

신경회로망을 활용한 타이어 크라운형상 최적설계

조진래[†] · 신성우^{*} · 정현성^{*} · 김남전^{**} · 김기운^{**}
(2002년 3월 20일 접수, 2002년 7월 23일 심사완료)

Optimum Design of Tire Crown Contour Utilizing Neural Network

Jin-Rae Cho, Sung-Woo Shin, Hyun-Sung Jeong,
Nam-Jeon Kim and Kee-Woon Kim

Key Words: Neural Network(신경회로망), Tread Contour Optimization(트레드 형상 최적화), Contact Pressure(접지압), Weight Adjustment(가중치의 조정), Wear Performance(마모특성)

Abstract

Contacting with ground in the post-card area size only, tire supports entire automobile weight. As well, it characterizes most of automobile running performance. Among the design parameters, the carcass contour becomes a key design factor. This paper deals with the time-effective optimal design of tire crown contour in order to improve the tire wear performance by employing a back-propagation neural network model.

1. 서론

엽서 한 장 크기의 접촉면적으로 차량의 전 하중을 지지하는 타이어는 운전성능, 승차감, 내마모성, 저소음 등과 같은 자동차의 주요한 주행성능들을 결정짓는 부품이다.⁽¹⁾ 1880년대 공기주입식 타이어가 개발된 이후 이러한 타이어의 성능을 향상시키기 위해 많은 연구가 지속적으로 이루어져 왔다.^(2~4)

본 논문은 자동차 타이어의 여러 성능 중 타이어의 균일한 마모를 위해서 트레드(tread)부분과 지면과의 접지압력을 최적으로 분포시키기 위한 트레드 형상 최적설계에 관한 것이다.

접지압 분포의 최적설계는 3차원 타이어 모델을 이용하여 ALM(augmented Lagrange multiplier) 기법을 사용한다. 이러한 최적설계를 수행하기 위해서는 많은 회수의 3차원 타이어해석이 요구되며, 또한 타이어 해석은 비선형, 접촉 등의 문제를 포함하고 있어 많은 해석시간을 요구한다.⁽¹⁾ 이와 같은 문제를 개선하기 위해서 신경회로망을 도입한 최적설계를 제시한다.

2. 트레드 형상의 최적설계

먼저 본 연구의 목적인 타이어의 내마모성을 향상시키기 위한 형상 최적설계 문제를 정식화한다. 타이어의 내마모성은 지면과 접하는 트레드부의 접지압 분포에 영향을 받게 되고, 이러한 접지압 분포는 트레드부 형상에 의해 제어되어진다. 따라서 Fig. 1과 같이 타이어의 중앙부 @에서부터 벨트 가장자리 @까지를 설계영역으로 정의한다.

[†] 책임저자, 회원, 부산대학교 기계설계공학과

E-mail : jrcho@hyowon.pusan.ac.kr

TEL : (051)510-2467 FAX : (051)514-7640

^{*} 부산대학교 대학원 기계설계공학과

^{**} (주) 금호산업 R&D Center




Fig. 1 Model for tread contour optimization

한편, 트레드 안쪽의 벨트나 카카스(carcase) 형상변화가 타이어의 다른 목적성능에 영향을 미칠 수 있으므로 설계영역 최 외각 즉, 지면과 직접 접촉하는 크라운 부분의 반경 N개를 설계변수로 잡는다.

$$\mathbf{X} = \{R_1, \dots, R_N\}^T \quad (1)$$

N개의 설계변수에 의해 설계영역내의 트레드 형상을 정의하기 위해서, 식 (2)와 같이 다항함수 보간을 이용하여 설계영역 내 크라운 형상을 근사한다.

$$R(\theta) = \sum_{i=1}^N R_i \varphi_i, \quad \varphi_i(\theta) = \prod_{j=1, j \neq i}^N \frac{\theta - \theta_j}{\theta_i - \theta_j} \quad (2)$$

다음으로 접지압력 분포를 조절하기 위한 목적함수를 정의한다. 우선, 접지압분포가 모든 절점에서 균일한 값을 가지도록 목적함수를 정의하였다. Fig. 1에 도시된 것과 같이 각각의 절점 압력값을 P_i 로 정의하고, 이 절점압력값에 대한 평균 압력값 \bar{P} 와의 편차를 목적함수로 식 (3)과 같이 정의하였다.

