

Support Vector Machine과 인공신경망을 이용한 가스터빈 엔진의 결함 진단에 관한 연구

박준철* · 노태성** · 최동환** · 이창호***

Defect Diagnostics of Gas Turbine Engine Using Support Vector Machine and Artificial Neural Network

Jun-cheol Park* · Tae-seong Roh** · Dong-whan Choi** · Chang-ho Lee***

ABSTRACT

In this Paper, Support Vector Machine(SVM) and Artificial Neural Network(ANN) are used for developing the defect diagnostic algorithm of the aircraft turbo-shaft engine. The system that uses the ANN falls in a local minima when it learns many nonlinear data, and its classification accuracy ratio becomes low. To make up for this risk, the Separate Learning Algorithm(SLA) of ANN has been proposed by using SVM. This is the method that ANN learns selectively after discriminating the defect position by SVM, then more improved performance estimation can be obtained than using ANN only. The proposed SLA can make the higher classification accuracy by decreasing the nonlinearity of the massive data during the training procedure.

초 록

본 논문에서 항공기용 터보 축 엔진의 결함 진단 알고리즘을 개발하기 위해 Support Vector Machine(SVM) 과 인공신경망(ANN)을 이용하였다. 신경망을 이용한 시스템은 비선형성이 과도한 데이터를 학습할 때 지역 최소점(Local Minima)에 빠져 분류 정확률이 낮아질 수 있다. 이러한 위험성을 보완하기 위해 SVM에 의한 ANN의 분할 학습 알고리즘(SLA)을 제안하였다. 이것은 SVM을 이용하여 결함 위치를 판별 한 후 신경망이 선택적으로 학습을 하는 방법으로 학습 데이터의 비선형성을 줄여 분류 정확률을 높이기 때문에 신경망을 단독으로 사용할 때보다 개선된 성능을 보여주었다.

Key Words : Support Vector Machine(지지 벡터 기계), Artificial Neural Network(인공 신경망), Separate Learning Algorithm(분할 학습 알고리즘)

† 2006년 3월 6일 접수 ~ 2006년 5월 10일 심사완료

* 학생회원, 인하대학교 항공공학과

** 정회원, 인하대학교 항공공학과

*** 정회원, 한국항공우주연구원 스마트무인기기술개발사업단
연락처, E-mail: dwchoi@inha.ac.kr

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 오작동을 판단한다. 결함의 확인 또는 초기 발견은 계획적인 정비를 가능하게 하며 정비비용, 운용경비를 줄이고 운항중의 갑작스런 엔진 정지를 방지하여 항공기 운항의 안정성을 증대시키며 가동성 및 신뢰성을 향상 시킬 수 있다.

이러한 결함 진단 시스템을 개발하기 위한 방법으로 패턴인식 문제를 해결할 수 있는 인공신경망(ANN : Artificial Neural Network)이 있다. 인공 신경망은 특정 정보들에 근거하여 아직 알지 못하는 집단이나 특징들을 예측하게 해주며 오류 역 전파 알고리즘(Error Back Propagation Algorithm)을 이용한 다층 퍼셉트론(MLP : Multi-Layer Perceptron)이 사용된다. 그러나 이 방법은 많은 데이터들이 필요하고 학습이 완료될 시간을 추정하기 어려우며 가장 큰 문제인 지역 최소점(Local Minima)에 빠져 전역 해에 도달이 어려워 분류 정확률이 떨어지는 문제점이 있다[1, 2]. 이러한 문제를 보완하기 위해서 제안된 통계적 학습 이론에 기반을 둔 지지 벡터 기계(SVM : Support Vector Machine)는 분류 분석 및 추정 등을 수행할 수 있는 알고리즘으로 매우 기능적이고 효율적인 기법으로 평가받고 있다. 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 보여주고 있다[3, 4, 7].

가스터빈의 고장 진단을 위한 알고리즘을 개발하기 위해 본래 이진 분류를 목적으로 개발된 Two-Class SVM을 Multi-Class SVM으로 확장하여 결함의 위치를 판단하기 위한 분류기로 사용하였다. 이러한 판단을 근거로 본 논문에서는 신경망을 이용하여 각각의 결함 위치에 따라 나누어 학습하는 분할 학습 알고리즘을 제안하였으며 모든 결함 데이터를 한 번에 학습하는 것보다 분류 정확률 및 수렴성에 있어서 개선된 성능을 보여주었다.

