

論文

항공기 날개 설계를 위한 강건성 및 신뢰성 최적 설계 기법의 적용

전상욱*, 전용희*, 김정화*, 이동호**

Application of the Robust and Reliability-Based Design Optimization to the Aircraft Wing Design

Sangook Jun*, Yong-Hee Jeon*, JeongHwa Kim* and Dong-ho Lee**

ABSTRACT

Using a deterministic design optimization, the effect of uncertainty can result in violation of constraints and deterioration of performances. For this reason, design optimization is required to guarantee reliability for constraints and ensure robustness for an objective function under uncertainty. Therefore, this study drew Monte Carlo Simulation(MCS) for the evaluation of reliability and robustness, and selected an artificial neural network as an approximate model that is suitable for MCS. Applying to the aero-structural optimization problem of aircraft wing, we can explore robust optima satisfying the sigma level of reliability than the baseline.

초 록

결정론적인 최적 설계 방법을 이용하는 경우 불확실성의 영향으로 인하여 제약조건의 위반이나 목표 성능의 저하를 초래할 수 있다. 이러한 까닭에 불확실성하에서 제약 조건에 대한 신뢰성을 보장하고 목적함수의 강건성을 확보하는 설계가 필요하다. 그러므로 본 연구에서는 강건성과 신뢰성을 평가하기 위하여 Monte Carlo Simulation(MCS)을 이용하였으며, 계산 효율의 증가를 위하여 MCS에 적합한 근사모델을 선정하는 과정을 거쳐 신경망 모델을 채택하게 되었다. 이를 공력-구조가 연동된 항공기 날개 설계 문제에 적용하여 봄으로써 그 가능성을 타진하였다. 불확실성을 고려한 최적 설계를 수행한 결과 요구되는 신뢰도 수준을 만족시키면서 baseline보다 강건한 최적해를 탐색하는 것이 가능하였다.

Key Words : Robust Design Optimization(강건 최적 설계), Reliability-Based Design Optimization(신뢰성 기반 최적 설계), Monte Carlo Simulation(몬테 카를로 시뮬레이션), Artificial Neural Network(인공 신경망)

1. 서 론

최적설계 기법은 오랜 기간 연구되어 여러 효율적인 이론이 확립되어 왔으며 많은 공학설계

문제에 적용되어 제품의 성능을 획기적으로 향상 시킴으로써 그 합리성을 인정받고 있다. 그러나 일반적으로 최적설계의 결과로 얻은 최적해는 불확실성에 대해 매우 민감한 극점에 존재하거나 제약조건의 경계에 위치할 가능성이 높다. 이와 같은 경우, 불확실성에 의한 변동으로 인하여 제약 조건이 크게 위배될 수 있으며 목적함수의 목표치를 만족하지 못할 가능성도 높아 실제 제품의 성능이 개선되지 못하는 경우가 발생할 수 있다[1].

† 2006년 4월 24일 접수 ~ 2006년 7월 6일 심사완료

* 정회원, 서울대학교 기계항공공학부 대학원

** 정회원, 서울대학교 기계항공공학부/
항공우주신기술연구소

연락처, E-mail : donghlee@snu.ac.kr
서울특별시 관악구 신림동 산56-1

이와 같이 기존의 최적설계 기법은 물리적 현상이나 변수의 불확실성을 고려하지 못하므로 시스템의 성능이나 신뢰성에 대한 정보의 제공이 어렵다. 이러한 까닭에 설계자는 최악의 경우를 가정하여 매우 신중하게 설계를 하게 되고 경제적인 관점에서 효율성이 감소하는 결과를 초래하게 된다[2]. 그러므로 이러한 단점을 보완하기 위해서 불확실성 모델을 확률, 통계적 접근법으로 구축하는 신뢰성 기반 최적 설계(Reliability-Based Design Optimization; RBDO)와 강건 최적 설계(Robust Design Optimization; RDO)에 대한 많은 연구가 진행되고 있다.

신뢰성 기반 최적설계는 제약 조건으로 구성되고 수학적으로 결합 확률 밀도 함수(joint probability density function)의 적분 형태인 한계 상태 함수(limit-state function)의 평가를 통하여 수행된다[3]. 이를 위하여 Monte Carlo Simulation이나 Reliability Index Approach (RIA)[4-6], Performance Measure Approach (PMA)[7-9], Approximate Moment Approach (AMA)[10]와 같은 방법이 이용되며, 안전지수(safety index)나 최대 가능점(Most Probable Point; MPP)을 탐색함으로써 불확실성에 의한 제약 조건의 위반을 방지하는 최적 설계가 가능하게 된다. 한편, 강건 최적설계는 주어진 최적화 문제에서 설계 변수와 제약 조건으로 이루어진 설계 파라미터의 불확실성이나 변동의 영향을 최소화하는 것을 그 목적으로 하고 있다[11,12]. 이와 같은 변동의 영향은 성능의 편차로 대표되며 이 값을 평가하기 위해서 통계적 방법을 이용하여 직접 산출하는 방법과 Taylor approximate를 이용하는 방법이 널리 알려져 있으며[12-19] 또한, 공리적 설계의 정보 지수 개념을 도입한 방법도 제안되었다[20]. 그런데 현재까지 수행된 여러 연구는 일반적으로 신뢰성과 강건성에 대하여 각각 수행하여 왔으며 이를 동시에 평가한 최적 설계는 단지 몇몇 경우만 알려져 있다. 이들 대부분은 방법론의 측면에서 수행된 것으로 실제 설계 문제에 적용한 예는 많이 보고되지 않았지만 최근 들어서 활발히 진행되고 있는 상황이다[8].

