

論文

퍼지 및 신경망을 이용한 무인 항공기용 터보축 엔진의 다중손상진단에 관한 연구

공창덕*, 기자영**, 고성희***, 구영주***, 이창호****

A Study on Multi-Fault Diagnosis for Turboshaft Engine of UAV Using Fuzzy and Neural Networks

Changduk Kong*, Jayoung Ki**, Seonghee Kho***, Youngju Koo*** and Changho Lee****

ABSTRACT

The UAV(Unmanned Aerial Vehicle) that is remotely operating in various and long flight environments must have a very reliable propulsion system. Precise fault diagnosis of the turbo shaft engine for the Smart UAV that has the vertical take-off, landing and forward flight behaviors can promote reliability and availability.

This work proposes a new diagnostic method that can identify the faulted components from engine measuring parameter changes using Fuzzy Logic and quantify its faults from the identified fault pattern using Neural Network Algorithms. The proposed diagnostic method can detect not only single fault but also multiple faults.

초 록

다양한 비행환경에서 장시간 체공하며 원격 조종되는 무인항공기에서 추진시스템을 신뢰성 있게 운영하는 것은 매우 중요하다. 스마트 무인기의 수직 이착륙 및 전진 비행에 사용 되는 터보축엔진의 정확한 손상진단은 신뢰성과 이용률을 향상시킬 수 있을 것이다.

본 연구에서는 엔진 측정 파라미터들의 변화로부터 퍼지이론을 적용하여 손상된 구성품을 식별한 후 훈련된 신경망 알고리즘을 식별된 손상 패턴에 적용 손상된 양을 정확히 진단할 수 있는 방법을 새로이 제안하였다. 제안된 진단방법은 단일손상은 물론 다중손상도 진단할 수 있다.

Key Words : Feed Forward Back Propagation(전방향 역전파), Gas Path Analysis(가스경로 해석), Fuzzy Logic(퍼지로지), Neural Network Algorithm(신경망알고리즘)

1. 서 론

엔진 주요 구성품의 실시간 상태진단은 주로 모델 기반(Model-based) 방법이 이용된다. 이는

결함이 없는 엔진의 성능모델링을 만들고 측정된 파라미터(온도, 압력, 회전수, 연료소모량 등)의 값을 기준 성능과 비교하여 각 요소들의 성능 파라미터(효율, 질유량 등)의 저하 여부를 정량적으로 산출하는 것이다[1]. 최근에는 이러한 모델 기반 진단 기법의 성능향상을 위해 신경망 이론, 퍼지 로직, 유전알고리즘과 같은 인공지능 이론을 적용한 진단 전문가 시스템이 연구되고 있다. 그 중 신경회로망은 우수한 학습 성능으로 인해 진단 시스템에 가장 많이 이용되고 있으나 학습할 데이터가 많아지면 훈련하는데 시간이 오래

† 2008년 12월 4일 접수 ~ 2009년 5월 26일 심사완료

* 정희원, 조선대학교 항공우주공학과

** 정희원, (주)이지가스터빈 R&D

*** 정희원, 조선대학교 항공우주공학과 대학원

교신저자, E-mail : habari@paran.com

광주광역시 동구 서석동 375번지

**** 정희원, 한국항공우주연구원

걸리고 정확성이 떨어질 수 있는 단점이 있다[2]. 또한 각 구성품의 단일 손상에서 여러 구성품에서 발생하는 다중 손상 탐지를 효과적으로 하기 위해서는 그 구조가 매우 복잡해진다.

따라서 본 연구에서는 일차적으로 손상된 구성품을 식별하고 그에 맞게 훈련된 신경회로망을 적용하여 정량적으로 엔진 상태를 진단하는 알고리즘을 제안하였다. 즉, 손상된 구성품을 식별하는 알고리즘에는 퍼지 로직을 이용하였으며 손상된 구성품의 계측 데이터 학습에는 FFBP (Feed Forward Back Propagation) 알고리즘을 이용하였다. 본 연구의 알고리즘 검증에 위해 임의의 다중 손상을 주었을 경우 엔진 손상을 정성, 정량적으로 잘 탐지함을 알 수 있었다.