2. 인공 신경망(ANN)

구성된 신경망은 현재 가장 일반적인 형태의 신경망인 다층 퍼셉트론을 사용하였으며 오류 역 전파 알고리즘을 적용하여 신경망을 학습하였다. 적용된 다층 퍼셉트론의 구조는 Fig. 1과 같다.

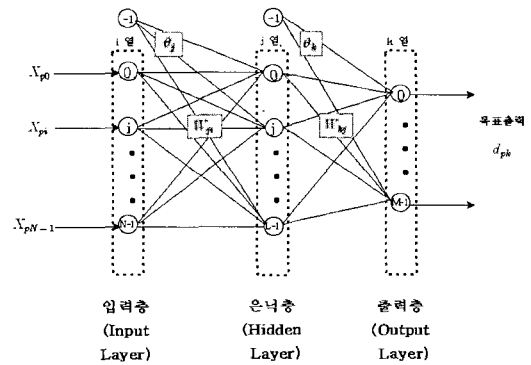


Fig. 1 Structure of ANN model

입력층으로 들어온 정보(X_p)는 연결강도(W)와 곱해서 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 오차(E)는 Eq. 1로 정의된다.

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

이 평균오차를 최소화하기 위해 Eq. 2와 같이 연결강도(W)를 변화시킨다.

$$W_{kj}(t+1) = W_{kj}(t) - \eta \frac{\partial E}{\partial W_{kj}} \quad (2)$$

위의 과정은 오차(E)가 원하는 수렴조건에 만족될 때까지 반복되며 최종적으로 얻은 학습 결과는 연결강도(W)와 임계치(θ)에 저장되어 새로운 정보에 대한 판단에 적용된다. 프로그램 구현을 위한 흐름도는 Fig. 2와 같다.

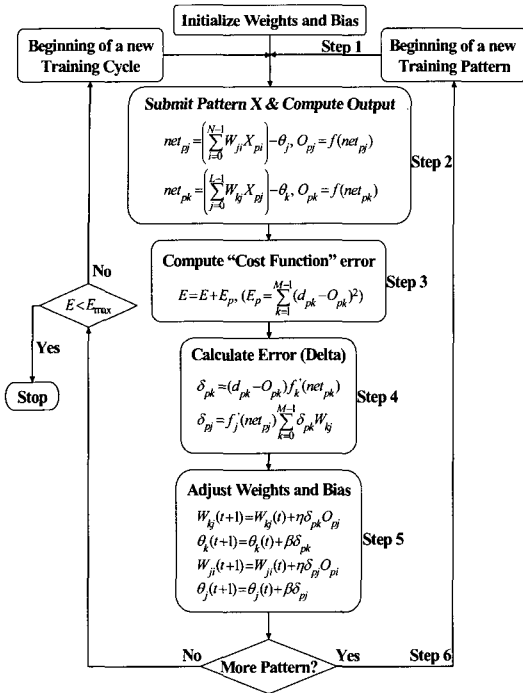


Fig. 2 Process of MLP Learning

신경망의 수렴성 향상을 위하여 모멘텀 기법을 사용하였으며 출력층의 활성화 함수는 Eq. 3의 시그모이드 함수를, 은닉층은 Eq. 4의 탄젠트 시그모이드 함수를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-bx}} \tag{3}$$

$$f(x) = \frac{1 - e^{-bx}}{1 + e^{-bx}} \tag{4}$$

3. 지지 벡터 기계(SVM)

SVM의 목적은 학습 자료를 두개의 부류로 구분하는 함수인 초평면(Hyper-plane)을 추정하는 것이다. 이러한 평면은 무수히 존재할 수 있지만 Fig. 3에서 보이는 것처럼 두 집단 사이의 유클리드 거리(Margin)를 최대화 하도록 제한을 두어 하나의 유일한 평면만이 해로 나타나게 한다.




Fig. 3 Optimal Hyper-plane and Support Vector

최적의 분류 초평면은 다음과 같은 두 가지 조건을 만족시키면서 경계면을 구하게 된다.

