

분류시스템을 이용한 다항식기반 반응표면 근사화 모델링

이종수*

Development of Polynomial Based Response Surface Approximations Using Classifier Systems

Lee, Jongsoo*

ABSTRACT

Emergent computing paradigms such as genetic algorithms have found increased use in problems in engineering design. These computational tools have been shown to be applicable in the solution of generically difficult design optimization problems characterized by nonconvexities in the design space and the presence of discrete and integer design variables. Another aspect of these computational paradigms that have been lumped under the broad subject category of soft computing, is the domain of artificial intelligence, knowledge-based expert system, and machine learning. The paper explores a machine learning paradigm referred to as learning classifier systems to construct the high-quality global function approximations between the design variables and a response function for subsequent use in design optimization. A classifier system is a machine learning system which learns syntactically simple string rules, called classifiers for guiding the system's performance in an arbitrary environment. The capability of a learning classifier system facilitates the adaptive selection of the optimal number of training data according to the noise and multimodality in the design space of interest. The present study used the polynomial based response surface as global function approximation tools and showed its effectiveness in the improvement on the approximation performance.

Key words : design optimization, function approximations, response surface method, machine learning, classifier systems, genetic algorithms

1. 서 론

컴퓨터의 성능 및 시뮬레이션기반 해석기술의 발전으로 공학문제의 설계 및 최적화를 위한 다양한 수치적 방법이 개발되었고 특히, 구조최적설계 분야에 수많은 최적화 방법론이 연구되어 실제 문제에 적용되고 있다. 수치적 방법에 의한 설계최적화를 수행하는 경우, 유한요소해석 등, 전산해석용 프로그램과 연결하여 설계 해의 반복적인 탐색과정을 거쳐 최적설계를 얻게되는데, 계산시간의 대부분은 해석모델 수행과정에서 소요되며, 이를 효율적으로 해결하기 위해 근사최적화(approximate optimization)기법을 이용하고 있다.

*정회원, 연세대학교 기계전자공학부

다량의 설계변수 및 구속조건을 수반하는 최적설계 문제의 경우, 설계공간이 불연속적(disjoint)이고 설계변수가 연속형(continuous)일 뿐 아니라, 정수형(integer) 또는 이산형(discrete)의 다양한 형태로 혼합되어 있으며 특히, 설계문제의 비선형성으로 인해 최종적으로 수렴된 최적설계는 전역설계(global design)가 아닌 초기 설계에서 개선된 국부설계(local design)일 가능성이 높다. 이러한 설계문제의 다양한 특성을 고려하기 위해 전역적 탐색 방법인 유전알고리즘(genetic algorithms, GA's) 또는 모사적냉각(simulated annealing, SA) 등을 최적화의 새로운 방법으로 이용하고 있으며, 실제 적용분야에 있어서 벤치마크 수준을 지나 다양한 구조최적화 및 대규모 최적설계 문제에 적용되고 있다^[1]. 유전알고리즘 등과 같은 진화연산(evolutionary computing)기반 최적

화 방법은 전역해를 탐색할 수 있는 장점을 내포하고 있으나, 전화세대에 걸쳐 설계해의 집단적 이동으로 인해 막대한 계산시간이 소요되며 이러한 단점을 극복하기 위해 전역함수근사화(global function approximations)모델을 이용하여 효율적 설계를 수행하고 있다.

전역함수근사화의 방법으로는 대표적으로 다항식 또는 신경회로망기반 반응표면법(response surface method, RSM)이 사용되는데^[2], 설계공간에 걸쳐 설계변수와 반응함수와의 관계를 다양한 해석데이터를 통해 훈련된 근사화모델을 구축한다. 그러나 함수근사화를 위해 선택하는 해석데이터 또는 설계점의 개수 및 그들의 위치는 근사화모델이 최상의 정밀도를 가질 때까지 반복적이거나 임의로 설정된다. 이러한 문제를 개선하기 위해 실험계획법(design of experiment)에서 사용되는 중심합성계획법 및 D-optimal 계획법 등을 적용하여 설계변수의 규모와 다항식의 계수 수에 따라 최적의 설계점을 구하여 반응표면을 구현하기도 한다^[3,4]. 그러나 대부분의 공학설계문제는 설계공간의 특성에 따라 multimodality의 특성이 불규칙적으로 나타나므로, 설계공간의 부분적 영역에 따라 적용할 수 있는 적용형 함수근사화기법이 필요하며, 이러한 설계공간의 복잡성에 의거하여 설계점의 균일 분포가 아닌 함수근사화를 정확히 묘사할 수 있는 설계점의 능동적인 분포가 요구된다. 즉, 반응표면 생성에 필요한 설계점을 근사화모델의 난이도에 따라 노이즈 및 multimodality의 특성이 강한 영역에는 더 많은 설계점을 부여하고, 단순한 함수영역에는 적은 양의 설계점으로 근사화를 구현하도록 함으로써, 불필요한 설계점의 생성을 억제하고 적은 수의 설계점으로 전체 설계영역에 걸친 전역함수근사화 모델링이 가능한 전략이 필요하다.

