

## 신경망을 이용한 현가시스템의 모델링 및 고장 진단에 관한 연구

이 정 호<sup>1)</sup> · 박 기 흥<sup>\*2)</sup> · 허 승 진<sup>2)</sup>

한국과학기술원 기계공학과<sup>1)</sup> · 국민대학교 자동차공학대학원<sup>2)</sup>

### A Study on Modeling and Fault Diagnosis of Suspension Systems Using Neural Network

Jungho Lee<sup>1)</sup> · Kihong Park<sup>\*2)</sup> · Seung-Jin Heo<sup>2)</sup>

<sup>1)</sup>Department of Mechanical Engineering, KAIST, Daejeon 305-701, Korea

<sup>2)</sup>Graduate School of Automotive Engineering, Kookmin University, Seoul 136-702, Korea

(Received 29 June 2002 / Accepted 19 November 2002)

**Abstract** : Driving safety of a vehicle is largely influenced by the damper and the tire. Developed in this research is a fault diagnosis algorithm for the two components so that the driver can be promptly informed when fault occurs in one or both of them. To this end, the damper and the tire were modeled using the neural network from their experimental data, and fault diagnosis was made using frequency responses of the damping force and the dynamic wheel force. The algorithm was tested via experiments, and it demonstrated successful diagnostic performance under various driving conditions.

**Key words** : Neural network(신경망), Empirical dynamics modeling(경험적 동역학 모델링), Fault diagnosis(고장진단), Suspension system(현가시스템)

#### Nomenclature

$f_d$  : damping force, N

$f_s$  : spring force, N

$f_i$  : dynamic tire force, N

$m$  : mass, kg

$z$  : vertical displacement, m

#### Subscripts

$s$  : sprung mass

$u$  : unsprung mass

#### 1. 서론

댐퍼와 타이어는 현가시스템을 구성하는 부품으

로서 차량의 운동 특성에 큰 영향을 미친다. 댐퍼의 경우 노화하거나 밀폐류에 고장이 발생하면 감쇠력의 변화가 일어나며 이 영향으로 차량의 제동거리가 늘어날 수 있다. 타이어의 경우 공기압의 감소는 승차감과 주행안정성을 떨어뜨리며 타이어의 빠른 마모를 가져온다. 하지만 대부분의 운전자는 댐퍼나 타이어의 고장상태가 심각하지 않는 한 이를 쉽게 인식하지 못하며, 이는 운전자의 50%가 규정 공기압보다 낮은 공기압 상태로 주행하고 있다는 조사 결과를 통해서도 알 수 있다.<sup>1)</sup> 따라서 이러한 문제점들이 발생했을 경우 차량 스스로가 고장 상황을 인식하고 정확하게 분석하여 운전자에게 알리는 것이 필요하다.

1970년대부터 본격적으로 연구되기 시작한 고장

\*To whom correspondence should be addressed.  
kpark@kookmin.ac.kr

진단은 최근 들어 많은 기계적인 장치가 전자적인 장치로 대체되면서 중요한 분야로 인식되고 있다. 특히 신뢰성과 안전성의 확보가 절대적인 자동차, 항공기 분야에서는 고장 진단의 중요성이 더욱 강조되고 있는 실정이다.

넓은 의미로서의 고장 진단은 크게 고장 발견과 고장 진단으로 분류할 수 있는데, 고장발견은 시스템의 이상 여부를 판단하는 것이며 고장 진단은 고장 발견 후의 과정으로써 고장의 위치, 크기, 정확성 등을 판단하는 과정이다. 고장 발견 및 고장 진단에는 여러 가지 방법들이 연구되어 왔다. 고장 발견 방법은 크게 상한값 검사법(limit-checking method)과 모델기반 방법(model-based method)으로 분류되며, 고장 진단 방법은 크게 분류법(classification method), 진단 추론법(diagnostic reasoning method)으로 분류되는데, 시스템과 상황에 따라 적절한 방법이 적용된다.<sup>2)</sup>

본 연구에서는 댐퍼와 타이어의 고장 발견을 위한 방법으로 모델기반 방법의 하나인 파라미터 추정법을 사용하여 댐퍼의 감쇠력과 동적 타이어힘을 관측하고자 한다. 이 방법에서는 댐퍼, 타이어의 모델을 이용하여 정확한 파라미터값을 관측하므로 댐퍼와 타이어의 모델의 정확도가 중요한 요건이 된다. 그러나 댐퍼, 타이어와 같은 부품들은 실제 큰 비선형성을 가지고 있으므로 측정된 신호를 바탕으로 간단한 수학적 근사화시키는 기존의 모델링 기법으로는 정확한 모델을 얻기 어렵다.

