

SVM-인공신경망 알고리즘을 이용한 고도 변화에 따른 가스터빈 엔진의 결함 진단 연구

이상명* · 최원준* · 노태성** · 최동환***

Defect Diagnostics of Gas Turbine with Altitude Variation Using Hybrid SVM-Artificial Neural Network

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

ABSTRACT

In this study, Hybrid Separate Learning Algorithm(SLA) consisting of Support Vector Machine(SVM) and Artificial Neural Network(ANN) has been used for developing the defect diagnostic algorithm of the aircraft turbo-shaft engine in the off-design range considering altitude variation. Although the number of learning data and test data highly increases more than 6 times compared with those required for the design condition, the proposed defect diagnostics of gas turbine engine using SLA was verified to give the high defect classification accuracy in the off-design range considering altitude variation.

초 록

본 논문에서는 고도 변화만을 고려한 탈설계 영역에서 항공기용 터보 축 엔진의 결함 진단을 위해 지지 벡터 장치(SVM)과 인공신경망(ANN)을 Hybrid로 사용한 분할 학습 알고리즘을 사용하였다. 정상 정지 상태에서보다 학습 데이터와 테스트 데이터 수가 크게 증가하지만, 분할 학습 알고리즘을 이용한 가스터빈 엔진의 결함 진단이 고도 변화를 고려한 탈설계 영역에서도 높은 결함 예측 정확성을 가짐을 확인하였다.

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

1. 서 론

가스 터빈 엔진의 결함 진단 시스템의 개발은 안정적인 항공기 운항뿐 아니라 예측적 정비수

† 2006년 8월 16일 접수 ~ 2007년 2월 11일 심사완료

* 학생회원, 인하대학교 항공공학과

** 중신회원, 인하대학교 항공공학과

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

리 측면에서 효율화와 경제성 제고를 유도할 수 있는 차세대 기술로서 각광을 받고 있다. 결합 진단 시스템은 항공기에 장착, 운용중인 엔진의 각 성능인자들(압축비, 회전수, 연소가스 온도, 연료 유량 등)을 측정하고 경향성을 분석하여 엔진의 오작동 여부를 판단한다. 결합의 확인 또는 초기 발견은 계획적인 정비를 가능하게 함으로써 정비 비용, 운용 경비를 줄이고, 운항중의 갑작스런 엔진 정지를 방지하여 항공기 운항의 안정성을 증대시키며 가용성 및 신뢰성을 향상시킬 수 있다.

이러한 결합 진단 시스템을 개발하기 위한 기법으로 인공신경망(ANN: Artificial Neural Network)과 지지 벡터 장치(SVM: Support Vector Machine)를 Hybrid로 사용하였다. 인공신경망은 특정 정보들에 근거하여 아직 알지 못하는 집단이나 특징들을 예측하게 해주며, 오류역전파 알고리즘(Error Back Propagation)을 이용한 다층퍼셉트론(MLP: Multi-Layer Perceptron)이 사용되었다[1]. 지지 벡터 장치(SVM)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 많은 학습 시간이 필요치 않으며 적은 데이터로 보다 효율적인 패턴 분류 성능을 보여준다.

인공신경망과 SVM 알고리즘을 가스 터빈 엔진의 결합 진단에 적용하기 위해, 방대한 데이터가 수반되는 탈설계점에서의 결합 위치 분류기로 SVM을 사용하였으며 분류되어진 데이터 집단별로는 인공신경망을 사용하여 결합의 심각성 정도를 판단하는 접근 방식을 택하였다. 본 논문은 비교적 적은 량의 데이터를 처리하는 지상 정지상태의 결합진단을 통하여 제안된 알고리즘의 타당성을 입증하였고 요구 데이터 set이 이보다 약 6배에 달하는 항공기의 고도 변화에 따른 결합예측에 확장, 적용하였다.

