

신경회로망 모델을 이용한 철도 현가장치 설계변수 최적화 Optimization of Design Variables of a Train Suspension Using Neural Network Model

김영국* · 박찬경* · 황희수** · 박태원***
Y. G. Kim, C. K. Park, H. S. Hwang and T. W. Park

(2002년 3월 29일 접수 : 2002년 5월 21일 심사완료)

Key Words : Railway Dynamics(철도차량 동역학), Experimental Design(실험계획), Neural Network(신경회로망), Back Propagation(역전파), Differential Evolution(차분진화), Suspension(현가장치), Optimization(최적화), Ride Comfort(승차감), Derailment Quotient(탈선지수), Unloading Ratio(윤증감소), Performance Index(성능지수), Stability(안정성), Design Variable(설계변수)

ABSTRACT

Computer simulation is essential to design the suspension elements of railway vehicle. By computer simulation, engineers can assess the feasibility of given design variables and change them to get a better design. Even though commercial simulation codes are used, the computational time and cost remains non-trivial. Therefore, many researchers have used a meta model made by sampling data through simulation. In this paper, four meta-models for each index group such as ride comfort, derailment quotient, unloading ratio and stability index, are constructed by use of neural network. After these meta models are constructed, multi-objective optimization are achieved by using the differential evolution. This paper shows that the optimization of design variables using the neural network model is very efficient to solve the complex optimization problem.

기호설명

b_j : 은닉층의 ~ 임계치
 Cr : 교배율
 d : 개체의 차원
 E_p : p 번째 입력치에 대한 제곱오차의 합
 F : 제어 파라미터(0~2)
 G : 진화 세대
 k : 활성화함수의 기울기 ($k > 0$)

net_{ij} : 입력신호들에 대한 합계함수
 O_{pj} : 은닉층의 출력
 O_{pk} : p 번째 입력치에 대한 k 번째 출력 뉴런의 실제출력
 $rand$: 0과 1 사이의 랜덤 ~ 변수
 T_{pk} : p 번째 입력치에 대한 k 번째 출력 뉴런의 원하는 출력
 w_{kj} : 은닉층과 출력층 사이의 연결강도
 w_{ji} : 입력층과 은닉층 사이의 연결강도
 $x_{r1,G}, x_{r2,G}$: i 번째 새로운 개체를 만들기 위한 서로 다른 기존개체
 $x_{i,G}$: i 번째 기존개체
 η : 학습률
 ϕ : 적합도
* : 교배 연산자로 균일교배임

† 책임저자, 정회원, 한국철도기술연구원
E-mail : ygkim@krii.re.kr
Tel : (031)457-6088(525), Fax : (031) 455-4868
* 정회원, 한국철도기술연구원
** 한라대학교 전기전자제어공학부
*** 정회원, 아주대학교 기계공학과

1. 서론

철도차량의 동적 거동과 관련한 성능은 주행안정성, 안전성 및 승차감 등으로 구분되며, 철도차량을 구성하는 질량요소, 현가장치의 성능 및 휠/레일의 접촉 조건(휠/레일 형상, 선로조건) 등에 의해 이러한 동적 성능이 결정된다. 철도차량의 질량요소는 차체, 대차 및 휠셀 등이며, 차체와 대차는 2차 현가장치에 의해 연결되고 대차와 휠셀은 1차 현가장치에 의해 연결된다.⁽¹⁾ 이러한 1차 및 2차 현가장치를 구성하는 현가요소는 코일스프링, 공기스프링, 유압 댐퍼, 고무 및 스테빌라이저 등이며, 이들 현가요소는 철도차량의 성능에 영향을 주기 때문에 차량의 설계 초기단계에서부터 검토가 필요하다. 그러나, 철도차량은 많은 설계변수와 성능지수를 갖고 있기 때문에 초기설계 단계에서 설계자가 모든 성능을 만족시키는 설계값을 선정하기는 무척 어렵다. 특히, 여러 성능을 동시에 만족시키려면 상당히 많은 데이터 정보를 필요로 한다. 그러나, 철도차량은 선로조건을 포함한 다량의 차량(예를 들면, 경부고속철도인 경우는 20량이 1편성입)으로 구성된 비선형 다자유도를 갖는 시스템이기 때문에 많은 데이터 정보를 얻으려면 VAMPIRE, ADAMS/RAIL, RecurDyn™ RAIL과 같은 철도동역학 전용 해석프로그램을 사용할 지라도 엄청나게 많은 해석시간을 필요로 한다. 따라서, 주어진 짧은 시간내에 정확하고 효과적인 현가장치의 설계를 위해 새로운 설계방향에 대한 제시가 필요하며, 이에 대한 연구가 이루어져야 한다.

