

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 consist of the compressor, the gas generation turbine and the power turbine. Compared to the on-design point, the learning data has been increased 200 times in case of 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 optimal division has been proposed for learning time decrease as well as the high accuracy. As results, the RMS errors of the defect diagnosis using the genetic algorithm have been confirmed under 5 %.

초 록

본 연구는 운용중인 항공기의 가스터빈엔진을 유전 알고리즘을 이용한 실시간 결합진단을 통해 엔진 운용의 안정성과 신뢰성을 확보하는 것이 목적이다. 대상엔진인 터보샤프트엔진의 구성품 중 성능 저하는 압축기, 가스발생기 터빈, 동력 터빈 중 한 구성품에서만 발생한다고 가정하였다. 설계점에 비해 탈 설계영역에서의 학습 데이터는 약 200배 이상으로 증가하였으며, 따라서 요구 수렴도를 만족시키기 위한 방대한 학습시간이 요구된다. 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(결합 진단), Off-Design Condition(탈 설계 조건)

* 2007년 12월 11일 접수 ~ 2008년 5월 10일 심사완료

* 학생회원, 인하대학교 대학원 항공공학과

** 정회원, 인하대학교 항공우주공학과

*** 종신회원, 인하대학교 항공우주공학과

연락처자, E-mail: goodman0222@naver.com

1. 서 론

가스터빈엔진은 항공, 선박 뿐 아니라 기계 및

발전 설비에서도 사용될 정도로 그 사용분야가 넓어지고 또한 그 규모도 커지고 있다. 가스터빈 엔진은 항공, 기계, 전자, 전기 등 다양한 분야의 기술이 집약된 시스템이다. 그러므로 그 제작도 중요하지만 운용상의 안정성을 높이는 일 또한 중요하다. 이와 같은 이유로 최근에 와서는 엔진의 성능을 진단하는 연구가 활발히 진행되고 있다.[1~3] 특히, 항공기는 다른 많은 운송수단과는 달리 지상에서 이륙하여 운용된다. 따라서 한번 이륙하게 되면 중간점검 및 정비가 불가능하여, 항공기의 운용이 끝날 때 까지 높은 신뢰성이 요구된다. 효율적인 가스터빈엔진의 사용을 위해서는 과도한 수리와 교체가 가급적 자주 일어나지 않아야 하고 급속한 성능 저하가 일어나지 않는 범위 내에서 엔진 정비가 이루어지는 것을 요구한다[4].

유전 알고리즘은 국내·외에서 주로 구조와 제어분야의 최적화 문제를 푸는 목적으로 사용되고 있다. 최근 대두되고 있는 고장진단 분야에서는 유전 알고리즘의 특징인 수렴 시간과 수렴 값의 오차에 대한 논제와 그 가능성 여부만이 논의되어 왔다.[1~3] 특히, 국내에서는 고장진단을 위해 우선 연구되어야 할 엔진 성능 선도를 유전알고리즘을 이용해 생성하는 방법이 연구되었다.[11~13] 그리고 유전 알고리즘을 이용한 설계점에서의 고장진단도 연구되었다.[14] 본 연구는 항공기용 가스터빈엔진이 탈 설계 영역에서 운용되고 있을 때, 엔진의 결합 위치 판단 및 결합량 진단을 위한 방법으로 유전 알고리즘을 사용하여 연구하였다.

가스터빈엔진의 결합 진단을 위해 고려한 구성 요소는 압축기, 가스발생기 터빈, 동력 터빈이며, 그 밖의 구성 요소에는 성능 저하가 없다고 가정하였다[2].

설계점에서의 결합진단을 위한 학습량에 비해 탈 설계 영역에서의 경우 약 200배 이상으로 학습 데이터가 증가하므로, 방대한 학습시간과 요구정확도를 고려한 효과적인 학습조건을 필요로 한다. 이에 본 논문에서는 이를 위해 최적분할 기법을 제안하였다.

2. 대상 엔진의 성능모사

2.1 대상 엔진의 모델링

스마트무인기 개발사업과 관련하여 실시되고 있는 본 연구의 성격에 맞추어 연구 대상 엔진으로는 소형 터보사프트엔진을 선정하였다. 선정된 엔진 대상은 스마트무인기 비행체 개발규격서[3]에서 요구하는 요구사항을 모두 만족시키는 P&W사의 206C엔진을 대상 엔진으로 선정하여 연구하였다[5].

