

# 신경회로망과 실험계획법을 이용한 타이어의 장력 추정

## Tension Estimation of Tire using Neural Networks and DOE

이동우<sup>1</sup>, 조석수<sup>2</sup>

Dong-Woo Lee<sup>1</sup> and Seok-Swoo Cho<sup>2</sup>

1 동아대학교 기계공학과 (Department of Mechanical Engineering, Dong-A Univ.)

2 강원대학교 자동차공학과 (Department of Vehicle Engineering, Kangwon National Univ.)

✉ Corresponding author: sscho394@kagnwon.ac.kr, Tel: 033-570-6394

Manuscript received: 2011.2.25 / Accepted: 2011.4.25

*Abstract It takes long time in numerical simulation because structural design for tire requires the nonlinear material property. Neural networks has been widely studied to engineering design to reduce numerical computation time. The numbers of hidden layer, hidden layer neuron and training data have been considered as the structural design variables of neural networks. In application of neural networks to optimize design, there are a few studies about arrangement method of input layer neurons. To investigate the effect of input layer neuron arrangement on neural networks, the variables of tire contour design and tension in bead area were assigned to inputs and output for neural networks respectively. Design variables arrangement in input layer were determined by main effect analysis. The number of hidden layer, the number of hidden layer neuron and the number of training data and so on have been considered as the structural design variables of neural networks. In application to optimization design problem of neural networks, there are few studies about arrangement method of input layer neurons. To investigate the effect of arrangement of input neurons on neural network learning tire contour design parameters and tension in bead area were assigned to neural input and output respectively. Design variables arrangement in input layer was determined by main effect analysis.*

Key Words: Neural Networks (신경회로망), Latin-hyper Cube (라틴 하이퍼 큐브), Main Effects Analysis (주효과 분석), Learning (학습)

### 1. 서론

오늘날 자동차의 성능향상에 따라 타이어 설계에 대한 요구도 다양화되고 있다. 원전성능, 내마모성, 내구성, 승차감, 소음 등의 다양한 요구 성능을 만족하는 설계를 하기 위해서 대부분의 타이어 회사들은 유한요소해석을 타이어 설계에 적용하고 있다. 그러나 타이어는 비선형 특성 때문에 유한요소해석 시간이 많이 요구된다. 따라서, 타이어의 해석시간을 줄이기 위해 최근에는

신경회로망을 적용하는 연구가 활발히 이루어지고 있다.<sup>1-3</sup>

이러한 연구로써, 김<sup>1</sup> 등과 조<sup>2</sup> 등은 타이어의 설계에 필요한 유한요소해석을 최소화하기 위하여 신경회로망을 적용시켜 해석시간을 단축시켰다.

하지만 신경회로망을 공학적으로 적용하기 위해서는 먼저 신경회로망을 효율적으로 설계를 해야 한다. 신경회로망은 일반적으로 입력층(Input layer), 은닉층(Hidden layer) 및 출력층(Output layer)

의 구조로 이루어져 있으며, 각 층마다 각각의 뉴런수(Unit)를 가지고 있다. 이러한 신경회로망의 성능은 입력층의 뉴런수, 은닉층의 개수와 뉴런수 그리고 학습데이터의 구성과 개수, 학습률, 학습회수 등에 의하여 많은 영향을 받는다. 따라서 신경회로망의 효과적인 구조설계에 대한 연구가 많이 진행되고 있다. 김<sup>1</sup> 등과 이<sup>4</sup> 등은 실험계획법의 직교배열표를 다중 퍼셉트론 신경망의 구조설계에 적용하여 적은 실험횟수로 적합한 신경회로망 모델을 구성할 수 있음을 검증하였다. 안<sup>5</sup> 등과 이<sup>6</sup> 등은 실제 사례에 적용하여 그 유용성을 제시하였다.