본 논문에서는 외부의 입력조건으로부터 시스템의 성능을 학습화를 통해 적용시키고 최적화하는 규칙기반 지능 체계인 분류시스템을 이용하여 반응표면법에 의거한 다항식 형태의 함수근사화모델을 구현한다. 분류시스템이 갖고 있는 적용형 규칙기반 시스템의 장점을 이용하여, 설계영역별 존재하는 반응 함수의 노이즈 및 multimodality의 특성으로부터 근사화의 정밀도를 위한 규칙을 생성, 발견한다. 이를 바탕으로 근사화의 난이도에 따라 능동적으로 설계점의 분포를 결정함으로써 근사화모델의 정밀도를 개선할 수 있는 효과적인 반응표면기반 함수근사화 모델링의 방법을 제시하고자 한다.

2. 분류시스템

분류시스템(classifier system, CS)은 이진수 방식(binary string) 등으로 암호화된 분류체(classifiers)가 외부로부터 입력되는 임의의 규칙(rules)과 결합함으로써 학습화를 통해 분류체의 성능을 조절하고 적용시키는 기계학습(machine learning) 기반 전산지능(computational intelligence and soft computing) 체계이다. 분류시스템은 초기에 컴퓨터과학 분야^[5,6]에서 수학적 이론을 바탕으로 발전하였으며, 최근에 와서 설계관련 분야에 응용되고 있다^[7,8].

분류체는 분류시스템의 기본단위이며, 규칙의 형태와 같은 if <condition> then <action>으로 표현된다. 분류시스템은 이러한 규칙형태의 분류체를 여러 적용과정을 통해 학습사킴으로써 그 역할을 수행하는데, 분류체와 일반적 규칙이 동일한 형태이므로 전문가 시스템과 유사성을 갖고 있다. 그러나 전문가 시스템은 실행하기 이전에 수많은 데이터베이스 및 규칙정보들을 확보해야하는 문제를 갖고 있으나, 분류시스템은 초기에 적은 양의 부정확하거나 임의적인 분류체로부터 시작하더라도 분류시스템이 갖고 있는 기계학습적 특성을 이용하여 외부로부터의 요구사항과 조합되는 분류체들을 학습하고 탐색, 발견하기 때문에, 궁극적으로 시스템의 성능 및 목적을 최적으로 제어할 수 있는 규칙 또는 분류시스템을 구축할 수 있다. 이러한 새로운 규칙 또는 분류체의 생성 및 발견은 유전알고리즘 등과 같은 진화연산기법을 통해 수행하며, 이미 분류체들이 이진수표현으로 암호화되어 있으므로 유전알고리즘을 용이하게 적용할 수 있다. 분류시스템을 구성하는 3가지 기본 요소 및 그 기능은 다음과 같다.

2.1 규칙 및 메시지 시스템

분류시스템은 두 종류의 규칙으로 구성되는데 하나는 분류체이며, 또 다른 하나는 외부로부터 입력되어 분류체와의 결합을 통해 각 규칙의 성능을 조절하는 메시지목록(message list)이다. 각 분류체는 <condition> 및 <action>으로 표현되는 규칙부분과 규칙강도(strength)로 구성되는데, 규칙강도는 외부로부터의 메시지와의 학습화를 통해 얻어지는 각 분류체 규칙의 성능을 정량적으로 표시한 측정치이다. 다시 말해, 규칙강도가 높은 분류체는 분류시스템의 성능을 향상시킬 수 있는 가능성을 보다 많이 내포하고 있다. 메시지는 외부로부터 시스템에 전달되는 하나의 규칙이며, 분류체의 <condition> 부분과 결합하고, 그

Table 1. Typical classifiers

condition	action	strength
011011	101	35.4
01#001	000	26.6
#011#	111	21.9
##0##0	010	8.3

결합정도에 따라 분류체 규칙을 실행하며 분류체의 규칙강도에 영향을 미치게 한다. 이진수방식으로 암호화된 분류체를 Table 1에 표현하였으며, 각 분류체는 수치화된 규칙강도를 갖고 있음을 알 수 있다.

여기서, #는 wild card이며, 0 또는 1의 두 가지 값이 모두 사용 가능함(don't care)을 표현한다. 즉, 이러한 wild card의 표현이 많을수록 규칙의 일반성이 커지게 되고, 반대로 wild card의 수가 적을수록 규칙의 상세성(specifity)이 커지게 된다. 초기에 할당된 분류체는 분류시스템이 실행하기 전에는 정확하지 않은 암의성이 많은 규칙으로 구성되므로 wild card의 수가 많으나, 시스템의 성능을 높이도록 학습화가 진행되면서 각 분류체의 정확한 의미가 생성되고 고유한 상세성이 증가하게 된다.

2.2 규칙 평가 시스템

규칙 평가 시스템은 학습화가 진행되는 분류체에 대한 규칙강도를 수정하는 단계이다^[10]. Fig. 1에서와 같이 분류시스템 내에 있는 분류체의 <condition> 부분과 외부로부터 전달되는 메시지의 <condition> 부분이 서로 결합하여 규칙의 <action>이 실행되면 외부에 다시 영향을 주게 된다. 이때 외부에 전달되는 영향정도에 따라 분류체의 규칙강도가 변화하게 된다. 즉, 외부 조건에 대해 성능을 향상시키게 되면 규칙강도는 증가하고, 반대로 성능이 떨어지는 분류

체에 의해 규칙이 실행되어 시스템에 영향을 주게 되면 이에 상응하는 만큼의 규칙강도가 감소하게 된다.

