

論文

천음속 영역의 조파항력 감소를 위한 효율적인 전역적 최적화 기법 연구

정성기*, 명노신**, 조태환**

An Efficient Global Optimization Method for Reducing the Wave Drag in Transonic Regime

Sung-Ki Jung*, Rho-Shin Myong** and Tae-Hwan Cho**

ABSTRACT

The use of evolutionary algorithm is limited in the field of aerodynamics, mainly because the population-based search algorithm requires excessive CPU time. In this paper a coupling method with adaptive range genetic algorithm for floating point and back-propagation neural network is proposed to efficiently obtain a converged solution. As a result, it is shown that a reduction of 14% and 33% respectively in wave drag and its consumed time can be achieved by the new method.

초 록

유전자 알고리즘은 공기역학적 최적 형상 설계를 위해 매우 유용한 도구임에도 불구하고 인구수 기반의 탐색 알고리즘이 내포하고 있는 과도한 계산 시간으로 말미암아 제한적으로 적용된다. 본 연구에서는 과도한 계산 시간을 줄이고 정확한 최적해를 유도하기 위해 근사모델인 역전파 신경망과 전역적 최적화 기법인 실수기반 적응영역 유전자 알고리즘을 결합한 하이브리드 기법을 제안한다. 그 결과 하이브리드 기법이 에어포일의 항력 및 최적화 계산 시간 측면에서 일반적인 유전자 알고리즘 대비 14%, 33% 향상된 결과를 나타내었다.

Key Words : Adaptive Range Genetic Algorithm(적응영역 유전자 알고리즘), Genetic Algorithm(유전자 알고리즘), Neural Network(신경회로망)

1. 서 론

최근 공기역학적 에어포일 형상 최적화는 많은 연구자들에 의해 수행되고 있는데, 일반적으로 두 단계로 분류할 수 있다. 첫 번째는 매개변수를 이용하여 에어포일의 형상을 결정하는 방법으로 NACA series, 천음속 영역에서 많이 이용되고 있는 PARSEC, Beizer curve 및 B-spline 등

이 이에 해당하며[1-4], 두 번째로 이러한 방법을 토대로 다양한 최적화 기법을 이용하여 최적의 형상을 결정하는 방법이다[5-11]. 최적화 기법은 확률론적 방법을 기반으로 한 전역적 최적화[5-7]와 경사도방법(Gradient-based methods)을 이용한 국소 최적화[8-11]로 대별되며 전자의 경우 전역적 최적해를 나타내나 상당히 많은 반복계산으로 복잡한 3차원 형상에 대한 공기역학적 형상 최적화는 제한적으로 적용된다. 반면 후자의 경우 빠른 수렴성과 반복계산의 횟수를 줄일 수 있는 장점이 있는 반면 전역적 최적해가 아닌 국소적 최적화의 한계를 지니고 있다.

본 연구에서는 천음속 영역에서 에어포일의 공기역학적 형상 최적화를 위해 매개변수 기반의

† 2008년 10월 20일 접수 ~ 2008년 2월 11일 심사완료

* 정회원, 경상대학교 기계항공공학부 대학원

** 정회원, 경상대학교 기계항공공학부 및 항공기부품기술연구소
교신저자, E-mail : thcho@gnu.ac.kr
경상남도 진주시 가좌동 900번지

PARSEC 기법[3]을 이용하였고, 전역적 최적화를 위해 실수 기반 적응영역 유전자 알고리즘[6]을 사용하였다. 실수 기반 적응영역 유전자 알고리즘(Adaptive Range Genetic Algorithm; 이하, ARGA)은 일반적인 유전자 알고리즘(Genetic Algorithm; 이하, GA)이 2진법으로 구성된 것에 반해 실수 기반으로 구성되며, 설계자에 의해 정해진 매 N번째에서 평균과 표준편차를 이용하여 자손 세대를 재구성하게 된다. 설계변수와 설계영역이 큰 경우 매우 큰 탐색영역을 가지는 2진법의 GA 대비 실수로 전환함으로써 GA의 단점을 극복할 수 있다. 또한 확률론적 최적화 알고리즘의 단점인 다수의 반복 계산을 줄이기 위해 근사 모델인 신경회로망을 이용하였다.