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[2]. 기존 신경망의 문제점은 학습 데이터 수가 많아짐에 따라 수렴성 및 성능 저하가 현저하게 나타난다는 것이었다. 또한 데이터의 수가 많아지고 비선형성이 증가하면 분류 정확률의 감소를 가져오게 된다. 이러한 단점을 보완하기 위해 학습 데이터를 분할하여 학습하는 방법을 사용하였다. 이는 해석해야 할 데이터량이 증가하는 탈설계 영역에서의 해석에 더 큰 효율성이 있다고 판단된다. 즉, 결합 위치의 데이터 구분은 Multi-Class SVM을 사용하고, 인공 신경망에서는 분할된 영역의 학습 데이터만을 가지고 학습하게 된다. 따라서 전체적인 해석 데이터 수는 증가하지만, 분류 정확률은 지상 정지 상태와 대등한 높은 정확성을 가지게 된다.

2.2 분할 학습 알고리즘의 구조

분할 학습 알고리즘의 구조는 Fig. 1과 같다.

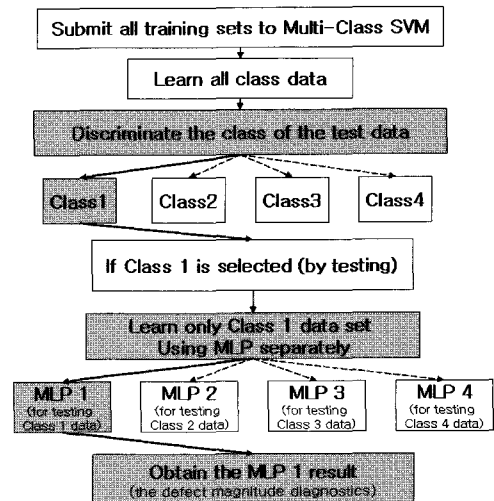


Fig. 1 Separate Learning Algorithm of MLP by Multi-Class SVM Classifier

Multi-Class SVM 알고리즘을 통해 Class에 따른 결합 위치를 판단하게 되고, MLP는 그 위치에서의 결합 크기만을 판단하게 된다.

2.3 지지 벡터 장치 (SVM)

SVM의 목적은 학습자료를 두 개의 부류로 구분하는 함수인 초평면(Hyper-plane)을 추정하는 것이다. 이러한 평면은 무수히 존재할 수 있지만 두 집단 사이의 유클리드 거리(Margin)를 최대화 하도록 제한을 두면 하나의 유일한 평면만이 해가 된다. 이 평면을 최적의 분류초평면(Optimal Hyper Plane)이라 하고, 이 평면을 중심으로 클래스를 이진 분류하게 된다.

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 n차원의 방향 벡터(w)의 값은 Eq. 1로 정리된다.

$$\begin{aligned} \text{Minimize } \frac{\|w\|}{2} &\approx \frac{\|w\|^2}{2} = \frac{(w \cdot w)}{2} \\ \text{subject to } y_i((w \cdot x_i) + b) &\geq 1 \text{ for } \forall i \end{aligned} \quad (1)$$

위 식을 풀기위한 라그랑지 목적함수는 Eq. 2와 같으며 그 해인 라그랑지 승수 α_i 를 구하기 위해 QP solver[3]를 사용하였다.

$$\begin{aligned} \text{Maximize } Q(\alpha) &= \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \\ \text{subject to } \sum_{i=1}^N \alpha_i y_i &= 0, \alpha_i \geq 0 \text{ for } \forall i \end{aligned} \quad (2)$$

Eq. 3과 Eq. 4를 사용하여 초평면의 식인 $w \cdot x + b$ 를 구하며 최종적으로 얻은 결정 함수(Decision Function)인 Eq. 5를 이용하여 임의의 벡터(x)가 속하는 집단을 분류해 내게 된다[2].

$$w = \sum_{i=1}^N \alpha_i y_i x_i = \sum_{i \in SV} \alpha_i y_i x_i z \quad (3)$$

$$y_i \left(\sum_{i \in SV} \alpha_i y_i (x_i \cdot x) + b \right) = 1 \quad (4)$$

$$\begin{aligned} f(x, \alpha^*, b^*) &= \text{sign}((w^* \cdot x) + b^*) \\ &= \text{sign} \left(\sum_{i \in SV} \alpha_i^* y_i (x_i \cdot x) + b^* \right) \end{aligned} \quad (5)$$

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

2.4 인공 신경망(ANN)

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




Fig. 2 Structure of ANN model

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. 6으로 정의 된다.