하지만 이러한 신경회로망의 구조설계에 있어 대부분의 연구는 은닉층의 수와 은닉뉴런 수, 학습에 이용되는 학습데이터의 개수 또는 학습횟수나 학습률 등에 한정되어 있다. 실질적인 공학문제에서 설계변수에 해당하는 입력층을 구성하는 입력뉴런의 구성에 관한 연구는 전무한 실정이다.

본 연구에서는 입력층 구성에 따른 신경회로망의 예측성능의 영향을 평가하였다. 타이어 컨투어(Contour) 설계에 사용되는 설계변수를 입력층으로 조종안정성에 영향을 미치는 비드부의 장력<sup>7</sup>을 출력층으로 하는 신경회로망을 구성하였다. 실험계획법의 주효과 분석을 이용하여 설계변수의 구성을 결정한 후, 설계변수의 구성 변화에 따른 신경회로망의 성능을 평가하였다. 이를 이용하여 타이어 비드부의 장력 예측에 적합한 신경회로망의 입력층을 설계하였다.

## 2. 신경회로망의 입력층 설계에 관한 연구

본 연구에서는 입력층의 구성에 따른 신경회로망의 예측성능의 영향을 평가하기 위하여, 실험계획법의 주효과 분석을 이용하여 설계변수의 구성을 결정한 후, 설계변수의 구성 변화에 따른 신경회로망의 성능을 평가하였다.

Fig. 1은 입력층 구성에 따른 신경회로망의 예측성능의 영향을 평가하기 위한 흐름도를 나타낸 것이다. 우선, 신경회로망의 입력층과 출력층을 결정한다. 본 연구에서는 타이어 컨투어(Contour) 설계에 사용되는 설계변수를 입력층으로 조종안정성에 영향을 미치는 비드부(Bead)의 장력을 출력층으로 하는 신경회로망을 구성하였다. 두 번째, 신경회로망을 구성하는 입력층의 영향을 평가하기 위

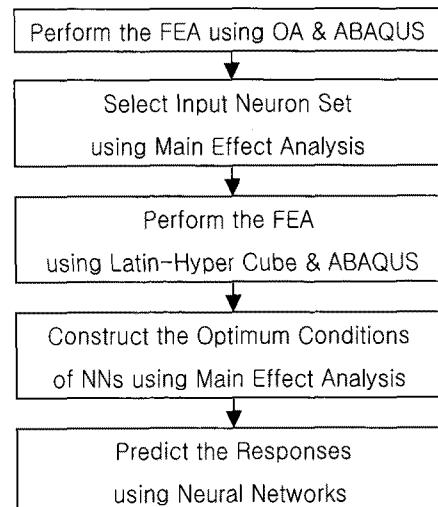


Fig. 1 Flow chart of estimation

하여 직교배열표를 구성하고 유한요소 해석 프로그램을 이용하여 해석을 수행한다. 세 번째, 앞에서 구한 결과값을 기초로 주효과 분석을 한 후 입력층을 설계한다. 네번째, 라틴하이퍼큐브 샘플링(Latin-hyper cube)에 따라 유한요소해석을 수행한 후 주효과 분석을 이용하여 신경망의 최적조건(학습률(Learning rate), 학습횟수, 모멘텀률(Momentum rate), 은닉층의 뉴런수)을 결정한다. 마지막으로, 앞에서 구한 입력층 입력뉴런 구성에 따라 신경회로망을 학습시킨 후, 미지의 입력값에 대한 반응값을 추정한다.

### 2.1 신경회로망 설계

#### 2.1.1 입력층 및 출력층 결정

본 연구에서는 타이어 컨투어 설계에 관련된 설계변수를 입력층으로 구성하였으며, 출력층으로 조종안정성에 영향을 미치는 비드부의 장력을 선택하였다. Fig. 2는 타이어 비드부의 장력을 나타낸 것이다.