설계변수와 성능지수가 많은 경우 통합 최적설계를 위한 모델로 일반적으로 반응표면 모델이 많이 사용되고 있다. 이 반응표면 모델은 2차의 다항식의 회귀곡선을 주로 사용하여 모델을 생성한다. 반응표면모델은 반도체 공정 최적화 및 CAD/CAE를 이용한 구조해석, 충돌해석, 공기역학, 차량동역학, 내구해석 등의 통합 최적설계에 사용되어왔다.^(2,3) 또한, 철도차량 대차의 탄성조인트에 대해 다구찌 적교배열을 이용하여 얻어진 데이터를 사용한 반응표면모델을 생성하고, 이 모델을 사용하여 최적설계를 수행한 적이 있다.⁽⁴⁾ 그러나, 반응표면을 이용한 모델은 비선형 시스템인 경우에는 높은 차원을 갖는 다항식의 회귀곡선을 사용하더라도 만족할 만한 결과를 얻기가 힘들기 때문에

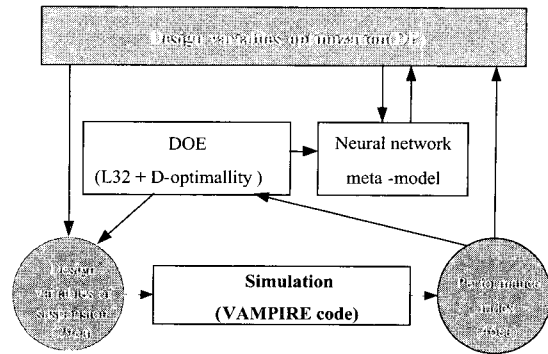


Fig. 1 Suspension optimization design flow

비선형 시스템에 적합한 모델을 필요로 한다. 비선형 모델의 하나인 신경회로망은 패턴인식, 의사결정, 시스템 인식⁽⁵⁾ 등이 뛰어나며, 성형공정설계, 자기진단, 금형설계⁽⁶⁾ 등의 기계분야로 그 적용 영역이 확장되고 있다.

본 연구에서는 한국형 고속전철의 설계변수와 성능지수와의 상호관계를 신경회로망으로 모델링하고, 그 모델링 결과를 차분진화 알고리즘을 이용하여 1, 2차 현가장치에 대해 최적설계를 수행하였다. 본 연구에서 수행하는 현가장치의 최적설계과정은 Fig. 1의 흐름도에서 알 수 있다.

2. 신경회로망과 차분진화 이론

2.1 신경회로망

다층 퍼셉트론 신경회로망은 인간의 뇌를 수학적으로 모델링한 것으로 Fig. 2와 같이 일반적으로 입력층, 은닉층 및 출력층으로 구분되며, 전형적인 역전파 학습 알고리즘에 의해 학습된다. 이 학습 알고리즘은 전향단계(feed forward)와 후향단계(feed backward)로 이루어지는 데, 전향단계에서는 입력값으로부터 출력값이 계산되고 후향단계에서는 출력값과 실제 기대하는 값의 평균제곱오차가 최소화되는 연결강도(가중치)를 계산하게 된다.⁽⁷⁾