- ① 두 집단이 각 클래스의 경계선 안쪽에 있을 조건
- ② 두 집단의 경계선 사이의 거리(Margin)를 최대화할 조건

위 두 조건을 정리하면 Eq. 5가 된다.

$$\text{Minimize } \frac{\|w\|}{2} \simeq \frac{\|w\|^2}{2} = \frac{(w \cdot w)}{2} \tag{5}$$

$$\text{subject to } y_i((w \cdot x_i) + b) \geq 1 \text{ for } \forall i$$

위 식을 풀기위한 라그랑지 목적함수는 Eq. 6과 같으며 그 해인 라그랑지 승수 α_i 를 구하기 위해 QP solver[5]를 사용하였다.

$$\text{Maximize } Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \tag{6}$$

$$\text{subject to } \sum_{i=1}^N \alpha_i y_i = 0, \alpha_i \geq 0 \text{ for } \forall i$$

Eq. 7과 Eq. 8을 사용하여 초평면의 식인 $w \cdot x + b$ 를 구하며 최종적으로 얻은 결정 함수(Decision Function)인 Eq. 9를 이용하여 임의의 벡터가 속하는 집단을 분류해 내게 된다.

$$w = \sum_{i=1}^N \alpha_i y_i x_i = \sum_{i \in SV} \alpha_i y_i x_i \tag{7}$$

$$y_i \left(\sum_{i \in SV} \alpha_i y_i (x_i \cdot x) + b \right) = 1 \tag{8}$$

$$f(x, \alpha^*, b^*) = \text{sign}((w^* \cdot x) + b^*) = \text{sign} \left(\sum_{i \in SV} \alpha_i^* y_i (x_i \cdot x) + b^* \right) \tag{9}$$

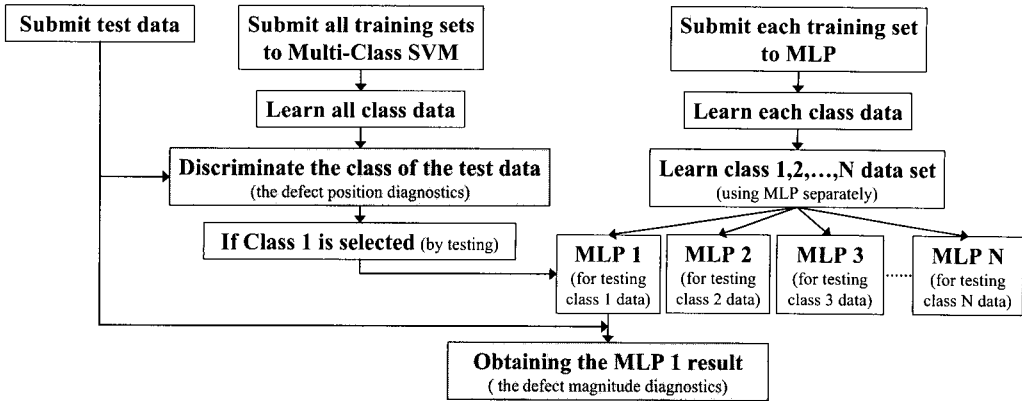


Fig. 5 Separate Learning Algorithm of MLP by Multi-Class SVM Classifier

비선형적인 입력데이터에 대한 분류 정확률을 높이기 위해 가우시안 커널 함수(Kernel Function)를 적용하였으며 다중 집단의 분류가 가능한 Multi-Class SVM으로 기본 알고리즘을 확장하였다. Fig. 4는 Clarkson과 Moreno에 의해 제안된 “One vs. One”형식의 Multi-Class SVM[6]이다.