따라서 본 연구에서는 신경망 이론을 이용하여 비선형성이 강한 시스템을 모델링하고 기존의 모델링 기법의 단점을 극복할 수 있는 경험적 동역학 모델링(EDM: Empirical Dynamics Modeling)기법<sup>3)</sup>을 이용하고자 한다. 고장 진단은 신경망 모델로부터 계산된 진단용 변수의 주파수 특성변화를 감지하여 고장 여부를 분석하고 운전자에게 알리는 과정으로 이루어지도록 설계하고자 한다.

## 2. 현가시스템 모델링

### 2.1 댐퍼 모델

댐퍼는 비선형성이 강한 시스템으로서 이러한 비선형성을 정확히 모델링하는 것은 상당히 어려운

일이다. 그러나 차량 개발 시 차량운동 해석을 위해 댐퍼의 모델이 필수적으로 포함되기 때문에 댐퍼의 비선형성을 보다 정확하게 모델링하기 위한 연구들이 다각적으로 이루어져 왔다.

Fig. 1은 Sachs사의 상용 가변댐퍼의 특성을 나타낸 것이다. 이러한 형태의 그래프는 차량 운동 시뮬레이션에 많이 사용되는데, 이는 시험을 통해 얻은 가변 댐퍼특성 데이터를 커브피팅하여 다항식으로 만든 것이다. Fig. 1과 같은 f-v 선도는 정현파 입력 시험을 통해 구해지는데, 실제 시험에서 측정된 데이터를 자세히 살펴보면 Fig. 2와 같은 비선형의 이력(hysteresis) 특성을 관찰할 수 있다. 따라서 정확한 댐퍼 모델이 요구되는 환경에서는 Fig. 1과 같은 해석적 모델은 부적절함을 알 수 있다.

이러한 댐퍼의 비선형 모델링에 따르는 문제를 극복하기 위해 80년대부터 신경망을 이용한 모델링에 관한 연구가 시작되었다. 신경망을 이용한 모델링은 고전적인 방법들로 풀기 어려웠던 문제들에




Fig. 1 Polynomial damper model

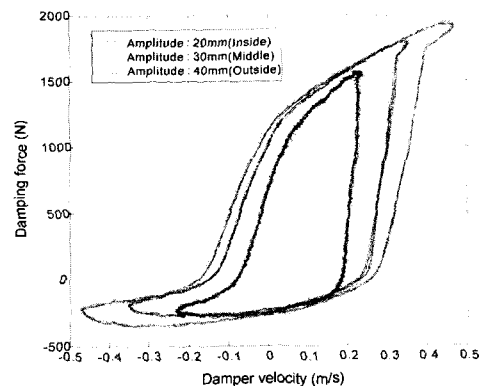


Fig. 2 Dynamic characteristics of variable damper

대한 해결책을 제시하였으며, 특히 비선형 동적 시스템의 모델링 문제에 있어 오류 역전과 알고리즘은 만족할 만한 결과를 보여주었다.<sup>3-5)</sup>

본 연구에서는 비선형 문제와 동특성 문제를 해결할 수 있는 방법으로서 신경망을 이용한 모델링 기법을 사용하였다. 특히 MTS에서 개발한 EDM기법에 기반하여 신경망을 설계하였다. Fig. 3은 본 논문의 신경망 모델의 구조를 나타낸다.

