

가스터빈 엔진의 복합 결함 진단을 위한 SVM과 MLP의 성능 비교

박준철* · 노태성** · 최동환**

A Performance Comparison of SVM and MLP for Multiple Defect Diagnosis of Gas Turbine Engine

Juncheol Park* · Taeseong Roh** · Dongwhan Choi**

ABSTRACT

In this study, the defect diagnosis of the gas turbine engine was tried using Support Vector Machine(SVM). It is known that SVM can find the optimal solution mathematically through classifying two groups and searching for the Hyperplane of the arbitrary nonlinear boundary. The method for the decision of the gas turbine defect quantitatively was proposed using the Multi Layer SVM for classifying two groups and it was verified that SVM was shown quicker and more reliable diagnostic results than the existing Multi Layer Perceptron(MLP)

초 록

본 연구에서는 Support Vector Machine (SVM)을 이용하여 가스 터빈 엔진의 결함 진단을 시도하였다. SVM은 벡터 공간에서 임의의 비선형 경계인 Hyperplane을 찾아 두 개의 집합을 분류하는 방법으로 수학적으로 최적의 해를 찾을 수 있다고 알려져 있다. 이러한 이진 분류용 SVM을 다층으로 결합하여 가스 터빈의 결함을 정량적으로 판단해 내는 방법을 제안하였으며 기존의 Multi Layer Perceptron(MLP)보다 빠르고 신뢰성 있는 진단 결과를 보여주었음을 확인하였다.

Key Words : Support Vector Machine, Support Vector(지지 벡터), Hyperplane(초평면), Convex Quadratic Programming(볼록 이차 계획법), Kernel Function(커널 함수), MLP(다층 퍼셉트론)

1. 서 론

가스 터빈 엔진의 결함 진단 시스템은 항공기에 장착, 운용중인 엔진의 각 요소들(압축비, 회전수, 연소가스 온도, 연료 유량등)을 측정하여 경향성을 분석하여 엔진의 오작동을 판단한다. 결함의 확인 또는 초기 발견은 계획적인 정비를

* 정회원, 인하대학교 항공공학과

** 정회원, 인하대학교 항공공학과

연락처, E-mail: dwchoi@inha.ac.kr

가능하게 하며 정비비용, 운용경비, 운항중의 갑작스런 엔진 정지를 방지하여 항공기 운항의 안정성을 증대시키며 가동성 및 신뢰성을 향상시킬 수 있다.

이러한 결합 진단 시스템을 개발하기 위한 기법으로 패턴인식 문제를 해결할 수 있는 인공 신경망이 있다. 신경망은 특정 정보들에 근거하여 아직 알지 못하는 집단이나 특징들을 예측하게 해주며 오류 역전파 알고리즘(Error Back Propagation Algorithm)을 이용한 Multi-Layer Perceptron(MLP)이 사용된다[7]. 그러나 이 방법은 많은 데이터들이 필요하고 학습이 완료될 시간을 추정하기 어려우며 가장 큰 문제인 지역 최소점(Local Minima)에 빠져 전역 해에 도달이 어려울 수 있다는 문제점이 있다[7]. 이러한 문제를 해결하기 위해서 제안된 통계적 학습 이론에 기반을 둔 Support Vector Machine(SVM)은 분류 분석 및 추정 등을 수행할 수 있는 알고리즘으로 매우 기능적이고 효율적인 기법으로 평가받고 있다[4-6, 8]. 명료한 이론적 근거에 그 기반을 두고 있어서 기존의 MLP처럼 원하는 오차에 수렴시키기 위한 방대한 학습 시간이 필요치 않으며 더 적은 데이터로 더 효율적인 패턴 분류 성능을 보여주고 있다.

가스터빈의 고장 진단을 위한 알고리즘을 개발하기 위해 본래 이진 분류를 목적으로 개발된 SVM을 다층으로 구성하여 이진 분류 이상의 정량적인 패턴 분류를 할 수 있도록 알고리즘을 구현하였다. 이를 기존의 MLP의 성능과 비교하면서 연구를 수행하였으며 학습 속도(Training Time)와 분류율(Classification Error)에 있어서 SVM의 효율성을 보여 주었다[1].

2. SVM (Support Vector Machine)

2.1 이론적 배경

SVM의 목적은 학습 자료를 두개의 부류로 구분하는 함수인 초평면(Hyperplane)을 추정하는 것이다. 이러한 평면은 무수히 존재할 수 있지만

Fig 1.에서 보이는 것처럼 두 부류간의 모든 점들 사이의 거리를 최대화 하도록 제한을 두어 하나의 유일한 평면만이 해로 나타나게 한다.