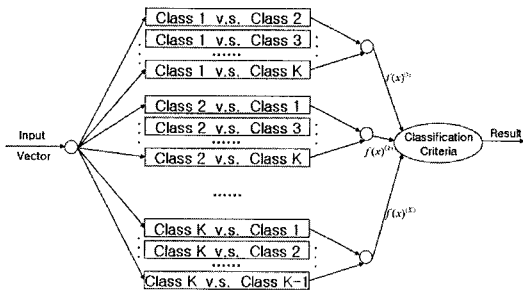


Fig. 4 Structure of “One vs. One” Multi-Class SVM Classifier

4. 분할 학습 알고리즘

4.1 분할 학습 알고리즘의 필요성

본 논문에서는 신경망 학습의 분류 정확률과 수렴성을 높이기 위한 방법으로 분할 학습 알고리즘을 제안하였다. 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 학습데이터를 분할하여 학습하는 방법을 제안하였다. 즉, 분할을 하기위한 분류기로서 Multi-Class SVM을 사용하고, 그 결과 분할되어 선택된 영역의 학습데이터만을 가지고 신경망을 학습하게 된다. 분할 학습 알고리즘(SLA : Separate Learning Algorithm)의 구조 및 데이터의 흐름도는 Fig. 5와 같다.

5. 가스 터빈 엔진의 결함 진단에 적용

5.1 대상 엔진 선정 및 모델링

Figure 6은 본 논문에서 대상엔진으로 선정된 터보 축 엔진 모델로써 GSP 상용 프로그램을 사용하여 구현하였다. 엔진의 구성품 맵은 GSP 프로그램 내에서 제공하는 터보 샤프트 압축기 맵과 터빈 맵을 사용하였다.

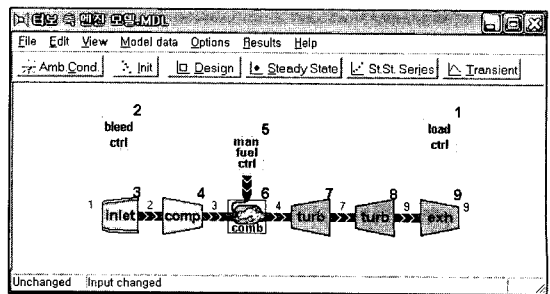


Fig. 6 Turbo-Shaft Engine Model using GSP Program

Table 1은 대상 엔진의 설계점이다.

Table 1. Design Point of the Turbo-Shaft Engine

Variable	Value
Atmospheric condition	Sea Level Static Standard Condition
Mass flow rate(kg/s)	2.008
Fuel flow rate(kg/s)	0.0402
Compressor PR	8.037
TIT(K)	1254
Shaft horse power(hp)	416
SFC(kg/kW hr)	0.3478
Gas generator rotational speed(100% RPM)	54850
Propeller rotational speed(100% RPM)	6000
Compressor efficiency	0.8028(isentropic)
Compressor turbine eff.	0.9209(isentropic)
Power turbine eff.	0.9206(isentropic)

5.2 단일 결함 진단 과정

결함 진단의 범위는 엔진에 단일 구성품 결함이 발생한 경우에 한하며 결함 발생 위치는 압축기, 압축기 터빈, 동력 터빈으로 선정하였다.

신경망의 학습을 위한 입력 데이터로 사용될 성능 진단 변수(Performance Monitoring Parameter)로는 압축기 전 압력비(P_{t3}/P_{t2}), 압축기 전 온도비(T_{t3}/T_{t2}), 동력터빈 전 온도비(T_{t7}/T_{t6}), 축 마력(SHP)을 사용하였고, 목표 출력 데이터인 측정 변수(Sensed Parameter)로는 압축기, 압축기 터빈, 동력 터빈의 저하된 등 엔트로피 효율을 각각 사용하였다. SVM은 학습 데이터로 신경망과 동일한 성능 진단 변수를 입력 데이터로 사용하고 각 데이터 set에 맞는 클래스로 2진 분류하기 위해 레이블($y = 1$ or -1)을 목표 출력 데이터로 사용하였다.

Table 2. The Range of Defect Diagnostic

	Class 1	Class 2	Class 3	Class 4
State	Normal state	Abnormal state (Single Defect)		
Position	Normal state	Abnormal state (Single Defect)		
Compressor	-	○	-	-
Comp. Turbine	-	-	○	-
Power Turbine	-	-	-	○

○ : Defect, - : Normal

Table 2는 정상 상태(Normal state)와 비정상

상태(Abnormal state)를 합하여 모두 네 종류의 엔진 상태가 존재함을 보여준다.