가스터빈엔진의 결합 진단은 실제 운용중인 엔진으로부터 얻은 측정값들을 이용하여 엔진의 각 구성요소에 발생한 결합량을 예측하는 기법이다. 그러나 실제 엔진을 이용하여 모든 조건에서의 측정값을 얻는 것은 현실적으로 어려우므로 대상 엔진과 동일한 결과를 얻을 수 있는 가상엔진모델을 구성하여 필요한 데이터를 추출하여 사용하여야 한다. 가상엔진모델을 구성하는 도구로서 네덜란드 NLR사에서 개발된 Gas Turbine Simulation Program (GSP)이 사용되었다. GSP에서 대상엔진을 기본으로 제공하지 않기 때문에 P&W사에서 제공한 성능테 프로그램에서 얻은 데이터를 이용하여 GSP 프로그램 내에서 제공하는 터보 축 엔진의 구성품 성능맵을 재구성하여 사용하였다[5].

2.2 측정 변수

가스터빈엔진으로부터 얻을 수 있는 측정변수의 값으로는 압축기 및 터빈의 회전수, 각 구성요소 전후의 전온도 및 전압력 등이 있으며 본 연구에서는 Table 1과 같이 총 7개의 측정변수를 사용하였다.

터빈입구 전압력은 피토관으로 측정할 시 연소가스에 내재되어 있는 불완전연소 및 윤활유에 의한 이물질 등이 센서에 흡착하게 되어 측정이 매우 곤란한 것으로 알려져 있다. 반면에 터빈입구온도는 측정가능 온도영역이 -20°C ~ 1200°C 인 고온용 열전도계(니켈-크로뮴, 온도오차 2.2°C , 오차범위 2%이내)를 사용하여 측정이 가능하며 실제 엔진에 장착되어 있다. 본

대상엔진 PW206C 엔진의 최대 터빈입구온도는 약 800°C 전후로 알려져 있다. 이와 같은 이유로 GSP를 통해 추출한 데이터 중 압축기의 압력은 유전알고리즘의 학습데이터로 고려한 반면 가스발생기 터빈과 동력 터빈 전후의 압력은 고려하지 않았다.

Table 1. Sensed Parameters

Description	Parameter
Compressor Inlet Temperature	T_a
Compressor Inlet Pressure	P_a
Compressor Outlet Temperature	T_b
Compressor Outlet Pressure	P_b
Gas Generator Turbine (G. G. Turbine) Inlet Temperature	T_u
G. G. Turbine Outlet Temperature (= Power Turbine Inlet Temperature)	T_v
Power Turbine Outlet Temperature	T_w

2.3 독립변수

엔진 구성품에 결함이 발생하였을 경우 전후 온도비 및 압력비는 결함량에 비례하여 증가 혹은 감소하게 된다. 따라서 측정된 변수 값들을 사용하여 공식 (1), (2), (3), (4)와 같은 4개의 무차원화 된 독립변수를 만들 수 있다.

$$\tau_c = \frac{T_{t3}}{T_{t2}}, T_c = \frac{\tau_c}{\tau_{c, \text{normal}}} \quad (1)$$

$$\pi_c = \frac{P_{t3}}{P_{t2}}, \Pi_c = \frac{\pi_c}{\pi_{c, \text{normal}}} \quad (2)$$

$$\tau_{ggt} = \frac{T_{t5}}{T_{t4}}, T_{ggt} = \frac{\tau_{ggt}}{\tau_{ggt, \text{normal}}} \quad (3)$$

$$\tau_{pt} = \frac{T_{t6}}{T_{t5}}, T_{pt} = \frac{\tau_{pt}}{\tau_{pt, \text{normal}}} \quad (4)$$

위의 식에서 아래첨자 c , ggt , pt 는 각각 압축기, 가스발생기 터빈, 동력 터빈을 나타내는 것이다. T 와 Π 는 온도비와 압력비를 무차원화 시킨 값으로 결함이 없는 상태의 값이 이 되도록 한다. 무차원화 된 온도비와 압력비는 고장진단 알고리즘의 입력값으로 사용되어 엔진의 성

능변수를 예측하도록 하였다.

