

실수코드 유전알고리즘과 인공신경망을 이용한 가스터빈 엔진의 복합 결함 진단 연구

서동혁* · 장준영* · 노태성** · 최동환**

Multiple Defect Diagnostics of Gas Turbine Engine using Real Coded GA and Artificial Neural Network

Donghyuck Seo* · Junyoung Jang* · Taeseong Roh** · Dongwhan Choi**

ABSTRACT

In this study, Real Coded Genetic Algorithm(RCGA) and Artificial Neural Network(ANN) are used for developing the defect diagnostics of the aircraft turbo-shaft engine. ANN accompanied with large amount data has a most serious problem to fall in the local minima. Because of this weak point, it becomes very difficult to obtain good convergence ratio and high accuracy. To solve this problem, GA based ANN has been suggested. GA is able to search the global minima better than ANN. GA based ANN has shown the RMS defect error of 5% less in single and dual defect cases.

초 록

본 논문에서는 실수코드 유전 알고리즘(RCGA)과 인공신경망(ANN)을 이용하여 항공기용 터보 축 엔진의 복합 진단에 관한 연구를 수행하였다. 인공신경망만을 이용하여 엔진의 결함을 판단 할 경우 많은 학습데이터 때문에 지역 최소점으로 수렴하는 단점이 있다. 이를 개선하기 위해 전역 최소점을 찾는 능력이 뛰어난 실수코드 유전 알고리즘을 사용하였다. 5% 이내의 RMS 결함오차로 높은 결함 예측 신뢰도를 가짐을 확인하였다.

Key Words: Defect Diagnostics(결함진단), Real Coded Genetic Algorithm(실수코드 유전알고리즘), Artificial Neural Network(인공신경망), Local Minima(지역 최소점), Global Minima(전역 최소점)

1. 서 론

항공기가 한번 이륙을 하게 되면 엔진에 결함이 발생하더라도 정비나 부품교체를 할 수가 없으므로 높은 안정성과 신뢰성이 보장되어야 한다. 이를 위해서 가스터빈 엔진의 성능 진단 시스템의 연구가 활발히 이루어지고 있다. 성능 진단

* 인하대학교 항공공학과

** 인하대학교 항공공학과

연락처, E-mail: dwchoi@inha.ac.kr

단 시스템은 엔진의 온도, 압력, 회전수, 연료유량 등과 같은 성능인자를 통해 그 경향성을 분석하고 그것을 토대로 엔진의 이상 유무를 판단한다. 이 판단을 근거로 엔진의 결함을 예측 또는 조기 발견하여 정비비용과 운용경비를 줄이고, 항공기 운항의 안정성과 신뢰성을 향상시킬 수 있다.[1]

일반적으로 결함 진단 시스템에는 인공신경망 이론(ANN)과 유전 알고리즘(GA)과 같은 패턴 인식 문제를 해결하기 위한 알고리즘이 사용된다. 인공신경망 이론은 수학적인 모델을 기초로 하여 목표 값과 계산 된 값의 오차를 줄여나가는 방법이지만 학습할 데이터의 양이 많아지면 전역 최소점(Global Minima)이 아닌 지역 최소점(Local Minima)으로 수렴하게 되어 원하는 분류 정확도를 얻지 못한다. 유전 알고리즘은 적합도를 계산하여 높은 것은 살아남고 낮은 것은 도태되는 자연계의 법칙을 모델로 하는 방법이다. 이 방법은 전역 최소점을 찾는 능력은 다른 알고리즘보다 뛰어나지만 난수를 발생시켜서 확률적인 탐색이 이루어지기 때문에 학습시간이 많이 소비된다.[3-5]

운용범위가 넓은 항공기 엔진의 경우 학습 데이터의 양도 따라서 많아진다. 이 경우 인공신경망 이론이나 유전 알고리즘을 단독으로 사용하면 학습시간도 오래 걸리고 수렴 정확도 또한 낮아진다. 이에 본 논문에서는 인공신경망 이론과 유전 알고리즘을 함께 사용하여 이런 문제점을 해결하였다.

