

## 유전 알고리즘을 이용한 탈 설계 영역에서의 항공기용 가스터빈 엔진 결함 진단

용민철\* · 서동혁\* · 최동환\*\* · 노태성\*\*

### A Study on Defect Diagnostics of Gas-Turbine Engine on Off-Design Condition Using Genetic Algorithms

Minchul Yong\* · Donghyuck Seo\* · Dongwhan Choi\*\* · Taeseong Roh\*\*

#### ABSTRACT

In this study, the genetic algorithm has been used for the real-time defect diagnosis on the operation of the aircraft gas-turbine engine. The component elements of the gas-turbine engine for consideration of the performance deterioration is consist of the compressor, the gas generation turbine and the power turbine, repectively. Compared to the on-design point on the sea-level condition, the learning data has been increased 200 times in case of the off-design conditions for the altitude, the flight mach number and the fuel consumption. Therefore, enormous learning time has been required for the satisfied convergence. The optimum division has been proposed to decrease learning time as well as to obtain high accuracy. As results, the RMS errors of the defect diagnosis using the genetic algorithm have been estimated under 5 %.

#### 초 록

본 연구에서는 항공기용 가스터빈 엔진의 운용에 있어 실시간 결함 진단을 위해 유전 알고리즘을 사용하였다. 탈 설계 영역에서 성능 저하를 고려한 가스터빈 엔진의 구성요소는 압축기, 가스발생기 터빈, 동력 터빈이다. 지상정지 상태인 설계점에 비해 고도, 비행 마하수, 연료유량에 대한 탈 설계 진단의 경우 학습 데이터는 약 200배 이상으로 증가하였으며, 요구 수렴도를 만족시키기 위해 방대한 학습시간이 요구된다. 탈 설계 영역에서 단일결함에 관한 진단오차를 만족시키고 학습시간을 단축시키기 위해 최적분할을 사용하였고 그 결과, 오차범위 5% 이내로 진단됨을 확인하였다.

Key Words: Genetic Algorithms(유전 알고리즘), Performance Deterioration(성능저하), Learning(학습), Defect Diagnostics(결함 진단)

#### 1. 서 론

\* 학생회원 인하대학교 대학원 항공공학과 석사과정  
\*\* 정회원 인하대학교 항공우주공학과

항공기용 가스터빈 엔진의 실시간 성능진단에 관한 본 연구는 2002년도에 시작한 스마트 무인 기 개발사업과 관련하여 수행되고 있다. 스마트

무인기 비행체 개발규격서[1]에서 요구하는 PW206C 엔진을 대상 엔진으로 선정하여 결합 진단에 관해 연구하였다[2]. 본 연구에서는 항공 기용 가스터빈 엔진이 탈 설계 영역에서 운용되고 있을 때 엔진의 성능 저하 및 결합 진단을 위한 방법으로 유전 알고리즘을 사용하여 연구하였다. 엔진의 결합 진단을 위해 고려한 구성 요소는 압축기, 가스발생기 터빈, 동력 터빈이며, 그 밖의 다른 구성 요소에는 성능 저하가 없다고 가정하였다[3]. 설계점에서의 결합진단을 위한 학습량에 비해 탈 설계 영역에서의 학습의 경우 약 200배 이상으로 학습 데이터가 증가하므로, 효과적인 학습을 위한 최적분할 기법이 요구된다.

## 2. 본 론

### 2.1 유전 알고리즘

유전 알고리즘은 자연계의 진화과정을 모사하여 적합한 해를 탐색한다. 엔진 성능의 학습 및 진단에 유전 알고리즘을 사용할 경우, 학습 데이터 수와 알고리즘 처리 방법에 의해 학습시간 및 진단 정확성의 차이가 발생한다.

본 연구에서 유전 알고리즘을 사용하여 성능 진단을 할 때, 계산속도와 수렴성을 향상시키기 위해 Table.1 과 같은 변수를 사용하였다.