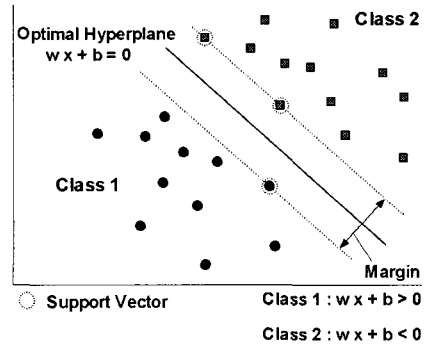


Figure 1. Optimal Hyperplane and Support Vector

n차원의 최적의 초평면은 n차원 방향벡터 w 와 기준벡터 b 로 $w \cdot x + b = 0$ 을 만족하는 점들의 집합을 의미한다. 학습 데이터의 출력으로 $\{-1, 1\}$ 처럼 이진 값만이 존재한다면 학습 데이터를

$$s_+ = \{x_i : (x_i, d_i), d_i = +1\} \text{ 과}$$

$$s_- = \{x_i : (x_i, d_i), d_i = -1\} \text{ 의}$$

두 집합으로 구분 지을 수 있다. 그러면 최적의 초평면은 다음의 식을 만족한다.

$$d_i [w \cdot x_i + b] \geq k > 0, i = 1, \dots, T$$

Figure 1.에서처럼 학습자료 중에서 초평면에 가장 가까운 점들을 Support Vector라 하고 상수 k 는 그 거리를 나타낸다. 초평면에서 거리 k 는

$$k = \frac{|w \cdot x + b|}{|w|} \geq \frac{1}{|w|}$$

이 된다. 따라서 주어진 데이터의 두 클래스에서 각각 초평면까지의 거리는 $\frac{2}{|w|}$ 가 되며 이 거리(Margin)을 최대로 하는 분리 초평면을 찾는 문제에 귀착된다. 이 문제는 다음과 같은 블록 최적화(Convex Optimization) 문제가 된다.

$$\text{Minimize } \frac{w^t w}{2}$$

$$\text{subject to } d_i (w^t x_i + b) \geq 1 \text{ for } i = 1, \dots, T$$

이 문제를 라그랑즈 배수(Lagrange multiplier)로 쌍대화시키면 아래의 Quadratic Programming (QP)문제가 된다.

$$Q(\alpha) = \sum_{i=1}^T \alpha_i - \frac{1}{2} \sum_{i=1}^T \sum_{j=1}^T \alpha_i \alpha_j d_i d_j x_i^t x_j^t \quad (1)$$

subject to $\sum_{i=1}^T \alpha_i d_i = 0, \alpha_i \geq 0$

하지만 선형 분리 경계면으로 완전히 구분할 수 없는 경우에는 비선형 패턴을 분리하기 위하여 비선형 패턴의 입력 공간을 다음과 같은 선형 패턴의 특징 공간(Feature Space)으로 전환한다.

$$x_i \rightarrow \phi(x_i)$$

$$K(x_i, x_j) = \phi(x_i) \phi(x_j)$$

$K(x_i, x_j)$ 은 커널(Kernel)함수이며 Eq. 1에 대입하여 다시 표현하면 다음과 같다.

$$Q(\alpha) = \sum_{i=1}^T \alpha_i - \frac{1}{2} \sum_{i=1}^T \sum_{j=1}^T \alpha_i \alpha_j d_i d_j K(x_i, x_j)$$

subject to $\sum_{i=1}^T \alpha_i d_i = 0, 0 \leq \alpha_i \leq C$

여기서 C는 Penalty Parameter이다. 라그랑즈 배수 α_i 를 구하기 위해 Quadratic Programming(QP)을 풀 수 있는 QL code를 사용하였다[3].

일반적으로 쓰이는 커널(Kernel)의 종류에는 다음과 같은 세 가지가 주로 이용된다.

1. Polynomial : $K(x_i, x_j) = (1 + x_i^t x_j^t)^p$
2. Gaussian RBF : $K(x_i, x_j) = e^{-\frac{|x_i - x_j|^2}{2\sigma^2}}$
3. Hyperbolic : $K(x_i, x_j) = \tanh(\beta_0 x_i^t x_j^t + \beta_1)$

이렇게 구해진 Support Vector에 대한 α_i^* 와 기준벡터 b^* 를 가지고 임의의 입력 벡터는 초평면과의 거리 $d(x)$ 의 부호, $f(x)$ 에 따라 분류될 수 있다.

$$d(x) = \sum_{\text{support vector}} \alpha_i^* d_i K(x_i, x_j) + b^*$$

$$f(x) = \text{sign}(d(x))$$

이와 같이 커널(Kernel)을 이용함으로써 새로

운 $Q(\alpha)$ 와 $d(x)$ 를 가지고 복잡한 고차 확장이 필요 없이 원래의 공간의 내적만으로 고차원 분류 경계를 학습하고, 입력 벡터를 분류할 수 있다.

22 다층 SVM을 이용한 결함 진단 과정

가스터빈의 모델은 GSP 상용프로그램을 이용하여 터보 축 엔진 결함에 대한 성능저하 Parameter들을 Table 1의 방법으로 추출하였으며 지상 정지 상태의 조건이다.

