

풍력발전 고장검출 시스템을 위한 인공 신경망 기반의 모델링 기법 개발

(Development of artificial neural network based modeling scheme for wind turbine fault detection system)

문대선*, 나인호**, 김성호***

(Dae Sun Moon, In Ho Ra, Sung Ho Kim)

요약

전 세계적으로 풍력발전은 전력생산을 위해 사용되는 신재생 에너지원 중 가장 빨리 성장하고 있는 분야로 새로 건설되는 풍력발전단지는 전체 전력 생산량에서 많은 부분을 차지해가고 있다. 풍력발전단지의 설치 증가는 더욱 효율적인 운영과 유지 보수에 대한 기술 개발을 요구하게 된다. CM(Condition Monitoring) 시스템은 풍력발전 시스템의 효율적 운영을 가능케 하는 중요한 도구로 운영자에게 기계의 운전 상태에 대한 정보를 제공함과 동시에 유지보수와 관련된 체계적인 정보를 제공한다. 이에 본 연구에서는 풍력발전용 SCADA 시스템으로부터의 각종 정보를 이용하여 해당 장치의 고장검출에 효율적으로 사용될 수 있는 인공신경망을 기반으로 하는 정상 동작 모델의 체계적인 설계 과정에 대해 고찰하고자 한다. 또한 제안된 설계 기법의 유용성 확인을 위해 군산 비응도에 설치된 Vestas사의 850KW급 풍력발전시스템으로부터의 SCADA 데이터를 사용하였다.

■ 중심어 : | 풍력발전 | 상태모니터링 | SCADA 시스템 | 인공신경망 | 고장검출 |

Abstract

Wind energy is currently the fastest growing source of renewable energy used for electrical generation around world. Wind farms are adding a significant amount of electrical generation capacity. The increase in the number of wind farms has led to the need for more effective operation and maintenance procedures. Condition Monitoring System(CMS) can be used to aid plant owners in achieving these goals. In this work, systematic design procedure for artificial neural network based normal behavior model which can be applied for fault detection of various devices is proposed. Furthermore, to verify the design method SCADA(Supervisor Control and Data Acquisition) data from 850kW wind turbine system installed in Beaung port were utilized.

■ keywords : | Wind Generation | Condition Monitoring | SCADA system | Artificial Neural Network | Fault detection

I. 서 론

최근 풍력발전기에 대한 시장의 주된 동향은 대용량화이다. 일 예로 5MW급 풍력발전기의 블레이드의 지름과 타워의 높이는 약 120m이며 따라서 대형화로 인한 설계상의 기술적 문제 및 유지관리상의 문제가 대두되고 있다. 일반적으로 대용량 풍력발전 기에는 고 신뢰성을 갖는 고가의 부품이 다량으로 사용되고 있기 때문에 이들 부품에 대한 상태 모니터링의 중요성이 더욱 증가되고 있는 실정이다. 특히, 고장이 발생되었을 경우 접근성의 제약을 갖는 해상 풍력발전 시스템에 있어서의 상태 모니터링은 필수적이라 할 수 있다[1].

실시간 상태 모니터링 시스템(Condition Monitoring System)은 설치된 각종 센서들로부터의 정보를 기반으로 기계의 운전 상태를 모니터링하고 장기간에 걸쳐 누적되는 부품의 노후화 정도 및 갑작스런 이상의 발생을 조기에 감지할 수 있는 기능을 갖는다. 따라서 CMS의 도입은 고장이 발생된 후의 유지보수 및 정기점검으로 인한 운전비용의 절감을 도모할 수 있으며, 또한 고장의 발생을 적기에 예측함으로써 부품수명의 증가 및 안정성을 확보할 수 있다는 장점을 갖는다.

일반적으로 CMS를 설계하기 위해서는 고장검출 대상에 대한 고수준의 수학적 정보가 요구되나 이들 정보는 얻기에 힘들뿐만 아니라 경우에 따라서는 존재하지 않는 경우도 많다. 이러한 이유로 풍력발전용 CMS 설계와 관련된 연구들은 풍력발전기의 운

* 학생회원, 군산대학교 전자정보공학부 박사과정

** 정회원, 군산대학교 정보통신공학과 교수

*** 정회원, 군산대학교 제어로봇공학과 교수

이 연구는 군산대학교 정보통신기술연구소의 부분적인 지원으로 수행되었다.