Table 1. Techniques of EHM Algorithm

Reproduction	Crossover	Mutation
Tournament (+ Elite Preserving)	1-Point	Adaptive

유전 알고리즘은 설계 집단을 사용하여 확률론적인 탐색을 하므로 같은 조건으로 계산을 수행하여도 매번 조금씩 다른 결과를 얻게 된다 [4]. 따라서, 유전 알고리즘의 신뢰성을 높이기 위해서는 반복계산을 수행하여 결과 값의 변화 범위를 확인하여야 한다. 본 연구에서 사용된 유전 알고리즘의 정확성과 신뢰성을 얻기 위해 각 Case마다 23번의 반복 계산을 수행하였고, 그때의 최대 오차 값을 해당 Case의 결합 오차 값으

로 사용하였다.

### 2.2 엔진 모델링

유전 알고리즘을 사용한 결합진단 프로그램을 만들기 위해 본 연구에서는 NLR사에서 개발한 GSP를 사용하여 데이터를 추출하였다. 이때 사용한 Map은 엔진 제조사에서 제공한 성능 Deck 을 사용하여 scaling 한 것으로 실제 엔진과 동일한 결과 값을 갖는다.

### 2.3 학습 및 오차계산

본 연구에서는 학습을 위한 유전 알고리즘 작성을 위해 압축기, 가스발생기 터빈, 동력터빈 전후의 온도와 압력으로 총 10개의 측정변수에 대하여 Eq. 1과 같은 5차 조합 적합함수를 사용하였다.

$$\begin{aligned}\eta_C &= C_{01} \cdot (\eta_c') + C_{02} \cdot (\eta_c')^2 + C_{03} \cdot (\eta_c')^3 + C_{04} \cdot (\eta_{gt}') + C_{05} \cdot (\eta_{pt}') \\ \eta_{GT} &= C_{06} \cdot (\eta_c') + C_{07} \cdot (\eta_{gt}') + C_{08} \cdot (\eta_{gt}')^2 + C_{09} \cdot (\eta_{gt}')^3 + C_{10} \cdot (\eta_{pt}') \\ \eta_{PT} &= C_{11} \cdot (\eta_c') + C_{12} \cdot (\eta_{gt}') + C_{13} \cdot (\eta_{pt}') + C_{14} \cdot (\eta_{pt}')^2 + C_{15} \cdot (\eta_{pt}')^3\end{aligned}\quad (1)$$

### 2.4 설계점에서의 단일 결합진단

설계점에서의 단일 결합진단을 수행한 결과, 결합 발생 위치를 100% 판단하였으며, 계산 시간을 고려한 최적의 학습량인 50 Set 의 학습조건에서 각 구성요소의 최대 결합오차율은 압축기 3.87%, 가스발생기터빈 0.10%, 동력터빈 0.58% 로 나타났다. 이를 토대로 탈 설계 영역에서의 단일결합에 대한 성능저하 및 결합 진단을 수행하도록 하였다.

### 2.5 탈 설계 영역에서의 단일 결합 학습

가스터빈 엔진은 설계점에서 뿐만 아니라 항공기의 운용 조건에 의해 다양한 탈 설계 영역에서의 운용 능력을 필요로 한다. 따라서 엔진의 상태에 가장 민감하게 영향을 주는 고도, 비행 마하수, 연료유량에 대해 결합진단을 위한 학습을 수행하였다. 각 범위에 대해 동일한 구간으로 등분하여 학습하였으며, 학습된 단계에서 사용되는 학습 데이터의 구간과 명칭에 대한 정의는 Table.2와 같다.

Table 2. Off-Design Parameter

Parameter	Min ~ Max	Name
Altitude (m)	0 ~ 5,000	Pack
Mach No.	0 ~ 0.5	Flock
Fuel Flow (kg/s)	0.0307 ~ 0.0457	Group

탈 설계 영역에서의 학습을 위해 항공기의 운용조건을 설정하였고, Table.3과 같은 구간으로 나누어 학습하였다.