신뢰성이나 강건성 어느 하나에만 초점을 맞춰 최적 설계를 수행하는 경우 불확실성의 영향이 제대로 고려되었다고 말하기 어려운 경우가 존재한다. 가령 신뢰성만을 고려하는 경우 제약조건의 목표치는 만족시킬 수 있지만 제품의 성능 혹은 목적함수는 불확실성에 의한 영향에 민감하게 반응하여 제품의 역할을 제대로 수행하지 못할 수도 있다. 역으로 강건성만을 고려하여 최적 설

계를 수행하는 경우 제품의 성능은 강건해지지만 외란에 의하여 제약조건을 위반할 수도 있다.

따라서 본 연구에서는 신뢰성과 강건성에 대하여 이전에 제안된 방법들을 적용, 불확실성하에서 이들 둘을 동시에 고려한 최적 설계를 실제적인 문제에 적용하여 보고자 한다. 설계 과정에서 불확실성 요인은 제어 가능 인자(controllable factor)와 제어 불가능 인자(uncontrollable factor)로 나누었으며, 각각의 인자는 통계적으로 독립이고 정규 분포를 가진다고 가정하였다. 그리고 신뢰성과 강건성을 동시에 고려할 수 있는 최적 설계 방법으로 Monte Carlo Simulation과 인공신경망을 채택하였으며 이와 같은 조합이 어떤 이유로 타당한지에 대하여 논의하였다. 이를 바탕으로 공력-구조를 고려한 항공기 날개 문제에 신뢰성과 강건성을 동시에 고려한 설계 방법을 적용하였다. 이 예제에서 구하여진 결과를 통하여 불확실성을 고려하는 최적 설계 문제에서 요구되는 신뢰성을 만족하면서 강건한 해를 찾을 수 있는지 그 가능성과 타당성을 확인하였다.

II. 이론적 배경

2.1 불확실성을 고려한 최적설계

일반적으로 최적설계 문제는 목적 함수, $f(x,p)$ 와 제약조건, $g(x,p)$ 로 구성되어 있으며, 다음과 같이 정의된다.

$$\begin{aligned} \min. & f(x,p) \\ \text{s.t.} & g(x,p) \leq 0 \quad i = 1, \dots, m \\ & x_j^L \leq x_j \leq x_j^U \quad j = 1, \dots, n \end{aligned} \quad (1)$$

여기에서 x 는 설계변수 벡터, p 는 시스템 파라미터 벡터, m 과 n 은 각각 제약조건과 설계변수의 수, x^L 과 x^U 는 설계변수의 상한과 하한을 의미한다. 식 (1)을 불확실성하에서 신뢰성과 강건성을 모두 고려하는 최적 설계 문제로 변환하기 위해서는, 설계 변수(x)와 시스템 파라미터(p)는 서로 독립이며 정규 혹은 비정규 분포를 가지는 확률 변수(X)로 가정하게 된다. 이와 같은 가정으로 인하여 목적함수, $f(x,p)$ 역시 임의의 분포를 따르게 된다. 그러므로 강건 최적 설계(Robust Design Optimization)를 수행하기 위해서는 목적함수의 변동, 즉 목적함수의 편차가 최소화 되어야 하며 이와 더불어 목적함수의 평균값을 최소화하여야 한다. 한편 신뢰성 기반 최적 설계(Reliability-Based Design Optimization)를 위해서는 식 (1)의 제약조건을 한계 상태 함수(limit-state function; G)로 바꾸어 주어야 하며 G

함수가 0보다 작은 경우는 제약조건, $g(x,p)$ 을 위반하는 경우를 의미한다. 이를 확률의 형태로 표현하여 신뢰성을 평가하게 된다. 이를 바탕으로 본 연구에서 사용된 최적화 문제는 식(2)와 같다.

$$\begin{aligned} \min. F(X) &= (E[f(X)], \sigma[f(X)]) \\ \text{s.t. } P[G_i(X) \leq 0] &\leq p_i \quad i=1, \dots, m \end{aligned} \quad (2)$$

식 (2)의 목적함수 $F(X)$ 는 평균값($E[f(X)]$)과 편차($\sigma[f(X)]$)로 구성된 다목적 함수의 형태를 가지게 되며 편차가 최소화됨으로써 강건성을 보장하게 된다. 제약조건은 $g(x,p)$ 를 위반한 확률로 계산되며 설계 시 요구되는 실패확률(p)보다 작아야 된다는 조건이 부여되어 설계자가 원하는 신뢰성을 확보할 수 있다. 이들을 평가하기 위해서는 다음의 식(3)~(5)를 이용하여야 하는데 모두 확률 변수들에 대한 결합 확률 밀도 함수(joint probability density function)인 $f_X(X)$ 에 관한 형태를 취하고 있다.

$$E[f(X)] = \int f(X) \cdot f_X(X) dX = \mu \quad (3)$$

$$\sigma[f(X)] = \int \{f(X) - \mu\}^2 \cdot f_X(X) dX \quad (4)$$

$$P[G_i(X) \leq 0] = \int_{G_i(X) \leq 0} f_X(X) dX \quad (5)$$

$f_X(X)$ 는 외재적인 형태로는 알려져 있지 않으며 설사 알려져 있다고 하더라도 지수와 양함수의 복잡한 형태이기 때문에 이것을 정확하게 적분하는 것은 쉬운 일이 아니다. 이러한 까닭에 Taylor approximate를 이용하여 1차 혹은 2차로 식 (3)~(5)를 근사화하여 사용하는 해석적인 방법과 Monte Carlo Simulation과 같은 직접적인 방법이 사용된다. 해석적 방법의 경우 복잡한 적분식을 근사화함으로써 계산의 효율성은 증가하지만 해의 정확성을 보장하기 어려운 경우가 발생할 수 있으며 경우에 따라 이차 미분을 포함하는 Hessian 행렬의 계산으로 인하여 막대한 계산 비용이 요구될 수도 있다. 한편 직접적 방법의 경우 많은 수의 표본을 바탕으로 평균값, 편차 등을 계산하기 때문에 타당한 최적해(feasible solution)를 구할 수 있으며 문제의 복잡성에 관계없이 적용할 수 있지만 표본의 수가 아주 크기 때문에 많은 계산 비용을 요구한다[3,21,22].