II. 본 론

2.1 적응영역 유전자 알고리즘: ARGA

ARGA는 Arakawa와 Hagiwara[7]에 의해 처음 제안되었으며, 2진법 기반으로 최적화를 진행하는 동안 가능성 있는 영역으로 인구를 적응시키는 것이 주된 개념이다. 가능성 있는 영역으로 인구를 적응시키기 위해서 인구 분포 선정시 정규분포에 따라 균등 분포를 통해 배열하며, 기존의 GA 대비 배열의 길이가 줄어들고 강건한 특성을 나타낸다. 그러나 이러한 방법은 GA의 확률론적인 방법과 대치되며 설계 변수가 정규분포에 따르므로 사전에 정의된 경계조건이 사라진다. 본 연구에서 사용된 실수 기반의 ARGA[6]는 Oyama, Obayashi 와 Nakamura에 의해 제안된 방법으로 다음 세대를 위한 인구 선정시 정규분포를 이용하되 난수를 생성하여 난수와 동일한 정규분포 함수의 적분 값을 이용한다. 이러한 방법은 2진법 기반의 ARGA에서 정규분포의 일정한 간격으로 다음세대를 결정했던 방법과 차별화한 방법으로 기존의 GA의 확률론적 방법과 일치하며 2진법으로 구성된 ARGA의 탐색 영역을 줄임과 동시에 기존의 GA의 확률론적 방법을 사용할 수 있는 장점이 있다. ARGA의 순서는 Fig. 1과 같다. 선택된 매 N번째 세대에서 자손 세대를 생성하기 위해 평균과 표준편차를 이용한 새로운 영역이 설정되며 그 외 과정은 GA와 동일한 방법으로 구성된다. 여기서 N은 전체 세대수에서 적응영역을 구성하기 위해 사용자에 의해 설정된 값을 의미한다. 예를 들어 N이 3이면 전체 세대수 중 3, 6, 9, ... 번째에서 적응영역을 구성하게 된다. 이러한 실수 기반의 ARGA는 확률

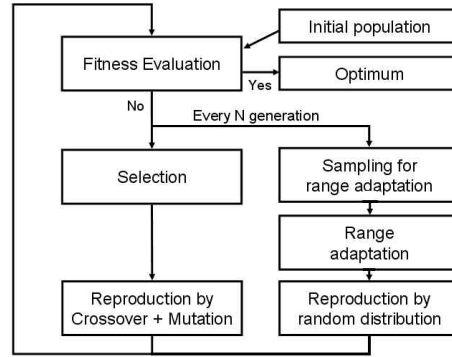


Fig. 1. Flowchart of ARGA for the floating points representation

론적 방법을 기반으로 다음 세대를 구성하기 위해 난수를 발생시키는데 난수의 범위는 수식 1과 같다.

$$0 \leq r_i \leq 1 \tag{1}$$

여기서 r_i 는 난수를 나타내며 정규분포의 적분값이 난수와 일치하는 pn_i 가 결정된다.

$$r_i = \int_{-\infty}^{pn_i} N(0,1)(z) dz \tag{2}$$

결정된 pn_i 를 통해 평균과 표준 편차를 이용하여 다음세대의 인구가 결정된다.

$$p_i = \sigma_i \cdot pn_i + \mu_i \tag{3}$$

여기서 평균 및 표준 편차는 수식 4와 같다.

$$\begin{aligned} \mu_{new} &= \mu_{present} + \omega_\mu (\mu_{sampling} - \mu_{present}) \\ \sigma_{new} &= \sigma_{present} + \omega_\sigma (\sigma_{sampling} - \sigma_{present}) \end{aligned} \tag{4}$$

수식 4에서 $\mu_{sampling}$ 과 $\sigma_{sampling}$ 는 상위 50% 이내의 설계점들에 대한 평균과 표준편차를 의미하며 $\mu_{present}$ 와 $\sigma_{present}$ 는 한 세대에서 인구수들에 대한 평균과 표준편차를 의미한다. 그리고 ω_μ 와 ω_σ 는 가중계수이며 본 연구에서 ARGA 기법을 이용한 최적화 코드를 개발하였다.




