

< 논문 >

승용차용 스티어링시스템 지지 T-형구조물의 최적설계

김 성 철[†] · 이 종 수^{*}

(2004년 8월 31일 접수, 2005년 4월 20일 심사완료)

Optimization of T-Structure Supporting Steering System Using μ GA

Sung Chul Kim and Jong Soo Lee

Key Words : Micro-Genetic Algorithms (마이크로 유전자 알고리즘, μ GA), Backpropagation Neural Network(오류역전파신경망, BPN), Optimization Design(최적설계)

Abstract

The goal of this paper is to minimize the weight of the T-structure supporting steering system in reducing the vibration level on steering wheel which could be amplified by the resonance. Presently, requirements for reducing noise, vibration and harshness (NVH) in automotive area are more stringent than ever. One of them is the vibration of steering system which occurs sometimes at high speeds or when the engine is idling. Besides, the reduction of weight is also one of requirements for improvement of vehicle performance. This paper used the micro genetic algorithm as an optimization method to satisfy above two requirements. The whole T-structure assembly including steering column was used for frequency analysis.

1. 서 론

최근 자동차업계에서는 소음, 진동 그리고 중량을 줄이기 위한 많은 노력을 기울이고 있다. 이는 개념설계단계에서 상세설계에 이르기까지 반복해서 시험되고 검증되어야 하는 부분이기 때문이다. 특히, 소음진동과 중량처럼 일반적으로 서로 상반되는 설계인자들에 대하여 동시에 설계 요구사항을 만족시키는 것은 쉽지 않은 일이다.

이를 위해 설계 분야에 수많은 최적화 방법론이 연구되고 개발되어 실제 문제에 적용되고 있다. 특히 수치적 방법에 의해 설계 최적화를 수행하는 경우 상용 패키지를 연결하여 설계 해의 반복적인 탐색과정을 통해 최적설계를 얻게 된다. 다량의 설계변수 및 구속조건을 수반하거나 비선형적인 설계문제인 경우 최종적인 해가 국부적 최적해(local optimal)에 도달할 가능성이 크다. 이러

한 점들을 보완하기 위해서 본 연구는 설계 변수의 전영역에서 다수의 초기 설계변수들을 가지고 전역적 최적해(global optimal)를 탐색하는 유전자 알고리즘을 이용한 최적설계 기법을 이용했다.

중량에 민감한 진동문제를 다루는데 있어서는 단품이나 서브 어셈블리에 대한 보편적 접근방식 보다는 보다 효율적인 설계를 수행하는데 도움이 되도록 전체 시스템 기반의 해석이 요구된다. 따라서 본 논문에서는 스티어링 휠(steering wheel)과 컬럼(column)을 포함한 주변부품들과 이를 지지하는 전체 T-형구조물에 대하여 엔진의 기진력으로 가진되는 진동문제를 해석하고 또한 전체 어셈블리에 대하여 중량을 최소화하기 위한 T-형구조물 설계를 최적화 하였다. 각 단품의 고유진동수와 무게는 상용 패키지인 MSC.Nastran 을 이용하여 구하고 이를 훈런데이터로 사용하여 신경망내의 가중치를 최적화 하는 오류역전파신경망(back propagation neural network, BPN)으로 근사화 모델을 구성하였다. 또한 많은 시간을 필요로 하는 시스템 기반의 최적화 문제에 대하여 보다 효율적으로 문제에 접근하기 위해 적은 개체수를 갖는 마이크로 유전자 알고리즘

[†] 책임저자, 회원, 연세대학교 대학원 기계공학과
E-mail : sungk@yonsei.ac.kr
TEL : (02)2123-4474 FAX : (02)2123-2736

^{*} 회원, 연세대학교 기계공학부




Fig. 1 Profile of T-structure

(micro-genetic algorithms, μ GA)을 적용하였다.