외부로부터의 메시지와 결합하는 분류체는 결합정도에 따라 bid $B(i)$ 를 지불함으로써, 규칙강도 $S(i)$ 가 다음의 식과 같이 변하게 된다.

$$S(i+1)=S(i)-B(i) \quad (1)$$

메시지와 어느정도의 결합성을 갖는 분류체는 식 (1)과 같이 변화된 규칙강도를 갖게 되며, 메시지와 결합된 다양한 분류체중 가장 영향력이 큰 분류체(winning classifier)는 <action> 부분이 실행되어 외부에 영향(effect)을 미친다. 이때, 외부에 전달된 영향으로 전체 시스템의 성능을 향상시키면 그에 해당하는 보상치(reward)를 식 (2)와 같이 얻게 되며 이러한 규칙강도의 변화를 통해 각 분류체의 측정치를 기준으로 전체 분류체를 서열화한다.

$$S(i+1)=S(i)-B(i)+R(i) \quad (2)$$

초기화된 모든 분류체는 같은 값의 규칙강도로 출발하나, 외부에 공헌하는 영향정도에 따라 각 분류체는 서로 다른 규칙강도치를 갖게되며(Table 1 참조), 이 값은 한 학습세대(learning epoch)에 있어서 분류체의 성능차가 되며 새로운 규칙의 탐색 및 발견을 실행하는 판단 기준(reference)이 된다.

2.3 규칙 발견 메카니즘

분류시스템은 전문가 시스템의 특성과 규칙의 생성 및 발견의 특성을 접목시킨 기계학습 기반 전산지능 체계이다. 초기에 분류시스템을 구성하는 각 분류체는 정확한 시스템의 성능을 표현하는 규칙이 아니지만 학습화 및 적용화를 통해 외부 조건을 만족하면서 성능을 조절하는 분류체를 구성하게 되는데 이러한 과정을 수행하기 위해서는 기존의 규칙들을 변화시키고, 새로운 분류체를 탐색해야 한다. 규칙 발견 메카니즘으로서, 진화연산기법이 사용되며, 이진수방식으로 암호화된 규칙을 적용시킬 수 있는 유전알고리즘을 효과적인 탐색도구로 이용하게 된다. 각 분류체가 갖고 있는 규칙강도를 기준으로 분류체의 염색체 구조를 변화해가면서 규칙강도를 최대화하는 최적화 과정을 수행하게 되는데, 최적설계 입장에서 보면 각 분류체는 설계변수에 해당하고 규칙강도는 목적함수에 해당하는 비구속 최적화(unconstrained optimization)문제로 고려할 수 있다.

분류체와 메시지가 결합하고 이에 따라 외부에 영향을 미치는 기계학습과정을 통해 시스템의 성능

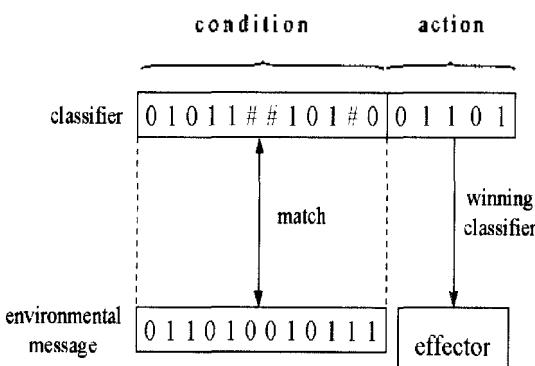


Fig. 1. Matching between message and classifier.

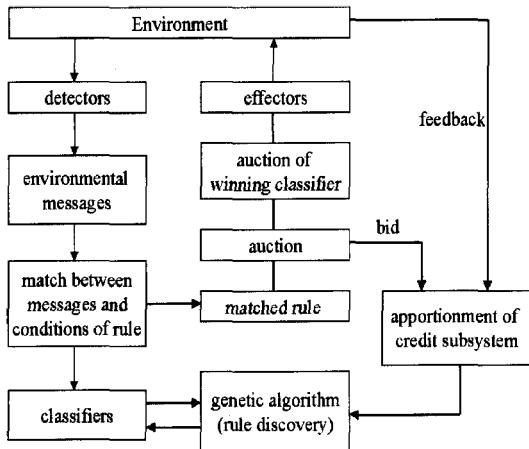


Fig. 2. A general procedure for classifier systems.

을 조절하고 최적화하는 분류시스템의 실행되는 과정을 Fig. 2에 나타내었다.