Fig. 2. Number pn_i selection

2.2 신경회로망

전역적 최적화 알고리즘인 ARGA의 수행시 세대수×인구수의 반복 계산이 요구된다. 전산 유체 해석을 이용한 최적화의 경우 다수의 계산시간이 요구되므로 직접적인 적용은 비용 및 시간 측면에서 어려움이 존재한다. 이러한 문제를 극복하기 위해 본 연구에서는 실수기반 ARGA와 신경회로망을 결합한, 효율적인 최적화를 수행하였다. 신경회로망은 입력층, 은닉층 및 출력층으로 구성되며 본 연구에 적용된 회로망은 일반적으로 널리 사용되는 역전파(Back-propagation) 신경회로망[12]을 사용하였다[Fig. 3].

역전파 신경회로망은 예측값의 강건성으로 많은 연구에서 사용되고 있으나 수렴에 도달하기까지 다수의 반복계산이 요구된다. 이러한 어려움을 극복하기 위해 입력층의 변수를 정규화(Normalization) 하였으며, 출력층의 값을 정규화와 전달함수를 이용하여 일정한 영역의 값으로 변환하였다.

$$\bar{p}^{i_L,j,k} = 2 \frac{p^{i_L,j,k} - p_{\min}^{i_L,j,k}}{p_{\max}^{i_L,j,k} - p_{\min}^{i_L,j,k}} - 1 \quad (5)$$

수식 (5)는 변수를 [-1, 1] 영역으로 정규화 한 것을 나타낸다. 이때 $p_{\min}^{i_L,j,k}$, $p_{\max}^{i_L,j,k}$ 는 선택된 세대수에서 설계 변수의 최소 및 최대값을 나타내며 i_L 는 선택된 세대수, j 는 인구수 및 k 는 설계 변수를 나타낸다. 수식 (6)은 결과값을 [0, 1] 영역으로 정규화한 것을 나타낸다.

$$\bar{F}^{i_L,j} = \frac{F^{i_L,j} - F_{\min}^{i_L,j}}{F_{\max}^{i_L,j} - F_{\min}^{i_L,j}} \quad (6)$$

여기서 $F_{\min}^{i_L,j}$, $F_{\max}^{i_L,j}$ 는 선택된 세대수에서 목적값의 최소 및 최대값을 나타낸다.

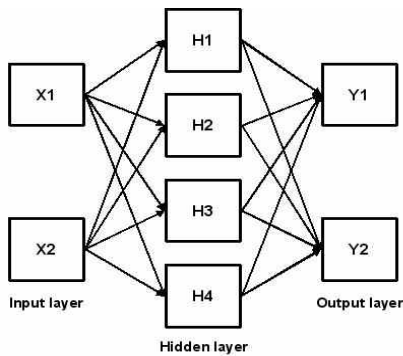


Fig. 3. Concept of neural network

$$F_T^{i_L,j} = \frac{1}{\sqrt{2\pi}} e^{-\bar{F}^{i_L,j)^2/2} \quad (7)$$

수식 (7)은 정규화한 목적값을 적당한 영역으로 전환하기 위해 전달함수로 표준정규분포 함수를 이용한 목적값의 변환을 나타낸다. 평균과 표준편차는 0와 1을 사용하였다. 위 수식을 이용한 신경망 구성을 통해 상당히 빠른 수렴성을 확인할 수 있었다.