2. 최적설계문제의 정의

2.1 T-형구조물의 구성과 진동특성

T-형구조물을 이루는 부품은 Fig. 1 과 같이 스티어링 서브시스템으로 구성되는 스티어링 칼럼(steering column), 축(shaft), 휠(wheel) 어셈블리 그리고 차체에 지지되는 타이바(Tie-bar)와 마운팅 브라켓(mounting bracket)등 13 개의 주요 부품으로 구성된다. 특히 타이바(Tie-bar)의 동적거동은 스티어링 시스템의 성능에 큰영향을 미치는 것으로 알려져 있다. 자동차 엔진의 공회전(idling)시 진동은 엔진의 가진력이 차체에 전달되고 차체의 고유모드와 공진(resonance)을 일으켜 대부분의 소형차인 경우 공회전 영역인 700~900RPM 에서 20~30Hz 의 굽힘모드를 가지게 된다.^(1,2) 스티어링 시스템의 고유모드 또한 이 영역에서 존재하게 되어 국부적인 진동을 유발한다. 본 연구는 이러한 진동문제를 해결하고 또한 이와 관련된 구조물의 무게를 최소화하기 위한 최적설계문제로 스티어링 시스템을 포함한 전체 T-형구조물에 대하여 고려하였다.

목적함수로는 T-형 구조물의 부품에 대한 전체 질량이 최소가 되도록 하였으며 이를 간단히 수식화 하면 식 (1)과 같고 구속조건으로 식 (2)와 같이 1 차 고유진동수가 34Hz 이상 되도록 영역을 제한하였다. 이는 엔진 가진력으로 인한 모드 20~30Hz 를 피하기 위한 설계영역이다.

$$\text{Minimize } F(x) = \sum_{e=1}^{n_e} \rho_e \Omega_e(x) \quad \text{for } e=1,2,\dots,13 \quad (1)$$

$$\text{subject to } \omega_1(\text{1st frequency}) \geq 34\text{Hz} \quad (2)$$




Fig. 2 FE modeling of T-structure

여기서 ρ 는 밀도, Ω 는 체적, 그리고 ω_1 은 1 차 고유진동수이다.

2.2 FE 모델링과 진동해석

진동해석을 위해 유한요소 모델(FE modeling)을 구성하는 것 역시 정확한 해를 얻기 위한 중요한 부분이다. Fig. 1 와 Fig. 2 에서 스티어링 휠과 스티어링 샤프트는 빔요소로 스티어링 컬럼과 그 외 판재부분들은 쉘요소로, 그리고 연결부와 볼 베어링부는 집중질량요소와 스프링 요소로 강성을 표현하고 그 밖에 에어백의 무게와 같은 부수적인 부분은 더미요소(dummy element)로 집중질량요소를 표현하였다.

3. 최적설계 방법

3.1 실험계획법

실험계획법(design of experiments)이란 해결하고자 하는 문제에 대하여 실험을 어떻게 행하고 데이터를 어떻게 취하며 어떠한 통계적 방법으로 데이터를 분석하여 최소의 실험회수에서 최대의 정보를 얻기 위한 계획이다.

특히 최적화를 위해 반응표면을 생성함에 있어 회귀분석이나 오류역전과신경망에 필요한 훈련데이터들이 각 인자의 효과를 충분히 고려하고 설계 영역내의 임의의 설계점에서의 실제 반응값을 가져야 한다. 따라서 본 연구는 Table 1 에 나타낸 설계변수 13 개에 대하여 각각 3 개의 수준을 선정하고 직교배열표($L_{27}(3^{13})$)를 이용하였으며 이것은 인자가 13 개이고 각 인자의 수준이 3 개일 때 이들 처리 조합의 수가 총 27 개이며 실시하게

될 총 실험횟수를 의미한다. 또한 중량과 1 차 고

Table 1 Design variables

No	Design Variables	Constraints(mm)
x1	Tie_brkt_lh,rh	$1.5 \leq t1 \leq 4$
x2	Tie_bar	$1 \leq t1 \leq 4$
x3	Crt_brkt_lh,rh	$0.7 \leq t1 \leq 4$
x4	Strg_lwr_brkt	$0.7 \leq t1 \leq 4$
x5	Strg_upr_brkt	$0.7 \leq t1 \leq 4$
x6	Key_brkt	$2 \leq t1 \leq 4$
x7	Jacket_lwr_brkt	$2 \leq t1 \leq 4$
x8	Jacket_to_strg_brkt	$2 \leq t1 \leq 4$
x9	U_brkt	$1 \leq t1 \leq 4$
x10	Jacket_upr_brkt	$1 \leq t1 \leq 4$
x11	Inner_jacket_upr_brkt	$1 \leq t1 \leq 4$
x12	Jacket_low	$0.5 \leq t1 \leq 3$
x13	Jacket_upp	$0.5 \leq t1 \leq 3$




Fig. 3 Variation of design variables for weight




Fig. 4 Variation of design variables for 1st frequency

유진동수에 대한 결과데이터는 상용패키지인 MSC.Nastran 을 이용하여 얻었다.