$$F(\mathbf{X}) = \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2} \quad (3)$$

$$\bar{P} = \frac{1}{n} \sum_{j=1}^n P_j, \quad n=1,2,\dots,11 \quad (4)$$

일반적으로 타이어 형상최적설계에는 크기와 형상에 대한 제약이 따르게 되는데, 먼저 식 (5)

와 식 (6)에서와 같이 호의 길이에 대한 제약을 둔다.

$$g_1(\mathbf{X}) = L - (1 + \vartheta)L_0 \leq 0 \quad (5)$$

$$g_2(\mathbf{X}) = (1 - \vartheta)L_0 - L \leq 0 \quad (6)$$

$$L_0 = \sum_{i=1}^{N-1} \sqrt{(y_{i+1}^0 - y_i^0)^2 + (x_{i+1}^0 - x_i^0)^2} \quad (7)$$

여기서 (x_i^0, y_i^0) 는 Fig. 1에서 최적설계전의 호㉓ ㉔ 위의 절점 좌표값을 나타내고, L은 최적설계 후의 호의 길이이다. 한편, ϑ 는 설계영역내 호의 길이변화를 구속하는 상수로 미리 정의되는 상수이다. 그리고, 각 설계변수의 반경변화에 대한 제약조건은 식 (8)과 (9)와 같다.

$$g_{i+2}(\mathbf{X}) = R_i - R_i^U \leq 0, i=1, N \quad (8)$$

$$g_{i+N+2}(\mathbf{X}) = R_i^L - R_i \leq 0, i=1, N \quad (9)$$

여기서 R_i^U 와 R_i^L 는 트레드 반경의 최대, 최소 허용값을 나타낸다.

앞의 식 (1)-(9)에 의해 타이어의 내마모성을 향상시키기 위한 크라운 형상최적설계문제는 다음과 같이 표현된다.

$$\text{Find } \mathbf{X} = \{R_i\}_{i=1}^N \quad (10)$$

$$\text{Minimize } F(\mathbf{X}) \quad (11)$$

$$\text{Subject to } g_i(\mathbf{X}) \leq 0, i=1, 2, \dots, 2(N+1) \quad (12)$$

2.1 ALM 기법

앞에서 정의한 타이어 트레드 형상 최적설계 문제는 제약조건이 포함된 제약 최적설계 문제이다. 이 문제를 해결하기 위해서 ALM기법을 적용하여 제약 최적설계문제를 비제약 최적설계문제(unconstraint pseudo-objective optimization problem)로 다음과 같이 전환한다.

$$A(\mathbf{X}, \lambda_i, r_p) = F(\mathbf{X}) + \sum_{i=1}^{2(N+1)} [\lambda_i \psi_i + r_p (\psi_i)^2] \quad (13)$$

$$\psi_i = \max \left[c_i g_i(\mathbf{X}), -\frac{\lambda_i}{2r_p} \right] \quad (14)$$

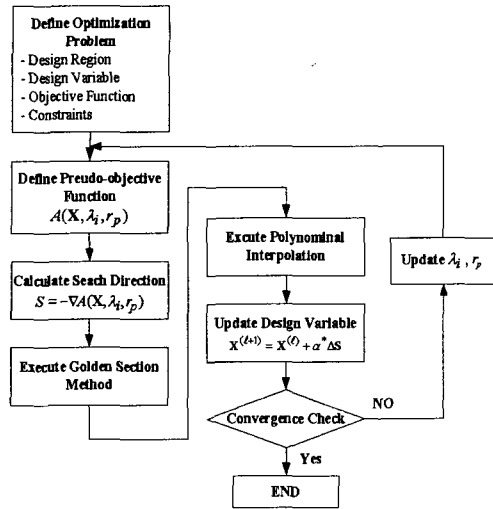


Fig. 2 Algorithm of optimization

여기서 λ_i 는 라그랑지 승수(Lagrange multiplier)이고, r_p 는 벌칙상수(penalty parameter)이다. 또한 목적함수에 대한 구속조건의 정규화(normalizing)를 위한 척도계수(scaling factor) c_i 는 다음과 같이 정의된다.

$$c_i = \frac{|F(\mathbf{X} + \delta \mathbf{X}) - F(\mathbf{X})|}{|g_i(\mathbf{X} + \delta \mathbf{X}) - g_i(\mathbf{X})|} \quad (15)$$

정의된 비제약 최적설계문제의 수행과정을 Fig. 2에 도시하였다.