II. 연구 대상 엔진 및 성능모델

연구대상 엔진은 Pratt-Whitney 사의 PW206C 분리축 방식 터보축 엔진으로 그림 1과 같이 1단 원심 압축기, 1단 압축기 터빈, 1단 동력터빈, 애슬러 형 연소기 챔버 등으로 구성되어 있다. PW206C 터보축 엔진은 현재 한국항공우주연구원 (KARI : Korea Aerospace Research Institute)에서 개발 중인 틸트 로터형 스마트 무인기의 추진기관으로 선정되었으며 곧 국내에서 지상시험 할 예정이다.

표 1은 KARI 스마트 무인기 기술개발사업단에서 제공한 추진시스템의 운용조건 이고, 표 2는 엔진 제작사에서 제공한 지상 정지 최대 이륙 조건에서의 설계점 성능이다[3].

표 1. 엔진 운용 범위

Ambient Temp. (°C)	ISA ± 30
Altitude (km)	0~5
Flight Velocity (km/hr)	0~500

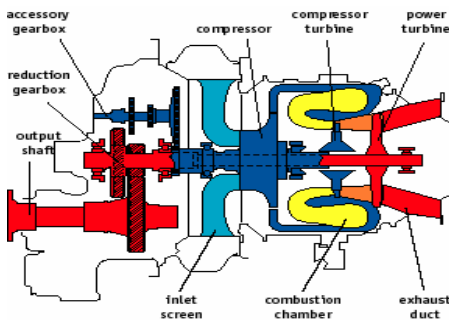


그림 1. PW206C 엔진 개략도

표 2. 설계점 성능 데이터

Variable	Values
Atmospheric condition	S/L, Static STD Condition
Mass flow rate (kg/s)	2.004
Fuel flow rate (kg/s)	0.0392
Compressor pressure ratio	7.912
Exhaust Gas temperature (K)	865
Power (kW)	416
SFC (kg/kW·hr)	0.34
Gas generator rotational Speed (100% RPM)	54751
Propeller rotational Speed (100% RPM)	6000

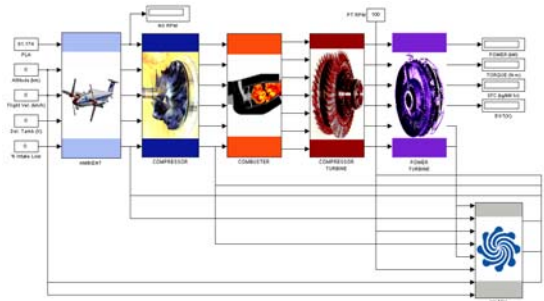


그림 2. PW206C 터보 축 엔진의 정상상태 성능 모델

PW206C 분리축 방식 터보축 엔진으로 그림 2는 SIMULINK를 이용한 정상상태 성능 모델링으로 각 구성품의 조합을 위해 알고리즘은 Stateflow 라이브러리를 이용하였다. 성능해석을 위한 압축기, 압축기 터빈, 동력터빈 성능도에는 β -line을 적용하였으며 압축기와 압축기 터빈 사이의 일 조합 및 유량조합, 가스발생기 및 동력터빈사이의 유량 조합을 수행하였다.

III. 모델 기반 상태진단

3.1 GPA(Gas Path Analysis)

가스터빈 엔진의 성능해석 모델은 구성품 성능도와 에너지와 질량보존의 법칙과 같은 열역학적 관계에 기초한다. 따라서 계산은 모든 구성품이 열역학적 관계를 만족하도록 진행된다. 구성품 성능도가 정확하게 정의되었다고 가정하면 모델은 압력, 온도, 연료유량, 회전속도 등과 같은 측정할 수 있는 독립변수와 효율, 유량과 같은

측정 불가능한 종속변수의 향으로 엔진의 성능을 파악할 수 있다.

부식, 오염, 마모, 비틀림 등으로 인해 엔진에 손상이 발생하면 각각의 손상은 가스가 통과하는 구성품에 영향을 미친다[4]. 구성품의 온도, 압력, 연료유량, 회전속도 등과 같은 측정할 수 있는 독립변수와 효율, 유량과 같은 측정 불가능한 종속변수의 향으로 엔진의 성능을 파악할 수 있다. 이러한 방법으로 구성품의 종속변수 사이의 역학적 관계식과 독립변수의 직접적인 측정으로 성능이 저하된 구성품을 분리시키는 것이 가능하다. 즉, 엔진 상태의 진단은 종속변수의 변화량을 분석함으로써 가능하며 이는 많은 경험과 데이터베이스에 기초한다.