Table 1. Defect Data Extraction

학습 데이터	(dn_c)	(dn_{ct})	(dn_{pt})	총 데이터 개수
$\pi_c, \tau_c,$ τ_t, SHP	0%, -0.5%, -5%, -10% (4개)	0%, -0.5%, -5%, -10% (4개)	0%, -0.5%, -5%, -10% (4개)	4*4*4 =64개

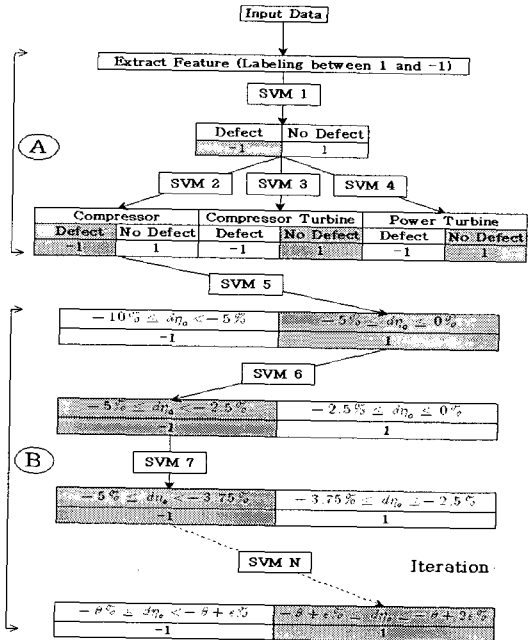


Fig. 2 Algorithm for Multiple Defect Diagnosis

SVM은 본래 이진 분류를 위한 알고리즘으로 개발되었기 때문에 가스터빈 엔진의 정상 작동

과 오작동 상태를 효율적으로 구분해 낼 수 있다. 그러나 정량적인 효율 저하 예측을 위해서 SVM을 Fig. 2와 같은 방법으로 다층으로 연결하였다. A 구간은 결함의 위치를 판단, B 구간은 정량적인 효율 저하량을 판단하는 과정이며 단일 및 복합 결함을 동시에 진단할 수 있다. Table 2는 MLP와 SVM의 구조를 나타낸다

Table 2. Structure and Coefficient of the MLP and SVM

Method	Structure	Coefficient
MLP 1	30-10-3	$\eta = 0.8, \beta = 0.5, Tol = 10^{-4}$
MLP 2	30-10-7-3	$\eta = 0.8, \beta = 0.5, Tol = 10^{-5}$
SVM	Gaussian Kernel	$\sigma = 0.1, C = 100$

Table 3. Testing Result of the MLP and SVM

Method	Classification Rate	Learning Time
MLP 1	95.8%	15677 sec
MLP 2	96.4%	1706 sec
SVM	99.7%	2.43 sec

Table 3은 SVM과 MLP의 결함 진단에 대한 비교 결과를 보여주며 SVM이 빠른 Learning Time과 더 정확한 분류율을 보여주고 있다. Testing Data로는 단일, 복합 결함을 포함한 총 500개의 임의의 결함 데이터를 사용하였다.

3. 결 론

본 논문에서는 가스 터빈 엔진의 결함 진단을 위해 기존의 신경 회로망과는 다른 통계적 학습 방법에 기반한 Support Vector Machine(SVM)이라는 기법을 제시하였고 동일한 학습 데이터를 가지고 학습 하였을 경우 신경 회로망보다 빠른 학습속도와 보다 정확한 분류율을 보여주었다. 또한 이진 분류를 목적으로 개발된 SVM을 다층으로 연결하여 정량적인 수치를 예측할 수 있음을 제안하였다. 나아가 다양한 탈설계 조건(고도, 속도, 연료 유량 등)에 따른 복합적인 결함 진단

을 위한 연구가 진행되고 있다.

후 기

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

참 고 문 헌

1. Stanislaw Osowski, Krzysztof Siwek, Tomasz Markiewicz, "MLP and SVM Networks - a Comparative Study", Proceedings of the 6th Nordic Signal Processing Symposium - NORSIG 2004
2. Christopher J.C. Burges, "A Tutorial on Support Vector Machines for Pattern REcognition", Kluwer Academic Publishers, Boston, pp.1-433
3. K. Schittkowski, "QL: A Fortran Code for Convex Quadratic Programming - User's Guide, Version 2.1", University of Bayreuth, 2004
4. 김한성, 권영희, 차성덕, "SVM 기반의 효율적인 신분위장기법 탐지", 정보보호학회 논문집, 제 13권, 2003
5. 이용민, 최경현, "Weighted Support Vector Machine", 한국과학기술/대한산업공학회 춘계 공동학술 대회, 2001
6. 김기성, 황진수, "Support Vector Machine을 이용한 분류분석", 인하대학교 통계학과 대학원석사 논문, 2003
7. 오장민, "신경망 기반의 자연 언어 문서 검색", 서울대학교 컴퓨터공학과 대학원 논문, 1999
8. 어장준, "Support Vector Machine을 이용한 문서 정보 기반의 단백질 기능 분류", 서울대학교 컴퓨터공학부 대학원 석사 논문, 2004