2.3 하이브리드 기법 : ARGANN

하이브리드 기법(Adaptive Range Genetic Algorithm Neural Network; 이하, ARGANN)은 최적화 기법과 근사모델을 결합한 알고리즘으로 근사모델을 통한 반복계산의 감소를 유도할 수 있다. 이 경우 최적화 알고리즘과 연계한 방법은 주로 오프라인(Off-line)[10, 11]과 온라인(On-line)[13]으로 구분된다. 오프라인은 설계변수에 대한 적당한 표본 수를 선정하여 해석한 후 다양한 근사 기법을 활용하여 설계변수와 목적값의 관계를 모델링한 다음 최적화 알고리즘을 통해 최적화를 수행하는 방법이다. 온라인은 최적화 알고리즘을 통해 최적화를 수행하는 동시에 근사모델을 구축하여, 근사모델에 대한 적합도가 적절하면 근사 모델을 이용하여 최적화를 수행하는 방법이다. 두 기법은 각각 장단점이 있는데 전자의 경우 표본의 수를 사용자가 선택할 수 있으며 알고리즘 구성이 용이한 반면, 적합도를 만족시키기 위해 다수의 시행착오 및 근사모델을 통한 최적해와 실제 함수값에 대한 오차가 발생한다. 후자의 경우 알고리즘 구성이 전자에 비해 다소 복잡하며 적합도를 만족시키기 위해 지속적인 표본 추출 및 반복계산이 요구된다. 그러나 전자에 비해 적합도를 만족시키기 위한 시행착오가 적으며 근사모델을 통한 최적화 수행시 최적해와 실제 함수값의 오차가 전자에 비해 비교적 작은 특징이 있다. 본 연구에서는 후자의 개념을 활용하는 반면 오차를 제거하기 위해 적절한 적합도를 가지는 근사 모델을 통해 직접적인 최적해를 유도하는 것이 아닌 적응 영역으로 설계 변수를 분포시키는 것으로, 근사모델 사용시 대두되는 계산 결과의 오차를 완벽히 제거하였다. Fig. 4는 ARGANN에 대한 순서도를 나타낸다. ARGA의 적응영역은 매 N 번째에서 수행되는데 이때 N-1의 설계 변수가 적응영역을 구성하기 위해 사용된다. 본 연구에서는 ARGA의 기본 구조는 동일하게 사용하되 N-1의 설계 변수에 대한 계산 결과를 신경망을 통해 획득하는 알고리즘으로 Fig. 4의 신경망 시스템이 ARGA에 추가되었다.

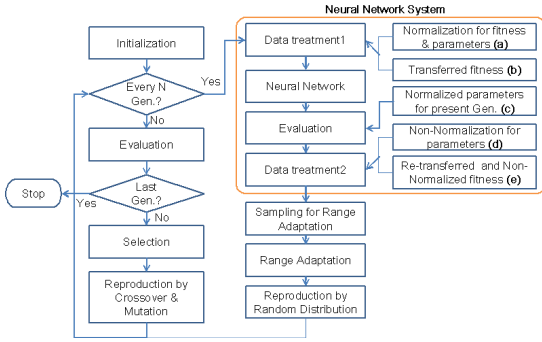


Fig. 4. Flowchart of ARGANN

Fig. 4의 우측에 있는 (a, b)는 수식 (5-7)를 의미하며 (c, d, e)는 수식 (8-10)을 의미한다. 수식 (8)은 현 세대에서 선택된 설계변수의 표본에 대한 정규화를 나타낸다.

$$\bar{p}^{i_p,j,k} = 2 \frac{p^{i_p,j,k} - p_{\min}^{i_p,j,k}}{p_{\max}^{i_p,j,k} - p_{\min}^{i_p,j,k}} - 1 \quad (8)$$

여기서 L 은 $[i-N+1, i-1]$ 를 나타내며 i_L, i_p 은 과거 및 현재 세대를 나타낸다. 현 세대에 대한 비정규화 과정은 수식(8)을 통해 역 계산 가능하다. 또한 현재 세대는 과거 세대의 최대 및 최소 값을 이용하여 정규화하며 이때 현 세대의 표본이 과거 세대의 표본 범위를 위반하지 않는다. 수식 (9)는 과거 세대를 통해 구성된 신경망에 수식 (8)을 통한 표본에 대한 결과값과 이에 대한 역 전달함수 값을 나타낸다.

$$\bar{F}_{NN}^{i_p,j} = \sqrt{-2 \ln(\sqrt{2\pi} F_{NN}^{i_p,j})} \quad (9)$$

여기서 $F_{NN}^{i_p,j} = \text{func.}(\bar{p}^{i_p,j,k})$ 이며 신경망 구성 후 현 세대의 인구에 대한 목적값의 위반을 방지하기 위해 구속조건이 적용되었다. 여기서 r 은 난수를 나타내며 r_c 는 계수이다.

$$F_{NN}^{i_p,j} = F_{NN}^{i_p,j} - r_c, \quad \text{if } F_{NN}^{i_p,j} > \frac{1}{\sqrt{2\pi}}$$

$$F_{NN}^{i_p,j} = 0 + r_c, \quad \text{if } F_{NN}^{i_p,j} < 0$$

Fig. 5는 신경망을 통한 모델링의 불용 영역, 즉 목적값의 위반을 방지하기 위해 정규화된 설계 변수의 표본, $\bar{p}^{i_p,j,k}$ 에 대한 전달함수, $F_{NN}^{i_p,j}$ 의 범위를 나타낸다.