3.2 퍼지 로직을 이용한 손상된 구성품의 식별

구성품의 손상 정도를 정량적으로 진단하기 전에 엔진의 손상 패턴을 식별하기 위한 퍼지 알고리즘을 개발하였다. 추진시스템의 계측변수는 가스발생기 회전수 및 동력터빈 회전수, 배기가스 온도, 연료유량, 토크, 압축기 출구 압력 및 온도 등 7개이다. 주요 구성품의 손상 패턴은 압축기, 압축기터빈, 동력터빈에서 각각 손상이 발생하는 경우와 2개 구성품에서 동시에 손상이 발생하는 경우, 그리고 3개 구성품에서 동시에 손상이 발생하는 경우 등을 고려해볼 수 있다.

본 연구에서는 주요 구성품에서 발생할 수 있는 손상패턴을 표 3과 같이 7가지 경우로 분류하였다.

Diakunchak의 실험에 의하면 압축기 오염은 엔진의 질유량과 효율을 감소시키며 터빈 침식 또는 부식은 엔진 질유량의 증가와 효율 감소를 가져온다[5].

표 3. 주요 구성품의 손상 패턴(FP, Fault Pattern)

FP 1	Compressor fouling
FP 2	Compressor turbine erosion
FP 3	Power turbine erosion
FP 4	Compressor fouling & compressor turbine erosion
FP 5	Compressor fouling & power turbine erosion
FP 6	Compressor turbine erosion & power turbine erosion
FP 7	Compressor fouling & compressor turbine erosion & power turbine erosion

Diakunchak의 실험 결과를 이용하여 압축기 오염, 터빈 부식과 같은 엔진 손상을 시뮬레이션하면 계측파라미터의 변화가 표 4와 같은 경향을 갖는다.

즉 압축기 오염이 발생하는 FP1의 경우 압축기 출구온도(COT) 및 압력(COP), 토오크(TRQ), 연료유량(WF)는 감소하고 가스발생기 회전수(Ng), 동력터빈 회전수(Np) 및 배기가스온도(EGT)는 증가한다.

FP7의 경우에는 COT, COP, Np, TRQ, WF는 감소하고 Ng 및 EGT는 증가하는 특성을 보인다.

표 4와 같은 엔진 손상형태에 따른 계측파라미터의 변화를 데이터베이스화하여 손상된 구성품을 식별하는 퍼지 로직을 개발하였다.

그림 3은 손상된 구성품의 식별을 위한 mamdani-type 퍼지추론 시스템이며 MATLAB의 FIS 에디터를 이용하여 개발하였다[6].

표 4. 손상 패턴(FP)에 따른 계측파라미터(MP)의 변화 추세

MP FP	COT	COP	Ng	Np	TRQ	EGT	WF
1	-	-	+	+	-	+	-
2	-	+	+	+	+	+	+
3	-	-	+	+	-	-	-
4	-	-	-	-	-	+	-
5	-	-	+	+	-	-	-
6	+	-	-	-	-	+	+
7	-	-	+	-	-	+	-

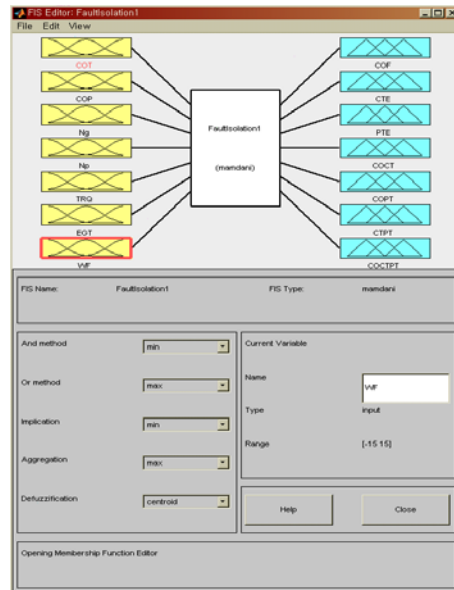


그림 3. 손상된 구성품 식별을 위한 퍼지추론 시스템

Fuzzyfication을 위한 입력 변수는 계측 파라미터의 Clean 엔진의 데이터에 대한 변화량이고 출력변수는 7가지 손상 패턴이다. 퍼지추론에는 'MAMDANI' 이론을 적용하였으며 비퍼지화에는 'Centroid' 기법을 이용하였다[7].