이렇게 얻어진 데이터를 가지고 평균분석법을 사용하여 각 변수들이 결과값에 미치는 영향을 판단하고 인자의 수준변화가 결과에 미치는 정도를 예측하였다. Fig. 3 과 Fig. 4 는 이것을 각각 도시화 한 것이다. 이 중 μ GA 에 적용하기 위해 각 설계변수를 임의의 범위에 대하여 중량과 1 차 고유진동수에 가장 민감한 설계변수 x1, x2, x3, x4, x5, 그리고 x13 의 6 개 설계변수를 선정하였다.

3.2 전역함수근사화 모델

본 연구에서는 μ GA 를 이용한 최적화 문제에 사용할 전역함수 근사화모델로 오류역전파신경망 (backpropagation neural network, BPN)을 사용하였으며 통계학적 반응표면을 생성하기 위한 별도의 회귀 분석(regression analysis)을 사용하였다.

3.2.1 오류역전파신경망을 이용한 모델

신경망은 생물학적 뉴런(neuron)을 모델링한 유닛(unit)들과 그 유닛 사이의 가중치 연결들로 이루어지며 각 신경망 모델에 따라 다양한 구조와 독특한 학습 규칙을 갖는다. 각 신경망은 계층별로 그룹화된 뉴런들의 집합으로 구성되어 있다. 이는 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)의 세 계층으로 이루어져 있으며 은닉층의 수는 문제의 비선형성이나 설계변수의 수에 따라 다양하게 사용될 수 있다. 처리 노드(node)가 많기 때문에 시스템의 부분적인 결함을 갖고 있더라도 전체 시스템은 안정적으로 동작할 수 있는 것이 신경망의 장점이다. 그러나 문제에 적합한 신경망을 구성하기 위해서는 내부의 가중치를 적절히 조절해 주어야 한다. 이 때 오류역전파신경망(BPN)은 실제 시험값과 학습을 통한 출력값의 오차를 최소화시키도록 내부의 가중치를 최적화시키는 방법으로 사용된다.⁽³⁾

또한 회로망 사이에 존재하는 상호 연결 가중치 행렬(interconnection weight matrix)로부터 전체 설계 영역에서의 입출력 데이터의 흐름을 파악하여 설계 변수와 반응함수 사이의 인과 관계(causality)를 분석하고 가중치 해석 행렬(weight analysis matrix)을 생성함으로써 전역 민감도(global sensitivity)에 대한 정보를 제공할 수 있다.⁽⁴⁾

모델을 학습시키기 위해 이미 선정된 6 개의 설계변수와 이에 대한 결과값(W1, W2; 무게, 1 차 고유진동수)에 대하여 81 개의 시뮬레이션 결과데이터를 BPN 을 위한 훈련데이터로 사용하였다.




Fig. 5 Backpropagation neural network

Table 2 Error rate for frequency

No	Frequency(kHz)			Error rate
	Result data	Training data	Error	
1	3.69E+01	3.66E+01	8.30E-03	1%
2	3.49E+01	3.32E+01	4.68E-02	5%
3	3.27E+01	3.22E+01	1.45E-02	1%
4	3.68E+01	3.59E+01	2.37E-02	2%
5	3.68E+01	3.60E+01	2.23E-02	2%

Table 3 Error rate for weight

No	Weight(kg)			Error rate
	Result date	Training date	Error	
1	1.93E+01	1.99E+01	-2.72E-02	3%
2	1.75E+01	1.79E+01	-2.12E-02	2%
3	1.70E+01	1.71E+01	-3.46E-03	0%
4	1.95E+01	1.95E+01	3.89E-04	0%
5	1.87E+01	1.95E+01	-4.00E-02	4%

데이터의 개수는 설계전영역에 대하여 임의의 설계점을 확보하기 위해 랜덤하게 선정하기 보다는 실험계획법을 이용하였다

Fig. 5 는 본 연구에 사용된 오류역전과 신경망 모델로서 입력층에 6 개의 노드, 은닉층에 4 개의 노드, 그리고 출력층에 2 개의 노드가 사용되었다. 또한 BPN 에 사용된 페라미터로 표준함수의 기대값은 0.05(5%), 학습율은 0.6, 모멘텀(momentum)은 0.8, 그리고 시그모이드 구배(slope of sigmoid)는 0.9 가 사용되었다.

