

# SVM과 인공신경망을 이용한 속도 및 연료유량 변화에 따른 가스터빈 엔진의 결함 진단 연구

최원준\* · 이상명\* · 노태성\*\* · 최동환\*\*

## Defect Diagnostics of Gas Turbine Engine with Mach Number and Fuel Flow Variations Using Hybrid SVM-ANN

Wonjun Choi\* · Sangmyeong Lee\* · Taeseong Roh\*\* · Dongwhan Choi\*\*

### ABSTRACT

In this paper, the hybrid algorithm of Support Vector Machine and Artificial Neural Network is used for the defect diagnostics algorithm for the aircraft turbo-shaft engine. The results of learning of ANN, especially, accuracy or speed of convergence are sensitive to the number of data, so a comparison between design point and off-design area, especially, Mach number and fuel flow variable area, is essential research. From application results for diagnostics of gas turbine engine, it was confirmed that the hybrid algorithm could detect well in the off-design area as well as design point.

### 초 록

본 논문에서는 항공기용 터보 축 엔진의 결함진단 알고리즘으로 지지 벡터 장치(Support Vector Machine) 과 인공신경망(Artificial Neural Network) 을 복합으로 이용하였다. 인공신경망 알고리즘의 특성상 데이터 수에 따라 정확성과 수렴속도 등에서 차이가 나므로 탈설계 영역에서의 효용성여부를 판단하기 위해서 연료유량과 마하수에 따른 탈설계 영역 진단 결과를 지상정지 상태와 비교하였다.

Key Words: Defect Diagnostics(결함 진단), Support Vector Machine(지지 벡터 장치), Artificial, Neural Network(인공신경망), Fuel Flow(연료 유량), Mach number(마하수)

### 1. 서 론

가스터빈 엔진의 결함 진단 기술은 예기치 않은 외부이물질의 유입이나 외부 환경의 변화에 의한 압축기 블레이드의 손상이나 기계적 결함

발생, 장기간 운용시 피로도, 열응력의 누적에 의한 부식 및 손상, 축 베어링의 마모에 의한 진동발생 등 엔진을 운용함에 있어서 발생할 수 있는 성능저하를 미리 예측할 수 있는 기술이다. 이는 엔진 각 요소에서 수치적으로 측정 가능한 파라미터(압축기 입출구 온도, 압력, 터빈 입출구 온도, 압력 등)을 측정하여 성능 파라미터(효율 등)를 산출하여 성능의 저하를 판단하는 것이다.

\* 인하대학교 항공공학과

\*\* 인하대학교 항공우주공학과

연락처, E-mail: dwchoi@inha.ac.kr

이러한 결함 진단 기술개발을 위한 연구로 오류역전파(Error Back Propagation)를 이용한 다층퍼셉트론(Multi Layer Perceptron : MLP)으로 패턴을 인식하고 분류하는 인공신경망(Artificial Neural Network)과 이론적 수식에 기반을 두어 보다 간단하고 효율적으로 데이터를 분류하는 지지벡터장치(Support Vector Machine : SVM)를 동시에 이용하였다.[1] 결함예측에 사용되는 방대한 양의 데이터를 SVM으로 결함 위치를 판단하여 그 범위를 줄여주고, 데이터를 학습시키는 인공신경망을 이용하여 정량적으로 접근하는 방법을 택하였다.[2]

이 알고리즘을 실제 상황에 적용하기 위해서는 탈설계 영역에서의 검증이 필요하다. 그래서 고도에 따른 고장진단 연구[4]에 이어 연료유량과 마하수에 따른 고장진단을 연구하였다.

## 2. SVM - ANN Algorithm

### 2.1 지지 벡터 장치 (SVM)

SVM은 학습 집단을 둘로 분류하는 이진 분류기이다. 집단을 둘로 분류하는 여러 개의 평면 중, Fig. 1에 나타나 있듯 두 집단 사이의 유클리드 거리(Margin)를 최대로 하여 구분을 할 수 있는 하나의 평면이 존재한다. 이평면을 초평면(Hyper-plane)이라고 한다.