수식 (10)은 신경망을 통해 획득한 목적값을 ARGAN에 적용하기 위한 비정규화 과정을 나타낸다.

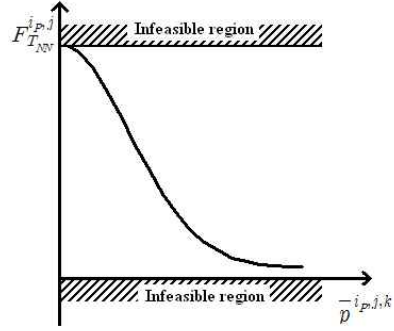


Fig. 5. Infeasible region of neural network evaluation

$$F_{NN}^{i_p,k} = \bar{F}_{NN}^{i_p,k} (F_{\max}^{i_L,k} - F_{\min}^{i_L,k}) + F_{\min}^{i_L,k} \quad (10)$$

Fig. 6은 ARGANN에 대한 성능을 점검하기 위해 실수 기반의 ARGAN 및 GA과 비교 결과를 나타낸다. 수식 11은 목적함수로서 최적화 알고리즘 개발시 예제가 되는 함수로, $x_i \in [-3, 3]$ 영역에 대한 실험 함수를 사용하였다.

$$F = \min \left(\sum_{i=1}^{20} (x_i^2 + 5 - 5 \cos(x_i \pi)) \right) \quad (11)$$

인구수 300, 세대수 150에 대해 GA, ARGAN과 ARGANN을 비교하였다. 다수의 실험을 통해 ARGAN과 ARGANN은 N이 3일 경우 성능이 가장 우수하였으며, 특히 ARGANN은 N의 설정에 따라 최대 50%에서 0%까지 효율이 결정되는데 N이 3일 경우 계산시간 대비 효율이 가장 우수한 것으로 나타났다. 또한 실수기반 ARGAN과 ARGANN은 정량적, 정성적으로 유사한 경향을 나타내었으며 GA 대비 보다 나은 최적해를 나타내었다.