전향단계에서 은닉층의 출력은 식 (1) ~ 식 (4)와 같이 입력값을 은닉층 노드에 연결된 입력층 노드의 연결강도를 곱하여 모든 합을 구한 후에 활성화함수를 통해 계산되며, 은닉층에서 출력층의 출력값을 구하는 것도 동일한 방법으로 계산할 수 있다. 후향단계는 전향단계에서 계산된 실제출력과 원하는 출력과의 오차를 최소화하여 신경회로망의 적절한 연결강도




Fig. 2 Typical back-propagation network

를 얻기 위한 학습과정이다.

$$net_{pj} = \sum_i w_{ji} O_{pi} + b_j \quad (1)$$

$$O_{pj} = \phi(net_{pj}) \quad (2)$$

여기서, $\phi(net_{pj})$ 는 활성화함수를 나타내는 데, 시그모드(sigmod)함수인 경우는 식 (3)으로, 선형(linear) 함수인 경우는 식 (4)로 정의된다.

$$\phi(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$\phi(x) = k \cdot x \quad (4)$$

원하는 출력패턴과 실제 출력의 전체 제곱오차 E는 식 (5)와 같이 쓸 수 있다.

$$E = \sum_p E_p = \frac{1}{2} \sum_k (T_{pk} - O_{pk})^2 \quad (5)$$

이 전체평균 오차를 최소화하기 연결강도의 증분량은 식 (6)으로부터 계산된다.

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} \quad (6)$$

따라서, 은닉층과 출력층 사이의 새롭게 조정된 연결강도는 식 (7)로 부터 구해진다.

$$w_{kj} = w_{kj} + \Delta w_{kj} \quad (7)$$

또한, 입력층과 은닉층 사이의 연결강도의 조정도 동일한 방법으로 수행하면 된다.

그러나, 앞에서 설명한 전형적인 역전파 학습 알고

리즘은 수렴속도도 느리기 때문에 실제 적용에는 한계가 있으며, 이러한 한계를 극복하기 위해 수정된 역전파 학습 알고리즘이 많이 제시되고 있다. 또한, 특징점에서 과도 적합(over-fitting)하게 되는 현상을 방지하기 위한 역전파 학습 알고리즘도 있다.⁽⁸⁾

2.2 차분진화

차분진화는 라이너(Rainer)와 커네스(Kenneth)에 의해 처음 제안되었으며, 이 방법은 집단에 속한 개체 벡터의 거리와 방향 정보를 사용한다. 이들은 5가지 진화 체계를 발표하였는데,^(9,10) 이 가운데 두 가지가 ICEC96 경연대회에서 10개의 시험 문제를 해결하는데 사용되어 진화알고리즘 중에서 가장 빨리 10개 문제를 풀 수 있었다. 이는 차분진화가 효율적인 함수최적화 방법임을 입증하는 것이다. 이 알고리즘은 구조와 연산이 대단히 간단하지만 수렴속도가 매우 빠르며 알고리즘 제어 파라미터가 적어서 사용하기 편리하고 병렬처리에도 적합하다. 차분진화는 집단 크기의 목적변수 벡터를 사용하는 탐색 방법으로 집단 크기는 진화 과정에서 변하지 않는다. 시스템에 대해 사전에 알려진 것이 없다면 초기 집단은 균일분포로 랜덤하게 구성하며, 만약 우수한 해를 초기값으로 알고 있다면 나머지 개체는 이 초기 값에 정규분포의 랜덤변화를 주어 발생되도록 할 수 있다. 차분진화의 핵심은 변화된 목적변수 벡터를 발생하는 체계에 있다. 차분진화는 식 (8)과 같이 랜덤하게 선택된 두개의 개체 벡터의 차이에 가중치를 곱한 것을 i번째 개체 벡터에 더해서 교배용 벡터를 발생한다. 이 벡터와 교배 대상 벡터가 교배되어 새로운 i번째 벡터가 식 (9)로부터 얻어지며, 모든 개체에 대해서도 동일한 방법으로 새로운 개체를 구하면 식 (10)과 같이 된다. 이 새로운 벡터의 목적함수 값이 교배 대상 벡터의 것보다 좋아지면 식 (11)과 같이 이 벡터를 교배 대상 벡터로 대체한다. 즉, 교배를 통해 새로 만들어진 벡터가 더 우수하면 이 벡터는 살아남게 된다. 이는 현재 집단과 적어도 같거나 보다 우수한 개체 벡터가 다음 세대에도 유지될 수 있도록 해주기 때문에 유전알고리즘에서 종종 사용되는 엘리트주의와 유사한 효과를 거둘 수 있다.