위의 최적설계문제를 수치적 방법으로 최적의 해를 얻기 위해서 식 (16)의 증분기법(incremental scheme)을 통해 최적의 설계변수 \mathbf{X} 를 반복적으로 찾아간다.

$$\mathbf{X}^{l+1} = \mathbf{X}^l + \Delta \mathbf{X}^l, \quad l=0, 1, 2, \dots \quad (16)$$

여기서 l 은 반복횟수를 나타내고, \mathbf{X}^0 는 초기 설계변수의 값, 그리고 $\Delta \mathbf{X}^l$ 은 현재 설계변수에서 증분량을 나타내며, $\Delta \mathbf{X}^l$ 은 아래 식과 같이 계산된다.

$$\Delta \mathbf{X}^l = \alpha \mathbf{S}^{(l)} \quad (17)$$

여기서 $\mathbf{S}^{(l)}$ 는 설계공간에서 최적설계 방향벡터를 나타내고, α 는 그 크기를 결정하는 상수값이다.

설계공간에서 최적설계 방향은 식 (18)과 같이 가목적함수 미분값 ∇A 의 반대방향으로 정의되고, 유한차분법(finite difference method)⁽⁵⁾으로 계산한다.

$$\mathbf{S}^{(l)} = -[A(\mathbf{X}^l + \delta \mathbf{X}) - A(\mathbf{X}^l)] / \delta \mathbf{X} \quad (18)$$

탐색방향이 결정되면, 그 크기를 결정짓는 상수값 α 를 구한다. 이 값은 황금분할법(golden section method)⁽⁵⁾과 다항식 보간법⁽⁵⁾으로 계산하며, 수렴조건식 (19)가 만족될 때까지 반복 수행한다.

$$\begin{aligned} \max |\lambda_i^l - \lambda_i^{l-1}| \leq \epsilon_\lambda \quad \text{혹은} \\ \max \left| \frac{F(\mathbf{X}^l) - F(\mathbf{X}^{l-1})}{F(\mathbf{X}^l)} \right| \leq \epsilon_F \end{aligned} \quad (19)$$

그리고 각 반복단계동안 λ_i 와 r_p 는 아래와 같이 새로운 값으로 갱신된다. 여기서, γ 는 벌칙상수의 증분값이다.

$$\lambda_i^{(l+1)} = \lambda_i^{(l)} + 2r_p^{(l)} \left\{ \max \left[c_i g_i(\mathbf{X}), -\frac{\lambda_i^{(l)}}{2r_p^{(l)}} \right] \right\} \quad (20)$$

$$r_p^{(l+1)} = \gamma r_p^{(l)} \quad (21)$$

2.2 목적함수의 조정

균일 접지압 분포가 항상 트레드부의 균일마모를 일으킨다면 식 (3)의 목적함수를 수정할 필요가 없으나, 실험결과에 의하면 타이어의 중앙부와 벨트 가장자리(belt edge)부의 압력비가 1:1.16일 때 가장 이상적인 마모가 일어난다. 또한 타이어에는 그루브(groove)가 존재하기 때문에 모델의 형태에 맞게 압력변화의 조절이 필요하다. 따라서 식 (3)에 c_i 와 가중치 W_i 를 추가하여 식 (22)와 같이 목적함수를 수정하였다.

$$F(\mathbf{X}) = \sqrt{\sum_{i=1}^n W_i \left(\frac{P_i}{c_i} - \bar{P} \right)} \quad (22)$$

$$\bar{P} = \frac{1}{n} \sum_{j=1}^n \frac{P_j}{c_j} \quad (23)$$

여기서 c_j 는 각각의 절점에서 설계자가 원하는 압력분포의 비를 나타내고, W_i 는 압력비의 중요성을 결정짓는 가중치를 나타낸다.

3. 신경회로망 알고리즘

신경회로망은 인간두뇌의 정보처리구조를 모방하여 어떠한 업무든지 분산, 병렬 처리하도록 만들어진 시스템이다. 신경회로망은 간단한 연산을 처리하는 하나의 간단한 신경조직(neuron)들의 결합으로, 복잡한 형태의 입·출력을 학습을 통하여 근사화하는 것이다.

본 논문에서는 설계 변수인 트레드부의 반경값을 입력하면, 지면과의 접지압이 출력되도록 신경회로망을 구성하였다. 즉, 최적설계에서 목적함수($F(\mathbf{X})$)의 계산에 필요한 부분을 학습을 통해 구성한 신경회로망으로 계산해서 유한요소해석을 대체한다.