본 연구에서는 신뢰성과 강건성을 동시에 평가하고 목적함수와 제약조건을 보다 정확하게 계산하기 위해서 직접적 방법인 Monte Carlo Simulation을 인공 신경망 모델에 적용하여 수행하였다. 앞서 언급하였듯이 근사 모델의 사용은 계산 비용의 문제를 개선하기 위해서 실제 해석

모델을 대신한 것이다. 따라서 large number theory에 의하여 식 (5)는 다음과 같이 추정할 수 있으며 식 (3), (4)도 유사한 방법으로 계산할 수 있다.

$$\begin{aligned} P[G_i(X) \leq 0] &= \int_{G_i(X) \leq 0} f_X(X) dX \\ &= \frac{1}{N_\infty} \sum_{k=1}^{N_\infty} I(X_k) \end{aligned} \quad (6)$$

$I(X_k)$ 는 하나의 표본이 제약조건을 만족하는가에 대한 여부를 나타내는 지표이며 식 (7)로 정의된다.

$$I(X_k) = \begin{cases} 1 & \text{if } G_i(X_k) \leq 0 \\ 0 & \text{if } G_i(X_k) > 0 \end{cases} \quad (7)$$

2.2 근사모델의 비교

공력해석이나 구조해석을 이용하여 최적설계를 수행하는 경우 Monte Carlo Simulation(MCS)의 적용은 매우 많은 수의 표본에 대한 평가를 수행하여야 하므로 막대한 비용이 요구된다. 그러므로 이와 같은 단점을 극복하기 위해서 해석 도구를 근사 모델로 대체하게 된다. 그런데 근사 모델의 형태와 특성이 매우 다양하기 때문에 MCS에 적절한 모델을 찾는 일은 매우 중요하다. 따라서 대표적인 근사 모델인 2차 다항회귀 모델(Polynomial Regression; PR) [23,24], 크리깅 모델(Kriging; KG) [25], 인공 신경망(Artificial Neural Network; ANN) [26,27]을 선택하여 이들의 특성을 정성적으로 비교, 검토하여 MCS와 같이 사용하기 적절한 근사 모델을 검토하였다 [27-32].

본 연구에서는 이들 세 가지 근사 모델의 특징을 그림 (1)에서 나타낸 것과 같이 반응의 신속성(rapid response), 비선형성(nonlinearity), 구성 효율(generating efficiency)의 세 가지 항목으로 평가하여 비교하였다. 첫째로 반응의 신속성(rapid response)이란 근사 모델이 구성된 후 표본에 대한 반응값을 얼마나 빨리 제공하는지를 나타낸다. PR과 ANN은 각각 2차 다항식과 행렬의 외재적인 형태로 구성되므로 빠르게 반응값을 계산하지만 KG는 새로운 input에 대한 반응값을 구할 때 모델을 매번 재구성하므로 PR이나 ANN에 비하여 신속하지 못하다. 다음으로 비선형성(nonlinearity)은 이들 모델이 설계 공간의 비선형성을 표현할 수 있는지를 의미한다. KG와 ANN은 실험점에 대하여 내삽(interpolation)으로 설계 공간을 모사하기 때문에 비선형성을 표현이 가능하지만 PR은 2차 다항식의 형태이므로 비선

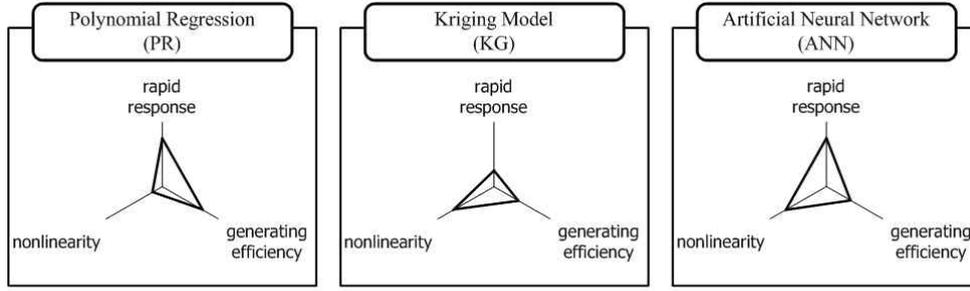


그림 1. 근사 모델의 비교

형성의 재현이 어렵다. 마지막으로 구성 효율 (generating efficiency)은 근사모델을 구성하는데 필요한 시간을 뜻한다. PR은 대수적인 방법을 통하여 모델이 구축되지만 KG나 ANN은 부최적화 과정을 거쳐야 모델이 만들어 진다. KG의 경우 최우량추정치(Maximum Likelihood Estimation)를 구하기 위하여, ANN은 각 뉴런(neuron)을 연결하는 시냅스(synapse)를 학습(learning)하기 위하여 simulated annealing이나 유전 알고리즘과 같은 전역 최적화 기법을 사용하기 때문에 PR보다 구성 효율이 떨어진다.