신경망에는 2개의 은닉층이 사용되었으며 뉴런의 활성화함수는 비선형성을 고려하여 hyperbolic tangent sigmoid 함수를 사용하였다. 또한 동특성을 고려하기 위해 시간지연(time delay) 신호를 이용하였다.<sup>6,7)</sup> 각각의 입력값을 3개의 시간지연 항을 넣어 지연시킨 후 입력으로 사용하였다. 이것을 식 (1)과 Fig. 4에 나타내었다.

$$v(k) = w_1x(k) + w_2x(k-1) + w_3x(k-2) + w_4x(k-3) \quad (1)$$

여기서  $x(k)$ 는 현재의 입력 데이터이며  $v(k)$ 는 신경망의 입력이다. 또한 신경망을 학습시키기 위해 오류 역전과 알고리즘을 사용하였다. 학습을 위한 입력값으로는 댐퍼의 상대가속도, 상대속도, 상대

변위와 각각의 시간 지연항을 사용하였고, 목표값으로는 로드셀에서 측정된 감쇠력을 이용하였다.

Fig. 5는 본 연구에서 사용된 댐퍼 특성 시험장치를 나타낸다. 유압 가진기에는 가속도계를 부착하였고, 댐퍼 끝단에 댐핑력을 측정하기 위한 로드셀을 부착하였으며, 댐퍼 변위는 LVDT를 이용하여 측정하였다.

Fig. 6은 가변댐퍼의 댐핑 계수를 고정하고 불규칙한 노면 데이터로 가진한 댐퍼 시험을 통해 얻은 데이터를 이용하여 댐퍼의 특성을 나타낸 것이다. 앞서 예상한 것과 같이 비선형성이 큰 것을 알 수 있다.




Fig. 3 Neural network model




Fig. 4 Input layer with delay



Fig. 5 Damper test equipment




Fig. 6 Force-velocity diagram of damper

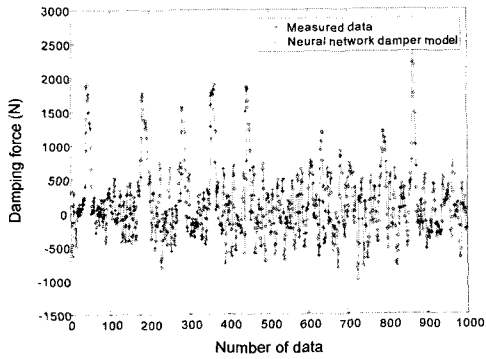


Fig. 7 Damping forces from measurement and neural network model

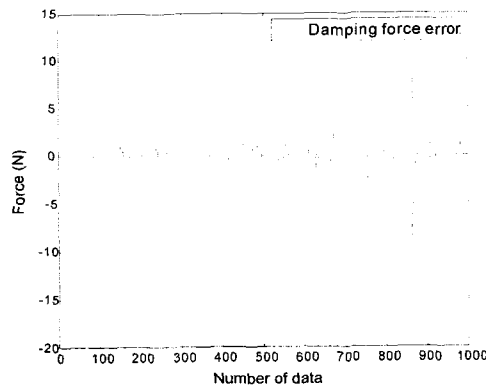


Fig. 8 Error in damping forces from measurement and neural network model

Fig. 7은 임의의 불규칙 노면 입력신호를 주었을 때 로드셀에서 측정된 댐핑력과 신경망 모델로부터 얻어진 댐핑력을 비교한 것이며, Fig. 8은 이들 두 신호의 오차를 보여주는 것이다. Fig. 8에서 최대오차는 15N이지만 대부분의 오차는 3N이내로, 신경망 모델이 실제의 댐핑력을 높은 정확도로 계산함을 알 수 있다.

### 2.2 타이어 모델

본 연구에서는 타이어의 고장 상황을 타이어의 공기압으로 판단하도록 설정하였다. 따라서 이러한 설정에 맞추어 타이어 모델로는 타이어의 수직방향의 운동만을 고려하는 모델을 사용하였다.

Fig. 9는 1/4 차량 모델을 나타내며 운동방정식은 식 (2)와 (3)에 주어진 식과 같다.

$$m_s \ddot{z}_s = f_d + f_s \quad (2)$$

$$m_u \ddot{z}_u = -f_d - f_s + f_t \quad (3)$$

Fig. 9에서 타이어는 하나의 스프링으로 모델링 되는데 본 연구에서는 신경망을 이용해 스프링이 비선형 특성을 가질 수 있도록 하였다.