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_{k=1}^{M-1} (d_{pk} - O_{pk})^2 \quad (6)$$

이 평균오차를 최소화하기 위해 Eq. 7과 같이

연결강도(W)를 변화시킨다.

$$W_{kj}(t+1) = W_{kj}(t) - \eta \frac{\partial E}{\partial W_{kj}} \quad (7)$$

위의 과정은 오차(E)가 원하는 수렴 조건에 만족될 때까지 반복되며 최종적으로 얻은 학습 결과는 연결 강도에 저장되어 새로운 정보에 대한 판단에 적용된다[2].

신경망의 수렴성 향상을 위하여 모멘텀 기법을 사용하였으며 출력층의 활성화 함수는 Eq. 8의 시그모이드 함수를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-bx}} \quad (8)$$

3. 결함 진단 결과

3.1 대상 엔진 선정 및 모델링

Figure 3은 본 논문에서 대상 엔진으로 선정한 P&W사의 PWC-206C 터보 축 엔진의 모델로서 GSP 상용 프로그램을 사용하여 구현하였다[2]. 엔진의 구성품 맵(Map)은 GSP 프로그램 내에서 제공하는 터보 축 엔진의 압축기 맵과 터빈 맵을 P&W사에서 제공한 성능데이터 프로그램의 데이터를 이용하여 대상 엔진에 맞게 스케일링하여 사용하였다[3]. 실제엔진의 데이터와는 약간의 오차가 있을 수 있지만 알고리즘의 효용성을 검증하는 데는 무리가 없을 것으로 판단된다.

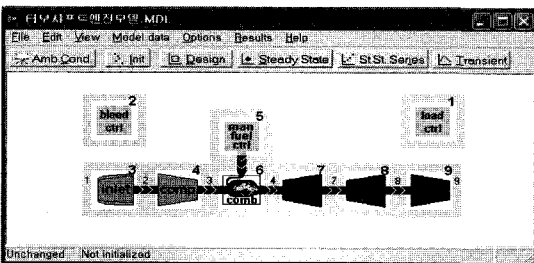


Fig. 3 Turbo-Shaft Engine Model using GSP Program

3.2 결함 진단 과정

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

결함 위치를 정성적으로 판단해 내기 위한 학습데이터로는 각 고도별 압축기 입구/출구 전온도, 입구/출구 전압력, 압축기-터빈 입구 전온도, 동력터빈 입구/출구 전온도를 사용하였다. 그리고 SVM은 2진 분류를 위한 알고리즘이기 때문에 정상과 비정상일때의 데이터들을 분류하기 위해서 레이블($y=1$ or $y=-1$)을 목표 출력 데이터로 사용하였다.

인공신경망의 학습을 위한 입력 데이터로 사용한 성능 진단 변수는 각 고도별의 압축기 전압력비, 압축기 전온도비, 압축기-터빈 전온도비, 그리고 동력터빈 전온도비를 사용하였다. 목표 출력 데이터는 각 고도에서 각각의 압축기, 압축기 터빈, 동력터빈의 저하된 등엔트로피 효율을 사용하였다.

지상 정지 상태가 아닌 고도 변화만을 고려한 탈설계 영역에서의 결함 진단을 위해서 최대 운용 고도인 16000ft를 10개의 고도로 나누어서 각 고도별 데이터를 사용하였고, 운용 속도는 비행 마하수 0.2로 고정시켜서 데이터를 얻었다.

3.3 Multi-Class SVM에 의한 결함 위치 판단

Multi-Class SVM을 사용하여 고도 변화에 따른 엔진 단일 구성품 결함의 위치를 판단하기 위한 테스트 데이터는 최대 운용 고도 16000ft까지, 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 SVM 학습을 위해 사용된 입력 데이터이다.

Table 1. Sensed parameter of input data for SVM training

	Input Data
Training sets	$T_{2'}, T_{3'}, P_{2'}, P_{3'}, T_{4'}, T_{5'}, T_{6'}$ (Sensed Parameter)

Table 2는 각 요소별 분류율을 나타내고 있다.