2. GA based ANN 알고리즘

2.1 알고리즘 구조

본 논문에서는 GA based ANN 알고리즘이 사용되었다. 이 알고리즘의 구조는 Figure 1과 같이 인공신경망 안에 유전 알고리즘이 포함된 구조다. 전체적인 구조는 인공신경망을 통해서 구축하고 알고리즘의 핵심 변수인 Weight와 Bias는 유전 알고리즘을 통해 최적화하는 방식이다.[4] 입력 데이터로는 압축기 전후의 온도와

압력, 가스발생기 터빈과 동력 터빈 전후의 온도가 사용되었다. 인공신경망을 통해 나오는 결과 값은 엔진 각 구성품의 효율이다.

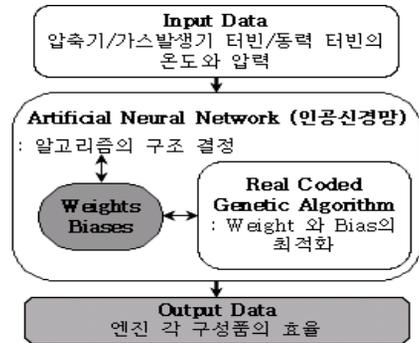


Fig. 1 The structure of GA based ANN

2.2 인공신경망 이론 (ANN)

인공신경망이란 사람의 신경 전달 과정을 단순화하고 이를 수학적으로 해석한 모델로써 복잡하게 얽혀있는 뉴런(Neuron)이 네트워크를 이루면서 뉴런끼리 연결강도를 조절하여 학습 과정을 통해 정량적으로 데이터 값을 부여하는 알고리즘이다. 신경망은 가장 일반적인 형태의 신경망인 다층퍼셉트론(MLP)을 사용하였다. 이 구조는 Fig. 2에 나타나 있다.

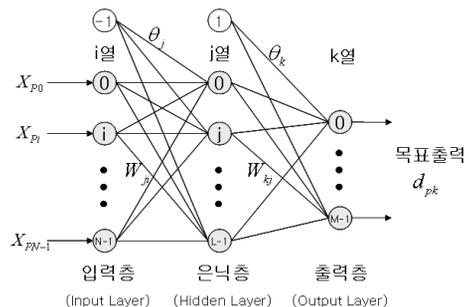


Fig. 2 Structure of ANN model

인공신경망은 전체 알고리즘의 구조만을 결정해주기 때문에 은닉층의 개수와 노드 수를 변화시키면서 최적의 구조를 찾아야 한다. 특히 은닉층의 노드 수는 Weight와 Bias의 크기를 결정해주기 때문에 특히 민감한 요소라고 할 수 있다.

본 논문에서는 Hidden Layer는 1개, 노드 수는 10개로 결정하였다.[2]

2.3 실수코드 유전 알고리즘(RCGA)

실수코드 유전 알고리즘을 사용하면 염색체를 실수로 표시함으로써 정확히 문제의 변수와 일대일 일치하는 실수 유전자를 가지게 되고 정밀도는 알고리즘을 수행하는 컴퓨터의 정도에만 제약을 받게 된다. 특히, 많은 변수로 이루어진 Weight와 Bias의 최적화 문제를 이진코드 유전 알고리즘을 통해 풀면 실수를 이진수로 변환하는 번거로운 과정이 들어가게 되어 원하는 해를 얻는데 소비되는 시간이 많아지게 된다. 또한 이진코드에서 발생할 수 있는 해밍절벽(Hamming Cliff)에 의해 지역 최소점으로 수렴하게 되는 문제가 발생 할 수도 있다.[4,5]