접수번호 : #2012-05-29-0025

접수일자 : 2012년 05월 29일

심사완료일 : 2012년 06월 29일

교신저자 : 김성호 e-mail : shkim@kunsan.ac.kr

영을 통해 얻어지는 SCADA(Supervisory Control and Data Acquisition) 데이터를 기반으로 한 것이 대부분이다. Hameed 등은 풍력발전 시스템을 위한 다양한 형태의 CMS 기법들에 대한 조사를 수행한 바 있으며 최근의 연구로 Sanz-Bobi 등은 풍력발전기의 핵심요소인 기어박스에 대한 고장검출을 위해 인공신경망 기반의 예측적 고장진단 기법을 제안하고 실용성을 입증한 바 있다[2-3].

SCADA 데이터를 이용한 대부분의 인공신경망 기반의 CMS에서는 고장검출 대상에 대한 정상 동작(normal behavior)을 표현하기 위해 인공신경망이 사용되고 있으며 이는 인공신경망이 입출력 변수들 간에 존재하는 상당한 크기의 비선형성을 효율적으로 처리할 수 있다는 점에 기인한다. 일반적으로 정상 동작의 모델링을 위해 인공신경망을 사용할 경우, 학습에 사용되는 입력 데이터의 선정 및 사용된 인공신경망의 구조에 따라서 모델링 특성이 변하게 되며 따라서 보다 정확한 정상 동작 모델의 구현을 위해서는 학습에 사용되는 입력 데이터의 체계적인 선정방법이 필요로 된다.

이에 본 연구에서는 첫째, 정상 동작 모델의 구현을 위해 적용될 수 있는 다양한 인공 신경망 모델의 특성에 대해 고찰하고자 하며 둘째, 인공신경망의 학습에 사용되는 변수 및 이와 관련된 지연시간의 체계적인 결정 방법에 대해 고찰하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 대형 풍력발전 시스템의 구성 요소 및 SCADA를 위해 설치되는 각종 센서의 종류에 대해 기술하고자 하며, 3장에서는 고장검출에 사용되는 인공신경망 기반의 정상 동작 모델링과 관련된 입출력 데이터의 체계적인 선정 기법에 대해 설명하고 4장에서는 군산 비옹항에 설치되어 운전되고 있는 Vestas사의 풍력발전기로부터의 SCADA 데이터를 사용하여 제안된 인공신경망의 학습 데이터 선정 기법의 유용성을 확인하고자 한다. 또한 5장에서는 결론에 대해 기술하고자 한다.

II. 풍력발전 시스템의 전체 구성

풍력발전 시스템은 블레이드, 타워 및 너셀로 구성되며, 소프트, 증속을 위한 기어박스 및 발전기는 타워상단에 설치된 너셀에 장착된다. 너셀 내부에는 각종 부품 및 이들의 상태 측정을 위해 다양한 센서들이 설치되며 이를 실제적 구현을 나타내면 그림 1과 같다.

그림 1에서 ①은 너셀 내부 온도, ②는 기어박스용 오일 저장소 온도, ③은 기어박스 베어링 온도, ④는 고속측 소프트의 회전속도, ⑤는 발전기 베어링 온도, ⑥은 3상 발전기의 고정자 권선 온도, ⑦은 전력량, ⑧은 외부 대기온도 등을 측정하기 위한 센서를 나타내며 이를 센서로부터의 정보는 표 1과 같이 10분간 평균값

으로 SCADA용 데이터베이스에 저장된다.