본 논문에서는 Multi-Class SVM을 통해 오분류 없이 모든 영역에서 단일 결함의 위치를 100% 분류해 내었다.

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,	-9.3%,	290 sets	100%
Power Turbine	16000ft	-9.6%, -9.9%		

Table 3은 고도 변화에 따른 각 요소별 결함 위치 판단 시간을 나타낸 것이다. 각 테스트 데이터 당 전체 평균 학습시간은 1.345초로 빠른 분류 성능을 보였다.

Table 3. Testing time of SVM with altitude variation

	Compressor	Comp. Turbine	Power Turbine
1600ft	1.344	1.359	1.375
3200ft	1.344	1.438	1.406
4800ft	1.328	1.313	1.344
6400ft	1.391	1.406	1.359
8000ft	1.328	1.359	1.297
9600ft	1.328	1.281	1.359
11200ft	1.328	1.297	1.375
12800ft	1.375	1.328	1.375
14400ft	1.281	1.313	1.344
16000ft	1.328	1.343	1.313

*unit: sec(s)

3.4 인공신경망에 의한 정량적 결함 판단

Table 4는 MLP 학습을 위한 입력 데이터와 출력 데이터를 표시한 것이다.

Table 4. Input data and output data for training

	Input Data	Output Data
Training sets	$P_{13}/P_{12}, T_{13}/T_{12},$ $T_{14}/T_{17}, T_{17}/T_{18}$ (Sensed Parameter)	Deteriorated isentropic efficiency

SVM으로 분류된 결함데이터 집단은 MLP를 이용하여 학습하였으며, 학습에 의해 구해진 목적함수를 이용하여 결함량을 정량적으로 예측할 수 있다. Fig. 4와 Fig. 5, Fig. 6, Fig. 7은 최대 운용고도 16000ft를 10개의 고도로 나눈 것 중, GSP 상용프로그램에서 얻은 3200ft, 6400ft, 9600ft, 12800ft에서의 각 엔진 요소마다 임의의 결함에 따른 29개의 효율 데이터와 MLP에서 예측한 효율 데이터와의 RMS 상대 오차율을 Eq. 9로 계산해서 엔진 요소별로 표시한 것이다. Table 5는 계산된 모든 고도에서의 RMS 상대 오차율을 정리한 것이다.

$$RMS \text{ Relative error rate} [\%] = \sqrt{\frac{\sum_{i=1}^N \left(\frac{\eta_{real} - \eta_{cal}}{\eta_{real}} \times 100\% \right)^2}{N}} \quad (9)$$

압축기는 4800ft 일 때 최대 0.269%의 오차를 가지고, 동력-터빈은 1600ft 일 때 최대 오차인 0.233%의 오차값을 가진다. 압축기-터빈의 결과 값이 상대적으로 다른 요소들보다 높은 것을 알 수 있는데, 1600ft 일 때 0.564%의 가장 높은 수치로 가장 낮은 예측 정확도를 보여주었고, 나머지는 0.4% 이내의 값들로 예측하였다.




Fig. 4 Result of MLP for defect diagnostic of each part at 3200ft

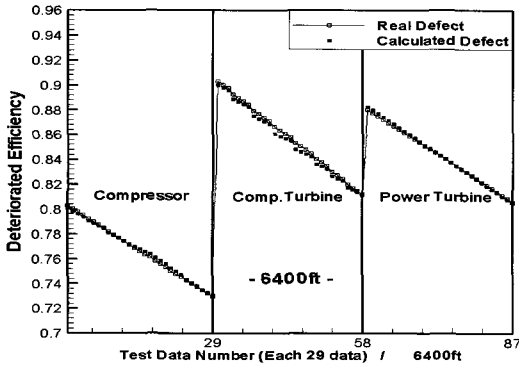


Fig. 5 Result of MLP for defect diagnostic of each part at 6400ft




Fig. 6 Result of MLP for defect diagnostic of each part at 9600ft




Fig. 7 Result of MLP for defect diagnostic of each part at 12800ft

Table 5. Absolute error rate of defect diagnostic for each part with altitude variation