3.1 신경회로망 구조

Fig. 3에 도시된 것과 같이 신경회로망은 수많은 처리요소(processing element)들이 서로 병렬로 연결되어있는데, 크게 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성되어 있다. 각층의 처리요소들은 다음 층의 처리요소와 모두 연결되어있는 형태이다. Fig. 4는 전달규칙⁽⁶⁾과 활성화규칙⁽⁶⁾에 따라 입력신호들이 하나의 처리요소에서 출력되어 지는 과정을 도시화하였다.

$$O_i = I_i \quad (24)$$

$$O_j = f(net_j), \quad net_j = \sum_i w_{ij} O_i \quad (25)$$

입력층으로 들어온 입력신호는 식 (24)와 같이 입력층의 출력값으로 출력된다. 여기서 입력층의 처리요소의 개수는 설계변수 개수와 동일하다. 각 은닉층과 출력층의 출력값은 이전 층의 출력신호를 입력받아 식 (25)와 같이 계산된다. 여기서 O_j 는 j번째 뉴런의 출력신호를 나타낸다.




Fig. 3 Back-propagation neural network model




Fig. 4 A processing element

함수 $f(\cdot)$ 는 일반적으로 계단함수, 시그모이드함수(sigmoid function), hyperbolic tangent 함수 등을 사용하나, 이 연구에서는 미분가능하고 일반적으로 많이 사용되는 시그모이드함수를 사용한다.

$$f(x) = 1/(1 + e^{-x}) \quad (26)$$

3.2 신경회로망의 학습과정

전방향으로 신호가 전파되어 가면서 설계변수에 의해 뉴런의 출력값들이 계산된다. 최종 출력층의 출력신호 O_j 와 목표 출력값 t_j 을 비교하여 오차의 제곱의 총합을 계산하면 식 (27)과 같이 표현할 수 있고, 이 값이 최소가 되도록 은닉층에서 출력층 사이의 연결강도 w_{kl} 를 조절해 간다. 또한, DOE(design of experiments)테이블⁽⁷⁾에 의해 정의된 m개의 데이터에 대해서도 학습(learning)⁽⁸⁾이 이루어져야 하므로 w_{kl} 는 연결강도 변화량의 평균값을 이용하여 식 (28)과 같이 갱신된다.

Table 1 DOE table(Orthogonal Array)

Data Number	Orthogonal Array : L ₂₇ (3 ¹³)							
	1	2	3	4	...	11	12	13
1	1	1	1	1	...	1	1	1
2	1	1	1	1	...	2	2	2
...
26	3	3	2	1	...	3	2	1
27	3	3	2	1	...	1	3	2

$$E_p = 1/2 \sum_{i=1}^n (t_i - O_i)^2 \quad (27)$$

$$w_{ki} = w_{kl} + \frac{1}{m} \sum_{s=1}^m \Delta w_{kl}^s \quad (28)$$

$$\Delta w_{kl} = \eta \delta_l O_k = \eta (t_l - O_l) O_l (1 - O_L) O_k \quad (29)$$

여기서, η 는 학습률을 나타내는 비례상수이며, t_l 은 목표출력값, O_k , O_l 은 각각 k, l 층에서의 출력값을 나타낸다.

그리고, 은닉층에서 은닉층으로 또는 은닉층에서 입력층으로 계속 신호가 역전되어 식 (30), (31)과 같이 연결강도 w_{jk} 를 조절한다.

$$w_{jk} = w_{jk} + \frac{1}{m} \sum_{s=1}^m \Delta w_{jk}^s \quad (30)$$

$$\Delta w_{jk} = \eta \delta_k O_j = \eta (\sum \delta_l w_{kl}) O_k (1 - O_k) O_j \quad (31)$$

위와 같은 학습과정을 반복해서 출력값이 학습 수렴률 내에 들어올 때까지 많은 회수의 계산을 수행하게 된다.

3.3 DOE 테이블에 의한 학습 자료의 선정

직교배열표는 효과적으로 학습 자료를 선별하는 방법으로 각각의 인자 R_1, R_2, \dots, R_N 의 개량치가 현재의 값보다 큰지 작은지 명확하지 않을 때, 3수준의 직교배열표를 사용한다.