Fig. 3은 타이어 컨투어 설계의 설계변수를 나타낸 것으로서 트레드(Tread) 형상과 사이드월(Sidewall) 형상을 결정하는 반경 A, B 및 위치결정을 위한 길이 C, D, E 등 5개를 설계변수로 결정하고 이를 입력층으로 선택하였다. 그리고 Table 1은 각 설계변수에 대한 범위를 나타낸 것이다. 그리고 Fig. 4는 신경회로망 구조를 나타낸 것으로 본 연구에서는 역전파 신경회로망을 사용하였다.

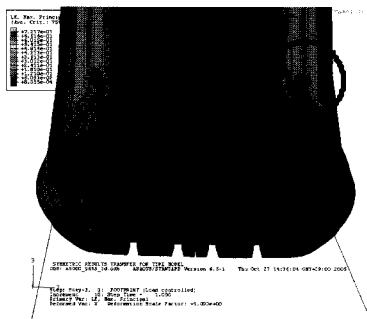


Fig. 2 Tension in bead area

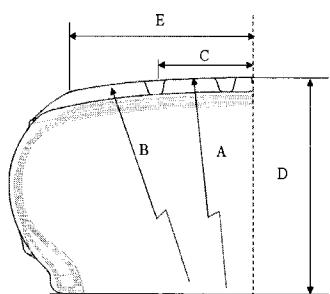


Fig. 3 Design variables for tire contour

Table 1 Bounds of design variables

	Bounds (mm)
Tire contour	$400 \leq A \leq 1200$
	$180 \leq B \leq 350$
	$30 \leq C \leq 50$
	$57.375 \leq D \leq 76.5$
	$70 \leq E \leq 90$

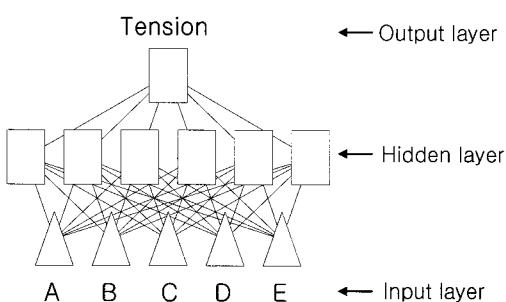


Fig. 4 Neuron network model

### 2.1.2 타이어 유한요소해석

본 연구에 사용한 타이어의 해석프로그램은 비선형 해석에 많이 사용되고 있는 상용프로그램인 ABAQUS 6.5를 사용하였다.<sup>8</sup> 그리고 해석에 사용

된 실제 타이어의 모델은 승용차용 타이어 P195/65R15이다.

Fig. 5는 타이어의 유한요소모델에 대한 경계 조건과 하중 조건을 나타낸 것이다. 유한요소 해석은 우선 림을 타이어의 좌우로 충분히 이동시켜 모델링 한 후 원래 위치로 찾아가는 방식으로 비드부를 고정시키고 공기압을 불어넣어주는 식으로 진행된다. 공기압은 유한요소모델 내부에서 균일한 압력으로 작용하며 크기는  $1.8 \text{ kgf/cm}^2$ 이다.

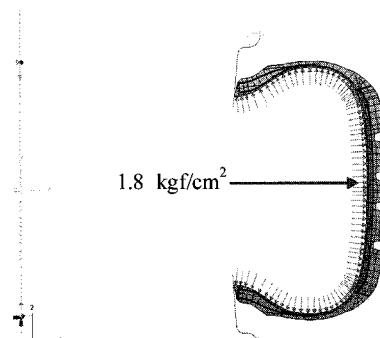


Fig. 5 Boundary and load conditions

### 2.2 주효과 분석

일반적으로 인자의 수준을 3 수준 이상의 실험을 하면 실험회수는 증가하나 데이터 분석이 2 차식으로 표현되어 비선형성을 고려할 수 있으므로, 본 연구에서는 타이어의 설계변수 개수를 고려하여, 타이어 컨투어를 결정하는 주요 설계변수 5 개를 인자로, 타이어의 목적성능인 조종안정성이 영향을 미치는 비드부의 장력을 반응값으로 하여 인자 5 개, 5 수준의  $L_{25}(5^6)$  직교배열표<sup>9</sup>로 결정하였다.

