

# SVM과 인공신경망을 이용한 고도 변화에 따른 가스터빈 엔진의 결함 진단 연구

이상명\* · 최원준\* · 노태성\*\* · 최동환\*\*

## Defect Diagnostics of Gas Turbine Engine with Altitude Variation Using SVM and Artificial Neural Network

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

### ABSTRACT

In this study, Support Vector Machine(SVM) and Artificial Neural Network(ANN) are used for developing the defect diagnostic algorithm of the aircraft turbo-shaft engine. Effect of altitude variation on the Defect Diagnostics algorithm has been included and evaluated. Separate Learning Algorithm(SLA) suggested with ANN to learn the performance data selectively after classifying the position of defects by SVM improves the classification speed and accuracy.

### 초 록

본 논문에서는 항공기용 터보 축 엔진의 결함 진단 알고리즘을 개발하기 위해 Support Vector Machine(SVM)과 인공신경망(ANN)을 이용하였다. SVM을 이용하여 결함 위치를 판별한 후 인공신경망이 선택적으로 학습하는 분할 학습 알고리즘(SLA)을 제안하였으며 이를 고도 변화에 따른 가스 터빈 엔진의 결함 진단에 적용하여 분류 속도 및 예측 정확률 개선 가능성을 확인하였다.

Key Words: Defect Diagnostics(결함 진단), Support Vector Machine(지지 벡터 장치), Artificial Neural Network(인공신경망), Separate Learning Algorithm(분할 학습 알고리즘), Altitude(고도)

### 1. 서 론

가스 터빈 엔진의 결함 진단 시스템은 항공기에 장착 및 운용중인 엔진의 각 요소들(압축비, 회전수, 연소가스 온도, 연료 유량 등)을 측정하고 경향성을 분석하여 엔진의 오작동 여부를 판

단한다. 결함의 확인 또는 초기 발견은 계획적인 정비를 가능하게 하며 정비 비용, 운용 경비를 줄이고, 운항중의 갑작스런 엔진 정지를 방지하여 항공기 운항의 안정성을 증대시키며 가용성 및 신뢰성을 향상 시킬 수 있다.

이러한 결함 진단 시스템을 개발하기 위한 기법으로 패턴인식 문제를 해결할 수 있는 인공신경망(ANN: Artificial Neural Network)이 있다. 인공신경망은 특정 정보들에 근거하여 아직 알지 못하는 집단이나 특징들을 예측하게 해주며

\* 학생회원, 인하대학교 항공공학과

\*\* 정회원, 인하대학교 항공공학과  
연락처, E-mail: dwchoi@inha.ac.kr

오류 역 전파 알고리즘(Error Back Propagation)을 이용한 다층 퍼셉트론(MLP: Multi-Layer Perceptron)이 사용된다[6].

지지 벡터 장치(SVM: Support Vector Machine)는 분류 분석 및 추정 등을 수행할 수 있는 알고리즘으로 매우 기능적이고 효율적인 기법이다. 명료한 이론적 근거에 그 기반을 두고 있어서 기존의 다층 퍼셉트론처럼 원하는 오차에 수렴시키기 위한 방대한 학습 시간이 필요치 않으며 더 적은 데이터로 더 효율적인 패턴 분류 성능을 보여준다.

따라서 본 연구에서는 방대한 데이터가 수반되는 탈설계점에서의 결함 위치를 판단해 내는 분류기로 SVM을 사용하였으며 분류되어진 데이터 집단별로 인공신경망을 사용하여 결함의 심각성 정도를 판단하는 접근방식을 택하였다.

## 2. 분할 학습 알고리즘 (SLA: Separate Learning Algorithm)

### 2.1 분할 학습 알고리즘의 필요성

본 논문에서는 신경망 학습의 분류 정확률과 수렴성을 높이기 위한 방법으로 분할 학습 알고리즘을 사용하였다. 기존 신경망의 문제점은 학습 데이터 수가 많아짐에 따라 수렴성 및 성능 저하가 현저하게 나타난다는 것이다. 또한 데이터의 수가 많아지고 비선형성이 증가하면 분류 정확률의 감소를 가져오게 된다. 이러한 단점을 보완하기 위해 학습 데이터를 분할하여 학습하는 방법을 사용하였다. 즉, 분할을 하기 위한 분류기로서 Multi-Class SVM을 사용하고, 그 결과 분할되어 선택된 영역의 학습 데이터 만을 가지고 신경망을 학습하게 된다.

### 2.2 지지 벡터 장치 (SVM)

SVM의 목적은 학습자료를 두 개의 부류로 구분하는 함수인 초평면(Hyper-plane)을 추정하는 것이다. 이러한 평면은 무수히 존재할 수 있지만 Fig. 1 에서 보이는 것처럼 두 집단 사이의 유클리드 거리(Margin)를 최대화 하도록 제한을 두어 하나의 유일한 평면만이 해로 나타나게 된다.