위와 같은 사실을 바탕으로 본 연구에 적당한 근사모델을 선정하기 위해서는 다음의 사항을 고려해야 한다. 우선 신뢰성과 강건성을 평가하기 위해서는 설계 공간의 비선형성을 제대로 모사할 수 있어야 하며 많은 수의 표본에 대하여 반응값을 제공해야 되기 때문에 신속하게 반응값이 계산되어야 한다. 따라서 이 조건을 모두 만족하는 ANN을 선정하였다.

III. 항공기 날개 최적 설계 결과

3.1 최적 설계 문제 정의

불확실성을 고려한 최적설계를 DC-9급 민간 항공기 날개에 적용하였다. 공력 및 구조 해석을 연동하였으며 각 해석은 vortex lattice method와 wing-box 모델을 사용하였다[33].

목적 함수는 항속 거리(Range)의 최대화이며 식 (8)의 Brequet 순항거리 방정식을 이용하였다.

$$Range = \frac{V}{SFC} \cdot \frac{L}{D} \cdot \ln\left(\frac{W_i}{W_f}\right) \quad (8)$$

여기서 V 는 순항속도, SFC (Specific Fuel Consumption)는 비연료소모율, L/D 는 양항비, W_i 는 항공기의 초기 중량, W_f 는 임무를 마친 후의 항공기 중량을 나타낸다. V , SFC , W_i 는 상수

값으로 가정하기 때문에 L/D 는 증가하고 W 는 감소해야 항속 거리가 최대화된다. 또한 W 를 감소시키기 위해서는 항공기 중량 중 연료중량(W_{fuel})의 비율을 더 늘리고 날개 중량(W_{wing})는 상대적으로 줄여야 한다. 이러한 까닭에 다음 3개의 제약조건을 선택하였다.

$$\begin{aligned} L/D &\geq L/D_{baseline} \\ W_{fuel} &\geq W_{fuel, baseline} \\ W_{wing} &\leq W_{wing, baseline} \end{aligned} \quad (9)$$

그리고 양력(Lift)은 이륙총중량(Take-off Gross Weight; $TOGW$)보다 커야 된다는 조건과 공탄성에 의한 날개 끝단의 변형량($d_{wing\ tip}$)은 baseline의 5%이내여야 한다는 2가지 제약조건을 추가하였다.

$$\begin{aligned} Lift &\geq TOGW \\ |d_{wing\ tip}| &\geq 0.05 \times d_{wing\ tip} \end{aligned} \quad (10)$$

또한 그림 2에 표현되어 있듯이 항공기 날개 형상을 나타내는 5개의 설계변수로 구성되어 있으며, 그 범위는 표 1에 정리하였다.

표 1. 항공기 날개 설계 문제의 설계 공간

Design Variables	min.	baseline	max.
semi-span(ft)	41.989	46.655	51.320
sweep angle(deg)	22.050	24.500	26.950
C30% span/Croot	0.685	0.761	0.837
taper ratio	0.184	0.204	0.224
incidence angle(deg)	-2.000	0.000	2.000

각 설계 변수의 초기값은 DC-9의 제원에 기초하여 결정하였고 비행조건은 마하수 0.75, 고도 25,000ft에서 순항할 때이며 받음각은 0도, 이륙총중량은 108,000lb로 선정하였다.

식 (8)~(10)에서 정의된 최적화 문제는 그림 3

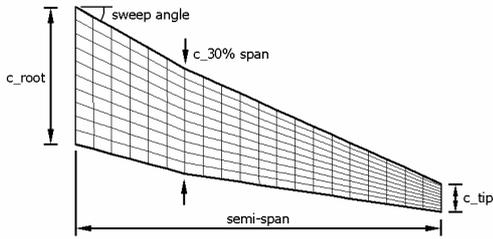


그림 2. 항공기 날개의 설계 변수

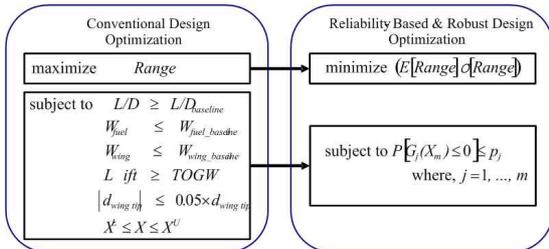


그림 3. 불확실성하에서 최적 설계 문제

과 같이 불확실성 하에서의 강건 최적 설계 문제로 변환하였다.

여기서 목적함수는 평균과 편차를 모두 고려해야 하므로 다목적 함수(multi-objective function)로 구성하였으며 순위 기반 유전 알고리즘(rank-based genetic algorithm)을 적용하였다. 이 과정에서 구하여진 파레토 최적해(Pareto Optimum) 가운데 적절한 값을 선택하는 것은 의사 결정의 문제이므로 본 연구에서는 특정 경우만을 선택하여 그 결과만을 다루었다. 제약조건은 2σ의 신뢰도에 해당하는 5% 실패확률을 허용하였다.

불확실성 요인은 제작상 발생할 수 있는 manufacturing uncertainty와 시스템을 운영하는 과정에서 발생할 수 있는 operating uncertainty로 두 가지로 분류하였으며 전자는 제어 가능 인자, 후자는 제어 불가능 인자에 속한다. 표 1에 나와 있는 5개의 형상 변수가 manufacturing uncertainty에 해당하며 이들은 설계 과정에서 직접 이용되며 설계자에 의해서 제어가 가능하다. operating uncertainty로는 조종 패턴이나 비행 시 외부 환경에 의하여 영향을 받는 순항속도를 선택하였고 평균(μ)은 마하수 0.75로 하였다. 이들 불확실성 요인들은 평균(μ)과 분산(σ²)을 가진 정규 확률 분포를 따르는 것으로 가정하였고 편차(σ)는 평균의 2%가 되도록 하였다.