타이어 모델을 위한 신경망은 댐퍼 모델을 위한 신경망과 동일한 구조를 갖도록 설계하였다. 신경망의 입력신호로는 스프링상 질량(sprung mass)과 스프링하 질량(unsprung mass)의 가속도, 그리고 보다 정확한 결과를 위해 상대 변위 신호를 추가적으로 사용하였다. 신경망의 목표값으로는 동적 타이어력을 사용하였다.

Fig. 10은 모델링한 결과를 또 다른 임의의 불규칙 입력 신호로 검증한 결과를 나타내고 있다. Fig. 11에서 보듯이 오차범위가 50N 이내로 상당히 정확하게 모델을 따라가고 있음을 알 수 있다.

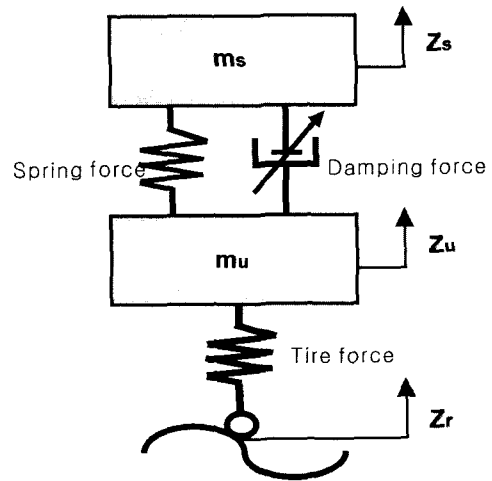


Fig. 9 Quarter car model

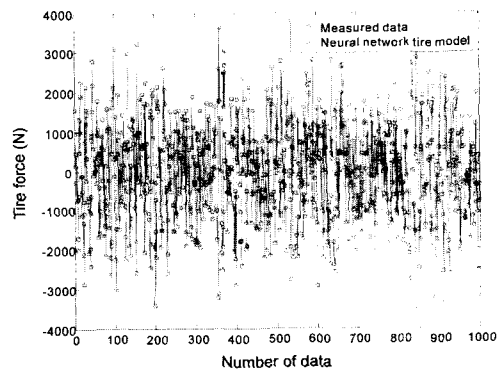


Fig. 10 Tire forces from measurement and neural network model

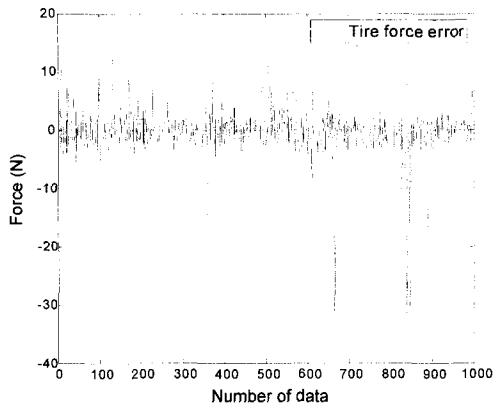


Fig. 11 Error in tire forces from measurement and neural network model




Fig. 12 Effect of variation of damping coefficient from 1/4 car simulation

### 3. 고장 발견 및 진단

#### 3.1 고장 발견 및 진단 방법

Buhardt는 파라미터 추정 기법을 이용하여 가변 댐퍼의 감쇠력을 관측함으로써 댐퍼의 상태를 감지하고자 하였다.<sup>1)</sup> 그러나 이 방법은 댐퍼의 비선형성이나 동특성을 충분히 고려하지 않고 단순히 속도에 따른 감쇠력의 크기만을 선형적으로 추측한 것이므로 실제 댐퍼의 특성을 정확히 고려했다고 보기 어렵다. 본 연구에서는 댐퍼의 특성을 보다 정확히 고려하기 위해 2장에서 얻은 신경망 댐퍼 모델을 이용하여 감쇠력을 구한 후 감쇠력의 주파수 특성 변화를 이용하여 댐퍼의 상태를 유추하고자 한다.