출력변수의 값은 0에서 1사이의 값을 가지며 1에 가까울수록 예측되는 손상 패턴에 가깝다.

3.3 구성품 손상의 정량적 진단을 위한 신경회로망 설계

신경회로망의 훈련을 위한 데이터베이스 구축을 위해 압축기는 오염에 의해 1~5%의 효율과 유량함수 감소, 압축기 터빈과 동력터빈은 침식에 의해 1~5%의 효율 저하 및 유량함수 증가가 발생하는 경우를 가정하였다. 신경회로망 학습을 위한 손상데이터는 GASTURB를 이용한 성능 시뮬레이션으로부터 획득하였다[8].

신경회로망의 훈련에는 FFBP (Feed Forward Back Propagation) 알고리즘을 적용하였으며 각각 1개의 입력층과 은닉층과 출력층을 갖는다[9].

FFBP 네트워크는 7개의 뉴런으로 이루어진 입력층과 1개의 은닉층, 6개의 뉴런으로 이루어진 출력층으로 구성되었다. 입력층의 7개 뉴런은 토오크 (TRQ), 연료유량(WF), 압축기출구압력(COP), 압축기출구온도(COT), 배기가스온도(EGT), 가스발생기 회전속도(Ng), 동력터빈 회전속도(Np)의 변화량을 나타내며 출력층의 6개 뉴런은 각각 압축기, 압축기 터빈, 동력터빈의 유량 및 효율변화를 나타낸다.

은닉층의 전달함수로는 식(1)과 같은 탄젠트 시그모이드 함수를 이용하였으며 출력층의 전달함수로는 식(2)와 같은 선형함수를 이용하였다[10].

$$y = \frac{e^{ax} - e^{-ax}}{e^{ax} + e^{-ax}} \quad (1)$$

$$y = x \quad (2)$$

학습율은 학습의 속도를 높이면서 안정성을 갖도록 하기위해 오차가 감소하는 방향으로 학습이 진행될 경우 구간의 크기를 10%씩 증가시키고 오차가 증가되면 50% 감소시키며 네트워크를 훈련하였다. 또한 오차가 감소되는 경우에만 가중치를 갱신하도록 하였다.

진단의 정확성을 계산하는 RMS 오차는 다음과 같이 정의하였으며 신경회로망은 RMS 오차가 1% 이내에 들도록 훈련된다.

$$RMSerror = \sqrt{\frac{\sum_{i=1}^n (y_n - T_n)^2}{n}} \quad (3)$$

식 (3)에서 T는 엔진에 임의로 이식한 성능 저하율이며 y는 신경회로망의 진단 결과이다.

3.4 다중 손상 진단 검증

제안된 진단 알고리즘을 검증하기 위해 다음과 같은 엔진 손상에 대한 예를 적용하였다. 표 5는 임의로 가정한 엔진 성능 저하율이다.

압축기와 압축기 터빈, 동력터빈에서 각각 오염과 침식이 발생하는 경우와 2 개의 구성품에서 동시에 손상이 발생하는 경우, 모든 구성품에서 손상이 발생하는 경우에 대해 알고리즘을 적용하였다.

먼저 GASTURB를 이용하여 가정된 손상량에 따라 성능해석을 수행하였다. 표 6은 각 경우의 계측변수 변화량이다.

표 5. 엔진 각 구성품의 가상 성능 저하율(%)

FP	COMA (압축기 유량)	COEF (압축기 효율)	CTMA (압축기 터빈유량)	CTEF (압축기 터빈효율)	PTMA (동력터빈 유량)	PTEF (동력터빈 효율)
1	-4	-2	0	0	0	0
2	0	0	4	-2	0	0
3	0	0	0	0	4	-2
4	-4	-2	4	-2	0	0
5	-4	-2	0	0	4	-2
6	0	0	4	-2	4	-2
7	-4	-2	4	-2	4	-2