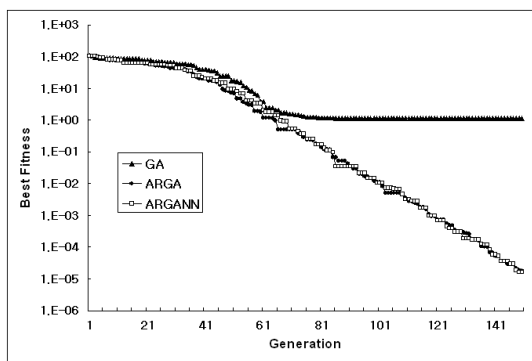


Fig. 6. Comparison of GA, ARGAN, and ARGANN

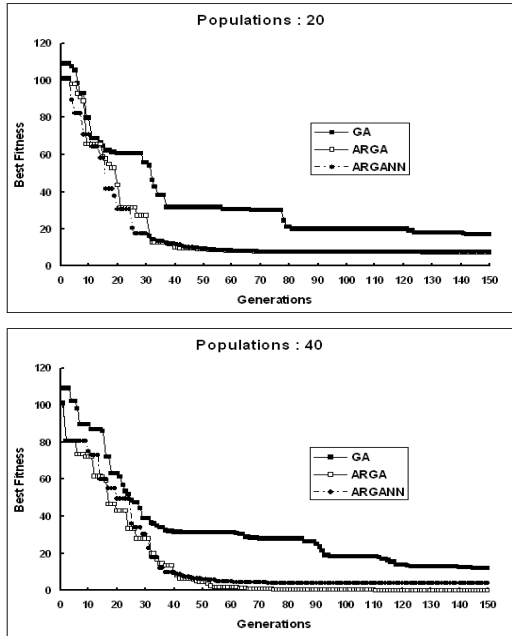


Fig. 7. Comparison of GA, ARGAN, and ARGANN in population




Fig. 8. Distribution of population between ARGAN and ARGANN

Fig. 7은 인구수의 변화에 따른 각 최적화 알고리즘의 비교 결과를 나타낸다. ARGANN의 특성상 ARGAN과 유사한 경향을 나타내나 인구수에 따라 다소 차이를 나타낸다. 이러한 원인은 Fig. 8에서 제시한 ARGANN의 특성으로 미루어 짐작할 수 있다. ARGAN은 전단계 세대의 결과를 통해 평균과 표준편차를 유추하며 정확한 해석해를 사용하는 반면 ARGANN은 신경망을 통해 획득한 결과값을 사용함으로써 정확해와 오차를 내포하고 있다. 이러한 오차는 인구 분포 선정시 ARGAN과 다소 차이가 있을 수 있는데 경우에 따라 보다 우수하거나($\delta 2$) 미숙한($\delta 1$) 인구를 선정할 수 있다. 이러한 오차는 GA에서 돌연변이와 같은 역할을 하며, Fig. 7의 위, 아래 그래프가 그 차이를 나타낸다. 하지만 인구수가 많을 경우 신경망의 정확도가 보다 개선되므로 ARGANN은 Fig. 6과 같은 ARGAN과 매우 일치하는 경향을 나타낸다.

III. 적용 및 해석결과 비교

3.1 설계점 선정

에어포일에 대한 공기역학적 형상 최적화를 위해 에어포일 형상에 대한 물리적 개념을 고려한 설계가 가능한 PARSEC 방법[3]을 사용하였다[Fig. 9].




Fig. 9. Parameterization of PARSEC method

$$Z = \sum_{n=1}^6 a_n X^{(n-0.5)} \tag{12}$$

PARSEC 방법의 매개변수는 총 11개이며 윗면과 아랫면에 6개씩 형상을 결정할 수 있는 변수들로 구성된다. 이때 앞전을 결정하는 r_{LE} 와 뒷전을 결정하는 β_{TE} , Z_{TE} 및 ΔZ_{TE} 는 중복 사용된다. 매개변수에 대한 에어포일 형상 함수는 수식 (12)이며 본 연구에서 Z_{TE} 와 ΔZ_{TE} 는 0으로 고정한 총 9개를 설계 변수로 선정하였다.

3.2 CFD 해석 및 격자 재생성

천음속 구간에서 공기역학적 에어포일 형상 최적화는 주로 조파항력의 감소에 집중된다. 그러므로 본 연구를 수행하기 위해 오일러 방정식을 사용하였다. 충격파를 보다 근접하게 모사하기 위해 대류항을 2차정확도 등으로 사용하였으며, 전산유체해석을 위해 상용프로그램인 FLUENT를 사용하였다. 또한 최적화 계산시 매번 요구되는 격자 재생성을 위해 TFI(TransFinite Interpolation)와 Spring analogy를 결합한 Hybrid 기법을 사용하여 에어포일 형상 변형에 대한 격자 재구성을 용이하게 하였다[13, 14].

3.3 계산 결과 및 분석

대륙간 비행하는 항공기는 주로 천음속 영역을 비행하는데 이 경우 충격파의 제어를 위해 다양한 연구가 수행되고 있다. 본 연구에서는 천음속 영역을 비행하는 항공기에 대한 비행조건을 고려하여 받음각 2.8도, 마하수는 0.75를 적용하였다. 양력을 일정 이상 유지하면서 항력을 감소하기위해 수식 (13)에 목적함수를 설정하였다. 목

적합수는 양력을 일정이상 유지하면서 항력을 최소화 할 수 있는 벌칙함수 개념을 적용하였으며 C_{L0} 을 0.9377로 설정하였는데 이는 마하수 0.75 및 받음각 2.8도 에서 RAE2822 에어포일에 대한 양력을 나타낸다.

$$F = \min(C_D + |\min(C_L - C_{L0}, 0)|) \quad (13)$$

Fig. 10은 각 기법에 대한 결과 비교를 나타낸다. 세대수 150, 세대 당 인구수는 20으로 설정하였으며 계산 결과 ARGANN과 ARGA가 GA 보다 우수하며 유사한 최적해를 나타내었다.