2.4 성능변수

엔진 구성요소에 결함이 발생하였을 때, 각 구성요소에 발생한 결함량은 해당 효율의 저하량으로 나타난다. 따라서 고장진단 알고리즘의 결과값이 될 성능변수로 각 구성요소의 효율을 사용하였다. 본 논문에서 사용되는 고장진단 알고리즘은 측정변수로만 구성된 독립변수를 통해 성능 변수를 구하는 것이다. 이를 위해서 유전 알고리즘을 이용한 학습을 통해 독립변수와 성능변수 사이의 관계식을 도출하여야 한다.

3. 유전 알고리즘을 사용한 학습

3.1 유전 알고리즘

유전 알고리즘은 자연계의 진화과정을 모사하여 적합한 해를 탐색한다. 집단 내에서 주어진 환경에 대한 적합도(Fitness)가 높은 개체의 유전자가 높은 확률로써 살아남도록 하는 재생산(Reproduction) 기법, 교배(Crossover) 및 돌연변이(Mutation) 등의 연산을 거쳐 다음 세대의 새로운 자손(Offspring)을 인공적으로 만들어내는 과정을 통해 적합한 해를 탐색하는 것이다[4].

일반적으로는 최적한 해를 탐색할 경우 단순 유전알고리즘을 많이 사용한다. 하지만 단순 유전 알고리즘은 한 세대에 많은 개체수를 이용하여 해를 탐색하기 때문에 계산 시 수렴속도가 느린다. 따라서 본 논문에서는 한 세대의 개체수를 30개 이하로 줄이고, 개체 간 형질 변이가 가능하게 하여 정확성을 유지하면서 수렴속도를 증가시킨 마이크로 유전 알고리즘을 사용하여 결함량을 진단하였으며, 이때 사용한 알고리즘의 계산속도와 수렴성을 향상시키고, 정확성을 높이기 위해 Table 2와 같은 변수를 사용하였다.

유전 알고리즘은 데이터 집단을 사용하여 확률론적인 탐색을 하므로 같은 조건으로 계산을 수행하여도 매번 조금씩 다른 결과를 얻게 된다 [5]. 따라서 유전 알고리즘의 신뢰성을 높이기

위해서는 반복계산을 수행하여 결과값의 변화 범위를 확인하여야 한다. 본 연구에서 사용된 유전 알고리즘의 정확성과 신뢰성을 얻기 위해 각 Case마다 23번의 반복 계산을 수행하였고, 그때의 최대 오차값을 해당 Case의 결합 오차값으로 사용하였다.

Table 2. Condition of Genetic Algorithm

Population size	5 EA
Reproduction	Roulette Wheel + Elite Preserving
Range of Value	-1.28 ~ 1.28
Learning Data Set	50 Set
Object Function	Linear scaling + Scaling window
Crossover	1-Point
Mutation	Adaptive
Percentage of Mutation	0.98

3.2 학습 및 오차계산

유전 알고리즘에서 독립변수와 성능변수에 대한 관계는 적합함수를 통해 정의된다. (5)식은 본 논문에서 사용한 1차 선형 적합함수를 나타낸다. 가스터빈엔진의 구성품인 압축기와 가스발생기 터빈 그리고 동력 터빈은 서로 종속적으로 연결이 되어 있다. 즉, 한 구성품에 성능저하가 일어나면 나머지 구성품에도 영향을 미친다는 것이다. 이 이유 때문에 독립변수의 선형 합으로 적합함수를 정의하였다. 독립변수의 계수로 사용된 C_i 는 각각의 독립변수가 각각의 구성품 성능저하에 얼마나 영향을 미치는지를 나타낸다.

$$\Delta C = C_1 \cdot T_c + C_2 \cdot \Pi_c + C_3 \cdot T_{gg} + C_4 \cdot T_{pt}$$

$$\Delta GGT = C_5 \cdot T_c + C_6 \cdot \Pi_c + C_7 \cdot T_{gg} + C_8 \cdot T_{pt} \quad (5)$$

$$\Delta PT = C_9 \cdot T_c + C_{10} \cdot \Pi_c + C_{11} \cdot T_{gg} + C_{12} \cdot T_{pt}$$

위의 식에서 ΔC , ΔGGT , ΔPT 는 각 구성요소에 결함이 발생하였을 경우 이때 발생한 결함량을 나타내는 성능변수이며, T_c , Π_c , T_{gg} , T_{pt} 는 결함이 발생한 엔진에서 측정된 값을 이용해 변화되어진 독립변수이다. C_i 값은 유전 알고리즘을

이용한 학습을 통해 구해야 하는 해가 된다.