3. 반응표면법

반응표면은 계산비용이 막대하게 소요되는 전역최적화 기법의 함수근사화모델의 구축을 위한 대체 방법으로서 일정한 정확도(accuracy)를 갖는 반응표면 방정식을 구성하여 실제 유한요소해석 도구 등과 연계하지 않고, 근사화모델을 최적화 알고리즘에 적용하여 급속한 설계과정을 가능하게 한다. 반응표면에서는 대표적으로 다항식 형태의 근사화모델을 사용하는데 예를 들어, 2개의 독립변수 x_1 및 x_2 를 갖는 제2차 다항식(a second order polynomial)의 표현은 식 (3)과 같다.

$$y = a_0 + a_1x_1 + a_2x_2 + a_3x_1^2 + a_4x_1x_2 + a_5x_2^2 \quad (3)$$

만일, N 개의 설계점 $(x_1, x_2)_i$, ($i=1, N$)으로 구성된 함수의 근사치를 행렬식으로 나타내면 다음과 같다.

$$\begin{pmatrix} f_1 \\ f_2 \\ \vdots \\ f_N \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{21} & x_{11}^2 & x_{11}x_{21} & x_{21}^2 \\ 1 & x_{12} & x_{22} & x_{12}^2 & x_{12}x_{22} & x_{22}^2 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & x_{1N} & x_{2N} & x_{1N}^2 & x_{1N}x_{2N} & x_{2N}^2 \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \\ a_4 \\ a_5 \end{pmatrix} \quad (4)$$

식 (4)를 행렬식으로 나타내면,

$$\{f\} = [Z]\{a\} \quad (5)$$

로 표현되는데, 적절히 선택된 임의의 설계점으로부터

함수를 근사화하는 다항식의 계수(coefficient)인 $\{a\}$ 를 구하게 된다. 이때, 구하고자 하는 계수의 수는 제2차 다항식의 경우에는 6개이며, 고차 다항식인 경우에는 각각, 10개, 15개, 21개 및 28개이다. 설계점의 개수 N 이 근사화함수의 계수의 수보다 큰 경우에는 최소자승방법(least square method)을 이용하여 다음의 행렬 관계식으로부터 근사화된 다항식의 계수를 얻을 수 있다.

$$[Z]^T \{f\} = [Z]^T [Z] \{a\} \quad (6)$$

$$\{a\} = ([Z]^T [Z])^{-1} [Z]^T \{f\} \quad (7)$$

식 (7)의 결과로부터 식 (3)을 표현하기 위한 다항식의 계수가 결정되며, 다수의 해석데이터를 이용해 함수근사화의 정밀도를 분산분석(analysis of variance)을 통해 검증한다.

4. 함수근사화 적용 예

분류시스템을 이용한 전역함수근사화의 적용문제로서 5개의 부재를 갖는 평면 트러스(Fig. 3참조)를 고려한다. 정하중을 받는 트러스는 우측 하단점의 위치에 따라 형상이 변화하며, 각 형상에 대해 허용응력 및 좌굴응력을 구속조건으로 하는 최적화문제를 구성 할 수 있다. 트러스 하단점의 좌표 변화에 의한 풀단의 이동범위(move limit)는 Fig. 3에 나타나 있다. 이로부터 얻어지는 함수근사화모델은 수평 및 수직 방향의 하단점의 변화에 따른 트러스의 최소무게로 표현되는데, 2개의 하단점은 입력 설계변수에 해당하며, 구조물의 최적 무게는 반응량이 된다. 이러한 반응표면에 의한 근사화는 앞절에 소개된 과정을 통해 얻게 되며, 근사화모델링을 위한 설계데이터는 다음의 순서로 얻는다.

(1) 우측 하단점의 고정된 임의의 위치에서의 트러스 형상을 기준으로 부재의 단면적을 최소화하는 경량설계 최적화를 수행한다. 트러스 하단점(수평좌표는 x_1 , 수직좌표는 x_2)의 위치를 고려한 경량설계 최적화문제의 구성은 다음과 같다.

$$\text{minimize } W = \sum_{i=1}^5 \rho_i A_i L_i(x_1, x_2) \quad (8)$$

$$\text{subject to } -15 \text{ksi} \leq \sigma_i \leq 20 \text{ksi} \quad (9)$$

$$\frac{\pi E A_i}{4 L_i^2(x_1, x_2)} \leq \sigma_i \quad (10)$$

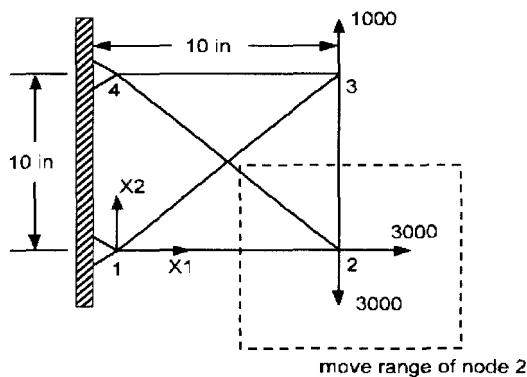


Fig. 3. 5-bar planar truss.

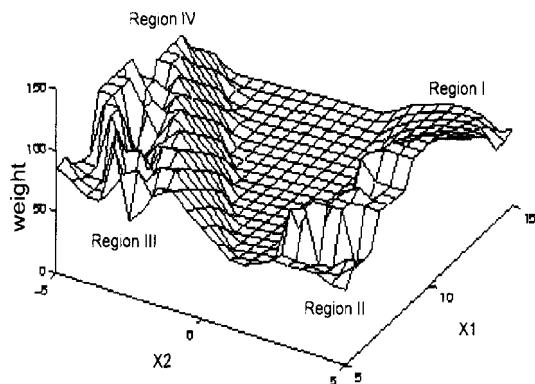


Fig. 4. Exact contour for optimal weight distribution.

$$\begin{aligned}0.01 \leq A_i &\leq 50.0 \\5.0 \leq x_1 &\leq 15.0 \\-5.0 \leq x_2 &\leq 5.0\end{aligned}$$

여기서, ρ_i , A_i , L_i 는 각각 부재의 밀도, 단면적 및 길이이다. 또한, 구속조건으로는 식 (9)의 암축/인장 허용응력 및 식 (10)의 Euler 좌굴응력을 고려하였다.