학습을 통해 얻은 BPN 모델이 설계변수와 반응함수 사이의 관계를 보다 정확히 나타내기 위해서는 실제 시험된 데이터와 학습을 통해 만들어진 BPN 결과 데이터간의 오차를 확인하는 작

업이 필요하며 각각 데이터가 오차범위 5%내에 들어오도록 은닉층의 수, 훈련데이터의 수 그리고 BPN 을 구성하는 페라미터들을 적절히 변경하여 반복, 학습시키는 과정이 필요하다. Table 2 와 Table 3 은 임의 샘플링한 데이터에 대하여 실제 시뮬레이션 결과값과 학습을 통해 얻어진 훈련값과의 오차를 나타내며 5%이하의 오차를 나타내어 구성된 BPN 모델의 유효성을 검증하였다.

3.2.2 회귀분석을 이용한 모델

회귀분석을 위해 앞서 훈련데이터로 이용했던 81 개의 시뮬레이션 데이터를 이용하였다. Table 4 는 상용 통계 프로그램인 SAS⁽⁵⁾를 이용한 회귀분석결과이다. 1 차 고유진동수에 대한 결정계수 R²_{adj} 는 98.65%의 신뢰도를 중량에 대해서는 93%의 신뢰도를 가졌다. 이 때 P-value 는 0 에 가까울수록 인자가 결과값에 유의한 영향을 주며 t-value 는 인자가 결과값에 얼마나 큰 영향을 주는지를 나타낸다. 또한 P-value 가 0.05 이상인 x4 의 경우를 제외한 x1, x2, x3, x5, 그리고 x13 의 주효과와 이의 조합으로 이루어진 x1x1, x2x1, x2x2, x3x1, x3x3, x4x1, x5x1, x5x5, x13x1, x13x3, x13x5 와 같은 교호작용이 고유진동수에 영향을 주는 것으로 나타났다. 그리고 식 (3)과 식 (4)는 P-value 가 0.05 보다 작은 추정계수(parameter estimate)의 조합으로 만들어진 근사화 모델이다. 중량에 대해서도 동일한 방법으로 분석이 수행되었고 결정계수 R²_{adj} 93.89%의 신뢰도를 가졌다.

$$\begin{aligned}
 \text{Frequency} = & 30.38877-2.86642*X[1]+1.01296*X[2]+0.98440*X[3]- \\
 & 3.70749*X[5]+8.81136*X[13]+0.38107*X[1]*X[1]- \\
 & 0.08148*X[2]*X[1]-0.09815*X[2]*X[2]+ \\
 & 0.04321*X[3]*X[1]-0.15967*X[3]*X[3]+ \\
 & 0.03086*X[4]*X[1]+1.12428*X[5]*X[1]+ \\
 & 0.49877*X[5]*X[5]-1.30173*X[13]*X[1]+ \\
 & 0.05630*X[13]*X[3]-1.29778*X[13]*X[5] \quad (3)
 \end{aligned}$$

$$\begin{aligned}
 \text{Weight} = & 13.09076+1.07598*X[2]+0.13284*X[3]*X[1]+0.14519 \\
 & *X[3]*X[2]+0.09236*X[4]*X[1]-0.09078*X[4]*X[3] \quad (4)
 \end{aligned}$$

3.3 마이크로 유전자 알고리즘을 이용한 최적화

마이크로 유전자 알고리즘(micro-genetic algorithms μGA)은 가장 적합하거나 혹은 최적의 해를 구하기 위한 많은 수의 세대에 대하여 최선의 잠재적

Table 4 Regression analysis of frequency ($R^2_{adj}:98.65$)