타이어의 경우, 기존의 방법에서는 고유진동수를 구하는 대수 방정식을 이용하여 타이어의 공기압을 관측하였으며<sup>1)</sup> 이때 방정식에 쓰이는 차량의 변수들은 선형으로 가정하였다. 본 연구에서는 이러한 차량 변수들을 선형으로 가정할 필요가 없는 신경망 타이어 모델을 이용하여 타이어에 걸리는 힘을 구한 후 주파수 분석을 수행하고 그 특성의 변화를 통하여 고장을 감지하고자 한다.

Fig. 12는 댐퍼가 노화되어 연해지는 경우 생기는 주파수 특성 변화의 경향을 보기 위해 1/4 차량을 대상으로 수행한 순수 시뮬레이션의 결과이다. Fig. 13은 타이어의 공기압이 부족한 경우에 대한 시뮬레이션 결과이다.

이때 댐퍼 모델로서는 Fig. 2의 비선형 댐퍼를 이용하였으며 타이어는 강성계수를 상수로 가정한 타




Fig. 13 Effect of variation of tire stiffness from 1/4 car simulation

이어 모델을 이용하였다. 노면 입력 신호는 일반 불규칙 도로 노면을 사용하였다. Fig. 12는 댐퍼 감쇠력의 PSD(Power Spectral Density)를 나타내며, Fig. 13은 동적 타이어력의 PSD를 나타낸다. Fig. 12에서 댐퍼의 감쇠계수가 다를 경우 2-20Hz의 주파수 영역에서 두 신호의 차이가 많이 나는 것을 볼 수 있다. 특히 2-9Hz사이에서 신호차가 많이 난다. Fig. 13에서 타이어의 강성계수가 달라지면 9-20Hz에서 두 신호차가 많이 나는 것을 알 수 있다.

#### 3.2 고장 발견 및 진단 알고리즘

3.1절의 시뮬레이션 결과로부터, 댐퍼의 경우 2-9Hz 주파수 영역의 감쇠력 성분을 이용하여 고장 여부 판단이 가능하며, 타이어의 경우 9-20 Hz 영역의 동적 타이어력 성분을 이용하여 고장 여부를 판

단할 수 있다는 것을 알 수 있다. 이러한 판단을 위해서는 고장 전과 고장 후의 주파수 특성을 비교할 수 있어야 한다.

본 연구에서는 이를 위하여 식 (4)를 이용하여 감쇠력을 계산하여 현재 댐퍼의 상황을 파악할 수 있도록 하였다.

$$f_d = m_s \ddot{z}_s - f_s \quad (4)$$

위 식에서 댐퍼 스프링은 고장진단 영역인 20Hz 미만에서는 거의 선형적으로 작동하므로<sup>10)</sup> 강성계수를 상수로 정하였으며 이에 따라 스프링력은 LVDT 측정 신호와 강성계수를 곱해서 얻을 수 있다. 따라서 댐핑 계수나 타이어 강성 계수 없이도 댐핑력과 동적 타이어력을 구할 수 있다.

또한 본 논문에서는 위의 감쇠력을 구하는데 사용된 센서 신호를 이용하여 신경망 댐퍼 모델로부터 참조 감쇠력을 얻도록 하였다. 즉, 앞서 구한 감쇠력은 고장난 상태의 댐퍼의 주파수 특성을 알려주며, 신경망 모델로 구한 감쇠력은 고장 전 상태의 댐퍼 특성을 알려준다. 따라서 이 두 신호의 차이로부터 고장 상황을 파악할 수 있게 된다.

Fig. 14는 앞서 서술한 내용을 바탕으로 본 연구에서 구현한 고장발견 및 진단 알고리즘의 흐름도를 나타낸다. 신경망 댐퍼 모델은 상대 가속도, 상대 속도, 상대 변위를 입력으로 필요로 하므로 측정되지 않는 입력인 상대 속도는 두개의 가속도 신호를 적분하여 계산하였다. 이러한 과정을 통해서 고장

이 발생한 것으로 판단이 되면 이 고장 판별에 대해 정확성을 높이기 위해 사용자가 정한 횟수만큼 데이터를 반복적으로 측정하여 계속 같은 결과가 나오는지를 판별한다. 고장에 대한 판단이 계속 나오면 컴퓨터는 운전자에게 시스템의 고장 상황을 알려주게 된다.