Fig. 1 Optimal Hyper-plane and Support Vector

초평면의 식인  $w \cdot x + b$ 를 구하여 최종적으로 얻은 결정 함수(Decision Function)인 Eq. 1을 이용하여 임의의 벡터가 속하는 집단을 분류해 내게 된다.

$$w = \sum_{i=1}^N a_i y_i x_i = \sum_{i \in SV} a_i y_i x_i \quad (1)$$

$$y_i \left( \sum_{i \in SV} a_i y_i (x_i \cdot x) + b \right) = 1 \quad (2)$$

$$f(x, a^*, b^*) = \text{sign}((w^* \cdot x) + b^*) \\ = \text{sign}\left(\sum_{i \in SV} a_i^* y_i (x_i \cdot x) + b^*\right) \quad (3)$$

비선형적인 입력데이터에 대한 분류 정확률을 높이기 위해 가우시안 커널 함수(Kernel Function)을 적용하였으며 다중 집단의 분류가 가능한 Multi-Class SVM으로 기본 알고리즘을 확장하였다.

### 2.3 인공 신경망 (ANN)

구성된 신경망은 가장 일반적인 형태의 신경망인 다층퍼셉트론(MLP)을 사용하였으며, 오류 역 전파 알고리즘을 적용하여 신경망을 학습하였다. 적용된 다층 퍼셉트론의 구조는 Fig. 2와 같다.

입력층으로 들어온 정보는 연결강도가 곱해져 모든 합을 구한 후 은닉층의 활성화 함수로 전달된다. 유사한 방법으로 은닉층의 계산 결과는 출력층으로 전달되어 신경망의 출력값( $O_{pk}$ )이 계산된다. 따라서 원하는 목표 출력값( $d_{pk}$ )에 대한 신경망의 출력값 오차는 Eq. 4로 정의 된다.

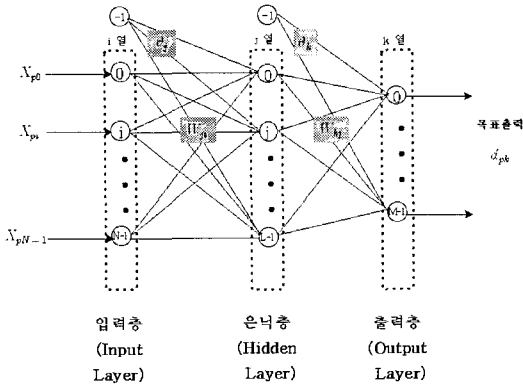


Fig. 2 Structure of ANN model

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_{k=1}^{M-1} (d_{pk} - O_{pk})^2 \quad (4)$$

이 평균오차를 최소화하기 위해 Eq. 5와 같이 연결강도( $W$ )를 변화시킨다.

$$W_{kj}(t+1) = W_{kj}(t) - \eta \frac{\partial E}{\partial W_{kj}} \quad (5)$$

위의 과정은 오차( $E$ )가 원하는 수렴 조건에 만족될 때까지 반복되며 최종적으로 얻은 학습 결과는 연결 강도에 저장되어 새로운 정보에 대한 판단에 적용된다.

### 3. 결함 진단 결과

#### 3.1 Multi-Class SVM에 의한 결함 위치 판단

Multi-Class SVM을 사용하여 고도 변화에 따른 엔진 단일 구성품 결함의 위치를 판단하기 위한 학습 데이터는 최대 운용 고도 16000ft 까지, 1600ft 씩 총 10개의 고도로 나누어서, 각 고도별 1.5~9.9%까지 결함을 준 29개의 데이터 집단인 총 290개의 데이터 집단으로 사용되었다. 데이터 획득은 GSP 프로그램을 이용하였다. Table.1은 SVM과 MLP 학습을 위해 사용된 Input Data와 Output Data이다.

Table 1 Input data and output data for training

	Input Data	Output Data
Training sets	$P_{13}/P_{12}, T_{13}/T_{12}, T_{17}/T_{10}$ (Sensed Parameter)	Deteriorated isentropic efficiency (Health Monitoring Parameter)

Table. 2는 각 요소별 분류율을 나타내고 있다. Multi-Class SVM은 오분류 없이 단일 결함의 위치를 판별해 내어 높은 분류 정확률을 확인할 수 있었으며, 학습시간은 총 21.2초로 빠른 분류 성능을 보였다.