본 연구에서는 설계변수가 13개 이하이므로 3수준의 직교배열표를 사용하여 Table 1과 같이 27개의 입력형태를 정의할 수 있다. 이 목표 출력값은 실제 유한요소 해석을 통하여 값을 얻는다. 여기서, 테이블 배열성분의 '1'은 반경의 이동이 없는 상태의 입력값, '2'는 반경이 + ΔR 만큼 이동했을 때의 입력값, '3'은 반경이 - ΔR 만큼 이동했을 때의 입력값을 나타낸다.




Fig. 5 Modeling and boundary condition

4. 수치결과

DOE 테이블에 따라 선정된 학습 데이터를 학습을 통하여 하나의 신경회로망으로 구성하였다. 신경회로망 구성과 최적설계를 위한 파라미터들을 Table 2에 제시하였고, 각 목적함수의 변화에 따른 최적설계 결과값을 수치적인 측면에서 비교하였다.

4.1 모델의 정의

앞에서 정의된 최적설계 알고리즘, 신경회로망 알고리즘과 상용 유한요소 해석프로그램인 ABAQUS에 의한 타이어 해석을 통해 트레드 형상 최적설계를 실시하였다. 해석에 사용된 타이어는 P205/65 R14이며, 경계조건은 Fig. 5에 도시하였다.

Fig. 6에서 초기압력분포에서 그루브에 의해 급격한 압력저하가 생기는 $P_6 \sim P_7$ 사이의 절점과 타이어가 지면과 접촉할 때 P_{11} 바깥쪽의 지면과 접촉하지 않는 절점의 압력분포를 최적설계의 목적함수에서 제외시켜 식 (3)과 같이 목적함수를 정의한다. 그리고, 타이어의 회전에 의한 효과는 고려하지 않는다.

4.2 균일 접지압력 분포를 위한 최적설계

목적함수의 조정 없이 초기 접지압과 균일접지압 최적설계 수행결과를 Table 3에 제시하였다. 신경회로망 결과 P_i^N 와 실제 ABAQUS해석을 통한 결과 P_i^F 의 최대오차가 0.52%정도로 두 압력 결과값이 거의 일치하므로, 신경회로망에 의한 최적설계의 타당성을 확인할 수 있다. 타이어 트

Table 2 Simulation data for tire optimization

Neural network learning parameter	
Parameter	Value
설계변수의 수준	3
은닉층의 수	3
각 은닉층의 뉴런수	17
학습률 비례상수, η	0.8
학습수렴률	0.005
Optimization parameter	
Parameter	Value
타이어의 공기압	30(psi)
지면과 마찰계수	0.5
하중	465(kgf)
설계변수의 수, N	7
카카스 호의 길이구속조건, θ	0.1
설계변수 이동거리	0.002(in)
초기 라그랑지 승수값	0
초기 벌칙상수값	1
벌칙상수 증분값	10

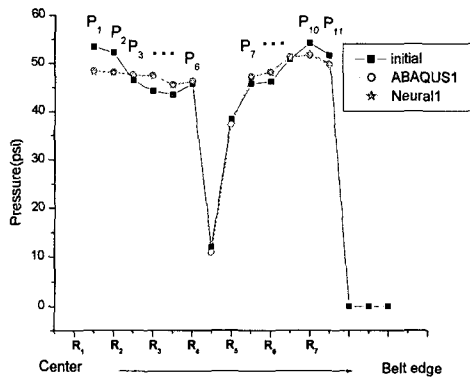


Fig. 6 Uniform contact pressure optimization

레드 중앙단면의 결과 압력그래프는 Fig. 6에 제시하였다.

Fig. 7과 Fig. 8는 각각 초기 접지압의 전체 압력분포와 균일접지압을 최적설계한 결과 얻어지는 전체 접지압의 분포를 나타내었다. 두 그림을 비교해 보면, 초기 접지압에 비해 접지압의 분포 특성이 많이 균일해 졌음을 확인할 수 있다.

균일접지압에 대한 최적설계 결과, 반경의 변화량이 5.72×10^{-3} in 정도로 트레이드 반경변화에 대한 압력분포가 아주 민감하게 반응한다.