Table 3. Definition of Learning Data No.

Parameter	Data No. (EA)					
Altitude	2	3	6	11	21	41
Mach No.	2	3	6	11	21	
Fuel Flow	2	3	6	11		

이는 고도, 비행 마하수, 연료유량에 대한 학습 Case 수를 나타내는 것으로, 각각의 탈 설계 영역의 조건과 가스터빈 엔진의 민감도를 고려하여 구간의 수를 선정하도록 하였다. 예를 들어, 고도에 대한 학습 데이터 구간 수가 11Pack, 비행 마하수는 6Flock, 연료유량은 3Group 일 때 전체 학습량의 수는  $50 \times 11 \times 6 \times 3$  으로 총 9900 Set로 결정되어진다. 이것은 각 조건에서의 구간수가 증가하면, 학습량은 그 배수로 증가하게 된다는 것을 의미한다. 따라서 앞으로의 연구 내용은 계산시간을 고려한 효율성을 유지하면서 각 단계에 대한 최적의 학습데이터를 구하는 것이 그 목적이다.

## 2.6 탈 설계 영역의 최적분할

설계점에서의 경우, 항공기용 가스터빈 엔진의 경우 지상정지 조건에서 학습으로 진단이 가능하다. 하지만, 탈 설계 영역의 경우 엔진에 민감한 영향을 주는 고도, 비행 마하수, 연료유량에 대해 모든 조건에서 결합량을 학습해야 하므로 결합진단에 방대한 학습량이 요구된다. Table.4 는 고도에 대한 학습 구간 수에 따른 최대 오차와 수렴시간의 비교를 나타낸 것이다.

Table 4. Maximum RMS Error of Altitude No.

Data No. (EA)	Max. Error (%)	Run Time (min)
On Design Point	3.873	413
2	25.941	549
3	25.099	584
6	7.968	682
11	6.374	1056
21	5.092	1134
41	3.149	1829

학습 구간 수를 증가시키면 오차가 감소하지만, 수렴시까지 방대한 계산시간이 요구됨을 알 수 있다. 본 연구에서는 고도 변화에 따른 결합진단을 위한 학습 시, 계산시간의 효율성과 결합진단의 정확성을 동시에 만족 할 수 있는 최적의 학습 구간 수로 21Pack을 결정하였다. 같은 방법으로 비행마하수와 연료유량의 학습 구간 수에 대한 최대 오차를 Fig. 1, 2에 나타내었다.

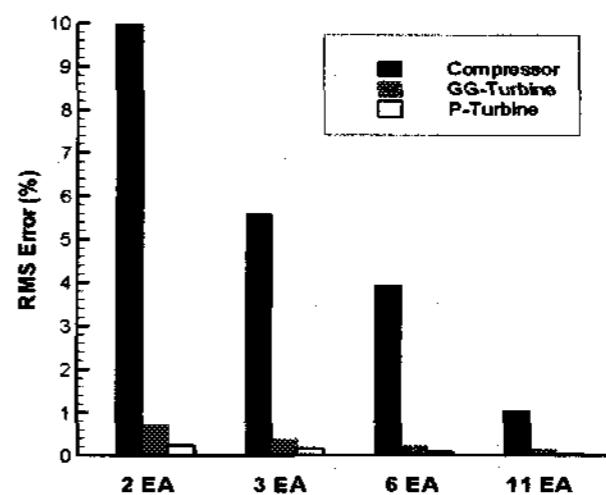


Fig. 1 RMS Error for Data Number of Flight Mach Number.