$$v_{i,G+1} = x_{i,G} + F \cdot (x_{n1,G} - x_{n2,G}) \quad (8)$$

$$x'_{i,G+1} = (v_{i,G+1} * x_{i,G}) \quad (9)$$

$$= \begin{cases} v_{i,G+1} & \text{if } (rand \leq Cr) \\ x_{i,G} & \text{otherwise} \end{cases} \quad i=1, \dots, d$$

$$x'_{G+1} = (x'_{1,G+1}, x'_{2,G+1}, \dots, x'_{d,G+1}) \quad (10)$$

$$x_{G+1} = \begin{cases} x'_{G+1} & \text{if } \phi(x'_{G+1}) > \phi(x_G) \\ x_G & \text{otherwise} \end{cases} \quad (11)$$

3. 신경회로망 모델

3.1 철도차량 모델링

철도차량의 동적거동 해석은 영국의 AEA Technology사의 철도차량 전용 해석프로그램인 VAMPIRE S/W⁽¹¹⁾를 사용하여 수행하였다. 해석을 위한 시스템 편성모델과 좌표계는 Fig. 3과 같다. 차량시스템 편성모델은 동력차 + 동력객차 + 객차(3대) + 동력 객차로 구성되었으며, 대차는 동력차용 동력대차 (PMB, power motor bogie) 2대, 동력객차용 동력대차 (MTB, motorized trailer bogie) 전후 2대 및 동력객차와 객차, 객차와 객차를 연결하는 관절대차 (ATB, articulated trailer bogie) 4대로 구성되어 있다. Fig. 4는 이러한 시스템 편성모델을 질량요소와 탄성요소의 특성치를 이용하여 VAMPIRE S/W로 표현한 것이다.




Fig. 3 Train model and axis system




Fig. 4 VAMPIRE train model

또한, 철도차량의 휠과 레일의 상호작용도 철도차량의 동적거동에 중요한 영향을 미치기 때문에 휠과 레일의 형상에 대한 모델링을 필요로 한다. 휠은 현재 부설중인 경부고속철도차량의 휠과 동일한 형상인 NFF 01-112규격에 따라 모델링을 하였으며 Fig. 5와 같다.

레일은 경부고속전철용 신선에 적용하고 있는 UIC 60 레일에 따라 Fig. 6과 같은 프로파일로 모델링을 하였다.

3.2 실험계획

본 연구에서 이용되는 설계변수는 동력대차와 관절대차의 1차 및 2차 현가장치에 사용되는 현가요소로 Table 1과 같이 29개이다. 또한, 성능지수는 Table 2와 같이 승차감 10, 탈선계수 12, 윤중감소 12, 안정성 12개로 총 46개가 선택되었다.