Fig. 7 Initial contact pressure distribution




Fig. 8 Uniform contact pressure distribution

Table 3 Uniform contact pressure optimization data

	P_1	P_2	P_3	P_4	P_5	P_6	P_7	P_8	P_9	P_{10}	P_{11}
Initial P_i^0 (psi)	53.36	52.13	46.37	44.23	43.45	45.71	45.73	46.17	50.77	54.13	51.63
Neural result P_i^N	48.14	48.07	47.47	47.34	45.44	46.13	47.19	48.08	50.99	51.79	50.00
ABAQUS result P_i^F	48.39	48.09	47.55	47.44	45.50	46.2	47.16	48.17	51.24	51.56	49.74
$\frac{ P_i^F - P_i^N }{P_i^F} \times 100(\%)$	0.517	0.042	0.168	0.211	0.132	0.152	0.064	0.187	0.488	0.446	0.523
$ P_i^N - \bar{P} $	0.11	0.19	0.73	0.84	2.78	2.08	1.12	0.11	2.96	3.28	1.46

4.3 이상적인 접지압력 분포를 위한 최적설계
 식 (22)와 같이 목적함수 수정 후의 최적설계 결과를 Table 5에 제시하였다. 가중치 W_i 를 모두 동일하게 하였을 때, 중앙부의 압력에 대한 다른 절점의 접지압의 비(P_i^N/P_1^N)가 사용자가 입력한 압력비 c_i 를 정확히 만족하지 않은 상태에서 최적설계가 수렴하였다. Fig. 9를 통해 중앙단면의 압력분포를 확인할 수 있다.

4.4 목적함수 가중치의 조정
 설계자가 입력한 압력비의 값을 보다 정확하게 만족하기 위해서 식 (22)의 목적함수의 가중치 W_i 를 조정하여 Table 5와 같은 결과를 얻었다. 가중치의 기준이 되는 P_1 의 가중치와 벨트가장자리 부근 P_9 의 가중치를 증가시키면서 최적설계를 수행하였는데, 가중치를 증가시키면 P_1 과 P_9 의 압력분포의 비는 향상되지만 상대적으로 가중치가 낮은 부분의 접지압력들은 Fig. 10과 같이 입력한 압력비 c_i 와 많은 차이를 가지게 된다. 그러므로 향상된 결과를 얻기 위해서 가중치의 적절한 선정이 중요하다. 여기서 가중치변화에 대한 최적설계의 결과는 항상 신경회로망에 의한

근사 오차를 포함하고 있다.
 Fig. 11은 가중치 조절후의 최종결과 접지압력 분포를 나타내었으며, Table 6은 최종 가중치에 따른 반경변화량을 제시하였다. 반경의 변화값은




Fig. 9 Ideal contact pressure optimization

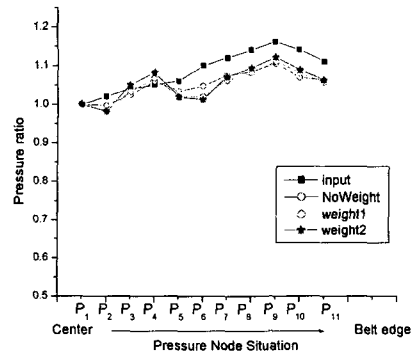


Fig. 10 Pressure ratio distribution for different weights

Table 4 Change of R_i for uniform contact pressure ($\times 10^{-3}$ in)

	R_1	R_2	R_3	R_4	R_5	R_6	R_7
ΔR	0.10	-5.72	0.61	0.94	0.87	-0.27	-5.20

Table 5 Ideal contact pressure optimization data

	P_1	P_2	P_3	P_4	P_5	P_6	P_7	P_8	P_9	P_{10}	P_{11}
Initial P_i^0 (psi)	53.36	52.13	46.37	44.23	43.45	45.71	45.73	46.17	50.77	54.13	51.63
c_i	1.00	1.02	1.04	1.05	1.06	1.10	1.12	1.14	1.16	1.14	1.11
Neural result P_i^N	45.70	45.53	46.84	48.40	47.25	47.85	49.13	49.57	50.52	48.84	48.58
Weight(W_i^0)	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
P_i^N/P_1^N	1.000	0.996	1.025	1.059	1.034	1.047	1.075	1.085	1.105	1.069	1.063
Pressure (P_i^N) $_{w1}$	45.96	45.11	47.47	49.03	46.85	46.86	48.81	49.73	51.06	49.62	48.55
1st Weight(W_i^1)	2.0	1.5	1.5	1.0	1.0	1.0	1.5	1.5	2.0	1.5	1.0
$(P_i^N)_{w1}/(P_1^N)_{w1}$	1.00	0.981	1.033	1.067	1.019	1.020	1.062	1.082	1.111	1.080	1.056
Pressure (P_i^N) $_{w2}$	45.68	44.83	47.98	49.45	46.57	46.25	48.94	49.98	51.22	49.73	48.53
2nd Weight(W_i^2)	4.0	2.5	2.5	1.0	1.0	1.0	2.5	2.5	4.0	2.5	1.0
$(P_i^N)_{w2}/(P_1^N)_{w2}$	1.00	0.981	1.050	1.083	1.019	1.012	1.071	1.094	1.121	1.089	1.062