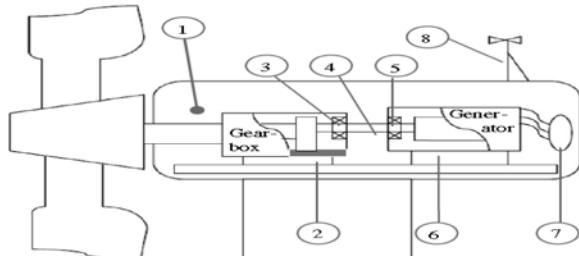


그림 1. 풍력발전 시스템의 너셀 내부 구조 및 각종 센서 배치도

표 1. 풍력발전 SCADA용 데이터베이스

Timestamps	WindSpeed	Power	Pitch	GenRPM	RotorRPM	EnvirTemp	NacelTemp	GearOilTemp	GearBear1Temp	GenPh1Temp	GenPh2Temp	GenPh3Temp	GenBear2Temp
2011-07-28 7:40	9.9	545.2	-1.8	1940	25.9	28	37	67	76	87	93	91	70
2011-07-28 7:50	9.9	539	-1.9	1940	26	28	37	67	76	88	94	92	70
2011-07-28 7:20	9.8	539	-1.9	1939	25.9	28	37	67	76	90	96	94	70
2011-07-28 7:10	10.6	627.4	-1.4	1940	26	28	37	68	77	90	97	95	70
2011-07-28 7:00	10.2	587.9	-1.6	1939	25.9	28	37	68	77	91	97	96	70
2011-07-28 6:50	10.3	611.4	-1.5	1940	26	28	37	68	77	92	99	97	70
2011-07-28 6:40	10.6	635.7	-1.2	1939	25.9	28	37	67	76	93	100	98	70
2011-07-28 6:30	11	707.4	-0.9	1939	25.9	28	37	67	76	93	101	99	69
2011-07-28 6:20	11	697.6	-1	1940	25.9	28	37	65	75	93	101	100	68

III. 고장 검출을 위한 인공신경망 기반의 정상 동작 모델

일반적으로 표 1과 같은 데이터베이스가 존재한다면 이로부터 풍력발전기의 핵심 장치에 대한 유용한 정보를 취득할 수 있다. 특히, 풍력발전 시스템이 정상적으로 운전되고 있을 경우에 대한 SCADA 데이터는 풍력발전기의 핵심 장치에 대한 정상 동작의 모델링에 효과적으로 사용될 수 있다[4].

일반적으로 SCADA 데이터로부터 얻어지는 각종 센서 데이터들 간에는 상호 연관성이 존재한다. 일례로 풍력발전기에 사용되는 3상 권선형 유도발전기의 고정자 권선의 온도는 풍속, 생산전력, 발전기의 회전속도, 발전기 베어링 온도 등과 밀접한 관계를 갖는다.

풍력발전기에 설치되는 각종 장치에 대한 정상 동작의 모델링을 위해 SCADA 데이터를 사용할 경우, 신경망의 학습에 사용되는 입력 데이터는 되도록 이면 상호 연관성이 높은 것을 채택하는 것이 바람직하다. 이에 본 연구에서는 풍력발전기의 각종 장치의 정상 동작 모델링에 사용되는 입력 변수의 체계적인 선정을 위해 측정 데이터 간에 존재하는 상관관계를 선정 기준으로 채택하고 선정된 데이터를 사용할 경우 다양한 형태의 인공신경망의 모델링 특성에 대해 고찰하고자 한다.

1. 인공신경망 기반의 정상 동작 모델링

본 연구에서는 풍력발전시스템에서 아용되는 기어박스용 오일 냉각시스템의 정상 동작 모델링에 대해 고찰하고자 한다. 풍력발전기 너셀 내부에는 블레이드로부터의 저속회전을 고속회전으로 만들기 위한 기어박스가 존재한다. 기어박스는 톱니바퀴로 연결되어 있기 때문에 원활한 회전을 위해서는 오일 순환장치가 필요로 된다. 만일 오일의 정체와 순환이 정상적으로 이루어지지 않는다면 오일의 온도는 상승하게 되고 이로 인해 오일의 점도가 떨어져 효율적인 유통작용이 불가능하게 되어 기어박스의 진동 및 이로 인한 기어의 마모 등을 초래할 수 있어 최악의 경우 발전이 중지되는 상황으로까지 진전될 수 있다.

이러한 기능을 갖는 기어박스용 오일 순환 시스템의 전체 구조를 나타내면 그림 2와 같다.