Variable	DF	Parameter Estimate	Standard Error	t-Value	Pr> t P-value
Intercept	1	30.38877	0.53124	57.20	<.0001
x1	1	-2.86642	0.22240	-12.89	<.0001
x2	1	1.011296	0.29813	3.40	0.0012
x3	1	0.98440	0.12027	8.18	<.0001
x4	1	0.00679	0.04247	0.16	0.8735
x5	1	-3.70749	0.20455	-18.12	<.0001
x1x3	1	8.81136	0.32861	26.81	<.0001
x1x1	1	0.38107	0.03295	11.56	<.0001
x2x1	1	-0.08148	0.0228	-3.56	0.0007
x2x2	1	-0.09815	0.04854	-2.02	0.0474
x3x1	1	0.04321	0.01525	2.83	0.0062
x3x3	1	-0.15967	0.02157	-7.40	<.0001
x4x1	1	0.03086	0.01525	2.02	0.0473
x5x1	1	1.12418	0.04315	26.06	<.0001
x5x5	1	0.49877	0.03295	15.14	<.0001
x1x3x1	1	-1.30173	0.05979	-21.77	<.0001
x1x3x3	1	0.05630	0.01831	3.08	0.0031
x1x3x5	1	-1.29778	0.05979	-21.71	<.0001

해를 진화시키기 위한 적자 생존(survival of the fittest) 이나 자연도태(natural selection)의 원칙하에 작동되며 작은 수의 개체군(population)을 갖는 유전자 탐색 알고리즘으로 Krishnakumar(1989)에 의해 제시되었으며⁽⁶⁾ 고전적 단순 유전자 알고리즘(simple genetic algorithms, SGA)에 비해 μ GA 가 더 적은 수의 개체군을 필요로 한다. 또한 각 개체군에 대하여 수많은 개체를 필요로 하는 SGA 와 비교하여 μ GA 는 3~7 개 정도의 개체 수를 가진다.

예를 들면 많은 시간의 연산시간을 필요로 하는 시뮬레이션의 경우, 작은 개체군의 크기는 전세대가 마치 3~7 개의 CPU 가 병렬적으로 실행되는 것처럼 매우 편리하다. 이러한 특징은 가장 적합한 해를 얻기 위해 요구되는 연산시간을 현저히 줄일 수 있다.

Fig. 6 은 μ GA 에 대한 순서도를 나타낸다. 우선 주어진 환경에 대하여 5 개의 임의의 개체를 선택하여 적합도를 결정하고 복제 연산자로는 다양성을 유지하는 토너먼트 선택(tournament selection)을 그리고 교배 연산자로는 균일교배(uniform crossover)방법을 각각 사용한다. 교배가 이루어지면 다시 새롭게 생성된 개체군에 대하여 수렴이 되었는지를 확인한다.(5% 미만이면 수렴) 이러한 방식으로 집 단내 하나의 염색체를 최적의 개체로 관리하고 나머지 염색체들은 임의의 그룹을 형성하고 토너먼트 선택을 사용하여 경쟁을 통해 적합도(fitness)가 큰 것이 선택되도록 함으로써 모집단의 나머지 부분을 채우게 된다. 또한 돌연변이(mutation)가 없기 때문에 유전연산자와 엘리트 선택(elitism selection)을 통

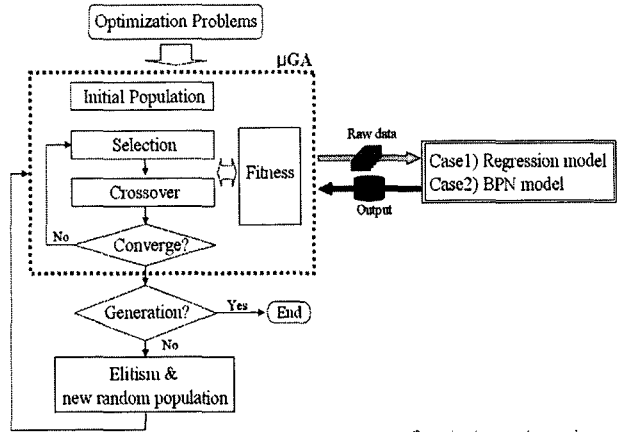


Fig. 6 Schematic of μ GA

Table 5 Optimization results

		μ GA				
Model		BPN model		Regression model		Initial data
Case		A	B	C	D	E
Value (mm)	x1	0.847	0.842	1.025	1.000	1.6
	x2	2.473	2.203	2.001	2.000	2
	x3	1.301	1.300	1.024	1.012	1.2
	x4	1.634	1.547	1.389	1.024	2
	x5	1.764	1.755	1.005	1.006	3
	x6	1.423	1.233	1.132	0.969	2
Frequency (kHz)		34.00	34.00	35.24	34.26	29.945
Optimal weight(kg)		15.38	15.38	15.18	15.10	15.845
N-function		2575	13200	2615	13190	

해 개체군이 진화해 간다.⁽⁷⁾

본 연구에서는 위에서 구성한 BPN 모델과 회귀 분석모델을 μ GA 에 근사화 함수로 적용하였으며, 적합도의 정도를 가늠하기 위한 함수로 페널티 함수법(exterior penalty function method)을 사용하였다.⁽⁸⁾

또한 초기 개체 수는 5 개로 설정하여 각 근사 모델에 대하여 총 100 세대와 500 세대의 진화연산을 각각 수행하였다.