여기서, 승차감은 주파수 보정된 가속도 실효값 (root mean square)값을, 탈선지수는 휠에 작용하는




Fig. 5 Wheel profile model




Fig. 6 Rail profile model

Table 1 Design variables

No	Bogie	Design variables
X1	Primary suspension of MTB and ATB	Elastic joint Kx, Kz
X2		Elastic joint Ky
X3		Elastic joint Kt, Kw
X4		Elastic joint Kp
X5	Primary suspension of MTB	Double coil spring Kz
X6		Vertical oil damper Cz
X7	Secondary suspension of MTB	Air spring Kx, Ky
X8		Air spring Kz
X9		Vertical oil damper Cz
X10		Vertical oil damper Cx
X11		Anti-yaw oil damper g1
X12		Anti-yaw oil damper g2
X13		Anti-yaw oil damper g3
X14	Anti-yaw oil damper g4	
X15	Primary suspension of ATB	Double coil spring Kz
X16		Vertical oil damper Cz
X17	Secondary suspension of ATB	Air spring Kx, Ky
X18		Air spring Kz
X19		Anti-yaw oil damper g1
X20		Anti-yaw oil damper g2
X21		Anti-yaw oil damper g3
X22		Anti-yaw oil damper g4
X23		Fixed and carrier ring
X24	Fixed and carrier ring Ky	
X25	Fixed and carrier ring Kz	
X26	Fixed and carrier ring Kt	
X27	Fixed and carrier ring Kw	
X28	Secondary suspension of MTB	Anti-roll bar Kt
X29	Secondary suspension of ATB	Anti-roll bar Kt

Table 2 Performance indices

Index	Responses	Description
Ride comfort	r1~r5	Lateral acceleration of trailer
	r6~r10	Vertical acceleration of trailer
Derailment quotient	d1~d12	Ratio of lateral and vertical force of right wheel
Unloading ratio	w1~w12	Dynamic wheel force of left wheel
Stability	s1~s12	Lateral displacement of wheel center

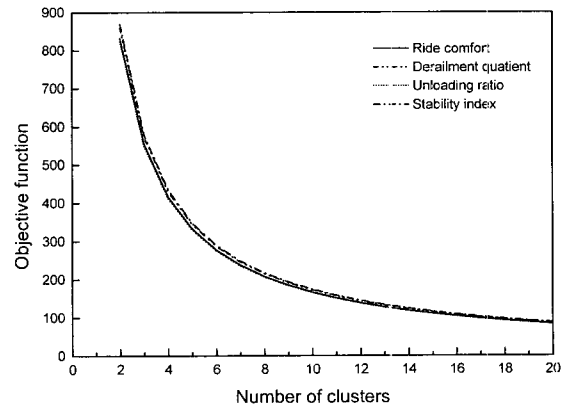


Fig. 7 Clustering result for performance index models

윤중과 횡압의 비로 표준편차값을, 윤중감소(unloading ratio)는 정적 수직력에 대한 동적 수직력의 비로 최대값을, 안정성(stability)은 초기 가진후에 발생하는 레일중심에서의 횡방향변위의 표준편차값을 사용하였다. 설정된 설계변수와 성능지수를 이용하여 신경회로망 모델을 생성하기 위한 실험계획은 29개의 설계변수에 대한 L32의 직교배열 33회에 정규화된 최대값[1]과 최소값[-1]의 중간값인 [-0.5, 0.5]에 대한 33회를 추가하여 총 66회로 하였다.

3.3 신경회로망 모델

29개 설계변수와 46개 성능지수에 대해 VAMPIRE S/W와 OPTIMUS S/W⁽¹²⁾를 통해 얻어진 66회의 전산실험 결과를 승차감, 탈선계수, 윤중감소 및 안정

성의 4개 성능분야별로 구분하여 신경회로망 모델을 생성하였다. 신경회로망은 입력층, 출력층 및 1개의 은닉층으로 구성하였으며, 은닉층에 대한 노드수는 패턴인식에 많이 사용되고 있는 퍼지클러스팅 기법⁽¹³⁾을 이용하여 설계변수와 각 성능분야에 대한 성능지수에 함축되어 있는 공간분포 특성을 조사하여 결정하였다. 클러스터링 기법은 많은 데이터 속에서 데이터의 비슷한 구조를 찾거나 비슷한 데이터로 나누게 하는 방법이다. Fig. 7은 클러스터 수에 따른 목적함수의 변화를 나타낸 것이다. Fig. 7에서 볼 수 있는 바와 같이 승차감, 탈선지수, 윤중감소 및 안정성에 대해 비슷한 결과가 얻어지는 데, 클러스터 수가 증가함에 따라 목적함수 값의 감소 추세가 점점 작아진다. 이 결과로부터 클러스터의 수는 10 ~ 15개 정도가 적당하다고 판단할 수 있다. 따라서, 성능분야별 신경회로망 모델의 은닉층의 기본적인 노드수는 10개로 하고, 만일 10개의 노드수로 원하는 수준의 모델을 찾을 수 없는 경우에 은닉층의 노드수를 15개까지