Table 3. Training Set Extraction from Turbo-Shaft Engine Model

	Defect input for training	Each training set number	Total training set number
Normal state	0%	1 Set	34 Sets
Compressor	-0.5%, -1~-10%	11 Sets	
Compressor Turbine	-0.5%, -1~-10%	11 Sets	
Power Turbine	-0.5%, -1~-10%	11 Sets	

Table 3은 GSP로 구현한 터보 축 엔진 모델로부터 각 구성품에 효율 저하량을 주어 총 34개의 학습데이터 set을 추출하는 방법을 보여준다.

6. 결함 진단 결과

6.1 Multi-Class SVM에 의한 결함 위치 판단

Multi-Class SVM을 사용하여 엔진 단일 구성품 결함의 위치를 판단하기 위한 학습 데이터는 총 34개가 사용되었으며 Table 4와 같이 총 90개의 검증용 자료 집단이 사용되었다.

Table 4. Testing Set Extraction and Classification Rate of Multi-Class SVM

	Defect input for testing	Testing set number	Classification rate for testing
Compressor		30 sets	100%
Compressor Turbine	-0.3%, -0.6%, -0.9%, -9.3%, -9.6%	30 sets	100%
Power Turbine	-9.9%	30 sets	100%

Multi-Class SVM은 오 분류없이 단일 결함의 위치를 판별해 내어 높은 분류 정확률을 확인할 수 있었으며 학습시간은 총 2.92초로 빠른 분류 성능을 보여 주었다.

6.2 신경망에 의한 결함 크기 판단

신경망을 이용한 단일 결함 진단 결과를 두 단계로 적용하여 비교하였다. 첫 단계는 분할 학

습 알고리즘을 적용하지 않고 신경망을 학습한 경우이며 두 번째는 분할 학습 알고리즘(SLA)을 사용하여 학습한 경우이다.

Table 5. Training sets for MLP Learning

	Input Data	Output Data
Training sets	$P_{13}/P_{12}, T_{13}/T_{12},$	Deteriorated
	$T_{17}/T_{19}, SHP$ (Sensed Parameter)	isentropic efficiency (Health Monitoring Parameter)

Table 5는 신경망의 학습데이터로 이용된 입, 출력 데이터이다.

6.2.1 일반적인 신경망 학습

분할 학습 알고리즘을 사용하지 않고 34개의 학습 데이터를 모두 사용하여 학습하기 위한 신경망의 구조는 Fig. 7과 같다. 결함의 위치를 모르기 때문에 압축기, 압축기 터빈, 동력 터빈의 단일 결함에 대한 데이터가 모두 필요하다. 신경망 학습 시 구성품 하나에 결함이 있으면 나머지 구성품의 결함은 0으로 두고 계산한다.

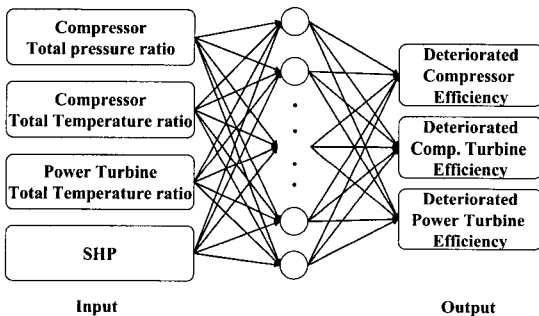


Fig. 7 Standard MLP Structure for Single Defect Diagnostic

신경망의 구조는 4개의 입력층 노드, 5개의 은닉층 노드, 3개의 출력층 노드로 구성되어 있으며 허용오차(E_{max})는 10^{-5} , 10^{-6} , 10^{-7} 으로 선정하여 각각 학습을 수행하였다.

다음은 엔진의 단일 구성품 결함에 대한 예측 결과이며 학습되지 않은 90개의 자료 집단으로 검증하였다. 결함이 없는 구성품의 효율은 일정하며 정상적인 성능을 내고 있음을 말해준다.