Fig. 6은 반응값 즉 비드부의 장력에 대한 설계변수의 주효과를 나타낸 것이다. Fig. 6에서 점선은 반응값의 총평균이고 각 점은 수준에서의 평균을 의미한다. 비드부의 장력이 크면 클수록 조종안정성이 좋게 나타난다. 따라서, 비드부의 장력에 대한 각 설계변수의 주효과를 살펴보면, 설계변수 D의 경우는 57.38에서 주효과가 크게 나타났으며, 설계변수 E의 경우는 90 일 때 주효과가 크게 나타나고 있다. 이는 타이어 컨투어 설계시 설계변수 D의 경우는 치수를 감소하는 방향으로, 설계변수 E의 경우는 치수가 증가하는 방향으로 설계를 해야 한다는 것이다. 그리고 설계변수 A, B, C의 경우는 치수의 변화에 따른 비드부의 장력이 변하지 않는다는 것으로 치수변화가 비드부의 장력에

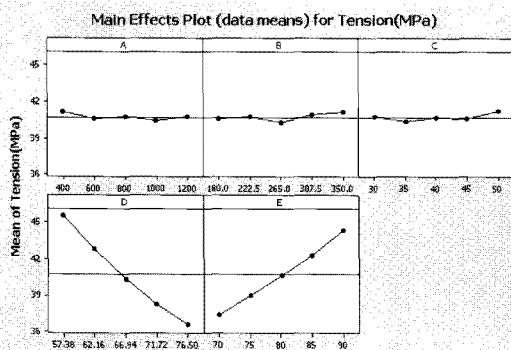
Fig. 6 Main effects plot for tension<sup>8</sup>

Table 2 Input layer set

Case	Input layer		
	I	II	III
Design variables	D, E	A, B, C	A, B, C, D, E

영향을 주지 않는다는 것을 의미한다. 따라서, 본 연구에서는 입력층 구성에 따른 신경회로망의 예측성능의 영향을 평가하기 위하여, Fig. 6의 주효과 분석을 이용하여, 3 가지 경우에 대하여 입력층을 구성하였다. Table 2는 입력층의 구성을 나타낸 것으로, Case I은 장력에 영향을 주는 설계변수, Case II는 영향을 주지 않는 설계변수, Case III는 모든 설계변수로 이루어진 입력 층으로 구성하였다.

### 2.3 신경회로망의 구조설계

타이어 비드부의 장력을 예측하기 위한 신경회로망의 학습데이터를 라틴-하이퍼큐브 샘플링법을 이용하여 설계점을 생성한 후, 각 설계점에 대하여 유한요소해석을 수행하였다. 그리고 이 데이터들을 기초로 신경회로망의 학습에 영향을 미치는 학습률과 모멘텀률, 은닉층 뉴런수 및 반복수의 최적조합을 결정하였다.

#### 2.3.1 라틴하이퍼 큐브에 의한 학습데이터 선정

신경회로망을 학습시키는데 필요한 데이터를 얻기 위하여 실험을 한번 시행하는데 많은 시간과 비용이 들거나 특히 인자가 많은 실험에 유용한 라틴-하이퍼큐브 샘플링법<sup>10</sup>을 이용하여 설계점을 생성하였으며 Table 3에 나타내었다.

그리고 학습된 신경회로망의 일반화 능력은 각 설계변수 구간에서 임의의 설계점 5개를 시험데이터(Test data)로 선정하여 평가하였으며 각 설계

점은 Table 4에 나타내었다.