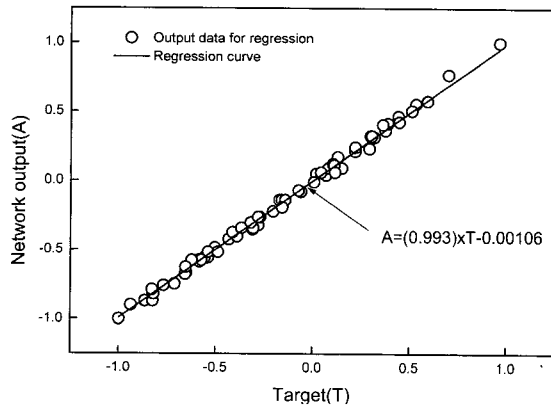


Fig. 8 Output regression of r1 between the true model and the neural network model

Table 3 Errors for performance index models

	Ride comfort	Derailment quotient	Unloading ratio	Stability
Abs. mean error	0.025	0.027	0.005	0.009
Abs. max. error	0.123	0.090	0.025	0.038

증가시키도록 하였다. 실제로 탈선계수만 은닉층의 노드수가 13개일 때 원하는 수준의 모델이 구해졌으며, 다른 성능분야의 경우는 은닉층의 노드수가 10개일 때 원하는 수준의 모델이 구해졌다.

신경회로망의 학습알고리즘은 수렴속도가 뛰어나며 특정점에서 과도적합되는 것을 방지하고 모든 점에서 적당히 일치하는 'Bayesian Regulation with Levenberg - Marquardt' 알고리즘⁽¹⁴⁾을 사용하였다. 각 모델의 입력변수는 29개이며, 출력변수는 승차감 모델은 10개, 그 외 모델은 12개이다.

Fig. 8은 승차감의 성능지수를 나타내는 동력객차의 좌우방향 가속도(r1)에 대해 학습 목표값(실험계 획법에 의한 결과)와 학습 결과값(신경회로망 모델에 의한 결과)를 회귀분석한 것이다. Fig. 8에서 볼 수 있는 바와 같이 기울기가 거의 1(상관계수 0.998)로 학습 목표값과 학습 결과값이 동일, 즉, 모델오차가 없는 것으로 판단할 수 있다. Table 3은 각 성능분야에 대해 신경회로망 학습이 완료되었을 때, 모든 출력변수에 대한 학습 목표값과 학습 결과값의 절대평균오차와 절대최대오차를 표시한 것이다.

여기서, 절대평균오차는 모든 출력에 대해 출력변수당 66개의 데이터에 대한 오차를 평균한 것이며,

절대최대오차는 모든 출력에 대해 66개 오차중에 가장 큰 값을 말한다. Table 3에 나타난 바와 같이 모든 모델에 대해 절대평균오차가 3% 이하였으며, 절대최대오차도 10% 내외로 신경회로망 모델이 타당성이 있는 것으로 판단된다.

4. 최적설계

일반적으로 최적화 문제는 최소화하거나 최대화해야 할 목적함수와 함께 제약조건을 갖는다. 진화알고리즘을 이용한 최적화 문제의 경우는 목적함수와 제약조건을 결합하여 사용하여야 한다. 현가장치 설계변수의 최적화에 사용될 최소화 목적함수는 식 (11)과 같다.

$$\min. f(x) = \sum_{i=1}^j p(x)_i \quad (11)$$

여기서, $f(x)$ 는 목적함수이며, $p(x)_i$ 는 i 번째 성능지수로 i 는 각 성능지수로서 1부터 j 까지로 본 연구에서는 j 가 46이다.