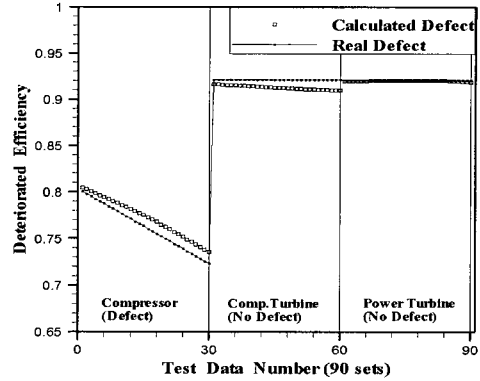


Fig. 8 Result of Standard MLP for Compressor Defect Diagnostic ($E_{max} = 10^{-5}$)

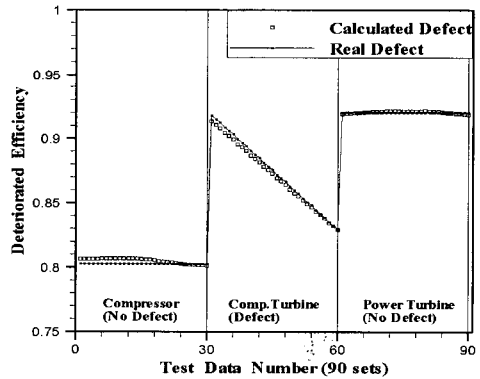


Fig. 9 Result of Standard MLP for Compressor Turbine Defect Diagnostic ($E_{max} = 10^{-5}$)




Fig. 10 Result of Standard MLP for Power Turbine Defect Diagnostic ($E_{max} = 10^{-5}$)

6.2.2 분할 학습 알고리즘(SLA)에 의한 신경망 학습

Figure 11은 분할 학습 알고리즘에 의한 신경망의 형태이다. 기존의 신경망과 달리 단일 구성품의 결함을 판단하는 신경망이 각각 독립적으로 학습을 하게 된다.

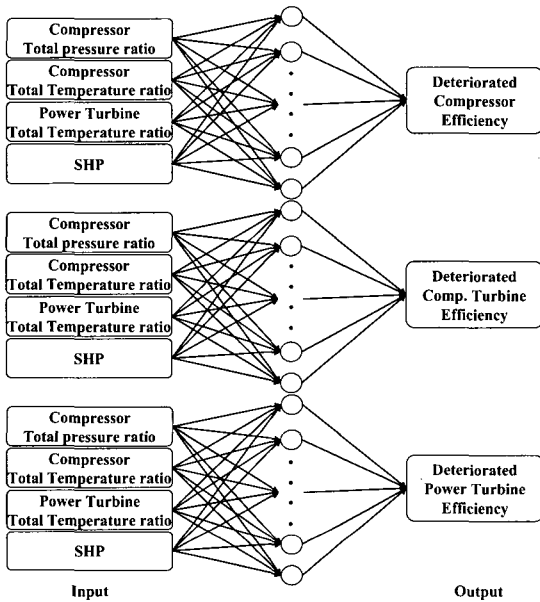


Fig. 11 Proposed MLP(SLA) Structure for Single Defect Diagnostic

이 방법은 Multi-Class SVM에 의하여 결함이 발생한 구성품을 판별해 낸 후, 총 34개의 학습 데이터 중에서 결함이 발생한 구성품에 대한 데이터 11개와 정상 상태의 데이터 1개를 합하여 총 12개의 학습데이터를 가지고 각각의 신경망을 학습한다. 신경망은 독립적으로 각각 세 번 학습하게 되며 결함이 발생하지 않은 구성품에 대한 데이터가 필요치 않기 때문에 출력층의 노드는 1개이다. 분할 학습 알고리즘을 사용한 이 신경망은 4-5-1 구조로 되어 있으며 허용오차 (E_{max})는 10^{-5} , 10^{-6} , 10^{-7} 으로 설정하여 학습하였다. 분할 학습 알고리즘의 장점 중 하나는 신경망이 독립적으로 학습하게 되기 때문에 학습률이나 초기치 등, 성능에 큰 영향을 미치는 모수들의 조사를 각각 시도할 수 있다는 것이다.




