

신경회로망을 적용한 가스터빈 엔진의 성능진단 연구

공창덕* · 고성희** · 기자영* · 강명철**

A Study on Performance Diagnostics of a Gas Turbine Engine Using Neural Networks

Chang-Duk Kong* · Seong-Hee Kho** · Ja-Young Ki* · Myoung-Cheol Kang**

ABSTRACT

An intelligent performance diagnostic computer program of a gas turbine using the NN(Neural Network) was developed. Recently on-condition performance monitoring of major gas path components using the GPA(Gas Path Analysis) method has been performed in analyzing of engine faults. However because the types and severities of engine faults are various and complex, it is not easy that all fault conditions of the engine would be monitored only by the GPA approach. Therefore in order to solve this problem, application of using the NNs for learning and diagnosis would be required. Among them, a BPN (Back Propagation Neural Network) with one hidden layer, which can use an updating learning rate, was proposed for diagnostics of PT6A-62 turboprop engine in this work.

초 록

본 연구에서는 신경회로망을 이용한 가스터빈 엔진의 지능형 성능 진단 컴퓨터 프로그램을 개발하였다. 최근에는 엔진 손상을 분석하는데 있어서 주요 구성품의 가스 경로를 실시간 모니터링(monitoring)하는 가스경로해석(GPA, Gas Path Analysis)방법이 사용되고 있다. 그러나 엔진손상의 형태나 정도가 다양하고 복잡하기 때문에 가스경로해석 접근법만 가지고서는 엔진의 손상상태를 모두 모니터링하기란 쉽지 않다. 따라서 이 문제를 해결하기 위해 학습과 진단을 할 수 있는 신경회로망을 적용하였다. 본 연구에서는 PT6A-62 터보프롭 엔진의 진단에 1개의 은닉층을 갖는 역전파 신경회로망(BPN, Back Propagation Neural Network)이 제안되었다.

1. 서 론

최근 가스터빈 엔진에 인공지능의 하나인 신경회로망이 적용되어지고 있는데, 특히 가스터

빈 엔진의 고장 진단에 적합한 특징을 가지고 있다.¹⁾²⁾³⁾ 엔진 가스 경로에서 측정된 변수의 변화는 구성품 특성의 변화를 나타낸다. 만약 신경회로망을 이용하여 이것들의 상호관계를 나타

* 조선대학교 항공우주공학과(Chosun University, Dept. of Aerospace Engineering)

** 조선대학교 대학원 항공우주공학과(Chosun University, Dept. of Aerospace Engineering)

낼 수만 있다면 다른 형태의 손상들도 진단할 수 있다. 엔진 고장 진단에 신경회로망을 이용한 많은 연구들이 수행되어지고 있는데, 몇몇의 신경회로망 접근법이 개발되었다. 그 중 역전파 신경회로망(BPN, Back Propagation Network)이 간단하고 이미 만들어진 알고리즘 때문에 널리 사용되어진다.⁴⁾ 이에 본 연구에서는 손상 패턴 별로 BPN을 학습시키고, 각각의 경우를 조합하여 전체 학습 네트워크를 구성하는 방법을 제안하였다. 신경회로망의 구성을 위한 손상 데이터와 실험 데이터는 시뮬레이션 프로그램을 이용하여 획득하였다.

2. 신경회로망을 이용한 가스터빈 성능진단

연구대상 엔진으로 축마력 857.9 kW(1150 hp)급인 PT6A-62 분리축 터보프롭 엔진을 선정하였다. 이 대상 엔진의 최대출력은 857.9 kW급이지만 엔진 감속기어부의 과응력을 방지하기 위하여 708.7 kW(950 hp)로 제한되어 있다.

계측변수는 축마력(SHP), 연료유량(MF), 압축기출구압력(PT2), 압축기출구온도(TT2), 압축기터빈출구압력(PT4), 압축기터빈출구온도(TT4), 동력터빈출구온도(TT5)를 이용하였다. 구성품의 성능저하를 탐지하기 위한 변수로는 각 구성품의 유량과 효율을 이용하였다. 즉 압축기, 압축기터빈, 동력터빈의 유량과 효율 등 6개의 성능인자를 이용하여 압축기 오염, 터빈 부식, 다른 손상을 탐지한다.