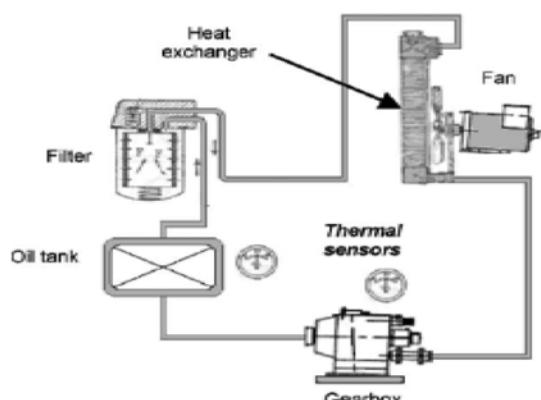


그림 2. 기어박스용 오일 순환 시스템

그림 2와 같은 장치에 대한 정상 또는 고장을 판단하기 위해서 단지 오일의 온도만을 측정하는 것은 바람직하지 않다. 왜냐하면 풍력발전 시스템은 정격이상의 풍속에서도 동작을 하며 이로 인해 기어박스의 오일 온도는 상당히 높아지게 된다. 따라서 단순히 오일온도의 임계치 검사에 의한 고장의 검출은 신뢰성이 낮아지게 된다. 그러나 오일 온도 이외의 다른 데이터를 함께 고려한다면 보다 정확한 정상 동작에 대한 모델링이 가능하게 된다.

본 절에서는 오일 온도이외의 계측 데이터를 정상 동작 모델링에 사용할 경우 어떤 데이터를 사용하는 것이 바람직한지 그리고 선택된 데이터의 지연시간을 어떻게 설정할지에 대해 체계적인 방법에 대해 고찰하고자 한다.

해당 장치에 대한 정상 동작 모델을 인공신경망에 의해 구현할 경우, 정상 동작의 학습을 위한 입력 데이터의 선정이 요구된다. 이에 본 절에서는 인공신경망의 학습에 사용되는 입력 변수의 결정을 위해 입·출력 변수들 간에 존재하는 상관관계를 고려하고자 하였다.

이 경우 인공신경망의 출력은 기어박스 오일 온도

(Gear_Oil_Temp)이다. 또한 인공신경망에 사용될 입력변수들과 출력변수간의 상관관계의 고찰을 위해 표 2와 같은 발전기의 생성되는 전력(Power), 회전수(Gen_RPM) 및 기어박스 베어링 온도(Gen_Bearing_Temp), 기어박스 오일 온도(Gear_Oil_Temp)를 선정하였다.

표 2에서 t-1 및 t-2 등은 해당 변수에 대한 시간지연을 의미하며, 따라서 출력변수 Gear_Oil_Temp(t)와 Gen_RPM(t-1)과의 상관관계는 0.854843이고, Gear_Bearing_Temp(t-1)와의 상관관계는 0.973947, Gear_Oil_Temp(t-1)와 상관관계는 0.991985임을 의미한다.

표 2. 출력변수 Gear_Oil_Temp(t)와 각 변수들의 시간지연에 따른 상관관계

	t-1	t-2	t-3	t-4
Power	0.595813	0.58639	0.578275	0.570629
Gen_RPM	0.854843	0.831344	0.811907	0.794077
Nacelle_Temp	-0.14435	-0.14838	-0.15206	-0.15588
Gear_Oil_Temp	0.991985	0.984102	0.975661	0.966298
Gear_Bearing_Temp	0.973947	0.96431	0.954172	0.943411
Stator_Temp	0.758574	0.756638	0.753405	0.749229
Gen_Bearing_Temp	0.756903	0.752164	0.745226	0.7371116

표 2의 상관관계로부터 기어박스 오일 순환 시스템의 인공신경망 기반의 정상 동작 모델의 입력으로 상관관계가 높은 데이터를 선정하는 것이 바람직함을 알 수 있으며 최종적으로 선정된 입력 데이터 및 해당 변수의 지연시간을 나타내면 표 3과 같다.

표 3. 기어박스용 오일 냉각 및 세정 시스템의 정상 동작 모델링을 위한 인공신경망 입·출력 변수

Output	Inputs
Gear_Oil_Temp(t)	Power(t-1) Generator_RPM(t-1) Gear_Oil_Temp(t-1) Gear_Bearing_Temp(t-1)

2. 학습을 위한 인공 신경망의 종류

본 연구에서는 인공신경망 기반의 정상 동작 모델링을 위해 다음과 같은 두 종류의 인공신경망을 사용하였다.