#### 2.3.2 신경회로망 구조의 최적설계

입력층의 구성에 따른 신경회로망의 학습 효과를 평가하기 위하여, 우선 각 입력층의 구성 즉, Table 2의 Case I-III에 대한 최적의 신경회로망을 설계해야 한다. 따라서, 본 연구에서는 각 경우에 대한 신경회로망의 학습능력에 영향을 미치는 학습률과 모멘텀률, 은닉층 뉴런수 및 반복수의 최적조건을 결정하기 위하여 인자의 개수를 고려하여 L<sub>9</sub>(3<sup>4</sup>) 직교배열표를 적용하여 주효과 분석을 수행하였다. Table 5는 각 인자의 수준을 나타낸 것이다.

학습률, 모멘텀률과 은닉층 뉴런수의 수준은 기존 논문의 연구결과를 참고하여 결정하였다.<sup>11-15</sup>

그리고, 반응값은 신경회로망의 타당성을 평가하기 위하여, 신경회로망에서 구한 추정값과 유한요소해석값과의 평균퍼센트오차이며 식(1)에 나타내었다.

$$Ave.\%error = \frac{1}{n_t} \sum_{i=1}^{n_t} \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100(\%) \quad (1)$$

Table 3 Latin-hyper cube

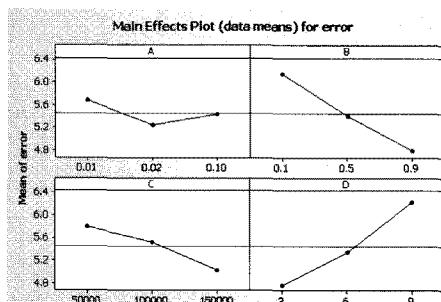
No.	Factors					Response
	A	B	C	D	E	
1	859.84	269.83	37.77	60.00	73.14	32.86
2	1170.32	181.80	41.80	63.28	89.38	34.86
3	970.96	326.35	42.39	73.57	76.17	30.29
:	:	:	:	:	:	:
48	441.20	250.70	40.86	64.11	87.00	32.06
49	698.24	325.40	31.55	65.14	80.66	30.77
50	1118.32	294.04	36.57	58.99	88.90	34.87

Table 4 Test data for confirmation

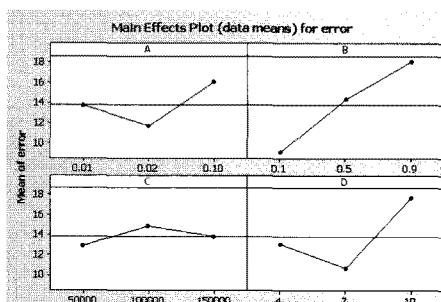
No.	Factors					Response
	A	B	C	D	E	
1	851.36	290.092	40.622	64.81	89.694	31.69
2	1029.84	302.281	39.988	76.251	72.19	27.46
3	744.48	238.242	30.704	70.416	86.44	29.68
4	419.36	281.898	35.81	62.096	81.178	28.30
5	1088.48	187.021	44.824	66.524	70.366	28.14

Table 5 Levels of factor

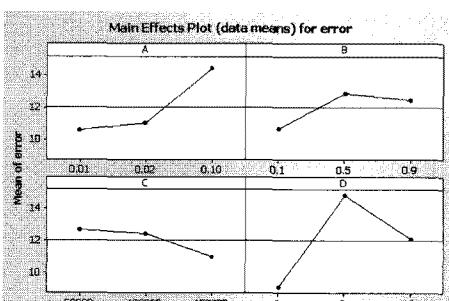
Level	Level of factor					
	Learning rate	Momentum rate	Epochs	No. of hidden neuron		
				2 EA	3 EA	
1	0.01	0.1	50,000	3	4	6
2	0.02	0.5	100,000	6	7	9
3	0.1	0.9	150,000	9	10	12



(a) Case I: 2EA



(b) Case II: 3EA



(c) Case III: 5EA

Fig. 7 Main effects plot for error<sup>8</sup>

Table 6 Optimal conditions for each case

Case	Factor				
	Learning rate	Momentum rate	Epochs	No. of hidden neuron	
I	2 EA	0.02	0.9	150,000	3
II	3 EA	0.02	0.1	50,000	7
III	5 EA	0.01	0.1	150,000	6

여기서,  $n_t$  는 테스트점의 갯수이며, 실제값(True value)  $y_i$ 는 유한요소해석 결과값으로 설정하였다.