Fig. 1 Optimal Separating Hyper-plane and Margin of SVM

초평면의 식으로 얻어지는 결정함수(Decision Function) Eq. 2, Eq. 3, Eq. 4를 이용하여 임의의 벡터가 속하는 집단을 분류한다. 입력데이터

가 비선형적인 분포를 가지므로 분류정확률을 높이기 위해 가우시안 커널 함수(Gaussian Kernel Function)을 적용시켰고 여러 Class의 분류가 가능하도록 Multi - Class SVM으로 확장 적용시켰다.[3]

$$\omega = \sum_{i=1}^N \alpha_i y_i x_i = \sum_{i \in SV} \alpha_i y_i x_i \quad (2)$$

$$y_i \left( \sum_{i \in SV} \alpha_i y_i (x_i \cdot x) + b \right) = 1 \quad (3)$$

$$f(x, \alpha^*, b^*) = \text{sign}((\omega^* \cdot x) + b^*) \quad (4)$$

$$= \text{sign} \left[ \sum_{i \in SV} \alpha_i^* y_i \left\{ \exp \left( - \frac{\|x_i - x\|^2}{2\sigma^2} \right) \right\} \right]$$

### 2.2 인공신경망(Artificial Neural Network)

본 논문에서 구성한 인공신경망은 가장 일반적이라고 할 수 있는 다층퍼셉트론(Multi Layer Perceptron : MLP)를 이용하였고 오류역전파(Error Back Propagation)를 통해 학습이 이뤄졌다. 입력층으로 들어온 데이터는 강도(W)가 곱해져 전체 합으로써 은닉층에 전달되고 같은 방식으로 한 번 더 계산하여 출력층에 전달된다. 여기서 나온 결과값(Output :  $O_{pk}$ )과 목표 결과값(Desired Output :  $d_{pk}$ )을 비교하여 오차를 Eq. 5 와 같이 계산한 후 오차가 최소화될 때까지 강도(W)를 변화시켜가며 학습을 반복한다. 오차가 최소화 되었을 때의 강도(W)를 새로운 데이터 판단에 이용한다.[1]

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_{k=1}^{M-1} (d_{pk} - O_{pk})^2 \quad (5)$$

## 3. 결함 진단 결과

### 3.1 SVM에 의한 결함위치 판단

본 논문에서 사용된 모든 데이터는 GSP(Gas turbine Simulation Programme)를 이용하여 추출하였다. Table. 1은 SVM에 사용된 결함위치 판단을 위한 입력데이터이다. 압축기 입출구 온도, 압력, 압축기-터빈 입출구 온도, 동력 터빈 입출구 온도 등을 사용하였다.

Table. 1 Input data of SVM

	Input Data
Data sets	$T_{t2}, T_{t3}, P_{t2}, P_{t3}, T_{t4}, T_{t7}, T_{t8}$

Multi-Class SVM으로 마하수에 따른 결합위치 판단을 하기 위한 데이터 집단은 지상 정지 상태에서 마하수 0.1~0.5까지 총 5개의 구간으로 구분하고 테스트 데이터로 각 구간에서 -0.9%, -0.6%, ~, -9.9%로 결함을 주어 구간 당 31개씩, 총 155개의 데이터집단을 사용하였다. 연료유량에 따른 판단은 0.031kg/s~0.0382kg/s 까지 총 5개의 구간으로 구분하여 마하수와 같은 155개의 테스트 데이터 집단을 사용하였다. 각 학습에 따른 결함 분류율은 Table. 2와 같다. 모든 구간에서 오차 없는 분류율을 보였다.

Table. 2 Classification rates of Multi-class SVM

	Mach No.	Classification Rate (%)	Fuel Flow (kg/s)	Classification Rate (%)
Comp.	0.1	100	0.0310	100
	0.2	100	0.0328	100
	0.3	100	0.0346	100
	0.4	100	0.0364	100
	0.5	100	0.0382	100
Comp.-Turbine	0.1	100	0.0310	100
	0.2	100	0.0328	100
	0.3	100	0.0346	100
	0.4	100	0.0364	100
	0.5	100	0.0382	100
Power-Turbine	0.1	100	0.0310	100
	0.2	100	0.0328	100
	0.3	100	0.0346	100
	0.4	100	0.0364	100
	0.5	100	0.0382	100

### 3.2 인공신경망에 의한 결함예측 판단

SVM에 의해 분류된 데이터로 위치를 판단한 후 인공신경망으로 학습을 하였다. 인공신경망은 학습데이터 수에 의해 시간과 수렴도가 상당히 좌우되므로 최대한 데이터 수를 줄이기 위하여 입력데이터를 Table. 3과 같이 비(Rate)로써 사용하였다.