(2) 하단점의 위치변화를 통해 트러스의 형상을 변환시켜 가면서 식 (8)-(10)의 경량설계 최적화의 과정을 반복하여 (x_1, x_2) 에 대한 W^* 의 데이터를 얻는다.

하단점의 위치변화에 따른 트러스의 최적무게의 값을 Fig. 4에 표현하였다. 설계공간에 걸쳐 W^* 은 multimodality 및 국부적인 noise를 가지므로 전체 영역을 일정한 개수의 하부영역(subregion)으로 분리하여 반응표면에 의해 근사화할 수 있도록 하부영역에 할당되는 최적의 설계데이터 수를 결정해야하는데 이를 위해 적응형 근사화모델링 기법을 적용한다. Fig. 4에서의 multimodality 및 noise의 특성을 고려하여 전체 영역을 다음과 같이 4개의 영역으로 분리

Table 2. Domain decomposition

	$10.0 \leq x_1 \leq 15.0$ $0.0 \leq x_2 \leq 5.0$	$5.0 \leq x_1 \leq 10.0$ $0.0 \leq x_2 \leq 5.0$
Region I	$5.0 \leq x_1 \leq 10.0$ $-5.0 \leq x_2 \leq 0.0$	$10.0 \leq x_1 \leq 15.0$ $-5.0 \leq x_2 \leq 0.0$
Region III		Region IV

하였다.

즉, 분류시스템의 사용 목적은 반응표면 근사화에 필요한 설계데이터의 개수(the amount of training data)와 그 위치(the region in which these training data are located)를 결정하기 위한 것이다. 분류시스템을 이용한 적응형 반응표면 근사화모델링의 순서는 다음과 같다.

(1) 초기에는 다항식의 차수(order) 및 시작단계에 필요한 최소의 설계데이터를 선정하고 이를 이용하여 오차가 비교적 큰 초기의 반응표면을 구성한다.

(2) 설계데이터의 추가에 의한 근사화오차의 변화량을 분석하기 위한 민감도해석용 모델을 생성한다.

(3) 분류시스템을 위한 분류체를 초기화한다. 또한, 다항식을 표현하기 위해 기존에 사용되지 않은 새로운 설계데이터 및 실제의 함수값과 이에 해당하는 근사화의 오차를 알고 있는 데이터를 이용하여 이를 메시지로 할당하며 분류체의 규칙 중에서 `<condition>` 부분과 결합하도록 한다. 분류체는 `<condition>` 및 `<action>`으로 구성되는데 `<condition>`은 설계데이터가 속하는 영역 및 그 설계데이터에 의한 근사화 오차이며 `<action>`은 근사화개선을 위해 필요한 설계점의 개수 및 영역이다.

(4) 분류체의 `<condition>` 부분이 메시지와 결합하게 되고 그 결합정도에 따라 규칙강도가 식 (1)에 의해 변화한다. 본 연구에서 적용하는 bid는 식 (10)과 같이 일정한 값으로 고려하였다.

$$B(i)=B_o \quad (10)$$

외부의 메시지와 결합성이 가장 높은 분류체가 결정되면 그 분류체(winning classifier)의 `<action>` 부분이 작동하여 함수근사화의 데이터를 생성하게 되는데 시스템의 공현도에 따라 reward를 규칙강도에 부과하여 그 값을 식 (11)로 주어진다.

$$R(i)=[k_1(\alpha x_{\max} - |x_{\text{message}} - x_{\text{condition}}|)^p + k_2 \frac{\Delta E}{\Delta n}]^{(i)} \quad (11)$$

여기서, x 는 암호화된 분류체의 규칙이며, $(\Delta E/\Delta n)$ 은 설계데이터 수의 변화에 대한 근사화 오차의 민감도

이다.

(5) bid 및 reward의 관계식을 적용하여 분류체의 규칙강도를 변화시켜 가면서 근사화모델의 정밀도를 향상시킬 수 있는 규칙들을 유전알고리즘을 통해 탐색한다. 또한, 새로 얻어진 규칙강도가 높은 분류체로부터 ($\Delta E/\Delta n$)값을 개선한다.

(6) 위의 과정을 주어진 분류시스템의 전화과정을 반복하여 수렴된 설계데이터를 각 하부영역에 대하여 생성한다.

5. 결과 분석

반응표면 모델을 구축하기 위해 다항식의 차수를 변화시켜가며 분류시스템을 통하여 결과를 제시하였다. 분류시스템의 적용에 필요한 파라메터는 Table 3에 나타나 있다. 본 연구에서는 2차, 3차 및 4차 다항식을 4개로 분리된 하부영역에 적용하였다. 결과에 대한 통제적인 경향을 분석하기 위해 유전알고리즘 및 분류시스템을 각기 다른 random seed로부터 10회의 반복과정을 거쳤으며 근사화모델에 대한 평균오차, 오차에 대한 표준편차, 각 영역에 할당되는 최적의 설계데이터 수 및 이에 해당하는 표준편차 등을 Tables 4-7에 나타내었다.