Fig. 7 과 Table 6 은 각 인자에 대한 주효과 분석의 결과와 그에 따른 최적값을 나타낸 것이다.

## 2.4 결과 및 토의

Fig. 8 과 Table 7 은 앞 절에서 구한 Table 6 의 신경회로망 최적조건을 이용한 학습결과와 평균퍼센트오차를 나타낸 것이다. Case I~III 모두 일반적인 공학적 오차 5% 이내로 수렴이 됨을 알 수 있다.

Table 8 과 Fig. 9 는 학습된 신경회로망을 이용한 시험데이터에 대한 예측결과이다. 반응치에 영향을 많이 주는 Case I의 경우, 시험데이터의 예측치 대부분의 오차가 5% 이내로 안정적인 결과를 나타내었다. 하지만, Case II 와 III의 경우는 예측치의 오차가 넓게 산포하고 있어 예측의 정도가 멀

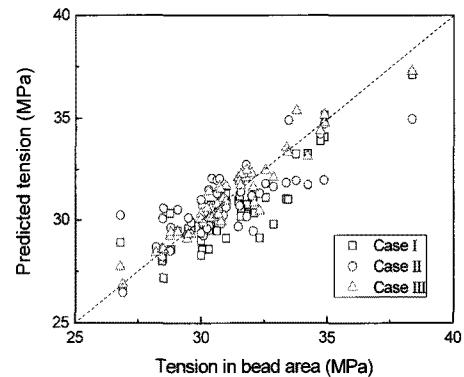


Fig. 8 Learning results for Latin-hyper cube data

Table 7 Results of % error for learning

Case	Error (%)
I	2EA
II	3EA
III	5EA

Table 8 Estimation results for test data

Case	Exp. No.	Results				
		1	2	3	4	5
I 2EA	Test	31.32	26.48	30.95	30.84	27.98
	FEA	31.69	27.46	29.68	28.30	28.14
	%Error	1.18	3.58	4.28	8.97	0.56
II 3EA	Test	31.89	31.93	36.65	26.40	31.59
	FEA	31.69	27.46	29.68	28.30	28.14
	%Error	0.64	16.23	23.48	6.71	12.28
III 5EA	Test	34.26	28.11	30.76	30.69	25.74
	FEA	31.69	27.46	29.68	28.30	28.14
	%Error	8.11	2.36	3.64	8.44	8.52

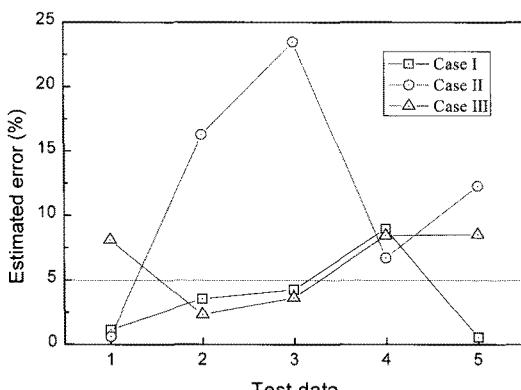


Fig. 9 Results of %error for test data

어지는 것으로 나타나고 있다. 특히, 반응 치에 영향을 주지 않는 설계변수를 입력층으로 구성한 Case II의 경우는 매우 큰 예측오차를 나타내고 있다.