PT6A-62 터보프롭 엔진의 성능해석 프로그램을 이용하여 40개 패턴의 학습 데이터와 15개 패턴의 테스트 데이터를 획득하였다. 학습과 테스트를 위한 손상 패턴은 1%~5% 성능저하율 범위에서 압축기 오염, 터빈 부식, 여러 구성품의 복합적인 손상의 경우로 다양하게 구성되어 있다. 훈련 알고리즘에는 1개의 은닉층을 갖는 BPN을 이용하였으며 은닉층에는 탄젠트 시그모이드 전이함수를, 출력층에는 선형 전이함수를 이용하였다.

2.1 데이터 집합 구성

훈련을 위한 데이터 집합은 40개의 손상 패턴으로 구성되어 있다. 압축기 오염은 유량과 효율의 감소를 가져오며 데이터 집합에서는 5% 범위의 변화율을 가정하였다. 터빈 부식은 유량의 증가와 효율의 감소를 가져오며 데이터 집합에서는 역시 5% 범위의 변화율을 고려하였다. 손상 패턴으로는 압축기 오염, 압축기 터빈 부식, 동력 터빈 부식이 단독으로 발생하는 경우와 여러 구성품에서 복합적으로 손상이 발생하는 경우를 다양하게 가정하였다. 같은 방식으로 테스트를 위해 15개의 손상 패턴으로 테스트 집합을 구성하였다.

2.2 신경회로망 훈련 알고리즘

손상 패턴들은 BPN 알고리즘을 이용하여 훈련하였다. BPN은 Fig. 1과 같이 7개의 뉴런으로 이루어진 입력층과 1개의 은닉층, 6개의 뉴런으로 이루어진 출력층으로 구성되었다. 입력층의 7개 뉴런은 각각 계측변수인 SHP, MF, P2, T2, P4, T4, TT5의 변화량을 나타내며 출력층의 6개 뉴런은 압축기와 압축기터빈, 동력터빈의 유량과 효율을 나타낸다.

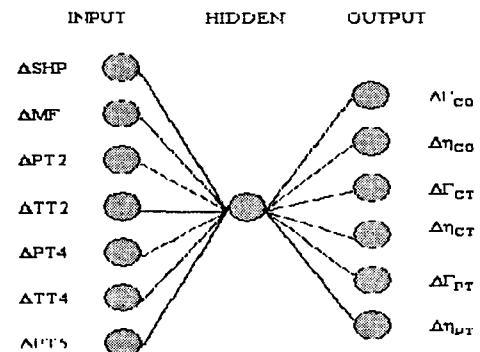


Fig. 1 Architecture of three layer BPN

은닉층의 전달함수로는 탄젠트 시그모이드 함수를 이용하였으며, 출력층의 전달함수로는 선형 함수를 이용하였다.

BPN은 전향되는 패스에서 효과적인 계산을 할 수 있도록 전달함수의 미분전개를 필요로 한

다. 학습율은 학습의 속도를 높이면서 안정성을 갖도록 하기위해 오차가 감소하는 방향으로 학습이 진행되면 구간의 크기를 10%씩 증가시키고 오차가 증가되면 50% 감소시키며 네트워크를 훈련하였다. 또한 오차가 감소되는 경우에만 가중치를 갱신하도록 하였다. 네트워크 출력 값과 목표 값과의 오차는 RMS로 정의하였다. 본 연구에서 목표 최대 RMS 오차는 0.0001 이하가 되도록 하였다.