분류시스템에 의한 근사화모델의 수치실험에서, 2차 다항식의 경우보다 3차 다항식의 경우에 개선된 결과를 얻었다. Tables 4 및 5를 비교하면 결과치(근사화 정밀도, 각 영역에 포함되는 근사화 설계점의 개수)에 대한 평균값 및 표준편차 등이 향상되었음을 알 수 있다. 그러나, 3차 다항식의 경우와 4차 다항식의 경우를 비교하면 근사화의 결과가 비교의 대상이 된다. Region-III에서 보면 각각의 다항식의 사용에 있어서 근사화 정밀도의 평균은 4차 다항식이 개선된 결과를 제시하고 있으나, 표준편차에 있어서

는 3차 다항식이 좋은 결과를 제공한다. 또한, 근사화를 위해 필요한 최적의 설계데이터의 개수는 이 값에 해당하는 표준편차와 같은 경향을 보여준다. 다항식의 차수가 증가할수록 Regions-I, II 및 IV에 대해서는 근사화 오차가 감소하지만 필요한 설계데이터의 개수는 증가하고 있는데, Region-I의 경우에는 multimodality 및 노이즈의 정도가 심하자 않으므로 고차의 다항식 및 이에 따른 초기의 설계점이 다양으로 요구되지 않으므로 낮은 차수의 다항식으로도 충분히 반응표면을 구축할 수 있기 때문이다. 본 예제는 전체적인 근사화의 오차가 5-10%의 정확도를 보여주고 있다. 유전알고리즘 및 분류시스템을 적용하는 경우에는 선정하는 설계데이터가 모두 random하게 선택되므로 각 하부영역의 경계부근에서 충분히 설계데이터가 선택하도록 조절한다면 근사화의 정밀도가 개선될 수 있으리라 예측된다.

이러한 함수근사화는 분류시스템이 갖고 있는 분류체의 적용화를 통해 각 하부영역에 근사화 정밀도를 향상시키고 이를 위해 필요한 설계점을 추가함으로써 수행되는데, 분류체를 구성하는 규칙은 초기에 부정확하거나 의미가 없는 정보로 출발하나, <action>에 의해 근사화의 향상에 공헌하는 분류체 규칙들을 규칙강도의 최대화를 통해 발전하고 개선함으로서 가능해 진다. 이 경우 초기의 규칙들은 최적의 설계점 및 그 개수를 탐색하는 과정에서 다음과 같은 중요한 규칙을 생성하게 되었다.

규칙-1: if <한 하부영역에서의 근사화 오차가 다른 하부영역에서의 오차보다 크다>, then <현재의 하부영역에 설계점을 추가하라>.

규칙-2: if <한 하부영역에서의 근사화 오차가 다른 하부영역에서의 오차에 비해 작다>, then <근사화 오차가 가장 큰 다른 하부영역에 설계점을 보강하라>.

분류시스템의 적용화 동안 얻어지는 각 하부영역에서의 반응표면 근사화결과의 수렴과정을 Figs. 5-6에 나타내었다. 위에 설명된 규칙들이 발달되면서 각 영역에서의 근사화 오차는 줄어들게 되고 분류시스템에 의한 반복과정을 거치면서 근사화 오차가 가

Table 3. Control parameters for classifier system

classifiers in population	250
bit lengths of condition part	12
bit lengths of action part	5
GA generations	50
classifier system epoches	50
initial strength (S)	10
bit payment (B_s)	0.1
weighting factor (α)	0.489
weighting factor (k_1)	0.9
weighting factor (k_2)	0.1
exponent in reward coefficient (p)	0.35

Table 4. Use of 2nd order polynomial

	E _{av}	SD1	NID	NFD	SD2
R-I	6.40	2.01	12	29	21
R-II	9.88	3.11	12	54	27
R-III	10.01	2.01	12	59	32
R-IV	8.87	3.51	12	40	30

Table 5. Use of 3rd order polynomial

	E_{ave}	SD1	NID	NFD	SD2
R-I	4.43	1.54	12	16	6
R-II	8.83	2.56	12	23	5
R-III	9.92	1.40	12	56	28
R-IV	8.25	3.83	12	31	19

Table 6. Use of 4th order polynomial

	E_{ave}	SD1	NID	NFD	SD2
R-I	4.95	1.83	18	22	5
R-II	8.31	2.59	18	37	14
R-III	8.86	2.58	18	48	24
R-IV	7.61	2.12	18	40	22

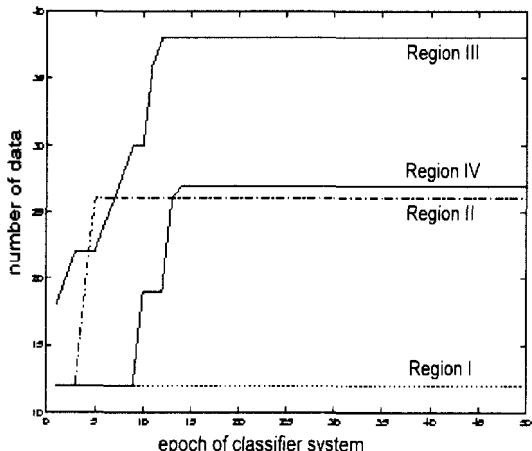
Table 7. Use of different order of polynomials