실수코드 유전 알고리즘 역시 재생산, 교배, 돌연변이와 같은 연산자를 통해 전역해를 탐색한다. 재생산 기법은 적합도를 기반으로 동작하기 때문에 교배나 돌연변이와 달리 염색체 표현에 자유롭다. 따라서 이진코드 유전 알고리즘에서 사용되었던 재생산 기법들을 그대로 사용할 수 있다. 이 논문에서는 구배 유사 선택자(Gradient-like selector)를 사용하였다. 새로운 개체는 이전개체와 이전개체의 최적 적합도의 선형조합으로 되어있다. 이 새로운 개체는 이전 개체보다는 최적개체 쪽으로 움직이도록 설계되었다.[5]

교배 연산자로는 산술적 교배(Arithmetical crossover)를 사용하였다. 이 기법은 두 부모 염색체를 일차 결합하여 새로운 자손 염색체를 얻는 방법이다. 다음의 식과 같이 0과 1사이의 난수 λ 를 이용하여 두 부모 염색체를 결합하였다. 이 기법은 초기집단에 의한 값 이외의 새로운 값을 만들 수 있다는 장점을 가진다.[4,5]

마지막으로 돌연변이 연산자로는 동적돌연변이(Dynamic Mutation)를 사용하였다. 이 연산자는 초기에는 전 공간을 두루 탐색하다가 세대수가 증가하면 점차 지역적으로 탐색하여 효율적 돌연변이를 일으키도록 작동한다.[4,5]

2.4 적합도 결정

실수코드 유전 알고리즘에서 사용된 적합도는 오류가 작을수록 큰 적합도를 갖도록 인공지능망에서 사용되는 수렴조건식의 역수를 이용하였다.

$$fit(n) = \frac{1}{\frac{Error(n)}{CN}}, \quad CN: \text{총 염색체 집단 수}$$

$$\sum_{n=1}^{CN} \frac{1}{Error(n)}$$

3. 진단 결과

3.1 엔진 데이터 선정

본 논문에서는 터보 축 엔진 모델을 대상 엔진으로 선정하였고, GSP(Gas turbine Simulation Program) 상용프로그램을 사용하여 엔진의 성능 인자들을 추출하였다. 엔진구성품의 성능 맵은 GSP 프로그램 내에서 제공하는 터보 샤프트 압축기 맵과 터빈 맵을 엔진 제작사인 P&W에서 제공한 성능데이터에 맞게 스케일링을 시켜 사용하였다.[2]

결함 진단 범위는 단일 결함과 이중 복합 결함이 발생한 경우이며, 결함요소는 압축기, 가스발생기 터빈, 동력 터빈으로 선정하였다.

탈 설계 영역에서의 학습 데이터는 고도, 마하수, 연료 유량을 고려하여 데이터를 구성하였다.

Table 1. Input data for Learning

| 엔진파트 | 고도 | 마하수 | 연료 유량 | 성능 저하 |
|----------------|---------|-------|--------------|---------|
| 압축기 | 0, 240, | 0.1 | 0.032 | 0, 0.5, |
| 가스발생기터빈 | | | | |
| 동력터빈 | ~ | ~ 0.4 | ~ | ~ |
| 압축기+ 가스발생기터빈 | | | | |
| 가스발생기터빈 + 동력터빈 | 4800m | | 0.038 kg/sec | -5% |
| 압축기+ 동력터빈 | | | | |

테스트 데이터는 고도와 성능저하가 학습데이터와 일치하지 않도록 하면서 각 구간 사이의

임의의 포인트를 잡아서 선정하였다. 각 테스트 데이터의 성능저하는 Table 2와 같이 0~5.0% 범위의 일정한 값으로 정하였다.