Table. 3 Input and Output Data of ANN

	Input Data	Output Data
Data sets	$T_{t3}/T_{t2}, P_{t3}/P_{t2}, T_{t4}/T_{t7}, T_{t7}/T_{t8}$	Isentropic efficiency (deteriorated)

Table. 4에 각 요소별 마하수와 연료유량의 변화와 그에 따른 평균오차율을 나타내었다.

Table. 4 Defect error to real data by ANN

	Defect error Rate for Mach No. (%)		Defect error Rate for Fuel flow (%)	
	No.	Error	Fuel	Error
Comp.	0.1	4.50	0.0310	4.10
	0.2	3.23	0.0328	3.40
	0.3	4.78	0.0346	5.38
	0.4	4.03	0.0364	7.10
	0.5	3.83	0.0382	7.86
Comp.-Turbine	0.1	15.11	0.0310	8.65
	0.2	11.75	0.0328	9.17
	0.3	7.13	0.0346	7.46
	0.4	3.30	0.0364	5.35
	0.5	7.66	0.0382	3.53
Power-Turbine	0.1	2.93	0.0310	4.35
	0.2	3.86	0.0328	2.27
	0.3	4.76	0.0346	1.04
	0.4	4.49	0.0364	2.75
	0.5	1.08	0.0382	5.44

Table. 4는 SVM에서 나눈 구간과 동일하게 마하수와 연료유량에 대하여 각각 -1%, -2%, ~, -10%까지 학습하고 테스트 데이터로 -0.9%, -1.2%, ~, -9.9%의 강제 결함을 주고 예측결과와의 결함오차율을 계산한 것이다. 마하수에 따른 압축기와 압축기 터빈, 그리고 동력터빈의 평균 결함오차율은 각각 4.07%, 8.99%, 3.42%로, 연료유량에 따른 평균결함 오차율은 각각 5.57%, 6.83%, 3.17%로 나타났다. 이는 참고문헌[2]의 결과와 비교해 볼 때 전체적으로 낮은 결함오차율을 보임으로써 본 알고리즘의 효용성을 보였다. 임의의 결함에 따른 예측치를 Fig. 2, Fig. 3, Fig. 4에 각 요소별로 나타내었다.

#### 4. 결 론

본 연구에서는 SVM과 인공신경망을 Hybrid로 사용하여 마하수 변화와 연료유량 변화에 따른 탈설계 영역에서 항공기용 터보 축 엔진의 결함을 예측하고 지상정지 상태와 비교하였다. SVM을 이용한 분류는 오분류 없이 정확히 결함위치를 판단하였고, 인공신경망을 이용한 학습과 결함 예측에서 결함 오차율은 마하수를 변화시켰을 때 압축기: 4.07%, 압축기터빈: 8.99%, 동력터빈: 3.42%, 연료유량을 변화시켰을 때 압축기: 5.75%, 압축기 터빈: 6.83%, 동력터빈: 3.17%로 신뢰할 만한 결함 예측 정확도를 보여주었다.

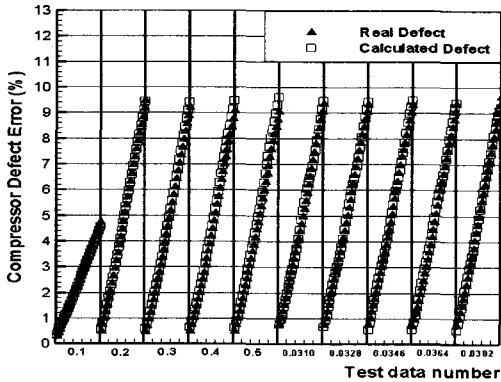


Fig. 2 Defect error of Compressor




Fig. 3 Defect error of Comp.-Turbine




Fig. 4 Defect error of Power-Turbine

#### 후 기

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

#### 참 고 문 헌

1. 박준철, 최동환, 노태성, 이창호, "Support Vector Machine과 인공신경망을 이용한 가스터빈 엔진의 결함 진단에 관한 연구", 한국 추진공학회지 10권 2호, 2006
2. Donald L. Simon, Takahisa Kobayashi, "A Hybrid Neural Network-Genetic Algorithm Technique for Aircraft Engine Performance Diagnostics", NASA/TM-2001-211088, 2001
3. K. Schittkowski, "QL: A Fortran Code for Convex Quadratic Programming - User's Guide, Version 2.1", University of Bayreuth, 2004
4. 이상명, 최원준, 노태성, 최동환, "SVM과 인공신경망을 이용한 고도 변화에 따른 가스터빈 엔진의 결함 진단 연구", 한국추진공학회 26회 춘계학술대회 논문집, 2006