### 3.3 실험 장치

Fig. 15는 댐퍼와 타이어의 고장진단 알고리즘을 개발하고 검증하기 위해 본 연구에서 사용된 1/4차량 시뮬레이터를 보여준다. 댐퍼의 경우 가변댐퍼를 사용하여 감쇠력을 감소시켜서 댐퍼의 누유현상 등에 의해 댐퍼계수가 작아지는 고장상황을 재현하였다. 타이어는 공기압을 감소시켜서 타이어의 고장상황을 재현하였으며, 정상상태인 경우 32psi, 고장상황의 경우 20psi의 공기압을 사용하였다. 스프링상 질량은 270kg, 스프링하 질량은 50kg, 댐퍼 스프링의 강성계수는 28600N/m이다.




Fig. 15 Quarter car simulator

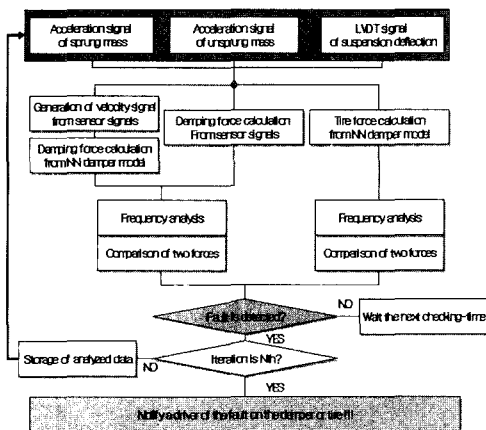


Fig. 14 Flow chart of fault diagnosis algorithm

### 3.4 알고리즘의 검증

본 연구에서는 실제 도로면과 유사한 여러 가지 노

면을 이용하여 고장 진단 알고리즘을 검증하였다.

Fig. 16과 Fig. 17은 알고리즘의 댐퍼 고장 판별 반복 횟수를 5회로 하였을 때 ISO A와 ISO B규격 노면에 대한 평균 PSD값을 나타내고 있다. 두 가지 노면 모두 2-9Hz영역에서 신경망댐퍼 모델로 추정된 값에 비해 식(4)로 계산한 값이 작음을 보이고 있다. 이는 댐퍼의 상태가 연해졌음을 보여주는 결과로서, 신경망 댐퍼 모델에 의한 고장진단 알고리즘이 노면의 상태와 상관없이 작동 가능함을 보여주는 것이다.

Fig. 18과 Fig. 19는 타이어가 공기압이 정상일 때와 규격보다 작은 두 가지 경우에 대해 ISO A와 ISO B 규격 노면을 주행했을 때의 시험 결과를 보여준다. 두 가지 노면 모두 PSD의 상대적인 크기는 다르지만, 공기압이 20 psi인 경우 9-20 Hz 영역에서 정상

공기압의 경우에 비해 신호가 작음을 알 수 있다.

Fig. 20과 Fig. 21은 ISO A 규격 노면을 주행할 때, 타이어와 댐퍼에 동시에 고장이 발생했을 경우의 결과를 나타내고 있다. Fig. 20에서는 타이어 공기압 변화의 영향으로 9-20 Hz영역에서 예상 결과와 약간의 차이를 보이고 있으나 전반적으로 앞의 댐퍼 진단 결과와 유사한 결과를 볼 수 있으므로 고장진단이 가능함을 알 수 있다.

Fig. 21 또한 댐퍼의 고장에는 무관하게 9-20 Hz 사이에서 신호차가 크음을 볼 수 있다. 따라서 이를 통하여 댐퍼와 타이어의 고장 진단 시에 두 요소가 서로에게 영향을 크게 미치지 않음을 알 수 있으므로 본 연구에서 제안한 알고리즘으로 효과적으로 고장진단이 가능하다는 것을 알 수 있다.