또한, 이러한 최적화문제에서 고려해야 할 사항은 최적화를 통해 얻은 성능지수가 일정한 값 이하가 되도록 해야하며, 이는 목적함수가 최소화되는 과정에서 특정한 성능지수가 희생되지 않도록 해야 한다는 것을 의미한다. 따라서, 식 (12)와 같은 제약조건이 필요하게 된다.

$$h(x)_i = p(x)_i - p(x)_{i,ini} < 0 \quad (12)$$

여기서, $h(x)_i$ 는 제약조건 식으로서 $p(x)_{i,ini}$ 는 각 성능지수의 초기값으로 최종적인 성능지수가 이 값보다는 작아야 한다. 또 다른 고려할 사항은 성능평가 지수별로 가중치를 두는 것이며, 가중치를 달리하면 최적화 과정에서 탐색결과도 달라지게 된다. 따라서, 최종적인 목적함수는 식 (13)과 같은 형태를 갖게된다.

$$f(x) = \begin{cases} \sum_{i=1}^j w_i \times p(x)_i & \text{if } (h(x)_i < 0) \\ \sum_{i=1}^j p_f & \text{otherwise} \end{cases} \quad (13)$$

여기서, p_f 은 식 (12)의 제약조건을 위반하는 경우에 곱해지는 벌칙계수이다.

Fig. 9는 임의로 5회에 걸쳐 랜덤하게 선택된 30개의 초기집단에 대해 진화횟수에 따른 식 (13)으로 정의된 목적함수의 변화를 나타낸 것으로 모든 경우에

진화횟수가 800회 이상에서는 수렴함을 보여주고 있다. Table 4는 초기 설계변수와 랜덤하게 선택된 임의의 초기집단에 대해 2500회 진화횟수를 완료한 후의 최적화된 설계변수를 나타낸 것이며, Fig. 10은 Table 4의 초기상태와 최적화된 상태에 대해 신경회로망 모델과 실제모델에 대한 성능지수를 표시한 결과이다. 식 (11)로 정의되는 각 성능지수의 합인 목적함수는 신경회로망의 경우는 초기상태에서는 -3.97이었지만, 최적화가 완료된 후에는 -26.84로 목적함수




Fig. 9 Convergence curve of cost function

Table 4 Design variables at initial and optimized states

No.	Design variable		No.	Design variable	
	Ininitial value	Optimized value		Ininitial value	Optimized value
X1	49.45	46.55	X16	0.006	0.007
X2	14.405	13.822	X17	0.187	0.201
X3	0.0653	0.0524	X18	0.26	0.21
X4	0.0072	0.0077	X19	8.712	10.379
X5	1.3453	1.6122	X20	3.318	3.159
X6	0.007	0.006	X21	2.4	2.3
X7	0.154	0.152	X22	3.6	4.1
X8	0.29632	0.27008	X23	45.0	36.3
X9	0.014	0.011	X24	111.5	89.2
X10	0.0237	0.0198	X25	76.63	63.84
X11	7.7007	8.3444	X26	1.61	1.80
X12	0.60	0.53	X27	0.026	0.030
X13	0.40	0.48	X28	3.80	3.90
X14	7.00	7.21	X29	3.30	3.59
X15	0.62964	0.62951			

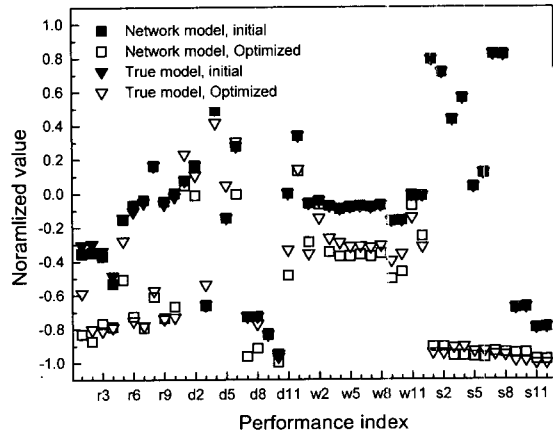


Fig. 10 Performance indices of initial state and optimized state for neural network and true model