유전 알고리즘을 이용하여 학습을 마친 후 실제 비행 중 엔진 결함이 발생하는 것을 가정하여 실시간 진단의 가능여부에 관하여 테스트하였다. 알고리즘을 통해 예측할 수 있는 최적 값과 실제 운용상에 얻어지는 값으로부터 오차를 구할 수 있으며, 오차 모델은 전체 시스템의 성능평가를 위해 사용될 수 있다[6]. 이를 위해 학습되지 않은 구간의 임의의 값을 이용하여 테스트를 실시하였고, RMS 결합 오차율(RMS defect error rate)을 이용하여 신뢰도를 비교하였다. (6)식은 결합 값에 대한 상대 오차율(Relative Error Rate)을 나타내고 있으며, (7)식은 RMS 결합 오차율이다. 결합 예측에 대한 오차율을 계산하기 위해서는 효율 값에 따른 오차율로도 비교할 수 있지만, 해외의 연구들이 결합 값(효율 저하량)에 대한 오차율 값을 사용하고 있기 때문에 본 연구에서도 같은 방법으로 비교하도록 하였다. 그리고 보다 정확한 비교를 위해서 오차의 제곱 평균값을 취하는 RMS 오차율을 도입해서 사용하였다[10].

$$\text{Relative Error} = \frac{\Delta[\text{Defect}]_{GSP} - \Delta[\text{Defect}]_{cal}}{\Delta[\text{Defect}]_{GSP}} \times 100 \quad (6)$$

$$\text{RMS Defect Error} [\%] = \sqrt{\sum_{i=1}^N \left(\frac{\Delta[\text{Defect}]_{GSP} - \Delta[\text{Defect}]_{cal}}{\Delta[\text{Defect}]_{GSP}} \right)^2} \times 100 \quad (7)$$

$$\sqrt{\frac{\sum_{i=1}^N \left(\frac{\Delta[\text{Defect}]_{GSP} - \Delta[\text{Defect}]_{cal}}{\Delta[\text{Defect}]_{GSP}} \right)^2}{N}} \times 100$$

RMS 오차를 구함에 있어 아래첨자 cal 값은 적합함수를 이용하여 학습하여 예측할 수 있는 결합 값이며, 아래첨자 GSP 값은 실제 GSP를 통해 구해진 결합 값이다.

4. 결합 진단

4.1 지상정지 상태에서의 단일 결합 진단 결과

P&W 206C 엔진의 지상정지 상태에서의 단일 구성요소에 대한 결합 진단은 비교적 적은 학습 데이터 수를 다루게 된다.

Figure 1, 2, 3은 압축기, 가스발생기 터빈, 동력 터빈에 단일결함이 발생했을 경우 결합량 예

축을 비교한 결과이다.

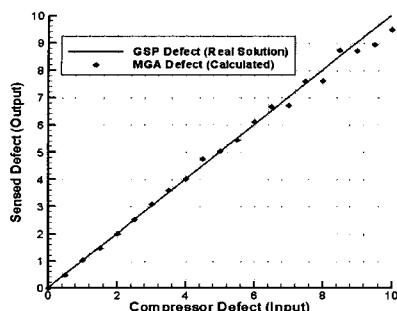


Fig 1. Compressor Defect Diagnostics

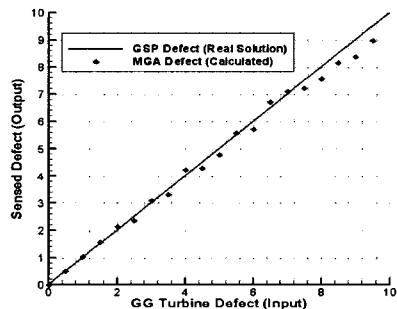


Fig 2. G.G. Turbine Defect Diagnostics

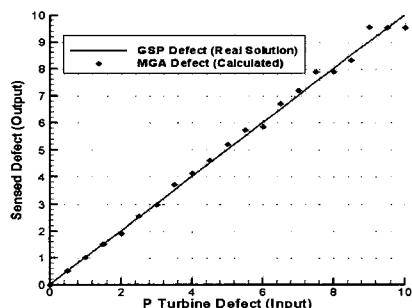


Fig 3. Power Turbine Defect Diagnostics

그래프의 x-축은 실제 발생한 결함량을 나타내며, y-축은 발생한 결함량에 대해 진단된 결과값이다. 점으로 표현된 부분이 마이크로 유전 알고리즘(MGA)을 통해 학습한 적합함수의 계수를 사용하여 결함 위치를 판단한 후 진단한 결함량이다.