표 6. 가정된 구성품 성능저하에 따른 계측파라미터의 변화 추세

MP FP	COT	COP	Ng	Np	TRQ	EGT	WF
1	-1.838	-6.790	1.118	0.983	-9.791	1.260	-7.263
2	-0.002	0.166	-1.709	-2.196	5.639	4.578	7.135
3	0.031	-1.827	0.852	1.109	-7.885	-1.073	-3.256
4	-1.820	-6.529	-1.648	-1.261	-4.441	3.270	-0.531
5	-1.947	-8.677	2.105	2.233	-17.31	-2.555	-10.56
6	0.029	-1.683	-0.848	-1.082	-2.545	3.361	3.632
7	-1.933	-8.401	0.334	-0.843	-12.19	1.878	-4.024

표 7. 퍼지를 이용한 손상된 구성품 식별 결과

FP CASE	1	2	3	4	5	6	7
1	0.5164	0.1103	0.1103	0.1103	0.4843	0.1103	0.1103
2	0.0945	0.9056	0.0945	0.0945	0.0945	0.0945	0.0945
3	0.0928	0.0928	0.9720	0.0928	0.0928	0.0928	0.0928
4	0.1089	0.1089	0.1089	0.8911	0.1089	0.1089	0.1089
5	0.1086	0.1086	0.1086	0.1086	0.8914	0.1086	0.1086
6	0.0929	0.2205	0.0929	0.0929	0.0929	0.7795	0.0929
7	0.1172	0.1172	0.1172	0.1172	0.1172	0.1172	0.8828

적용한 퍼지룰의 신뢰성을 확인하기 위해 표 3의 7가지 손상패턴에 해당하는 case를 시뮬레이션하여 퍼지추론 시스템에 적용한 결과 표 7과 같은 결과를 얻었다.

Case1의 경우 손상 패턴이 1인 경우가 0.5164로 가장 1에 가까운 결과를 보여 압축기 오염의 가능성이 높음을 알 수 있다. Case 7의 경우에는 손상 패턴이 7인 경우가 0.8828로 3개 구성품에서 동시에 손상이 발생하였을 가능성이 가장 높음을 보여주고 있다. Case 2, 3, 4, 5, 6에서도 각각 손상 패턴 2, 3, 4, 5, 6에서 가장 1에 가까운 값을 보여주고 있다.

이는 표 6에서 가정한 손상 패턴과 일치하는 것으로 퍼지 로직을 통해 손상된 구성품을 효과적으로 식별할 수 있음을 확인할 수 있다.

퍼지 로직을 통해 엔진의 손상 패턴이 식별되고 나면 그에 해당하는 신경회로망 진단 프로그램을 호출한다. 신경회로망을 이용한 손상 패턴에 따른 진단 결과는 그림 4와 같다.

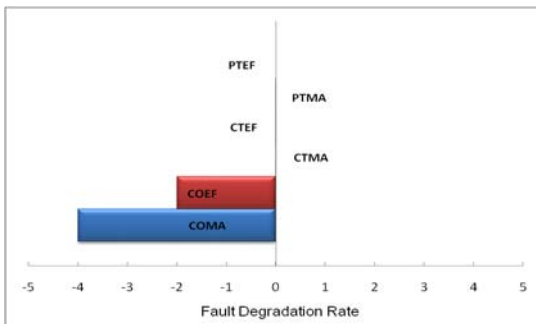


그림 4(a). 다중손상 진단 결과 (CASE 1)

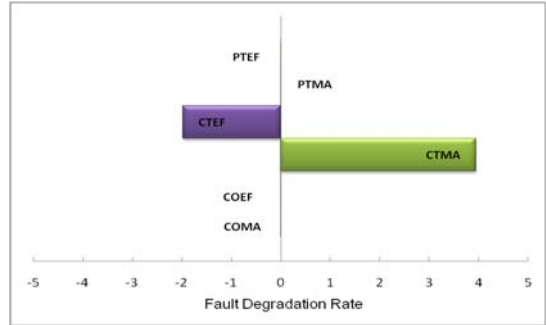


그림 4(b). 다중손상 진단 결과 (CASE 2)




그림 4(c). 다중손상 진단 결과 (CASE 3)

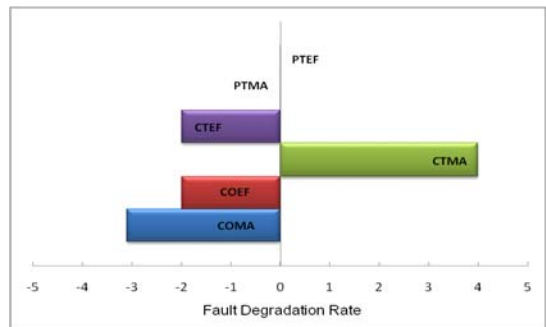


그림 4(d). 다중손상 진단 결과 (CASE 4)




