라 사료




Figure 23. Vertical displacement of chassis.




Figure 24. Vertical acceleration of chassis.




Figure 25. Bushing forces.

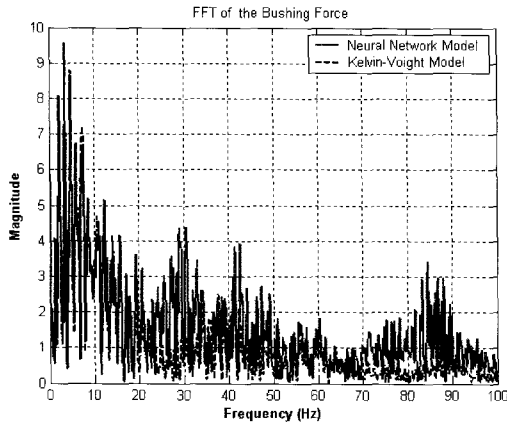


Figure 26. FFTs of bushing forces.

되며, 차후 실험과의 검증을 통해 이를 확인할 수 있을것으로 생각된다.

V. 결 론

차량에 사용되는 고무부싱은 고무의 비선형성으로 인하여 해석적으로 동역학 모델을 만드는 것은 매우 어려운 실정이다. 동역학 해석을 위해서는 정확한 부싱모델이 요구되는데 본 논문에서는 신경망이론을 적용하여 부싱변형에 대한 힘을 예측할 수 있는 부싱모델을 개발하였다. 신경망을 학습시키기 위해 요구되는 실험데이터는 MTS 1축 내구 시험기를 이용하여 계측하였으며, 부싱의 축방향과

반경방향에 대해서 가진실험을 할 수 있도록 지그를 제작하여 이용하였다. 삼각과 가진을 주어 시험기를 튜닝하였고, 부싱의 힘과 변위와의 관계를 사인파가진을 주어 주파수 및 진폭별로 시험하였으며, 랜덤 가진에 대한 시험도 행하였다. 범용 다물체동역학 해석프로그램인 ADAMS에서 사용가능하도록 Simulink와의 인터페이스 루틴을 개발하였고, 수치예제를 통하여 개발된 부싱모델이 랜덤 입력에 대해 잘 예측함을 확인하였다. 전체 차량모델을 이용하여 개발된 신경망 부싱모델의 유용성을 보였다.

본 연구의 결과는 ADAMS에서 제공하고 있지 않은 신경망 부싱모델을 이용할 수 있는 알고리즘을 소개하고 있다. 신경망 모델의 장점은 기존 부싱모델이 제공할 수 없는 비선형 특성 및 히스테리시스 특성을 반영하여 시뮬레이션을 할 수 있다는 점이며, 주요 단점으로는 일반 차량 설계에서 할 수 있는 부싱강성 설계 등을 할 수 없다는 점이다. 따라서 컴플라이언스 특성 등 설계를 위해서는 기존의 부싱모델을 사용해야한다. 신경망 모델의 제일 중요한 점은 학습 데이터가 충분히 다양해야 하며 많은 학습을 해야 임의의 입력에 대해서도 적절한 출력을 보장해준다. 따라서 실제 부싱을 제대로 모델링하기 위해서는 여러 개의 부싱을 테스트해야 한다. 또한 부싱은 동시에 3축으로부터 가진입력이 들어오는 데 반해, 본 연구에서는 반경방향과 축방향을 각각 가진 실험을 행하였다. 따라서 동시에 가진되었을 때의 결과와는 다소 차이를 보일 수 있다. 3축이 동시에 가진되었을 때의 알고리즘은 본 연구에서의 알고리즘과 동일하며, 입력 뉴런의 개수와 출력 뉴런의 개수가 조정되어야 한다.

감사의 글

본 논문은 산업자원부의 출연금 등으로 수행한 지역전략산업 석박사연구인력 양성사업의 연구결과입니다.

참고문헌

1. CADSI, DADS Revision 8.0 User's Manual, Oakdale, IA, U.S.A. (1995).
2. ADAMS Version 8.0 User's Guide, An Arbor, MI, U.S.A. (1994).
3. S. B. Lee, A. Wineman, "A Model for Non-linear Viscoelastic Coupled Mode Response of an Elastomeric Bushings", *Int. J. of Non-Linear Mechanics*, **35**, 177 (2000).
4. J. W. Fash, "Modeling of Shock Absorber Behavior using Artificial Neural Networks", *SAE 940248* (1994).
5. I. Y. Kim, K. T. Chong, T. S. No, D. P. Hong, "Empirical Closed Loop Modeling of a Suspension System Using Neural Network", *KSPE*, **14**, 7 (1997).
6. A. J. barber, "Accurate Models for Complex Vehicle Components using Empirical Methods", *SAE2000-01-1625* (2000).
7. R. C. Dorf, *Control Analysis and MATLAB and Simulink Application* (2003).
8. K.S. Narendra, K. Pathasarathy, "Identification and Control of Dynamic System Using Neural Networks", *IEEE Transactions on Neural Networks*, **1**, 1 (1990).
9. E. Y. Kuo, "Testing and Characterization of Elastomeric Bushings for Large Deflection Behavior", *SAE 970099* (1997).
10. 김대수, "신경망 이론과 응용(1)", 하이테크 정보, (1995).