Fig. 10은 신경회로망의 입력층 구성에 따른 학습데이터와 시험데이터의 정확도를 나타낸 것이다. 입력층 구성에 따른 모델의 정확도를 비교하기 위하여 Poliak<sup>16</sup>이 정의한 PA(Predictive ability) 식(2)를 이용하였으며, 오차범위 5% 이하의 예측을 정확한 예측으로 간주하여 정확도를 평가하였다.

$$PA = \frac{N_{PA}}{N_T} \times 100(\%) \quad (2)$$

여기서,  $N_{PA}$ 는  $\left| \frac{T_{FEA} - T_{NN}}{T_{FEA}} \right| \leq 0.05$  범위의 예측치

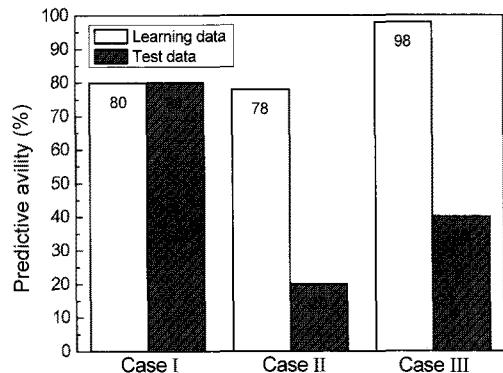


Fig. 10 Predictive ability according to input layer of neural networks

의 개수를 나타내며,  $N_T$ 는 전체 예측치의 개수를 나타낸다. 그리고  $T_{FEA}$ 는 타이어 비드부의 장력에 대한 유한요소해석값이며,  $T_{NN}$ 은 신경회로망에서 예측한 값을 나타낸다.

Fig. 10에서 보는 바와 같이 Case I의 경우는 학습데이터와 시험데이터의 정확도가 동일하게 나왔으며 정확도 측면에서도 비교적 우수하게 나타나고 있다. 그러나, Case II와 III의 경우는 학습데이터와 시험데이터의 정확도에서 많은 차이를 보이고 있으며 특히, 시험데이터에 대한 정확도는 매우 떨어짐을 알 수 있다. 이러한 결과는 입력층 구성이 신경회로망의 예측성능에 영향을 주고 있음을 나타내는 것이며, Case III의 경우는 과다 설계변수를 사용하는 경우의 예가 될 수 있다. 신경회로망에서 과다 설계변수를 사용하는 경우, 학습데이터의 수렴률은 향상시키거나 새로운 데이터 즉, 시험데이터를 정확히 설명하지 못하는 것으로 나타나고 있으며, 이러한 결과는 기존의 Yoon<sup>17</sup> 등과 Hong<sup>18</sup> 등의 연구결과와도 일치하고 있다.

따라서, 적절한 입력층의 구성 즉, 반응치에 민감한 변수를 사용하는 것이 신경회로망의 성능을 향상시킬 수 있으며, 이는 비선형성이 강한 타이어 비드부의 장력예측율을 향상시키기 위해서는 장력에 영향을 많이 주는 설계변수로서 입력층을 구성해야 함을 나타낸다.

### 3. 결론

본 연구에서는 타이어 컨투어 설계에 사용되는 설계변수를 입력층으로 조종안정성에 영향을 미치는 비드부의 장력을 출력층으로 하는 신경회로망

을 구성한 후, 설계변수의 구성 변화에 따른 신경회로망의 성능을 평가하여 다음과 같은 결론을 얻었다.

1) 실험계획법의 주효과 분석 결과, 타이어 컨 투어의 설계변수 중에서 위치결정을 위한 길이 D, E 가 비드부의 장력에 민감한 것으로 나타났다.

2) 반응치에 민감한 변수 D, E 에 대한 주효과 분석을 적용하여 신경회로망의 설계에 필요한 학습률(0.02)와 모멘텀률(0.9), 은닉층 뉴런수(3) 및 반복수(150,000)의 최적조건을 결정하였다.