그림 3은 비선형 시스템의 학습에 널리 사용되는 3층 인공신경망으로 오류 역전파 알고리즘(Back-propagation)이다. 오류 역전파 알고리즘은 입력층, 은닉층, 출력층으로 구성되며, 은닉층 뉴런의 출력은 다음 식(1)에 의해 계산될 수 있다.

$$\begin{aligned} z_1 &= f\left(\sum_{i=1}^n w_{i1}x_i + Bias_1\right) \\ &\vdots \\ z_j &= f\left(\sum_{i=1}^n w_{ij}x_i + Bias_j\right) \end{aligned} \quad (1)$$

여기서 w_{ij} 는 입력층 뉴런 j 와 은닉층 뉴런 i 간의 연결강도이며, 출력층은 다음 식(2)에 의해 입력에 해당하는 출력을 나타낸다.

$$\begin{aligned} y_1 &= f\left(\sum_{i=1}^z w_{i1}z_i + Bias_1\right) \\ &\vdots \\ y_m &= f\left(\sum_{i=1}^z w_{im}z_i + Bias_m\right) \end{aligned} \quad (2)$$

마찬가지로 여기서 w_{im} 은 은닉층 뉴런의 i 와 출력층 뉴런 m 간의 연결강도이고, $Bias$ 는 각 층에서 뉴런이 활성화되기 위한 최소 한계치이다.

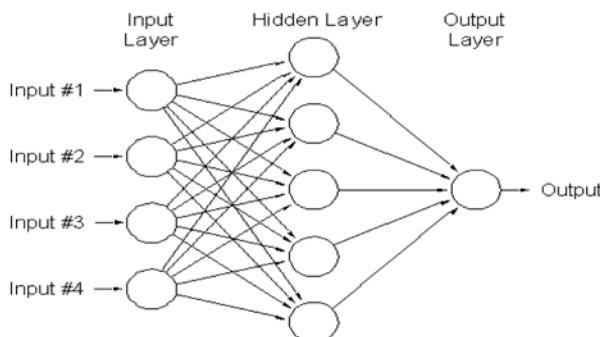


그림 3. 학습에 사용된 전형적인 3층 인공신경망의 구조

그림 4는 인공신경망과 퍼지로직의 복합적인 모형으로 두 모형의 장점을 결합한 ANFIS(Adaptive Neuro-Fuzzy Inference System)의 기본 구조를 나타낸다.

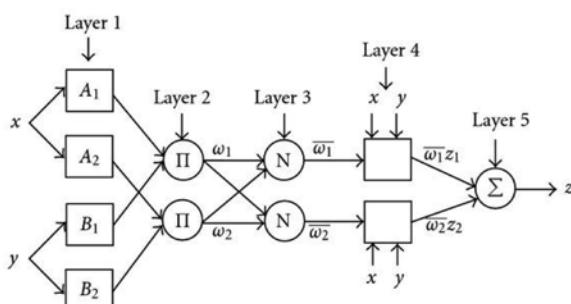


그림 4. 학습에 사용된 ANFIS 인공신경망의 구조

Layer 1 :

입력값 x, y 를 받아 membership 함수를 이용하여 입력값의 자료를 정량화 시킨다. 식(3)은 Gaussian2 변수 함수를 나타낸 것이다.

$$\mu_A(x) = \exp\left(-\left(\frac{x - c_i}{a_i}\right)^2\right) \quad (3)$$

Layer 2 :

membership 함수를 통하여 계산된 값들을 합산한다. 일반적으로 T-norm 실행자가 사용되며 이것은 fuzzy AND 연산자를 적용한 것과 같은 결과를 나타낸다. 식(4)는 일련의 과정을 수식으로 나타낸 것이다.

$$O_{2,i} = \omega_i = \mu A_i(x) \mu B_i(y), \quad i = 1, 2. \quad (4)$$

Layer 3 :

룰들의 강도를 합산하여 총 룰강도를 계산한다.

$$O_{3,i} = \bar{\omega}_i = \frac{\omega_i}{\omega_1 + \omega_2}, \quad i = 1, 2. \quad (5)$$

Layer 4 :

1~3번층에서 퍼지화 된 자료를 defuzzification을 하는 층이며, 식(6)으로 나타낸다.

$$O_{4,i} = \bar{\omega}_i f_i = \bar{\omega}_i (p_i x + q_i y + r_i) \quad (6)$$

Layer 5 :

4번층에서 계산된 결과를 합산하여 결과값을 도출한다.

$$\text{overall output } O_{5,i} = \sum_i \bar{\omega}_i f_i = \frac{\sum_i \bar{\omega}_i f_i}{\sum_i \bar{\omega}_i} \quad (7)$$