Table 2 Extraction of Testing set and classification rate of Multi-Class SVM

	Altitude	Defect input for testing	Testing set number	Classification rate for testing
Compressor	1600ft,	-1.5%,	290 sets	100%
Compressor	3200ft	-1.8%,		
Turbine	~	-2.1%, ~	290 sets	100%
Power Turbine	14400ft, 16000ft	-9.3%, -9.6%, -9.9%	290 sets	100%

SVM으로 분류된 결함데이터 집단은 MLP를 이용하여 학습하였으며, 학습에 의해 구해진 목적함수를 이용하여 새로운 결함량을 정량적으로 예측할 수 있다. Fig. 3과 Fig. 4, Fig. 5는 각 고도에 따른 29개의 임의의 결함데이터와 MLP에서 예측한 효율 저하 데이터와의 비교 오차를 엔진 요소별로 RMS error로 표시한 것이다. 압축기에서는 5.68%의 최대오차(평균오차 4.24%)를, 압축기-터빈에서는 16.61%(평균오차 13.72%), 동력터빈에서는 10.96%의 최대오차(평균오차 6.57%)로 결함을 예측하였다. 압축기-터빈의 결함 예측 오차율이 상대적으로 높은 이유는 압축기와 Coupling Effect 때문이라 판단되며, Donald L. Simson[2]이 단일고도에서 예측한 압축기 오차율 5.37%, 압축기-터빈의 오차율 15.14%와 비교할 때, 운용고도 전 영역에 대한 본 연구의 결과가 높은 결함 예측 신뢰도를 가짐을 확인하였다.

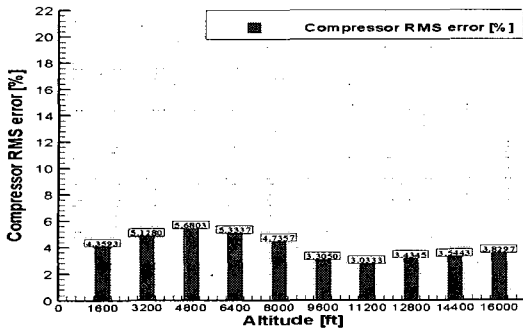


Fig. 3 RMS error of Compressor with Altitude variation

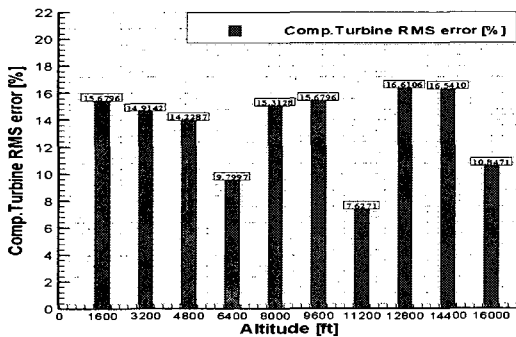


Fig. 4 RMS error of Compressor Turbine with Altitude variation

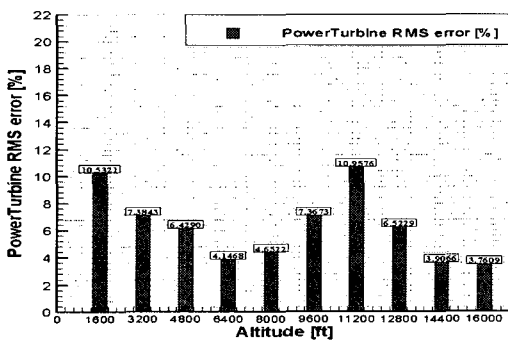


Fig. 5 RMS error of Power Turbine with Altitude variation

#### 4. 결 론

본 연구에서는 항공기용 터보 축 엔진의 고도 변화에 따른 엔진의 단일 결합 진단을 연구하였다. 기존의 신경망 학습에 분류 정확성을 높이기

위해서 SVM을 MLP와 함께 사용한, 분할 학습 알고리즘(SLA)을 사용하였다. 최대 운용 고도 (16000ft)를 10개의 고도로 나누어 학습하였으며, 엔진 각 요소별 결합을 예측하였다. 각 고도에 따른 결합데이터와 MLP에서 예측한 효율 저하 데이터와의 평균 오차가 압축기는 4.24%, 압축기-터빈은 13.72%, 동력 터빈은 6.57%로 높은 결합 예측 정확성을 가짐을 확인하였다.

후 기

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

#### 참 고 문 헌

1. 김기성, 황진수, "Support Vector Machine을 이용한 분류분석", 인하대학교 통계학과 대학원 석사 논문, 2003
2. Donald L. Simson, "A Hybrid Neural Network-Genetic Algorithm Technique for Aircraft Engine Performance Diagnostics", U.S Army Research Laboratory, Glenn Research Center, Cleveland, Ohio, 2001
3. K. Schittkowski, "QL: A Fortran Code for Convex Quadratic Programming - User's Guide, Version 2.1", University of Bayreuth, 2004
4. Christopher J.C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition", Kluwer Academic Publishers, Boston, pp.1-433
5. Stanislaw Osowski, Krzysztof Siwek, Tomasz Markiewicz, "MLP and SVM Networks - a Comparative Study", Proceedings of the 6th Nordic Signal Processing Symposium - NORSIG 2004, 2004