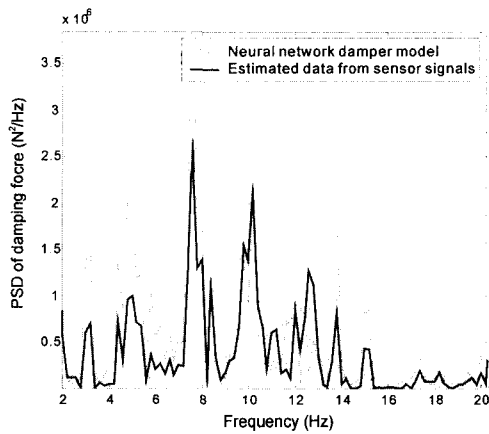


Fig. 16 Fault diagnosis algorithm of damper on ISO A road

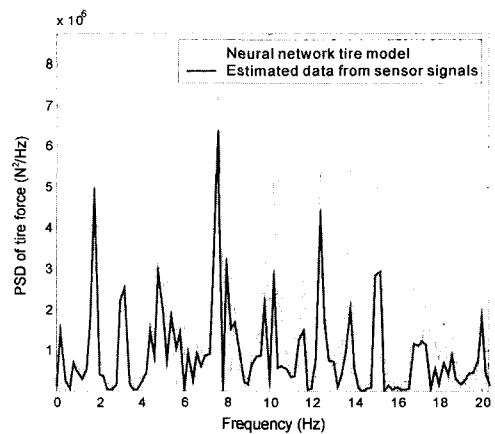


Fig. 18 Fault diagnosis algorithm of tire on ISO A road

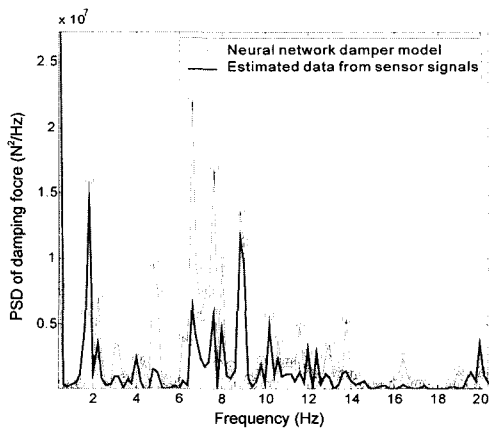


Fig. 17 Fault diagnosis algorithm of damper on ISO B road

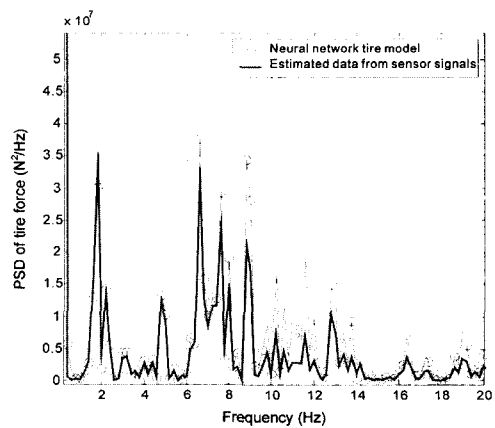


Fig. 19 Fault diagnosis algorithm of tire on ISO B road

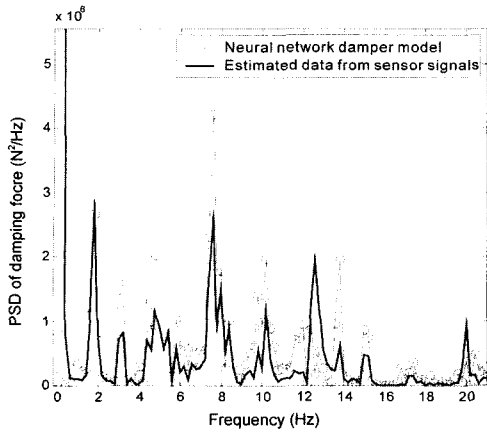


Fig. 20 PSD of damping force when faults occur in both damper and tire




Fig. 21 PSD of tire force when faults occur in both damper and tire

### 3.5 고장 진단 프로그램

앞 절에서 본 고장 진단 알고리즘을 기반으로 본 연구에서는 윈도우 기반 고장 진단 프로그램을 개발하였다. Fig. 22는 이 프로그램의 창을 보여준다.




Fig. 22 GUI window of fault diagnosis program

이 프로그램은 고장이 댐퍼에서 발생했는지, 타이어에서 발생했는지를 해당되는 경고를 점등하여 사용자가 알 수가 있게 했으며 PSD 선도를 보여줌으로써 고장의 정도를 판단할 수 있도록 하였다.