Fig. 10. Comparison of GA, ARGA, and ARGANN in convergence history

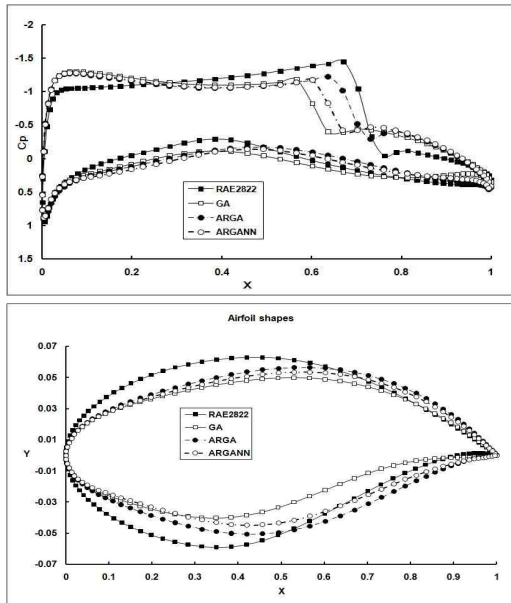


Fig. 11. Airfoil shapes and its pressure coefficient distributions of RAE2822, GA, ARGA, and ARGANN ($M = 0.75, \alpha = 2.8^\circ$)

Table 1. Aerodynamic coefficients and computing time of GA, ARGA, and ARGANN

	C_L	C_D	L/D	Time
RAE2822	0.9377	0.0339	27.65	-
GA	0.9382	0.0162	57.72	150hr
ARGA	0.9377	0.0137	68.43	150hr
ARGANN	0.9377	0.0140	66.72	100hr

Fig. 11은 RAE2822 에어포일과 최적화를 통해 획득한 설계변수에 대한 압력분포 및 에어포일 형상에 대한 비교를 나타낸다. 동일한 조건에서 비교 기준인 RAE2822 에어포일은 에어포일 코드 길이 기준 윗면의 약 75% 지점에서 충격파가 발생한 반면 GA는 약 60%, ARGA는 약 70%, ARGANN은 65%에서 충격파가 발생하였다. 또한 최적화 기법을 활용한 에어포일의 앞전에서 RAE2822 보다 압력이 크게 나타났으며 아랫면의 경우 형상 변화에 다소 둔감한 특성을 나타내었다. 동일한 조건에서 RAE2822은 에어포일 윗면에서 강력한 충격파를 발생하는 반면 최적화를 통한 에어포일 형상은 보다 미약한 충격파를 발생하였다. 또한 충격파의 위치와 에어포일 윗면의 최대 높이 위치의 상관관계를 미루어, 앞전을 기준으로 뒷전으로 에어포일 윗면의 최대위치가 이동 할수록 항력이 감소하는 경향을 나타내었다. 형상 변화에 따른 압력의 변화 측면에서 윗면 대비 아랫면이 둔감한 특성을 나타내는데 항력 측면에서 아랫면 형상에 대한 영향력을 보다 면밀히 분석하기 위해 점성력을 고려한 Navier-Stokes 방정식을 이용한 연구가 추가로 필요할 것으로 판단된다.

Table 1은 각 기법을 이용한 최적 에어포일 형상에 대한 양, 항력계수, 양항비 및 효율을 나타낸다. 본 연구에서 목적함수의 특성으로 미루어 가장 우수한 에어포일의 공기역학적 특성은 설정된 C_{L0} 와 동일한 양력을 발생하며 항력을 최소화 할 수 있는 에어포일이다. 각 최적화 기법을 통해 비교해 본 결과 실수기반 ARGANN과 ARGA은 C_{L0} 와 거의 동일한 양력을 나타내며 항력을 최소화 하였으나 GA의 경우 C_{L0} 보다 다소 높은 양력을 발생함으로써 최적해에 근접하기 위해서는 보다 많은 계산이 요구됨을 알 수 있다. 또한 본 연구의 기준이 된 RAE2822 에어포일 대비 ARGANN과 ARGA은 양항비 기준 약 2.5배의 성능향상을 나타냈으며 효율성 측면에서 N을 3으로 설정함으로써 ARGANN이 실수기반 ARGA보다 약 33% 우수한 특성을 나타내

었다. 본 연구를 통해 제안된 기법인 ARGANN이 일반적인 GA 대비 계산 시간 및 최적화 결과 우수함 특성을 나타내었으며 또한 ARGAN와 비교를 통해 최적화 결과는 정량적으로 근사한 반면 계산 시간 측면에서 보다 효율적인 결과를 나타내었다.