3. 네트워크 검증

훈련된 신경회로망의 검증을 위해 15개의 결합 패턴으로 구성된 테스트 데이터 집합이 사용되었다. 테스트 집합은 다양한 유형으로 이루어져 있고 구성품의 손상정도는 훈련에 대한 데이터 집합과 같다. Table 1은 검증을 위해 적용된 테스트 데이터 집합을 나타낸다.⁹⁾

Table 1. Fault patterns for NN validation

	Γ_{CO}	η_{CO}	Γ_{CT}	η_{CT}	Γ_{PT}	η_{PT}
1	-2	-2	0	0	0	0
2	-3	-1	0	0	0	0
3	0	0	2	-1	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
14	-2	-1	1	-1	1	-1
15	-3	-1	2	-1	2	-1

Table 2. RMS errors for each learning database sets

	CASE I	CASE II	CASE III	CASE IV	CASE V
1	14.935	3.3754	1.9546	1.1734	0.8399
2	14.989	3.3306	1.9488	1.1821	0.8974
3	14.913	3.1191	1.8329	0.8771	2.1929
⋮	⋮	⋮	⋮	⋮	⋮
14	14.367	2.6173	1.1718	0.7678	1.3329
15	13.932	2.1884	0.7452	1.1378	1.5194

진단 결과에 대한 데이터베이스의 구성이 미치는 영향을 알아보기 위하여 40개의 손상 패턴 중에서 추출한 5가지 경우의 조합을 가지고 해석을 수행하여 보았다. Table 2는 5가지 경우에 대한 각각의 RMS 오차를 보여준다.

진단 결과로부터, 40개의 손상패턴을 모두 가지는 경우 I은 부분적 손상패턴을 가지는 경우보다 RMS 오차가 매우 큼을 알 수 있다. 이는 불필요한 데이터가 역으로 부정확한 진단 결과를 가져올 수 있음을 의미한다. 경우 II는 Table 1의 1번~15번까지의 손상 패턴을 사용하여 데이터 집합을 훈련한 결과이며, 각각의 구성품에서 한 가지 손상이 일어났을 때의 다양한 유형들이다. 여기에서 경우 II는 다중손상 유형을 포함하고 있는 경우 I 보다 오차가 매우 적음을 알 수 있었다. 경우 III은 3%와 4%의 구성품 성능 저하율을 가지는 3, 4, 8, 9, 13, 14번의 손상 패턴을 사용하여 데이터 집합을 훈련한 결과이며, 경우 IV는 1%와 5%의 구성품 성능 저하율을 가지는 1, 5, 6, 10, 11, 15번의 손상 패턴을 사용하여 학습한 결과이다. 비교 결과에 따르면, 경우 IV가 경우 II, III보다 더 적은 RMS 오차를 보여 보다 넓은 범위의 손상을 가지고 훈련하는 것이 유용함을 확인할 수 있었다. 마지막으로, 경우 V는 1, 2, 3, 4, 5번의 손상 패턴을 사용한 학습 집합으로 구성하였다. 이 경우 압축기 오염 패턴을 잘 탐지할 수 있으나, 다른 단일과 다중 구성품 손상 패턴에 대해 큰 RMS 오차를 가진다.

더 나은 진단 결과를 얻기 위한 이 실험에서 첫 번째로, 불필요한 데이터베이스는 진단 신뢰성의 감소를 가져옴을 확인 할 수 있었다. 두 번째로, 단일 구성품 손상 패턴에 대한 학습 데이터베이스를 사용한 경우 다중 구성품 손상 패턴에 대한 것보다 높은 신뢰도를 가진다. 세 번째로, 광범위한 성능저하율을 사용한 경우 좁은 범위의 성능저하율을 사용한 경우보다 좋은 진단 결과를 갖는다. 마지막으로 단일 구성품 손상 패턴을 가지고 학습한 경우 동일 구성품 손상 패턴을 정확히 탐지 할 수 있을 뿐만 아니라 다른 구성품 손상 패턴 또한 잘 탐지 할 수 있다.

Fig. 2는 각각 PT6A-62 터보프롭 엔진의 진단에 대한 적용 결과이다. Fig. 2를 보면 압축기 유량과 효율 감소, 압축기 터빈 유량 증가와 효율 감소를 보여주기 때문에 압축기 오염과 압축

기 터빈 부식의 복합 손상임을 알 수 있다.