가 22.87이 감소하였다. 실제 모델(VAMPIRE 해석 결과)의 경우는 초기상태의 목적함수가 -3.87이었는데, 최적화가 완료된 후에 -24.72로 20.85가 감소되었다. 실제모델과 신경회로망 모델에 대해 최적화 후에 목적함수가 초기상태보다 신경회로망의 경우는 1/6.76배, 실제 모델의 경우는 1/6.39배로 거의 비슷한 비율로 크게 작아졌음을 알 수 있다. Fig. 10에서 알 수 있는 바와 같이 각 성능지수의 대부분은 신경회로망 모델과 실제 모델의 두 경우 모두에 대해 정도 차이는 있지만 초기상태보다 작아졌음을 알 수 있다. 특히, 승차감과 안정성 성능지수의 최적화 향상 정도는 최대 약 88%와 38%로 상대적으로 크다는 것을 알 수 있다.

이상의 결과에서 신경회로망 모델을 이용한 차분진화 최적화가 다설계변수 다목적함수를 갖는 현가장치의 최적화에 유효한 방법이라고 판단할 수 있다.

5. 결 론

본 연구의 결과를 통해 다음과 같은 결론을 얻을 수 있다.

(1) 다설계변수 다목적함수를 갖는 시스템 최적화 문제에 대해 적은 수의 실험 데이터로도 신뢰성이 있는 결과를 얻을 수 있음을 실제모델과 신경회로망 모델의 성능비교를 통해 입증하였다.

(2) 신경회로망 모델의 은닉층 노드 수 결정에 퍼지클러스터링 방법을 적용함으로써, 노드 수 변경에

따른 반복적인 모델링 과정을 줄일 수 있었다.

(3) 철도차량 현가장치의 최적설계를 위해 신경회로망을 이용한 시스템 모델을 구축하였고 차분진화를 통해 최적 설계변수 효과적으로 탐색할 수 있었다.

후 기

본 연구는 G7 고속전철 기술개발 사업의 지원으로 이루어졌으며, 이에 감사드립니다.

참 고 문 헌

(1) 김영국 등, 2001, "바람이 고속전철의 동적 안정성에 미치는 영향분석", 한국소음진동공학회논문집, 제 11 권, 제 8 호, pp. 349~356.
(2) Nick, T., 1997, "Numerical Methods for Modeling and Optimization of Noise Emission Applications", ASME Symposium in Acoustics and Noise Software, Detroit, MI, USA.
(3) Bennet, 1998, "Issues in Industrial Multi-disciplinary Optimization", AIAA Paper 98-4737.
(4) 박찬경 등, 2000, "반응표면모델에 의한 철도차량 대차의 탄성조인트 최적설계", 대한기계학회논문집 A권, 제 24 권, 제 3 호, pp. 661~666.
(5) Chen, S. et al., 1990, "Non-linear System

Identification Using Neural Networks", Int. J. Control, Vol. 6, pp. 1191~1214.

(6) 김동진 등, 1997, "신경망을 이용한 냉간단조품의 금형형상 설계", 대한기계학회논문집 A권, 제 21 권, 제 5 호, pp. 727~734.

(7) 이상배, 1999, 퍼지-뉴로제어 시스템, 교학사.

(8) Hagon, M. T. et al., 1996, Nueral Network Design, Boston, MA:PWS Publishing.

(9) Price, K. et al., 1997, "Differential Evolution: Numerical Optimization Made Easy," Dr. Dobbs Journal, pp. 18~24.

(10) Storn, R., 1996, "Minimizing the Real Functions of the ICEC96 Contest by Differential Evolution," IEEE Conference on Evolutionary Computation, pp. 842~844, Nagoya.

(11) AEA Technology, VAMPIRE Users Manual 1998.

(12) LMS, 1998, OPTIMUS Users Guide.

(13) Bezdek, J. C., 1981, Pattern Recognition with Fuzzy Objective Function, Plenum Press, New York.

(14) MacKay, D. J. C., 1992, "Bayesian Interpolation", Neural Computation, Vol. 4, No. 3, pp. 415~447.