3.2 신경망의 구축

이 설계 문제에서는 D-optimal 실험계획법으

로 66개의 실험점을 선택하여 인공 신경망의 학습(learning)에 이용하였으며, back-propagation 방법을 이용하여 입력층(input layer), 8개 노드를 가지는 은닉층(hidden layer), 항속 거리(Range), 양항비(L/D), 연료중량(W_{fuel}), 날개중량(W_{wing}), 양력(Lift), 날개 끝단의 변위(d_{wing tip})를 나타내는 출력층(output layer), 이와 같이 3개의 층으로 이루어진 신경망 모델을 구성하였다. 구성된 신경망을 검증하기 위해서, 앞서 선택한 66개의 실험점과는 다른 새로운 100개의 샘플을 이용, 분산분석(Analysis of Variance; ANOVA)을 통하여 R²와 Root Mean Square Error(RMSE)를 평가하였으며 그 결과를 표 2에 요약하였다. 모든 모델에 대하여 R²은 0.99 이상으로 1에 가깝고 RMSE는 0.016 이하이므로 구축된 신경망은 주어진 설계공간을 잘 모사하고 있고 신뢰성 있는 반응값을 제시할 수 있다고 판단된다. 또한 66개의 실험점으로도 신경망 모델의 충분한 학습이 가능하였기에 더 이상의 추가 해석은 수행하지 않았다. 이와 같이 충분한 수의 실험점으로 학습되고 분산분석을 통하여 근사 모델의 신뢰성이 검증된 신경망 모델은 정의된 설계 공간을 실제 해석 도구에 의해서 모사되는 것과 거의 비슷한 수준의 정확도를 유지하므로 이 신경망 모델과 Monte Carlo Simulation을 이용하여 신뢰성과 강건성을 평가하기에 적합하다.

표 2. 신경망 모델의 분산 분석 결과

	Range	L/D	W _{fuel}	W _{wing}	Lift	d _{wing tip}
RMSE	0.0136	0.0135	0.0095	0.0139	0.0152	0.0115
R ²	0.9985	0.9985	0.9993	0.9985	0.9982	0.9989

3.3 불확실성을 고려한 최적설계 결과

구성된 신경망 모델과 MCS를 이용하여 강건 최적 설계를 수행한 결과, 26개의 파레토 최적해를 찾을 수 있었으며 이를 그림 4에 도시하였다. 구하여진 최적해들 가운데 Range의 평균값이 1보다 작은 것들은 다른 해들에 비하여 편차가 작으므로 더 강건하다고는 말할 수 있지만 baseline의 Range보다 향상되지 못하였기 때문에 실제 최적 설계 예제에서 요구하는 최적해라고 판단하기는 어렵다. 한편 Range의 값이 향상되면 편차도 같이 증가하게 되어 강건성이 나빠지게 되고, 반대로 편차가 작아져 강건성이 좋아지면 Range의 값이 작아지므로, Range의 평균과 편차는 서로 상충하는 현상을 보이고 있어 적절한 trade-off가 필요하다. 이미 전술한 바와 같이 본 연구에서는

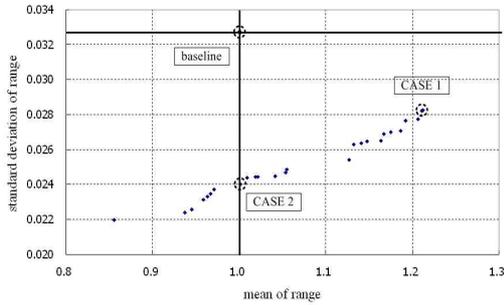


그림 4. 파레토 최적해 결과

불확실성을 고려하는 최적 설계 문제에서 요구되는 신뢰성을 만족하면서 강건한 해를 찾을 수 있는지 그 가능성을 조사하는 것이 목적이므로 다음 두 가지 경우에 대한 결과만을 제시하였다.

- Case 1 : 파레토 최적해 중 *Range*의 평균이 최대인 경우
- Case 2 : 파레토 최적해 중 *Range*의 평균이 baseline에 가장 가까운 경우

표 3은 baseline의 값, Case 1과 2의 최적화 결과, Deterministic Optimization(DO)의 결과를 정리한 것이다. DO의 sweep angle은 설계 공간의 하한에 존재하므로 불확실성의 영향으로 설계 공간에서 벗어날 수 있지만 Case 1과 2의 sweep angle은 불확실성에 의한 영향으로부터 안전한 영역에 위치하는 것을 확인할 수 있었다. 또한, DO의 연료 중량(W_{fuel}), 양력(*Lift*), 날개 끝단의 변위($d_{wing\ tip}$)는 제약조건의 경계 근처에 위치하지만, Case 1과 2에서 이들 값들은 안전한 영역에 있는 것 역시 확인할 수 있었다.