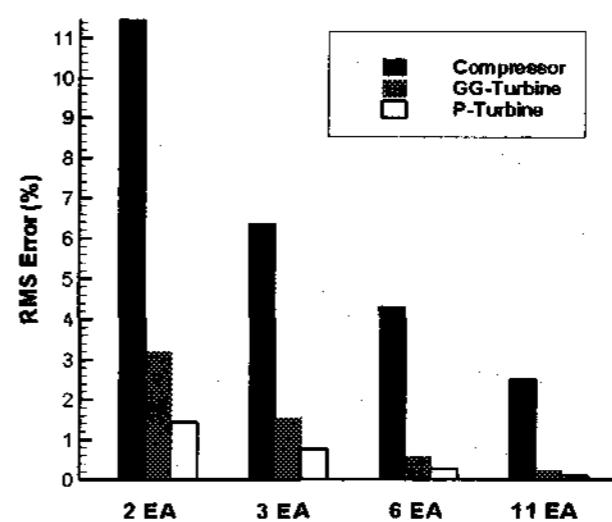


Fig. 2 Maximum RMS Error for Data Number of Fuel Flow Rate.

학습 단계에서의 오차를 분석한 결과, 비행 마하수와 연료유량에 대한 최적의 학습 구간 수는 각각 6Flock, 11Group로 나타났다.

## 2.7 탈 설계 영역에서의 단일 결합 진단

학습데이터 수를 변화시키면서 임의의 조건과 결합량에 따른 성능 진단을 수행하였다. 본 연구에서는 고도, 비행 마하수, 연료유량에 대한 구간의 수를 변화시키며 학습하였고, 학습되지 않은 탈설계 영역조건에 대하여 진단하였다. Figure 3, 4, 5는 탈 설계 영역의 최적 진단이 가능한 21Pack, 6Flock, 그리고 11Group 조건의 결과로 3,000m와 3,250m 사이의 고도에서 결합진단 결과를 각 구성요소에 대하여 나타낸 것이다. 결합진단 예측 결과를 보면 학습되지 않는 임의의 고도에 대한 최대 결합오차율은 각 구성요소에 대하여 각각 5.09%, 0.12%, 0.79% 으로 나타났다.