Table 2. Test data

| no | 고도/연료유량 (m)/(kg/sec) | 성능저하(%) | | |
|----|-------------------------|---------|-------------|----------|
| | | 압축기 | 가스발생기 터빈 | 동력 터빈 |
| 1 | 690/0.032 | -3.3 | -4.6 | -1.9 |
| 2 | 690/0.038 | | | |
| 3 | 1,000/0.032 | -1.3 | -2.6 | -3.9 |
| 4 | 1,000/0.038 | | | |
| 5 | 1,710/0.032 | -4.3 | -1.6 | -2.9 |
| 6 | 1,710/0.038 | | | |
| 7 | 2,190/0.032 | -2.3 | -3.6 | -4.9 |
| 8 | 2,190/0.038 | | | |
| 9 | 2,670/0.032 | -4.3 | -1.6 | -2.9 |
| 10 | 2,670/0.038 | | | |
| 11 | 3,150/0.032 | -2.3 | -3.6 | -4.9 |
| 12 | 3,150/0.038 | | | |
| 13 | 3,630/0.032 | -4.3 | -1.6 | -2.9 |
| 14 | 3,630/0.038 | | | |
| 15 | 4,350/0.032 | -3.3 | -4.6 | -1.9 |
| 16 | 4,350/0.038 | | | |

3.2 엔진 결함 진단 결과

결함 진단 결과는 다음과 같은 테스트 데이터의 RMS 결함 오차를 이용해서 비교하였다.

$$RMS\ defect\ error\ rate\ [\%] = \sqrt{\sum_{i=1}^N \left(\frac{D_{real} - D_{cal}}{D_{real}} \times 100\% \right)^2} / N$$

단일 결함에 대한 진단 결과는 압축기, 가스발생기 터빈, 동력 터빈에 대해 각각 16개의 테스트 데이터를 적용시켜 각 테스트 케이스에 대해 RMS 결함 오차를 구하고, 임의의 한 포인트에 대한 실제 효율 값과 계산된 효율 값을 비교하였다.

압축기와 가스발생기 터빈에서 발생하는 단일 결함의 경우 Fig. 5와 Fig. 6 같이 RMS 결함 오차가 3% 근방의 정확한 예측이 가능하였다. 동력 터빈의 경우, RMS 결함 오차는 상대적으로 큰 약 4%의 예측 정확도를 보여주었다.

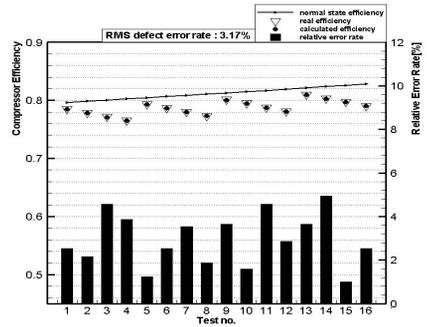


Fig. 3 Estimated RMS Defect Error Rate and Efficiency of Compressor

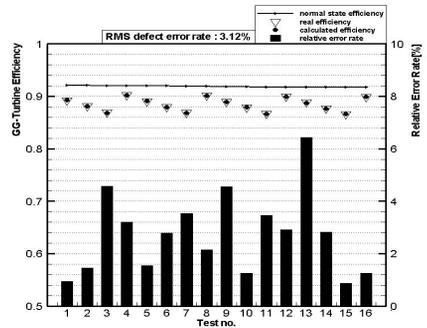


Fig. 4 Estimated RMS Defect Error Rate and Efficiency of GG-Turbine

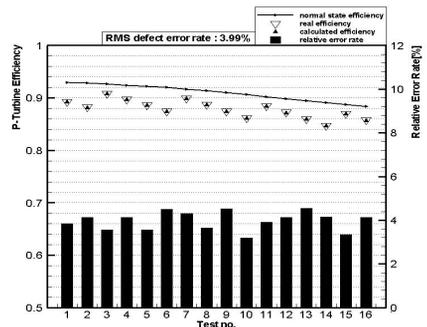


Fig. 5 Estimated RMS Defect Error Rate and Efficiency of Power Turbine

그래프에서 색이 채워지지 않은 포인트는 GSP에서 얻은 각 파트의 효율을 나타내고 색이 채워진 포인트는 계산되어진 결과 얻어진 효율이다.