	OP	E_{ave}	SD1	NID	NFD	SD2
R-I	3rd	4.61	1.87	12	14	3
R-II	3rd	8.96	1.52	12	24	9
R-III	4th	8.09	1.91	18	31	9
R-IV	3rd	7.80	2.48	12	38	23

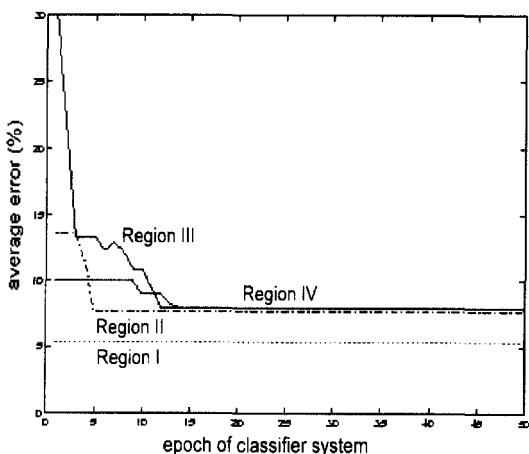
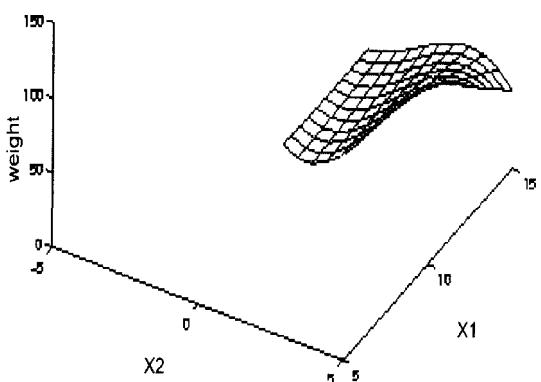
OP 다항식의 차수
 E_{ave} 근사화의 평균 오차
 SD1 E_{ave} 의 표준편차
 NID 초기 설계점의 개수
 NFD 최종 설계점의 개수
 SD2 NFD의 표준편차

장 큰 영역에 설계데이터를 추가하는 과정을 통해 반응표면 모델을 구현한다.

다항식의 차수를 각 하부영역에서 동일하게 선택한 경우에 근사화 정밀도의 변화에 대한 결과를 바탕으로 각 하부영역에서의 multimodality 및 노이즈

**Fig. 6.** Convergence of training data.

의 정도에 맞는 다항식의 차수를 결정한 후 분류시스템에 의한 근사화를 수행하였다. 이 결과를 Table 7에 나타내었는데, 3차 다항식을 Regions-I, II 및 IV에 사용하였고 근사화정도가 가장 어려운 영역인 Region-III에 대해서는 4차 다항식을 사용하였다. 기존의 결과와 비교하여 보면 근사화의 정밀도, 최적 설계점의 개수 및 각 결과에 대한 표준편차 등에서 개선된 결과를 생성하였으나, Region-IV의 경우에는 Fig. 4에서 보는 바와 같이 급경사진 부분과 평평한 부분간의 구배가 심하므로 3차 다항식으로부터 개선된 결과를 제공하지 못하고 있다. 이러한 결과들을 더욱 개선하기 위해서는 초기에 전체 설계영역을 균일한 하부영역으로 설정하기보다는 설계데이터의 노이즈 및 multimodality의 특성을 비교, 분석하여 평평한 영역과 굽곡이 많은 영역으로 분리할 수 있는 data clustering기법을 적용하여 근사화의 정밀도를

**Fig. 5.** Convergence of average error.**Fig. 7.** Classifier system result for Region I.

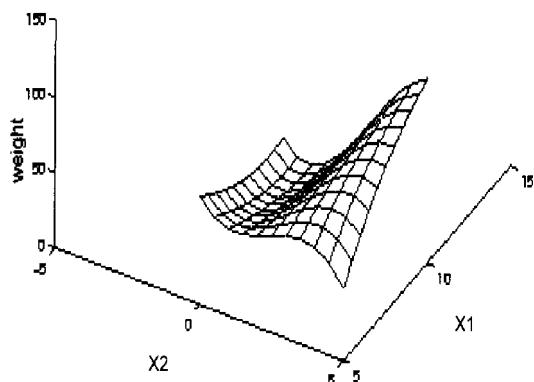


Fig. 8. Classifier system result for Region II.

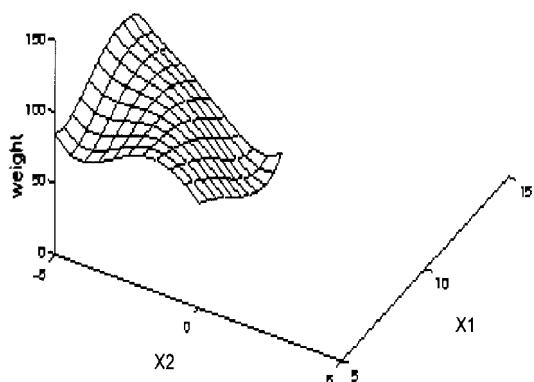


Fig. 9. Classifier system result for Region III.