3) 반응치에 민감한 설계변수 D 와 E 를 입력층으로 구성한 경우, 학습데이터와 시험데이터 모두 80%의 적중률(Poliak 식)로 장력을 예측할 수 있었다. 따라서, 신경회로망의 입력층 구성은 반응치에 민감한 변수를 사용하는 것이 효율적이라는 것을 알 수 있었다.

## 참고문헌

1. Kim, S. R., Sung, K. D., Kim, J. K. and Cho, C. T., "A Study on Application of Artificial Neural Network and Orthogonal Array for Performance Estimation of Tire," Proc. of the KSAE Spring Meeting, Vol. II, pp. 1031-1036, 2006.
2. Cho, J. R., Shin, S. W. and Yoo, W. S., "Crown Shape Optimization for Enhancing Tire Wear Performance by ANN," Computers & Structures, Vol. 83, No. 12-13, pp. 920-933, 2005.
3. Cho, J. R., Shin, S. W., Jeong, H. S., Kim, N. J. and Kim, K. W., "Optimum Design of Tire Crown Contour Utilizing Neural Network," Transactions of KSME A, Vol. 26, No. 10, pp. 2142-2149, 2002.
4. Lee, S. H., Kang, D. C., Lee, C. and Kang, M. J., "Structural Design of Artificial Neural Network using DOE," Proc. of KSPE Spring Conference, pp. 536-540, 1996.
5. An, J. H., Ko, D. C., Lee, C. J. and Kim, B. M., "Springback Compensation of Sheet Metal Bending Process Based on DOE & ANN," Transactions of KSME A, Vol. 32, No. 11, pp. 990-996, 2008.
6. Lee, D. W. and Cho, S. S., "Optimization of Vertical Roller Mill by Using Artificial Neural Networks," Transactions of KSME A, Vol. 34, No. 7, pp. 813-820, 2010.
7. Heo, H. S., Shim, J. S. and Shon, W. H., "Experimental Comparative Analysis and Subjective Evaluation on the Handling Stability Characteristics of Passenger Cars," Journal of KSAE, Vol. 3, No. 4, pp. 30-40, 1995.
8. ABAQUS Korea, "ABAQUS Analysis User's Manual, Version6.5," 2005.
9. Park, S. H., "Modern Design of Experiments," Minyoungsa Press, 2001.
10. Minitab Inc., "MINITAB Release 14," 2003.
11. McKay, M. D., Beckman, R. J. and Conover, W. J., "A Comparison of three methods for selecting values of input variables in the analysis of output from a computer code," Technometrics, Vol. 21, No. 2, pp. 239-245, 1979.
12. Mehrotra, K. G., Kohan, K. and Ranka, S., "Bounds on the number of samples needed for neural network," IEEE Transaction on Neural Networks, Vol. 2, No. 6, pp. 548-558, 1991.
13. Oh, C. S., 2000, "Neuro computer," Naeha Press, pp. 213-214, 2000.
14. Wasserman, P. D., "Neural computing," Van Nostrand Reinhold, pp. 53-54, 1989.
15. Rogers, J. L., "Simulating Structural Analysis with Neural Network," Journal of Computing in Civil Engineering, Vol. 8, No. 2, pp. 252-265, 1994.
16. Poliak, E. I., Shim, M. K., Kim, G. S. and Choo, W. Y., "Application of Linear Regression Analysis in Accuracy Assessment of Rolling Force Calculations," Metals and Materials, Vol. 4, No. 5, pp. 1047-1056, 1998.
17. Yoon, J. E. and Kang, K. I., "Prediction of the Compressive Strength of Recycled Aggregate Concrete by Data Mining Technique," Architectural Research, Vol. 21, No. 10, pp. 119-126, 2005.
18. Hong, S. H. and Shin, K. S., "Using GA based Input Selection Method for Artificial Neural Network Modeling: Application to Bankruptcy Prediction," J. of Intelligence and Information Systems, Vol. 9, No. 69, pp. 227-249, 2003.