표 3. 최적화 결과 비교

Design Variables	Baseline	Case 1	Case 2	DO
Semi-span (ft)	46.655	47.939	45.479	47.927
Sweep angle (degree)	24.500	22.657	22.931	22.050
c/c_{root} at 30% span	0.761	0.737	0.704	0.747
Taper ratio	0.204	0.210	0.192	0.199
Incidence angle (degree)	0.000	1.082	0.883	1.187
Output Values	Baseline	Case 1	Case 2	DO
<i>L/D</i>	18.21	21.42	20.82	21.51
$W_{fuel}(lb)$	23,132	22,928	20,406	23,121
$W_{wing}(lb)$	10,002	7,634	7,342	7,303
<i>Lift</i> (lbf, $\times 10^6$)	2.603	1.849	1.864	1.776
$d_{wing\ tip}(ft)$	8.50	8.82	8.29	8.92
<i>Range</i> (nm)	1,659.3	2,004.2	1,662.6	2,045.4

표 4는 제약조건의 신뢰도를 나타내는 한계 상태 함수의 값을 보여주고 있으며 제약조건을 위반할 확률과 sigma level ($n\sigma$)을 정리하였다. DO의 연료 중량(44.4%, 0.77 σ), 양력(49.0%, 0.69 σ), 날개 끝단의 변위(45.4%, 0.75 σ)는 제약조건을 위반할 실패확률이 44%이상이므로 이들은 2 σ 의 신뢰도를 만족하지 못하고 있지만 이와는 대조적으로, Case 1과 2의 모든 제약조건은 5% 안에 있어 2 σ 의 신뢰도를 보장함을 확인하였다.

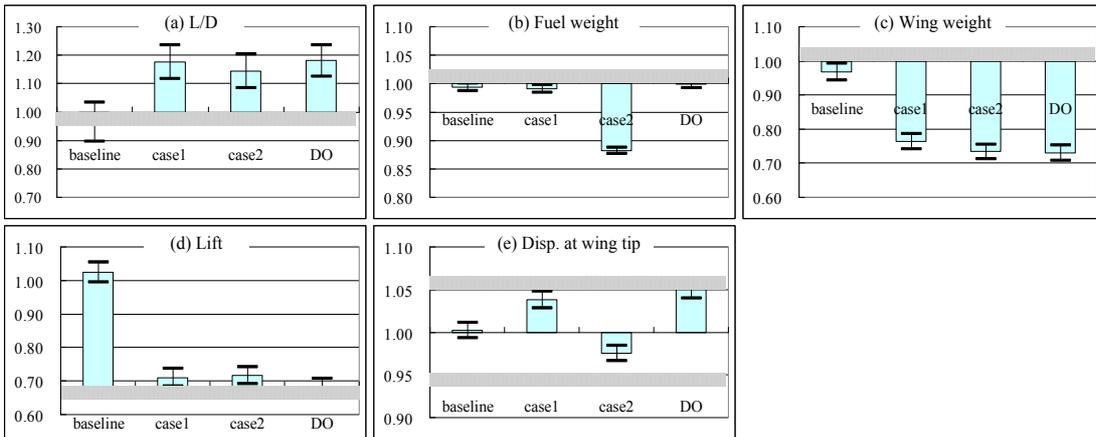


그림 5. 제약조건의 평균과 신뢰구간 (2 σ)

표 4. 제약조건의 실패 확률 및 신뢰도

Limit-state function	Baseline	Case 1	Case 2	DO
G ₁ <i>L/D</i>	85.2230% (0.19 σ)	0.0000% (6.12 σ)	0.0001% (4.98 σ)	0.0000% (6.67 σ)
G ₂ <i>W_{fuel}</i>	2.9373% (2.18 σ)	0.4125% (2.87 σ)	0.0000% (42.57 σ)	44.4016% (0.77 σ)
G ₃ <i>W_{wing}</i>	0.5704% (2.76 σ)	0.0000% (20.77 σ)	0.0000% (24.78 σ)	0.0000% (24.63 σ)
G ₄ <i>Lift</i>	0.0000% (23.25 σ)	1.4215% (2.45 σ)	0.2996% (2.79 σ)	49.0496% (0.69 σ)
G ₅ <i>d_{wing.tip}</i>	0.0000% (10.77 σ)	0.8420% (2.63 σ)	0.0000% (5.79 σ)	45.3785% (0.75 σ)

또한 제약 조건의 신뢰구간은 그림 5에 도시하였다. 수평축의 위치는 baseline의 제약조건 값과 교차한다. 가령 그림 5 (a)에서 제약조건 *L/D*는 baseline보다 큰 값이어야 하므로, 수평축은 수직축의 값이 1.00인 위치에 있게 된다. 빗금친 영역은 제약조건을 만족시키지 못하는 영역을 나타낸 것으로 2 σ 의 신뢰도를 가지기 위해서는 신뢰구간이 빗금친 영역과 겹치지 않아야 한다.

그림 6은 *Range*의 확률 밀도 함수를 나타낸 것으로 수평축은 정규화된 *Range*를 의미하며 수직축은 확률을 나타낸다. baseline의 확률 밀도 함수는 점선으로, Case 1과 2의 확률 밀도 함수는 실선으로 나타내었다. 그림 6 (a)에서는 2 σ 구간이 이동(shift)하고 줄어들었지만(shrink) (b)에서는 단지 줄어들기만 하였다. 표 5와 그림 6에

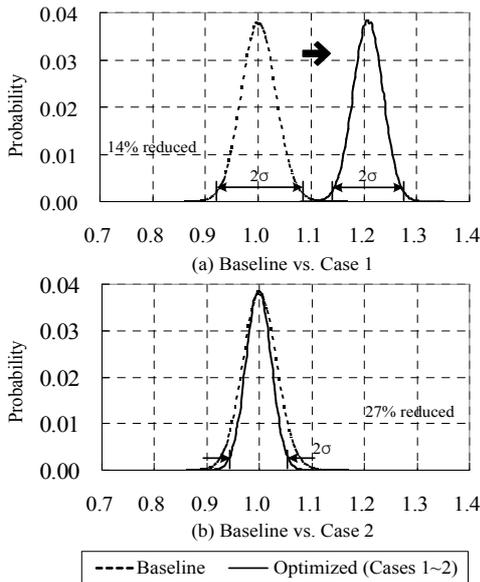


그림 6. 목적 함수 (*Range*)의 확률 밀도 함수

도시되어있는 바와 같이 Case 1에서 *Range*의 평균은 baseline에 비하여 약 21% 증가하였고 편차는 약 14% 감소하였으며 Case 2에서는 평균은 baseline과 거의 같고 편차는 27% 감소하였다.