IV. 결 론

천음속 영역을 비행하는 항공기 날개의 형상 설계를 수행하기 전단계로 날개의 단면인 에어포일에 대한 공기역학적 최적 형상 설계를 수행하였다. 에어포일 설계기법 선정을 위해 물리적 개념을 고려한 PARSEC 방법을 적용하였으며, 9개의 설계변수를 사용하였다. ARGANN과 GA, ARGAN을 비교 분석한 결과, GA 대비 ARGANN 및 ARGAN이 보다 우수한 결과를 나타내었으며, 효율성 측면에서 ARGANN이 GA 및 ARGAN 대비 약 33% 우수한 특성을 나타내었다. 본 연구를 통해 ARGANN의 효율성을 확인하였으며, 향후 3차원 공기역학적 형상 설계 문제로 확장할 예정이다.

후 기

본 연구는 학술진흥재단 중점연구소 사업(과제 번호: KRF-2005-005-J09901) 및 방위사업청과 국방과학연구소(UD070041AD)의 지원에 의해 수행되었으며, 이에 감사드립니다.

참고문헌

- 1) 손명환, "Beizer 곡선을 이용한 천음속 날개 꼴의 형상 설계 최적화", 한국항공우주학회지, 제 28권 제 1호, 2000, pp. 29-35.
- 2) Sharokhi, A. and Jahangirian, A., "Airfoil Shape Parameterization for Optimum Navier-Stokes Design with Genetic Algorithm", Aerospace Science and Technology, Vol. 11, No. 6, 2007, pp. 443-450.
- 3) Sobieczky, H., "Parametric Airfoils and Wings", Notes on Numerical Fluid Mechanics, Vieweg, 1998, pp. 71-88.
- 4) Song, W. and Keane, A. J., "A Study of Shape Parameterisation Methods for Airfoil

Optimisation", Proceedings of the 10th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference, 2004.

- 5) Giannakoglou, K. C., "Desing of optimal aerodynamic shapes using stochastic optimization methods and computational intelligence", Progress in Aerospace Sciences, Vol. 38, No. 1, 2002, pp. 43-76.

- 6) Oyama, A., Obayashi, S. and Nakamura, T., "Real-Coded Adaptive Range Genetic Algorithm Applied to Transonic Wing Optimization", Applied Soft Computing, Vol. 1, No. 3, 2001, pp. 179-187.

- 7) Arakawa, M. and Hagiwara, I., "Development of Adaptive Real Range(ARRange) Genetic Algorithms", JSME Intl. J., Series C, Vol. 41, No. 4, 1998, pp. 969-977.

- 8) 성춘호, 권장혁, "Adjoint 방법을 이용한 공력 최적 설계기법에 대한 연구", 한국항공우주학회지, 제 26권 제 8호, 1998, pp. 1-10.

- 9) 이상욱, 권오준, "비정렬 격자계에서 Continuous Adjoint 방정식을 이용한 공력 형상 최적 설계", 한국항공우주학회지, 제 30권 제 4호, 2002, pp. 18-27.

- 10) 구요천, 전용희, 김유신, 이동호, "반응면 기법과 크리징 기법을 이용한 설계공간의 타당성 향상", 한국항공우주학회지, 제 33권 제 2호, 2005, pp. 32-38.

- 11) 김양준, 조창열, "반응표면법을 이용한 지면효과익기 익형의 공력 설계최적화", 한국항공우주학회지, 제 33권 제 5호, 2005, pp. 18-27.

- 12) Hagan, M. T., Demuth, H. B. and Beale, M., Neural Network Design, PWS Publishing Company 1995.

- 13) 김수환, 권장혁, 김진, "데이터베이스 기반 유전 알고리즘을 이용한 효율적인 에어포일 형상 최적화에 대한 연구", 한국마린엔지니어링학회지, 제 31권 제 1호, 2007, pp. 58-66.

- 14) 정성기, 두용안호양, 이영민, 이진희, 명노신, 조태환, "항공기 공력특성 예측을 위한 Navier-Stokes 방정식 기반의 정적 유체-구조 연계 해석 시스템", 한국항공우주학회지, 제 36권 제 6호, 2008, pp. 532-540.

- 15) 두용안호양, 이영민, 정성기, 누엔안티, 명노신, "복잡한 형상에 관한 삼차원 변형 Multi-Block 정렬격자 프로그램 개발", 한국전산유체공학회, 제 12권 제 4호, 2007, pp. 1-10.