Table 3. Sea level condition, Single defect Diagnostics RMS error

Defect	Max. RMS Error [%]
Compressor	3.149
GG-Turbine	3.784
P-Turbine	3.422

각 구성요소의 결함량 진단에 대해 23번의 반복 계산에 따른 최대 RMS 오차는 Table 3에서 표기하였으며, 이때 평균 학습시간은 259.1 min 이었다. 그 결과를 비교하여 볼 때 비교적 정확히 결함량에 대해 진단함을 확인할 수 있다.

4.2 탈 설계 영역에서의 단일 결함 진단

가스터빈엔진은 설계점에서뿐만 아니라 항공기의 운용 조건에 의해 다양한 탈 설계 영역에서의 운용 능력을 필요로 한다. 정확한 결함 진단을 위해서는 탈 설계 영역에서 독립변수로 사용되는 엔진 구성요소의 온도 및 압력에 가장 큰 영향을 미치는 요소를 고려하여 탈 설계 영역에 대해 학습하여야 한다. 본 논문에서는 엔진의 상태에 가장 민감하게 영향을 주는 요소로 고도, 비행 마하수, 연료유량을 선정 하였다. 탈 설계 영역에서 일정구간을 가지는 고도, 비행 마하수, 연료 유량에 대해 각각을 동일한 크기로 나눈 후 독립변수를 추출하였다. 설계점에서는 한가지의 고도, 비행 마하수, 연료유량에 대한 독립변수를 추출한 것에 비해 탈 설계 영역에서는 그 수가 상당히 많아진 것을 알 수 있다.

탈 설계 영역에서의 학습을 위해 항공기의 운용조건을 설정하였고, 같은 크기의 구간으로 나누어 학습하였다. Table 4는 항공기의 운용조건 즉, 탈 설계 영역에서의 학습데이터 범위를 나타내고 있다. 또한 각각의 탈 설계 영역의 조건과 가스터빈엔진의 민감도를 고려하여 구간의 수를 선정하도록 하였다. 탈 설계 영역에서 항공기용 가스터빈엔진에 많은 영향을 주는 조건일수록 더 많은 구간의 수로 학습하도록 하였다.

Table 4. Learning data in Off-design

	Parameter		
	Alt.(m)	Mach no.	Fuel flow (kg/sec)
Operation region	0 ~ 5,000	0 ~ 0.5	0.0307 ~ 0.0457
The dividing number	2	2	2
	3	3	3
	6	6	6
	21	11	11
	41	21	21

전체 학습량의 크기는 각 조건별 구간의 수와 관계가 있다. 예를 들어, 고도에 대한 학습 데이터를 11 구간, 비행 마하수는 6구간, 연료유량은 3구간으로 정하였을 경우에 전체 학습량의 수는 성능저하 변수에 따른 학습 데이터 50 set을 포함하여 총 9900 Set로 결정되어진다. 이것은 각 조건에서의 구간수가 증가하면, 학습량은 그 배수로 증가하게 된다는 것을 의미한다. 탈 설계 영역에서 학습량이 증가하더라도 계산시간을 고려한 효율성을 유지하면서 결합량 진단의 정확성은 획득할 수 있는 최적의 학습 조건을 찾아야 할 것이다.

4.3 탈 설계 영역의 최적분할

설계점에서의 경우, 항공기용 가스터빈 엔진에 대해 하나의 설계 조건만의 학습으로 진단이 가능하다. 하지만, 탈 설계 영역의 경우 엔진에 민감한 영향을 주는 고도, 비행 마하 수, 연료 유량에 대한 모든 조건에서 결합량을 학습해야 하므로 결합진단에 방대한 학습량이 요구된다. 따라서 본 논문에서는 탈 설계 영역의 주요 조건인 고도, 비행 마하 수, 연료 유량에 대해 동일한 구간으로 나누어 적절한 진단 정확성을 유지하는 범위 내에서 최적의 계산시간을 얻을 수 있도록 최적분할 기법을 제안하였다. 최적 분할 기법이란 허용되는 정확성을 목표로 학습 구간 수를 정하는 방식으로 본 연구에서는 5% 내외의 RMS 오차율을 허용 정확성으로 설정하였다.