표 5. 목적함수의 평균과 편차

Output Values	Baseline	Case 1	Case 2	DO
<i>Range</i> (E, σ)	(1.0008, 0.0327)	(1.2078, 0.0282)	(1.0018, 0.0242)	(1.2327, 0.0272)

즉, 편차의 감소는 baseline에 비하여 강건한 최적점을 구하였음을 의미한다. 한편, DO 결과에서는 평균이 향상되었고 표준편차가 감소하였기 때문에 최적점의 강건성은 확보를 하였다고 판단할 수 있지만 제약조건의 2 σ 신뢰도를 보장하지 못하기 때문에 신뢰성까지 확보하지 못하였다.

IV. 결론

본 연구에서 Monte Carlo Simulation(MCS)과 신경망 이론을 신뢰성 및 강건 최적 설계를 수행하기 위해서 도입하였고, 이 방법을 항공기 날개의 공력-구조 최적 설계에 적용하였다. 최적화된 결과를 통하여, 다음과 같은 결론을 내릴 수 있다.

첫째로, MCS와 신경망 이론을 적용한 방법이 신뢰성과 강건성을 계산하기 위한 최적 설계 알고리즘으로 적합하다. 이 방법을 이용하여 구한 Case 1과 2의 모든 제약조건은 2 σ 의 신뢰도를 만족하였고, 강건한 영역이 탐색되었다. Deterministic Optimization (DO)의 결과 또한 강건한 최적해를 제공하였지만 기본적으로 불확실성을 고려하지 않기 때문에 신뢰성을 확보하지는 못하였다. 둘째로, MCS를 이용하여 단지 한 번의 표본 추출로 신뢰성과 강건성을 동시에 평가할 수 있었다. 신뢰성과 강건성을 평가하기 위해서 신뢰성 및 강건 최적 설계에서는 주로 두 가지 방법을 각각 따로 적용하기 때문에 각각의 해석 도구를 요구한다. 그러나 이 연구에서는 MCS를 이용하여 각각의 평가 부분을 통합하는 것이 가능하였다. 셋째로, 신뢰성과 강건성 평가에 있어서 10⁶의 샘플에 대하여 해석을 수행하여야 하는 MCS의 많은 계산 비용은 신경망으로 구성된 근사 모델을 이용하여 대폭 줄일 수 있었다. 빠른 응답, 비선형성, 구성 효율의 세 가지 면에 대하여 2차 다항 회귀모델과 크리깅 모델, 신경망 모델을 비교, 검토를 통하여 MCS에 적합한 모델을 탐색하

고 선정할 수 있었다. 마지막으로, 본 연구에서 이용한 접근 방법은 다분야간 설계 최적화(Multidisciplinary Design Optimization; MDO)에 쉽게 적용될 수 있다. 이는 많은 계산 비용을 요구하는 해석 도구를 대신하여 근사 모델을 이용하기 때문이며, 또한 수학적 정식화가 단순하고 대부분의 설계 문제에 적용이 쉬운 MCS의 특징 때문이기도 하다. 따라서 이 접근 방법이 실제적이며 대규모의 문제들에 적용이 가능하다고 판단된다.

후 기

이 논문은 2006년도 2단계 두뇌한국21사업 및 한양대학교 최적설계신기술연구센터의 연구비 지원으로 수행되었으며, 연구에 도움을 주신 관계자 여러분께 감사드립니다.

참고문헌

1) Du, X. and Chen, W., "Collaborative Reliability Analysis under the Framework of Multidisciplinary Systems Design", *Optimization and Engineering*, Vol. 6, No. 1, 2005, pp. 63~84.

2) DeLaurentis, D. A. and Mavris, D. N., "Uncertainty Modeling and Management in Multidisciplinary Analysis and Synthesis", *Proceedings of 38th AIAA Aerospace Science Meeting and Exhibit*, 2000.

3) Grooteman, F. P., "Advanced Stochastic Method for Probabilistic Analysis", *Netherlands National Aerospace Laboratory Report, NRL-TP-99398*, 1999.

4) Hasofer, A. M. and Lind, N. C., "An Exact and Invariant First-Order Reliability Format", *ASCE Journal of Eng. Mech.*, Vol. 100, No. 1, 1974, pp. 111~121.

5) Rackwitz, R. and Fiessler, B., "Structural Reliability under Combined Random Load Sequences", *Computers and Structures*, Vol. 9, 1978, pp. 489~494.

6) Liu, P. L. and Der Kiureghian, A. "Optimization Algorithms for Structural Reliability", *Com. Prob. Mechanics*, ADM-93, ASME, 1988, pp. 185-196.

7) Youn, B. D., Choi, K. K. and Park, Y. H., "Hybrid Analysis Method for Reliability-Based

Design Optimization", *Journal of Mechanical Design*, Vol. 125, No. 2, 2003, pp. 221-232.

8) Youn, B., Choi, K. and Yi, K., "Performance Moment Integration (PMI) Method for Quality Assessment in Reliability-Based Robust Design Optimization", *Mechanics Based Design of Structures & Machines*, Vol. 33, Issue 2, 2005, pp. 185-213.