	Absolute error rate[%]		
	Compressor	Comp. Turbine	Power Turbine
1600ft	0.231%	0.564%	0.233%
3200ft	0.249%	0.453%	0.084%
4800ft	0.269%	0.347%	0.143%
6400ft	0.212%	0.365%	0.169%
8000ft	0.156%	0.372%	0.131%
9600ft	0.163%	0.397%	0.118%
11200ft	0.193%	0.336%	0.109%
12800ft	0.149%	0.278%	0.149%
14400ft	0.141%	0.199%	0.213%
16000ft	0.199%	0.109%	0.148%
Average	0.196%	0.342%	0.149%

3.5 지상 정지 상태와의 비교

Table 6은 지상 정지 상태[3]와 탈설계 영역에서 고도변화만을 고려한 결함 예측에서 학습에 사용한 데이터 수와 테스트 데이터 수를 비교한 것이다. 지상 정지 상태일 경우 MLP를 학습시키기 위한 데이터가 34 sets 이지만, 전 고도 영역 변화에 따른 결함 예측을 위한 학습 데이터 수는 각 고도 당 11개의 sets로 총 110개의 sets가 사용되었다.

Table 6. Comparison of learning and testing set number for MLP at sea level and off-design condition

	Learning set number	Testing set number
Sea Level Condition	34×3 sets	30×3 sets
Off-Design (Altitude Variation)	110×3 sets	290×3 sets

Table 7은 지상 정지 상태와 탈설계 영역에서 각 요소들의 절대 오차율을 비교한 것이다. 절대 오차율의 정의는 Eq. 9로 나타내었다. 탈설계 영역의 절대 오차율은 전체 고도에서의 오차율을 평균으로 비교한 것이다. 전반적으로 지상 정지 상태에서의 오차율이 상대적으로 작은 것을 볼 수 있지만 Table 6에서 보듯이 학습 및 진단을

위한 데이터 수가 192 sets에서 1200 sets로 6배 이상 증가했음에도 불구하고, Comp-Turbine을 제외하고 대등한 결함 예측 정확성을 보여주고 있다. 이는 분할 학습 알고리즘을 이용한 결함 예측이 탈설계 영역에서도 높은 신뢰성을 가짐을 알 수 있다. Comp-Turbine의 경우는 성능맵의 특성에 의하여 작은 효율 저하에도 큰 결함 예측 오차를 나타내는 특성에 기인한다고 판단된다. 또한 Fig. 9에서 고도가 높아짐에 따라 결함 상대 오차율이 감소하는데 이는 높은 고도일수록 터빈 압력비가 줄어들어 상대적으로 성능맵 범위가 커지게 되므로 결함 예측 오차가 감소하게 되는 것으로 판단된다.

Table 7. Comparison of Absolute error rate for each part at sea level and off-design condition

	Comparison of Absolute error rate[%]		
	Compressor	Comp. Turbine	Power Turbine
Sea Level Condition	0.189%	0.116%	0.130%
Off-Design (Altitude Variation)	0.196%	0.342%	0.149%
	Average of all altitude range for absolute error rate		

3.6 상대 오차율에 의한 정량적 결함 판단

제안된 알고리즘의 고도변화에 따른 결함예측 정확도를 이미 연구되어진 유전자 알고리즘, GPA 기법, Hybrid 유전자-인공신경망 알고리즘 등의 결과들과 비교하기 위하여 절대오차율 외에 정상 데이터와 결함 데이터의 효율 값 오차인 결함치($\Delta\eta$)에 대한 상대오차율로 나타낼 필요가 있다. Fig. 8과 Fig. 9, Fig. 10 은 각 고도에 따른 결함데이터와 MLP에서 예측한 효율 저하 데이터와의 결함 상대 오차율을 엔진 요소별 RMS error로 표시한 것이다. 압축기에서는 5.92%의 최대오차(평균오차 4.78%)를, 압축기-터빈에서는 10.68%(평균오차 7.38%), 동력터빈에서는 8.29%의 최대오차(평균오차 4.70%)로 결함을 예측하였다. 이는 탈설계 영역에서의 예측임에도 불구하고 Donald L. Simson[5]에서 예측한 지상 정지 상태에서의 결함 상대 오차율(압축기: 5.46%, HP-터빈: 14.88%, LP-터빈: 9.82%)보다 정