Table 5. Maximum RMS Error for Data Number of Altitude No.

Data No. (EA)	Max. RMS Error (%)			Run Time (min)
	Compressor	G.G.-Turbine	Power Turbine	
On-Design	3.15	3.78	3.42	259.1
2	25.94	62.73	40.32	344.2
3	25.09	37.53	29.28	366.1
6	7.96	16.34	19.02	427.6
11	6.37	8.64	8.94	662.1
21	5.09	5.27	4.74	711.6
41	3.14	3.84	3.42	1146.8

Table 5는 고도에 대한 학습 구간 수에 따른 최대 오차와 수렴시간의 비교를 나타낸 것이다. 비교 값의 첫 행 값은 지상정지 상태에서의 단일결합에 대한 값으로 계산시간의 변화에 대한 비교를 위해 첨부하였다. 학습 구간 수를 증가시키면 오차가 감소하지만, 수렴까지 방대한 계산시간이 요구됨을 알 수 있다. 본 연구에서는 고도 변화에 따른 결합 진단을 위한 학습 시, 계산시간의 효율성과 결합진단의 정확성을 동시에 만족 할 수 있는 최적의 학습 구간 수로 21을 선정하였다. 같은 방법으로 비행마하수와 연료유량의 학습 구간 수에 대한 최대 오차를 Fig. 4, 5에 나타내었다.

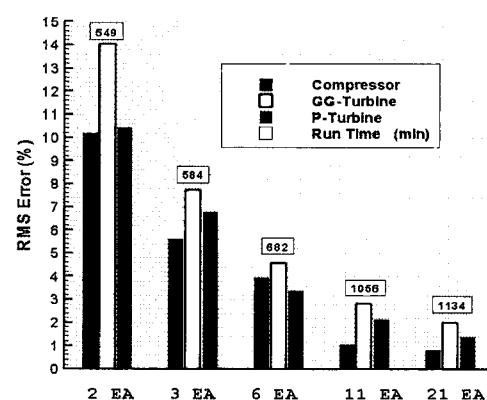


Fig. 4 RMS Error for Data Number of Flight Mach Number

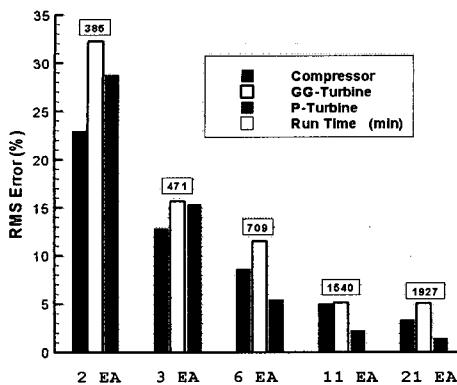


Fig. 5 Maximum RMS Error for Data Number of Fuel Flow Rate

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

4.4 탈 설계 영역에서의 단일 결합 진단 결과

본 연구에서는 고도, 비행 마하수, 연료유량에 대해 탈 설계 전체 영역에 대해 구간의 수를 변화시키며 학습하였고, 학습되지 않은 탈 설계점을 테스트 데이터로 사용하여 결합을 진단하였다.

탈 설계 전체에 대한 결합 진단을 할 경우, 최적 진단이 가능한 고도조건 21 구간, 비행 마하 수 6 구간, 그리고 연료유량 11 구간으로 분할하여 학습하는 것이 결합 진단의 정확성과 학습 시간의 효율성을 동시에 만족시킬 수 있음을 확인하였다. 위의 조건으로 학습할 경우 전체 학습 데이터 수는 69300 Set 이었다.

Table 6은 탈 설계 조건에 따른 각 구성요소의 결합량 예측에 대한 최대 RMS 오차율을 정리한 것이다. 결합진단 예측 결과를 볼 때, 각 탈 설계점에 대한 RMS 오차값은 고도 변화에 따른 변화가 가장 큰 것을 확인할 수 있었다.

본 연구는 무인항공기에 탑재된 가스터빈엔진의 현재 상태를 실시간 모니터링을 함으로써 실시간으로 그 성능을 진단하는 것이 개발목적 중 하나이다. 따라서 알고리즘의 진단 시간도 중요

한 척도가 된다. 지금까지 개발된 알고리즘의 경우, 결합진단에 걸리는 시간이 평균 0.110 sec으로 실시간 진단이 가능함을 확인하였다.