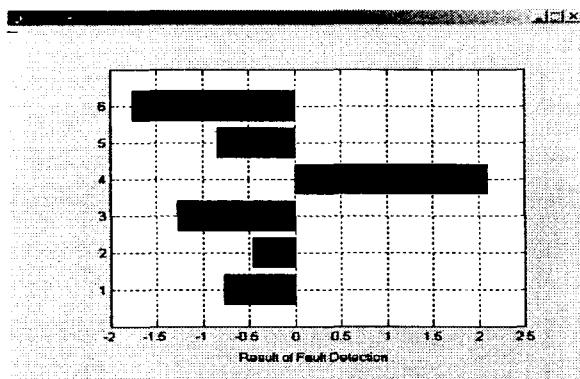


Fig. 2 Application results of the case IV network

4. 결 론

본 연구에서는 신경회로망을 사용한 가스터빈 엔진의 성능 진단 시스템을 제안하였다. 1개의 은닉층을 가지는 BPN의 신경회로망 학습을 위해 1개의 입/출력층이 사용되었다. 입력층의 7개 뉴런은 계측변수인 SHP, MF, P2, T2, P4, T4, T5의 변화량을 나타내며 출력층의 6개 뉴런은 압축기와 압축기터빈, 동력터빈의 유량과 효율을 나타낸다. 은닉층의 전달함수로는 탄젠트 시그모이드 함수를 이용하였으며, 출력층의 전달함수로는 선형 함수를 이용하였다. PT6A-62 터보프롭 엔진의 성능모사 프로그램을 이용하여 55개의 손상 패턴을 얻은 후, 네트워크의 훈련에 40개의 손상 패턴을 네트워크 검증에 15개의 손상 패턴을 사용하였다.

진단 결과에 대한 데이터베이스 구성의 신뢰성을 조사하기 위하여 40개 손상 패턴의 5가지 조합으로 해석을 수행하였다. 해석 결과, 불필요한 데이터베이스는 진단 신뢰성의 감소를 가져옴을 확인 할 수 있었고, 단일 구성품 손상 패턴에 대한 학습 데이터베이스를 사용한 경우 다른 구성품 손상 패턴에 대한 것보다 높은 신뢰도를 가지며, 광범위한 성능저하율을 사용하여 훈련한 경우가 좁은 범위의 성능저하율을 사용한 경우보다 진단 성능이 우수하였다. 또한 단

일 구성품 손상 패턴을 가지고 학습한 경우 동일 구성품 손상 패턴을 정확히 탐지 할 수 있을 뿐만 아니라 다른 구성품 손상 패턴도 잘 탐지 할 수 있었다.

학습된 네트워크를 사용하여 PT6A-62 터보프롭 엔진의 진단에 적용한 결과 제안된 진단 시스템은 압축기 오염, 압축기 터빈 부식, 동력 터빈 부식과 같은 단일 손상 형태뿐만 아니라 다중 손상 형태도 탐지 할 수 있음을 입증하였다.

후 기

본 논문은 2003년도 두뇌한국 21 사업에 의하여 지원되었으며 이에 감사드립니다.

참고문헌

- 1) Lu, P. J., Zhang, M. C., Hsu, T. C., and Zhang, J., "An Evaluation of Engine Faults Diagnostics using Artificial Neural Networks", Proceedings of ASME TURBO EXPO 2000, 2000-GT-0029, 2000
- 2) Sun, B., Zhang, J., Zhang, S., "An Investigation of Artificial Neural Network (ANN) In Quantitative Fault Diagnosis for Turbofan Engine", Proceedings of ASME TURBO EXPO 2000, 2000-GT-0032, 2000
- 3) Volponi, A. J., Depold, H., Ganguli, R., and Daguang, C., "The Use of Kalman Filter and Neural Network Methodologies in Gas Turbine Performance Diagnostics: A Comparative Study", Proceedings of ASME TURBO EXPO 2000, 2000-GT-547, 2000
- 4) Tang, G., Yates, C. L., and Chen, D., "Comparative Study of Two Neural Networks Applied to Jet Engine Fault Diagnosis", American Institute of Aeronautics and Astronautics, AIAA 98-3549, 1998
- 5) Diakunchak, I.S., "Performance Deterioration in Industrial Gas Turbines" Trans. ASME Journal of Engineering for Gas Turbine and Power, Vol. 114 : 161-168, 1992