9) Tu, J. and Choi, K. K., "A New Study on Reliability-Based Design Optimization", *Journal of Mechanical Design*, Vol. 121, No. 4, 1999, pp. 557-564.

10) Putko, M. M., Newman, P. A., Taylor, A. C., III and Green, L. L., "Approach for Uncertainty Propagation and Robust Design in CFD using Sensitivity Derivatives", *Journal of Fluids Engineering*, Vol. 124, No. 1, 2002, pp. 60~69.

11) Taguchi, G., "Taguchi on Robust Technology Development", ASME Press, New York, 1993.

12) Phadke, M. S., "Quality Engineering using Robust Design", Prentice Hall, Englewood Cliffs, New Jersey, 1989, pp. 6~11.

13) d'Entremont, K. and Ragsdell, K. M., "Design for Latitude using TOPT", In *Advances in Design Automation*, ASME, New York, Vol. 14, 1988, pp. 265~272.

14) Chen, W., Allen, J. K., Tsui, K. L. and Mistree, F., "A Procedure for Robust Design: Minimizing Variations Caused by Noise Factors and Control Factors", *Journal of Mechanical Design*, Vol. 118, No. 4, 1996, pp. 478~485.

15) Sundaresan, S., Ishii, K. and Houser, D. P., "A Robust Optimization Procedure with Variations on Design Variables and Constraints", *Advances in Design Automation*, ASME DE-Vol. 69-1, 1993, pp. 379~386.

16) Mavris, D. V., Bandte, O. and DeLaurentis, D. A., "Robust Design Simulation: A Probabilistic Approach to Multidisciplinary Design", *Journal of Aircraft*, Vol. 36, No. 1, 1999, pp. 298-397.

17) Koch, P. N., Simpson, T. W., Allen, J. K. and Mistree F., "Statistical Approximation for Multidisciplinary Design Optimization: The Problem of Size", *Journal of Aircraft*, Vol. 36, No. 1, 1999, pp. 275~286.

18) Du, X. and Chen, W., "Efficient

Uncertainty Analysis Methods for Multidisciplinary Robust Design", AIAA Journal, Vol. 40, No. 3, 2002, pp. 545~552.

19) Jung, D. and Lee, B., "Development of an Efficient Optimization Technique for Robust Design by Approximating Probability Constraints", KSME journal A, Vol. 24, No. 12, 2000, pp. 3053~3060.

20) Hwang, K. and Park, G., "A New Information Index of Axiomatic Design for Robustness", KSME journal A, Vol. 26, No. 10, 2002, pp. 2073~2081.

21) Chen, W., Tsui, K. L., Allen J. K. and Mistree, F., "Integration of Response Surface Method with the Compromise Decision Support Problem in Developing a General Robust Design Procedure", Advances in Design Automation, ASME DE-Vol. 82-2, 1995, pp. 485~492.

22) Mavris, D. N., Bandte, O. and Schrage, D. P., "Economic Uncertainty Assessment of an HSCT using a Combined Design of Experiments/Monte Carlo Simulation Approach", 17th Annual Conference of the International Society of Parametric Analysis, San Diego, CA, June, 1995.

23) Myers, R. H. and Montgomery, D. C., "Response Surface Methodology: Process and Product Optimization using Designed Experiments", John Wiley & Sons, Inc., 1995.

24) Giunta, A. A., "Aircraft Multidisciplinary Design Optimization using Design of Experiment Theory and Response Surface Modeling Methods", PhD thesis, Virginia Polytechnic Institute and State University, 1997.

25) Simpson, T. W., "A Concept Exploration Method for Product Family Design", PhD thesis, Georgia Institute of Technology, 1998.

26) Freeman, J. A. and Skapura, D. M.,

"Neural Networks Algorithm, Applications, and Programming Techniques", Addison-Wesley Publishing Company, 1992.

27) Kim, Y., Ghim, Y., Lee, D. and Lee, D., "Application of Neural Network to Approximate design space", KSAS spring annual meeting, 2002.

28) Giunta, A. A. and Watson, T. L., "A Comparison of Approximation Modeling Techniques: Polynomial versus Interpolating Models", Proceedings of 7th AIAA/USAF/NASA/ISSMO Symposium on Multidisciplinary Analysis & Optimization, AIAA-98-4758, 1998.

29) Simpson, T. W., Mauery, T. M., Korte, J. J. and Mistree, F., "Comparison of Response Surface and Kriging Models for Multidisciplinary Design Optimization", Proceedings of 7th AIAA/USAF/NASA/ISSMO Symposium on Multidisciplinary Analysis & Optimization, AIAA-98-4755, 1998.

30) Jin, R., Chen, W. and Simpson, T. W., "Comparative Studies of Metamodeling Techniques under Multiple Modeling Criteria", Proceedings of the 8th AIAA/USAF/NASA/ISSMO Multidisciplinary Analysis & Optimization Symposium, AIAA-2000-4801, 2000.

31) Ku, Y., Jeon, Y., Kim, Y. and Lee, D., "Feasibility Improvement of Design Space Using Response Surface and Kriging Method", KSAS spring annual meeting, 2004.

32) Jeon, Y., Jun, S., Rho, J., Kim, J., Kim, J. and Lee, D., "A Study on Approximation Techniques for the Multidisciplinary Optimization", KSAS spring annual meeting, 2005.

33) Yoon, S., Ahn, J., and Lee, D., "Multidisciplinary Optimal Design of a Transport Wing Configuration", KSAS Journal, Vol. 27, No. 6, 1999, pp. 128~138.