이중 복합 결함의 경우 Comp/GG-Turbine, GG-Turbine/P-Turbine, Comp/P-Turbine의 경우에 대해 결함 예측이 이루어졌다. 각각의 경우에서 3.73/3.78%, 3.31/4.29%, 3.36/3.99% RMS 결함 오차로 결함 예측이 이루어졌다.

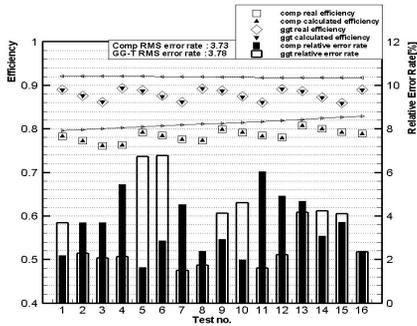


Fig. 6 Estimated RMS Defect Error Rate and Efficiency of Comp/GG-Turbine

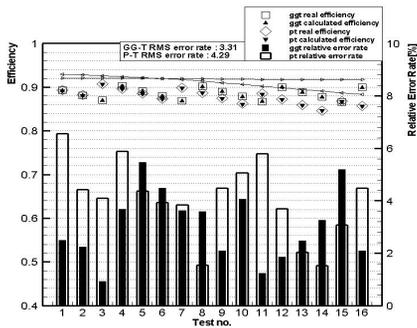


Fig. 7 Estimated RMS Defect Error Rate and Efficiency of GG-Turbine/P-Turbine

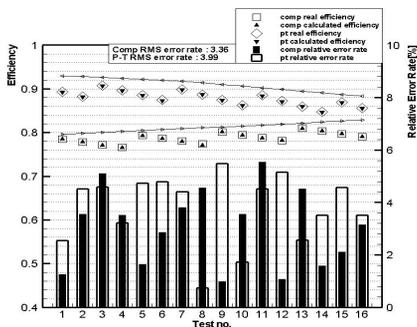


Fig. 8 Estimated RMS Defect Error Rate and Efficiency of Comp/P-Turbine

4. 결 론

본 논문에서는 항공기용 가스터빈 엔진의 결함 진단을 위한 연구를 수행하였다. 인공신경망 이론을 이용해서 알고리즘의 구조를 결정하고 인공신경망 이론의 중요 변수인 Weight와 Bias를 실수코드 유전 알고리즘을 사용하여 구한 후 엔진의 결함량을 진단하였다.

단일 결함과 이중 복합 결함의 경우 압축기, 가스발생기 터빈 그리고 동력 터빈에서 5% 미만의 RMS 결함 오차를 보이면서 엔진의 성능을 진단하였다. 압축기와 가스발생기 터빈의 경우 RMS 결함 오차가 3% 내외로 결함 예측이 이루어진 반면 동력 터빈의 경우는 4% 내외의 상대적으로 높은 RMS 결함 오차를 보이면서 결함 예측이 이루어지는 경향성이 보였다.

참 고 문 헌

1. R.B.Joly, S.O.T. Ogaji, R.Singh, S.D. Probert, "Gas-turbine diagnostics using artificial neural-networks for a high bypass ratio military turbofan engine," Applied Energy 78, 2004, pp.397-418
2. 이상명, 최원준, 노태성, 최동환, "SVM-이공신경망알고리즘을 이용한 가스터빈 엔진의 복합결함진단 연구", 한국항공우주학회 추계 학술발표회논문집, 2006, pp.976-979
3. A. A. Arkadan, P. Du, M. Sidani, M. Bouji, "Performance Prediction of SRM Drive Systems under Normal and Fault Operating Conditions Using GA-based ANN Method," IEEE, Vol. 36, No.4, July 2000
4. 진강균, "유전 알고리즘과 그 응용," 교우사, 2004
5. 조남철, "실수코드 유전알고리즘을 이용한 케이블 돔의 형상최적 설계," 인하대학교, 2003