그림 4(e). 다중손상 진단 결과 (CASE 5)

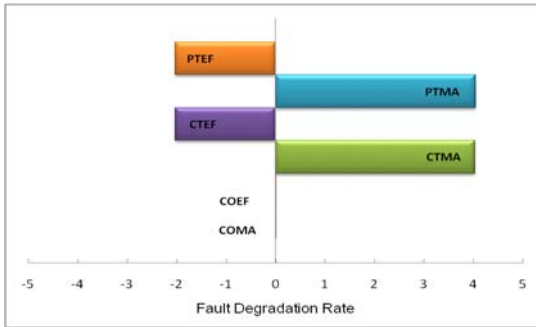


그림 4(f). 다중손상 진단 결과 (CASE 6)

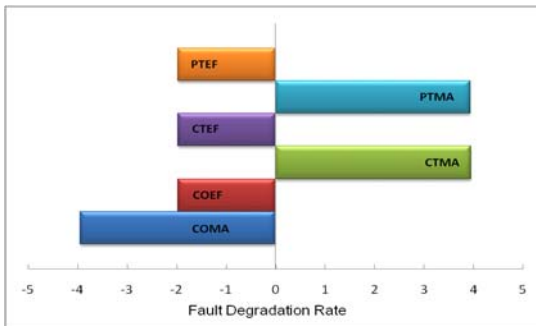


그림 4(g). 다중손상 진단 결과 (CASE 7)

7가지 손상 패턴에 대한 진단을 수행한 결과 표 5에서 임의로 준 손상값과 거의 일치하여 신뢰성 있는 진단이 가능함을 확인할 수 있었다.

IV. 결 론

본 연구에서는 1차적으로 손상된 구성품을 식별하고 그에 맞게 훈련된 신경회로망을 적용하여 정량적으로 엔진 상태를 진단하는 알고리즘을 제안하였다.

퍼지 로직은 다양한 형태의 손상 패턴을 정확하게 분류하였고 각 손상 패턴에 따라 훈련된 신경망에 적용한 결과 RMS오차율 0.1%이내에서 성능저하량을 예측하는 것이 가능함을 알 수 있었다.

그러나 이러한 결과는 센서 손상이나 계측시스템의 노이즈를 고려하지 않아 실제 시스템에 적용하게 되면 오차가 더 커질 것으로 예상되며 이에 대한 연구가 계속 진행되어야 할 것으로 판단된다.

후 기

이 연구(논문)는 지식경제부 지원으로 수행하는 21세기 프론티어 기술개발사업(스마트무인기 기술개발)의 일환으로 수행되었습니다.

참고문헌

- 1) Urban, L.A., 1972, "Gas Path Analysis Applied to Turbine Engine Condition Monitoring", J.of Aircraft, Vol. 10, No 7, pp. 400~406.
- 2) Lu, P.J., Zhang, M.C., Hsu, T.C., and Zhan, J., 2000, "An Evaluation of Engine Faults Diagnostics using Artificial Neural Networks, Proceeding of ASME TURBO EXPO 2000, 2000-GT-0029.
- 3) "EPPP (Estimated Engine Performance Program) Manual", Pratt-Whitney.
- 4) Boyce, M.P., 2006, "Gas Turbine Engineering Handbook", Elsevier Inc.
- 5) Diakunchak, I.S., "Performance Deterioration in Industrial Gas Turbines", Journal of Engineering for Gas Turbines and Power, Vol. 114, pp. 161~167, 1992.
- 6) Lee, H. Y., Mun, G. I., 1999, "Fuzzy-Neuro using MATLAB", A-Jin.
- 7) Tsoukalas, L.H. and Uhrig, R.E., 1997, "Fuzzy and Neural Approaches in Engineering", John Wiley & Sons, Inc.
- 8) Kurzke, J., 2001, "A Program to calculate Design and Off-Design Performance of Gas Turbines", GasTurb 9 User's Manual.
- 9) Heykin, S., 1994, "Neural Networks - A Comprehensive Foundation", Macmillan.