Table 6 Change of Ri for ideal contact pressure [last weight] ($\times 10^{-3}$ in)

	R_1	R_2	R_3	R_4	R_5	R_6	R_7
ΔR	-0.44	-12.8	-1.81	-0.97	-0.25	-1.59	-10.6




Fig. 11 Ideal contact pressure distribution

모두 음(-)의 값을 가지고, 초기 반경변화와 비교해 볼 때 압력이 많이 감소한 부분의 반경(R_2 , R_7)의 변화량이 크다. 여기서, 반경의 변화량과 압력의 변화량은 비례관계에 있다.

알고리즘에 따라 차이가 있겠지만, 일반적으로 유한요소법을 이용한 최적설계에서 유한요소 해석에 의해 목적함수를 구할 경우, 해석이 복잡하면 최적설계 과정의 대부분의 시간을 유한요소 해석에 사용한다. 신경회로망은 해석시간을 줄여 주는 역할을 한다.

5. 결론

본 연구에서는 타이어의 균일한 마모를 유도하여 내구성을 향상시키는 측면에서 접지압력을 조정하는 최적설계를 수행하였다. 그리고 신경회로망 알고리즘을 도입하여 균일한 압력분포에 대한 최적설계에서 신경회로망 알고리즘 도입의 타당성을 검증하였다.

또, 신경회로망의 결과값을 이용해서 목적함수를 변화시켜가면서 최적설계를 수행해서 좀더 향상된 결과를 얻을 수 있었다. 이 때 목적함수를 변화시키기 위해 입력상수값 c_i 과 가중치 W_j 를 도입하였다. 본 연구에서 얻은 결과를 바탕으로 다음과 같은 결론을 얻을 수 있다. 첫째, 트레드 반경 변화에 대한 접지압의 변화는 아주 민감하게 반응한다. 둘째, 신경회로망을 이용한 최적설

계 결과는 항상 유한요소 해석값과 오차를 포함하고 있다. 셋째, 유한요소 해석시간이 많이 소요되는 문제일수록 신경회로망을 이용한 최적설계가 더욱 효율적이다.

후 기

본 연구는 (주)금호산업 타이어 사업부의 지원으로 수행되었으며, 이에 관계자 여러분께 감사드립니다.

참고문헌

- (1) Clark, S. K., 1982, *Mechanics of Pneumatic Tires*, U.S. Government Printing Office Washington D.C.
- (2) Yamagishi, K., Togashi, M., Furuya, S., Tsukahara, K. and Yoshimura, N., 1987, "A Study on the Contour of the Radial Tire: Rolling Optimization Theory-(RCOT)," *Tire Science and Technology, TSTCA*, Vol. 15, No. 1, pp. 3~29.
- (3) Cho, J. R., Jeong, H. S., Lee, H. W., Kim, N. J. and Kim, K. W., 2001 "Finite Element Analysis for the Variation of Carcass Tension Distribution to the Sidewall-Radius Change," *Transactions of KSME, A*, Vol. 25, No. 6 pp. 980~987.
- (4) Cho, J. R., Jeong, H. S., Lee, H. W., Kim, N. J. and Kim, K. W., 2001 "Optimal Design of Tire Sidewall Contours for Improving Maneuverability and Durability," *Transactions of KSME, A*, Vol. 25, No. 10 pp. 1636~1643.
- (5) Garret N. Vanderplaats, 1984, *Numerical Optimization Techniques for Engineering Design*, McGraw-Hill, New York.
- (6) Simon, S., 1994, *Neural Networks : A Comprehensive Foundation*, Macmillan, New York.
- (7) Ross, P. J., 1988, *Taguchi Techniques for Quality Engineering*, McGraw-Hill, New York.
- (8) Nakajima, Y., Kadowaki, H., Kamegawa, T. and Ueno, K. 1999, "Application of a neural network for the optimization of tire design" *Tire Science and Technology, TSTCA* Vol. 27, No.2 pp. 62~83.