Table 4 는 BPN 과 회귀분석 모델에 대하여 최종적으로 최적화된 설계변수와 구속조건을 만족하는 최적화된 중량을 나타내고 있다. Case E 의 초기조건에 비해 BPN 모델의 경우, 구속조건인 1 차 고유진동수가 34 Hz 를 만족시키면서 중량은 3%감소하였고 회귀분석모델의 경우 마찬가지로 고유진동수에 대한 구속조건을 만족시키면서 중




Fig. 7 Convergence history of regression model




Fig. 8 Convergence history of BPN model

량은 5% 감소 하였다.

Table 4, Fig. 7 그리고 Fig. 8 에 나타나는 결과처럼 수렴속도는 BPN 의 경우 200 회, 회귀분석모델의 경우 약 2500 회 정도에서 최적해로 수렴함으로써 약 10 배정도의 수렴 속도차를 나타냈으며 여기서 N_function 은 수렴을 위한 함수의 반복된 횟수를 나타낸다.

4. 결 론

본 연구는 승용차용 스티어링시스템을 지지하는 T-형구조물에 대한 최적화 문제를 신경망 및 회귀분석에 의한 근사화 모델과 μ GA 기법을 적용한 유전자 알고리즘을 사용하여 수행하고 그 결과를 비유했다. 공진을 피하기 위한 고유진동수의 구속조건 하에서 BPN 과 회귀분석을

이용한 전역함수근사화 모델은 Table 4 의 초기 데이터에 비해 모두 3%~5%의 중량을 감소시켰다. 또한 유전자 알고리즘을 이용한 최적화 문제는 무작위로 선택되는 초기설계를 유용영역 내에서 선택되도록 함으로써 전역적 최적해로의 수렴이 보다 효과적임을 확인하였다. 그러나 본 연구는 구속조건이 고유진동수에 한정되어 있어, 앞으로 충돌과 피로등과 같은 구속조건을 만족하는 보다 광범위한 영역의 최적화 문제를 다루기 위한 연구가 진행되어야 한다.

후 기

이 연구는 한국과학재단 지정 한양대학교 최적설계신기술센터의 연구비 지원으로 수행되었습니다.

참고문헌

- (1) Seo, J. B. and Kim, B. S., 2001, "Shape Optimization of the Steering Support System Using Hydroforming," *Trans. of KSNVE*, pp. 572~573.
- (2) Byum, S. J., Park, N. G. and Park, Y. S., 2001, "Redesign of Steering Wheel Support T-Beam Structure to Reduce Its Vibration Using Frequency Response Function Synthesis Technique," *Trans. of KSNVE*, Vol. 11, No. 5, pp. 126~127.
- (3) Kim, Y. S., Kim, J. H. and Lee, J. S., 2002, "Optimization of Transonic Airfoil Using GA Based on Neural Network and Multiple Regression Model," *Trans. of KSME(A)*, Vol. 26 No.12, pp. 2259.
- (4) Kim, W. S. and Lee, J. S., 2000, "System Decomposition Techniques in Multidisciplinary Design Optimization Using Genetic Algorithms and Neural Networks," *Trans. of COSEIK*, Vol. 12, No. 4, pp. 621~622.
- (5) Han, J. K., Joe, J. and Park, B. H., 1998, *Analysis of Statistical Data Using SAS*, Kyowoo Publish Company, Seoul, Korea
- (6) Rajeev, S. and Krishnakumar, C. S., 1992, "Discrete Optimization of Structures Using Genetic Algorithms," *Trans. of Structural Engineering*, Vol. 118, No. 5, pp. 1233~1250.
- (7) Kang, J., 2000, *Genetic Algorithms and Its Application* Kyowoo Publish Company, Seoul, Korea.
- (8) Vanderplaats, Garret N., 1993, "Numerical Optimization Techniques for Engineering Design with Application," McGraw-Hill Inc., pp. 124~152.