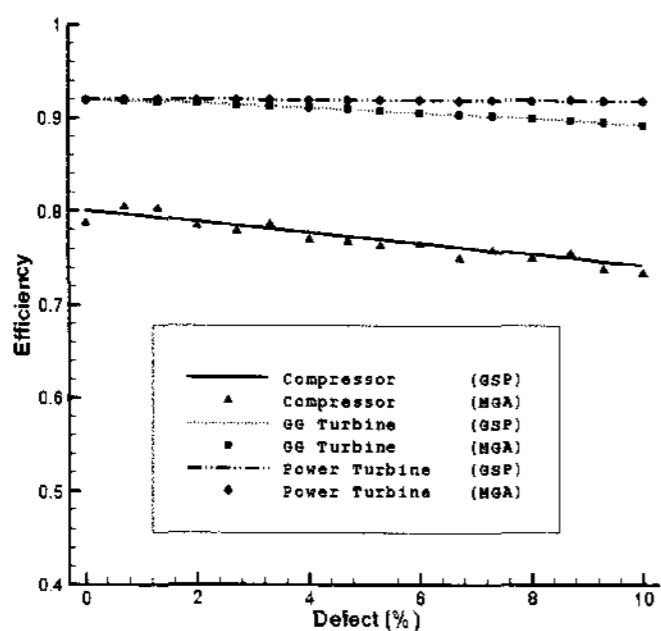


Fig. 3 Performance Estimation for Compressor Defected

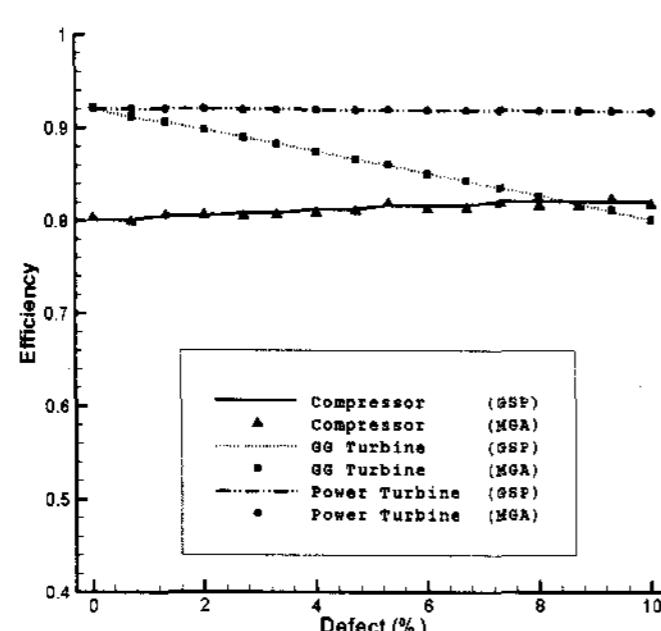


Fig. 4 Performance Estimation for GG - Turbine Defected

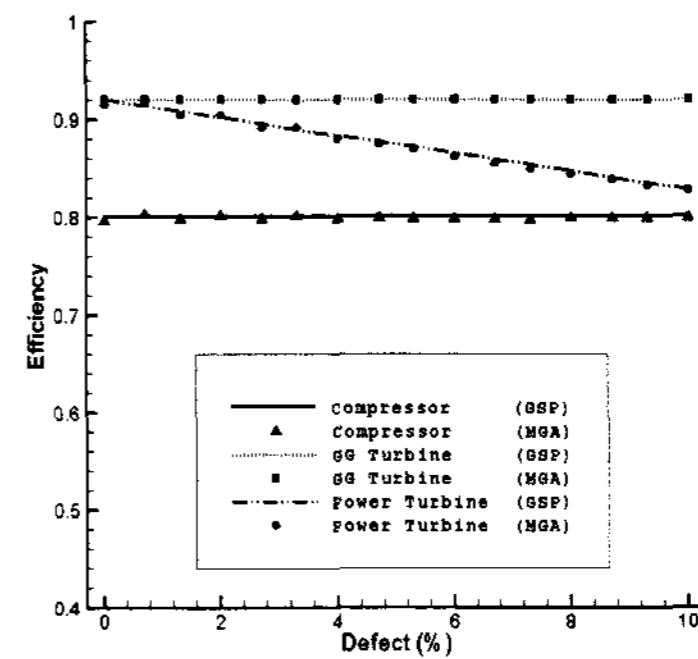


Fig. 5 Performance Estimation for Power Turbine Defected

## 3. 결 론

본 연구에서는 대상 엔진 PW206C의 탈설계 영역에 대한 결합 학습 및 진단을 최적분할 기법을 적용한 유전 알고리즘을 사용하여 수행하였다. 하나의 탈설계점에서의 학습 데이터는 50 Set, 고도 조건의 수는 21Pack, 비행 마하수 조건은 6Flock, 그리고 연료유량 조건은 11Group 이었을 때, 계산시간의 효율성과 정확성을 동시에 얻을 수 있었다. 이 때, 각 구성요소의 결합 진단에 대한 RMS 오차율은 각각 5.09%, 0.12%, 0.79%의 값을 얻었으며, 전체 학습 데이터 수는 69300 Set이다.

## 참 고 문 헌

1. 전용빈, "스마트무인기 후보엔진 기술검토", 한국추진공학회지 10권 1호, 2006, pp.64~71
2. 박준철, "스마트무인항공기용 터보축엔진의 동적 성능과 응답성에 관한 연구", 한국추진 공학회지 2005, 9권 2호, pp.17~24
3. 정석우, "진화 시스템을 위한 유전자 알고리즘 프로세서의 구현", 전기학회논문집, 53권 4호, 2004
4. Mark Juric, "Optimizing Genetic Algorithm Parameters Fault Diagnosis Applications", Artificial Intelligence Programs, 1994