Fig. 12 Result of Proposed MLP for Compressor Defect Diagnostic ($E_{max}=10^{-5}(L), 10^{-6}(R)$)




Fig. 13 Result of Proposed MLP for Comp. Turbine Defect Diagnostic ($E_{max}=10^{-5}(L), 10^{-6}(R)$)




Fig. 14 Result of Proposed MLP for Power Turbine Defect Diagnostic ($E_{max}=10^{-5}(L), 10^{-6}(R)$)

분할 학습 알고리즘을 사용하여 학습한 결과 기존의 신경망이 수렴하지 못한 $E_{max} = 10^{-6}$ 까지 학습이 가능하였다. 따라서 Fig. 12, 13, 14의 우측 그래프에서 보이듯이 효율 저하 예측 오차가 감소했음을 알 수 있다. Table. 6은 허용 오차(E_{max})를 10^{-5} , 10^{-6} , 10^{-7} 으로 변화시키면서 비교한, 기존 신경망과 제안된 분할 학습 알고리즘의 결과이다. 분할 학습 알고리즘에 의한 결함

Table 6. Result Comparison of Standard MLP and Proposed MLP for Single Defect Diagnostic

		Compressor	Comp. Turbine	Power Turbine	Training time
		Mean error	Mean error	Mean error	
$E_{\max} = 10^{-5}$	Standard MLP	0.694%	0.544%	0.087%	37.4 sec
	MLP using SLA	0.132%	0.118%	0.119%	4.2 sec
$E_{\max} = 10^{-6}$	Standard MLP	-			-
	MLP using SLA	0.054%	0.032%	0.037%	5.8 sec
$E_{\max} = 10^{-7}$	Standard MLP	-			-
	MLP using SLA	-	-	0.012%	2.5 sec

E_{\max} : Tolerance, SLA : Separate Learning Algorithm, - : No Convergence

예측 정확도와 학습 시간이 기존 신경망보다 향상된 것을 알 수 있다.

원해주신 산업자원부 및 한국항공우주연구원에 감사드립니다.

7. 결 론

본 연구에서는 항공기용 터보 축 엔진의 단일 결함 진단을 위하여 기존의 신경망 학습에 앞서 기계 학습인 SVM을 이용하여 결함의 위치를 판단해 내는 분할 학습 알고리즘을 제안하였다.

1) SVM에 의한 결함 위치의 판단으로 신경망이 학습해야할 데이터의 수와 비선형성을 감소시켜 수렴성을 향상시킬 수 있었다.

2) SVM으로 학습한 결과 단일 결함이 발생한 구성품의 위치를 오 분류 없이 판단해 내었으며 결함 진단을 위한 알고리즘으로서의 활용 가능성을 확인하였다.

3) 분할 학습 알고리즘(SLA)을 사용하여 신경망을 학습한 결과 기존의 신경망 보다 학습 속도를 향상시키고 오차를 감소시킬 수 있음을 확인하였다.

4) 분할 학습 알고리즘(SLA)은 개별적인 학습으로 기존의 신경망보다 허용오차(E_{\max})를 더 낮출 수 있어 특정한 구성품의 결함 예측에 대한 오차를 줄일 수 있음을 확인하였다.

후 기

본 연구는 스마트 무인기 기술개발사업의 일환으로 지원 수행된 연구의 일부이며, 연구를 지

참 고 문 헌

- 오장민, "신경망 기반의 자연 언어 문서 검색", 석사학위논문, 서울대학교 컴퓨터공학과, 1999
- 강문식, 이상용, "데이터 마이닝을 위한 경쟁 학습모델과 BP 알고리즘을 결합한 하이브리드형 신경망", 한국정보기술응용학회, 제9권 2호, 2002, pp.1-16
- 김기성, 황진수, "Support Vector Machine을 이용한 분류분석", 인하대학교 통계학과 대학원 석사 논문, 2003
- 어상준, "Support Vector Machine을 이용한 문서 정보 기반의 단백질 기능 분류", 석사학위논문, 서울대학교 컴퓨터공학과, 2004
- K. Schittkowski, "QL: A Fortran Code for Convex Quadratic Programming - User's Guide, Version 2.1", University of Bayreuth, 2004
- Christopher J.C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition", Kluwer Academic Publishers, Boston, pp.1-433
- Stanislaw Osowski, Krzysztof Siwek, Tomasz Markiewicz, "MLP and SVM Networks - a Comparative Study", Proceedings of the 6th Nordic Signal Processing Symposium - NORSIG 2004