## 4. 결론

댐퍼와 타이어는 현가시스템을 구성하는 부품으로 차량의 운동 특성에 큰 영향을 미친다. 이들 부품에 고장이 발생하면 이는 차량의 안전에 영향을 줄 수 있는데, 댐퍼와 타이어의 경우 고장상태가 심각하지 않는 한 이를 운전자가 인식하는 것이 쉽지 않다. 따라서 이러한 문제점들이 발생했을 경우 차량 스스로가 고장 상황을 인식하고 정확하게 분석하여 신속하게 운전자에게 알리는 것이 매우 중요하다.

본 논문에서는 이러한 연구 배경을 바탕으로 댐퍼와 타이어의 고장진단을 위한 알고리즘을 개발하였다. 이를 위해 신경망 이론을 이용하여 댐퍼와 타이어를 모델링하여 비선형성과 동특성을 고려할 수 있도록 하였다. 고장 진단은 진단용 변수의 주파수 특성의 변화를 바탕으로 판단하도록 하였으며, 진단의 정확성을 위해 데이터를 여러 회 받아서 연속으로 고장 판별이 난 경우에 최종 고장 진단을 하도록 설계하였다.

ISO에서 규정한 두 가지 노면에 대해 설계된 고장진단 알고리즘의 성능을 판별하였으며, 그 결과 본 알고리즘이 댐퍼와 타이어의 두 요소 중 하나에서 고장이 발생한 경우, 그리고 두 요소에 동시에 고장이 발생한 경우, 적절히 진단을 내리는 것을 확인할 수 있었다.

본 연구는 추후 알고리즘이 노면에 관계없이 정확한 진단을 내릴 수 있도록, 보다 많은 노면을 대상으로 알고리즘의 성능을 검증하고자 한다. 또한 차속을 알고리즘의 입력으로 받아들여 차속에 따른 주파수 특성 변화를 고려하고 주행조건에 관계없이 정확한 고장진단을 내릴 수 있도록 알고리즘을 보완하고자 한다.

## 후 기

이 논문은 2001년도 두뇌한국21 사업에 의하여



지원되었음.

### References

- 1) R. Isermann, "Diagnosis Methods for Electronic Controlled Vehicles," AVEC'2000, 2000.
- 2) R. Isermann, P. Balle, "Trends in the Application of Model-based Fault Detection and Diagnosis of Technical Processes," Control Eng. Practice, Vol.5, No.5, pp.709-719, 1997.
- 3) A. J. Barber, "Accurate Models for Complex Vehicle Components Using Empirical Method," Proceedings of the Automotive Dynamics and Stability Conference, pp.117-146, 2000.
- 4) K.-D. Chong, "Nonlinear System Identification : Comparison of the Traditional and the Neural Network Approaches," Journal of Korean Society of Precision Engineering, Vol.12, No.5, pp.157-165, 1995.
- 5) K.-D. Chong, T.-S. No, D.-P. Hong, "Nonlinear System Modeling using Neural Networks," Journal of Korean Society of Precision Engineering, Vol.13, No.12, pp.22-29, 1996.
- 6) J. Giacomini, "Neural Network Simulation of an Automotive Shock Absorber," Engng Applic. Artif. Intell. Vol.4, No.1, pp.59-64, 1991.
- 7) I. Y. Kim, K. T. Chong, T.-S. No, D. P. Hong, "Empirical Closed Loop Modeling of a Suspension System using Neural Network," Journal of Korean Society of Precision Engineering, Vol.14, No.7, pp.29-38, 1997.
- 8) J. Giacomini, Modeling of Shock Absorbers with Neural Network, Neural Networks, 1993.
- 9) J. Lee, D. J. Thompson, "Dynamic Stiffness Formulation, Free Vibration and Wave Propagation of Helical Springs," Journal of Sound and Vibration, Vol.239, No.2, pp.297-320, 2001.
- 10) J. M. Lee, "Understanding Neural Networks," ICASE Magazine, Vol.1, No.3, pp.22-38, 1995.