Table 6. Maximum RMS Error on Off-Design Condition

Parameter	Data No. (EA)	Max. RMS Error (%)		
		Compressor	G.G.-Turbine	Power Turbine
Altitude	21	5.09	5.27	4.74
Mach No.	6	3.95	4.56	3.38
Fuel Flow Rate	11	5.08	5.14	2.26

5. 결 론

본 연구에서는 터보 축 엔진 P&W사 206C엔진의 탈 설계 영역에 대한 단일결합에 대한 학습 및 진단을 최적분할 기법을 적용한 마이크로 유전 알고리즘을 사용하여 수행하였다. 최적 분할 기법을 통해 탈 설계 영역에서의 학습데이터를 고도 21 구간, 비행 마하수 6 구간 그리고 연료유량은 11 구간으로 분할하였을 때, 계산시간의 효율성과 정확성을 동시에 얻을 수 있었다. 이 때, 각 구성요소의 결합진단에 대한 RMS 오차율은 압축기, 가스발생기 터빈, 동력 터빈 각각 5.09%, 5.27%, 4.74%의 값을 얻었다. 또한 실시간 진단이 가능할 정도로 진단시간이 0.110 sec로 짧음을 알 수 있다.

연구 결과를 토대로 유전 알고리즘을 이용한 탈 설계 영역에서 엔진의 결합 진단 가능성을 획득하였다. 향후, 탈 설계 영역에서의 복합 결합 진단을 수행할 예정이다. 복합 결합은 단일 결합에 비해 그 학습데이터의 양이 더욱 더 증가할 것이므로 수렴도와 수렴시간을 만족시키기 위해 더 많은 연구가 이루어져야 할 것이다.

본 연구는 스마트 무인기 기술개발사업의 일환으로 지원 수행된 연구의 일부이며, 연구를 지원해주신 산업자원부 및 한국항공우주연구원에 감사드립니다.

참 고 문 헌

1. Link C. Jaw, "Recent Advancements in Aircraft engine health management (EHM) Technologies and Recommendations for the Next Step", 50th ASME International Gas Turbine & Aeroengine Technical Congress, 2005
2. Suresh Sampath, Ankush Gulati, Riti Singh, "Artificial intelligence techniques For Gas Turbine Engine Fault Diagnostics", 38th AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit, 2002
3. Suresh Sampath, "Engine-fault Diagnostics: an optimization procedure", Applied Energy, 2002, pp.47-70
4. 추동호, "가스터빈엔진의 실용적인 성능진단 기법 개선", 한국항공우주학회 1996년 춘계 발표회, 1996, pp.134-139
5. 박준철, "스마트무인항공기용 터보축엔진의 동적 성능과 응답성에 관한 연구", 한국추진 공학회지 2005, 9권 2호, 2005, pp.17-24
6. 전용빈, "스마트무인기 후보엔진 기술검토", 한국추진공학회지 10권 1호, 2006
7. 정석우, "진화 시스템을 위한 유전자 알고리즘 프로세서의 구현", 전기학회논문집, 53권 4호, 2004
8. Mark Juric, "Optimizing Genetic Algorithm Parameters Fault Diagnosis Applications", Artificial Intelligence Programs, 1994
9. 김유단, "회전익 무인기의 고장진단 및 다중화관리 연구 동향", 한국항공우주학회지 32권 7호, 2004, pp.133-141
10. 이상명, ""Hybrid SVM-인공신경망 알고리즘을 이용한 가스터빈 엔진의 결함 진단에 관한 연구", 인하대학교 항공공학과 석사학위 논문, 2007
11. 기자영, 공창덕, "인공지능 및 성능데 데이터를 이용한 압축기 성능도 식별에 관한 연구", 한국추진공학회지, 2005
12. 공창덕, "스마트 무인기용 가스터빈 엔진의 탈설계 영역 구성품 손상 진단에 관한 연구", 한국추진공학회지, 2007
13. 공창덕, "스마트 무인기 추진시스템의 주요 구성품 손상 탐지에 관한 연구", 한국 추진 공학회 추계학술대회 논문집, 2006
14. 김승민, "유전자 알고리즘을 이용한 항공기용 가스터빈 엔진에 대한 복합 결함 진단에 대한 연구", 한국 추진 공학회 추계학술대회 논문집, 2006