확한 결함 예측 신뢰도를 가짐을 확인하였다. 결함치에 대한 RMS 결함 상대 오차율은 Eq. 10으로 계산했으며, Table 8은 전 고도 변화에 따른 각 요소별 RMS 결함 상대 오차율을 나타낸 것이다.

$$RMS \text{ Defect Relative error rate} [\%] =$$

$$\sqrt{\sum_{i=1}^N \left(\frac{\Delta\eta_{real} - \Delta\eta_{cal}}{\Delta\eta_{real}} \times 100\% \right)_i^2 / N} \quad (10)$$




Fig. 8 Defect relative error rate of Compressor according to Altitude variation




Fig. 9 Defect relative error rate of Compressor Turbine according to Altitude variation




Fig. 10 Defect relative error rate of Power Turbine according to Altitude variation

후 기

Table 8. Defect relative error rate of defect diagnostic for each part according to altitude variation

	Defect relative error rate[%]		
	Compressor	Comp. Turbine	Power Turbine
1600ft	5.658%	10.677%	6.868%
3200ft	5.924%	8.899%	0.937%
4800ft	4.316%	7.859%	3.286%
6400ft	5.452%	8.516%	7.389%
8000ft	5.848%	8.847%	4.466%
9600ft	3.745%	9.015%	2.064%
11200ft	4.223%	7.632%	3.971%
12800ft	4.172%	5.791%	5.999%
14400ft	4.616%	4.259%	8.286%
16000ft	3.891%	2.267%	3.695%
Average	4.78%	7.38%	4.70%

4. 결 론

본 연구에서는 항공기용 터보 축 엔진의 고도 변화에 따른 엔진의 단일 결합 진단을 연구하였다. 기존 신경망 학습 알고리즘의 분류 정확성을 높이기 위해서 SVM과 MLP를 연계한, 분할 학습 알고리즘(SLA)을 사용하였다. 지상 정지 상태가 아닌 탈설계 영역에서, 운용속도는 비행 마하 수 0.2로 고정하고 고도변화에 따른 가스 터빈 엔진의 결합 진단을 하였다. 최대 운용 고도(16000ft)를 10개의 고도로 나누어 각 고도별 측정데이터를 학습하였으며, 엔진 각 요소별 결합을 예측하였다. 탈설계 영역에서 6배 이상의 상대적으로 많은 학습 및 테스트 데이터수를 가짐에도 불구하고 지상 정지 상태 못지않은 높은 결합 예측 신뢰도를 보여주었다. 각 고도에 따른 결합데이터와 MLP에서 예측한 효율 저하 데이터와의 평균 결합 상대 오차율은 압축기는 4.78%, 압축기-터빈은 7.38%, 동력 터빈은 4.70%로 고도 변화만을 고려한 탈설계 영역에서 높은 결합 예측 정확성을 가짐을 확인하였다.

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, 2004
2. 박준철, 최동환, 노태성, 이창호, "Support Vector Machine과 인공지능망을 이용한 가스 터빈 엔진의 결합 진단에 관한 연구", 한국추진공학회지, 제10권 제2호, 2006, pp.102-109
3. Sellers, J.F & Daniele, C.J, "DYNGEN - A Program for Calculating Steady-state and Transient Performance of Turbo jet and Turbo fan engine", NASA TN D-7901, 1975
4. K. Schittkowski, "QL: A Fortran Code for Convex Quadratic Programming - User's Guide, Version 2.1", University of Bayreuth, 2004
5. Donald L. Simon, Takahisa Kobayashi, "A Hybrid Neural Network-Genetic Algorithm Technique for Aircraft Engine Performance Diagnostics", NASA/TM-2001-211088, 2001
6. Christopher J.C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition", Kluwer Academic Publishers, Boston, pp.1-433
7. 강문식, 이상용, "데이터 마이닝을 위한 경쟁 학습모델과 BP 알고리즘을 결합한 하이브리드형 신경망", 한국정보기술응용학회, 제9권 제2호, 2002, pp.1-16
8. 김기성, 황진수, "Support Vector Machine을 이용한 분류분석", 인하대학교 통계학과 대학원 석사 논문, 2003