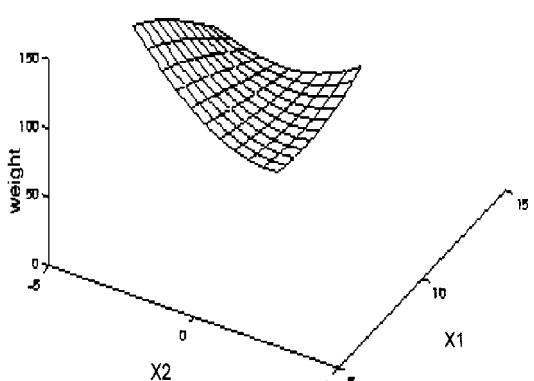


Fig. 10. Classifier system result for Region IV.

향상시킬 수 있다. 분류시스템에 의한 각 하부영역에서의 근사화의 결과를 Figs. 7-10에 나타내었다.

6. 결 론

본 논문에서는 시스템의 성능을 적응화 및 학습화

를 통해 최적화하는 규칙기반 전산지능 체계인 분류시스템을 이용하여 반응표면법에 의거한 다향식 형태의 함수근사화 모델을 구현하였다. 분류시스템을 구성하는 초기의 규칙들은 부정확하거나 임의성이 높은 상태에서 출발하지만, 설계문제의 기계학습적 원리를 기반으로 함수근사화의 정밀도 향상에 공헌하는 유용한 규칙들을 탐색, 발견함으로써 최적의 반응표면을 생성할 수 있다. 즉, 설계공간에서의 multimodality 및 노이즈의 특성을 고려하여 분리된 다수의 설계영역에 대해 설계점의 개수를 다르게 분포시킴으로써 불필요한 설계점의 생성을 억제하고 적은 수의 설계점으로 전체 설계영역에 걸친 전역함수근사화 모델링이 가능하도록 하였다. 또한, 전역최적화과정에서 사용되는 유전알고리즘을 분류시스템에서의 규칙발견 메카니즘의 도구로 활용함으로써, 진화연산 기반 전역최적화 기술 개발에 중요성을 제고할 수 있는 계기가 되었다.

감사의 글

이 연구는 한국과학재단 지정 최적설계신기술연구센터(Center of Innovative Design Optimization Technology, iDOT)의 연구비 지원으로 수행되었습니다.

참고문헌

- Hajela, P. and Lee, J., "Genetic Algorithms in Multi-disciplinary Rotor Blade Design", proceedings of the 36th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conference, AIAA Paper No. 95-1144, pp. 2187-2197, New Orleans, LA, April, 1995.
- Carpenter, W. C. and Barthelemy, J.-F. M., "A Comparison of Polynomial Approximations and Artificial Neural Networks as Response Surface", *Structural Optimization*, Vol. 5, pp. 166-174, 1993.
- Box, G. E. P. and Wilson, K. B., "On the Experimental Attainment of Optimum Conditions", *Journal of the Royal Statistical Society, Series B.*, Vol. 13, pp. 1-14, 1951.
- Miller, A. J. and Nguyen, N.-K., "A Fedrov Exchange Algorithm for D-Optimal Designs", *Applied Statistics*, Vol. 43, No. 4, pp. 669-678, 1994.
- Goldberg, D. E., *Genetic Algorithms in Search, Optimization & Machine Learning*, Addison-Wesley, Reading, MA, 1989.
- Booker, L. B., Goldberg, D. E. and Holland, J. H., "Classifier Systems and Genetic Algorithms", *Artificial*

- Intelligence*, Vol. 40, pp. 235-282, 1989.
7. Richards, R. A., "Zeroth-Order Shape Optimization Utilizing A Learning Classifier System", Ph.D. Dissertation in Mechanical Engineering, Stanford University, Stanford, CA, August, 1995.
 8. Goel, S. and Hajela, P., "Adaptive Optimization Technique Using Classifiers Based Machine Learning Paradigm", proceedings of the 36th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conference, Kissimmee, FL, April, 1997.
 9. Hajela, P. and Lee, J., "A Machine Learning Based Approach to Improve Global Function Approximations for Design Optimization", proceedings of the International Symposium on Optimization and Innovative Design, Tokyo, Japan, July, 1997.
 10. Holland, J. H., "Properties of the Bucket-Brigade Algorithm", proceedings of the 1st International Conference on Genetic Algorithms, Hillsdale, NJ: Lawrence Erlbaum Associates, pp. 1-7, 1989.



이종수

1988년 연세대학교 기계공학과 학사
1992년 University of Minnesota 항공우주
공학 석사
1990년 Rensselaer Polytechnic Institute
기계공학 박사
1997년 Research Associate in Rensselaer
Rotocraft Technology Center, RPI
1997년 현재 연세대학교 기계전자공학부
조교수

관심분야 : Multidisciplinary Design Opti-
mization, Soft Computing in Design
Engineering, Aerodynamics, Aero-
acoustics, Fluid-Structure Interactions