3. 인공신경망 기반의 고장 검출 기법

학습이 완료된 인공신경망은 해당 장치에 대한 정상 동작의 모사가 가능하며 따라서 인공신경망의 출력과 실제 계측된 값과의 차를 이용한다면 해당 장치의 고장검출이 가능하게 된다. 본 연구에서는 그림 5와 같이 SCADA시스템으로부터 얻어지는 풍력발전기의 실시간 정보를 신경망을 이용한 오일냉각 시스템의 고장을 검출하는 인공신경망 기반의 고장검출 시스템을 구축하고자 하였다.

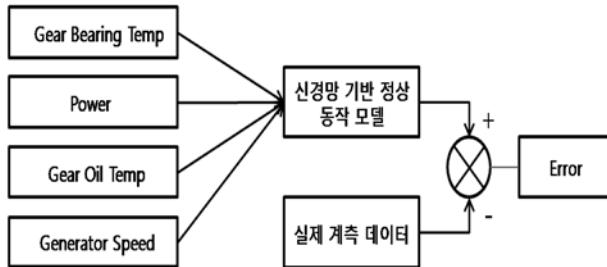


그림 5. 인공신경망 기반의 고장 검출 시스템의 구조

IV. 인공신경망 기반의 정상 동작 모델의 모델링 및 고장 검출 특성

본 장에서는 제안된 인공신경망 기반의 모델 및 이의 고장검출 특성의 확인을 위해 군산 비옹항에 설치·운영되고 있는 Vestas사 850KW급 발전기의 SCADA 운전 데이터를 사용하였다. 그림 6은 학습에 사용된 10분 평균 전체 데이터 8000개로 운전 중 정상상태의 데이터만을 학습에 사용하기 위해 정기적인 오일 교환 및 센서 고장 등으로 인해 발전기의 가동이 중지되었을 경우에 해당하는 데이터는 제거되었다. 또한 인공신경망의 효율적인 학습을 위해 각 변수들에 대한 평균 및 분산을 구한 후, 해당 변수에서 평균을 빼고 분산으로 나누어 해당 변수에 대한 정규화를 수행하였다.

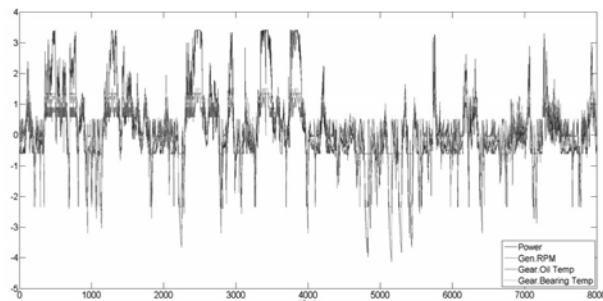


그림 6. 인공 신경망의 학습에 사용된 10분 평균 SCADA 데이터

시뮬레이션에 사용된 신경망의 구조는 3층 인공신경망의 경우 입력층, 은닉층, 출력층을 각각 4개, 30개, 1개를 사용하였으며, ANFIS 신경망의 경우 입력층, 출력층, 멤버쉽함수(Inputmf, Rule, Outputmf)를 각각 4개, 1개, 9-27-27개를 사용하였다.

기어박스 오일 순환 시스템의 정상 동작 모델의 학습을 위한 입출력 데이터는 데이터들 간의 상관관계를 고려하여 표 3와 같이 선정하였으며, 학습이 완료된 두 개 인공신경망의 모델링 특성 및 오차를 나타내면 그림 7, 8과 같다.

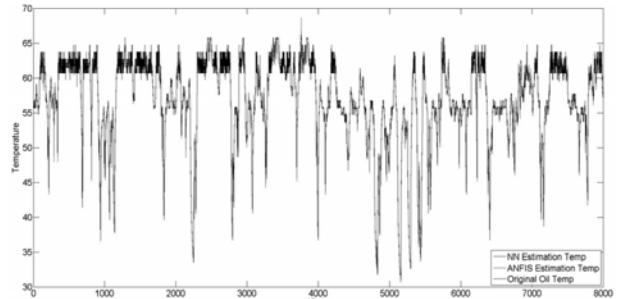


그림 7. 각 인공신경망의 모델링 특성

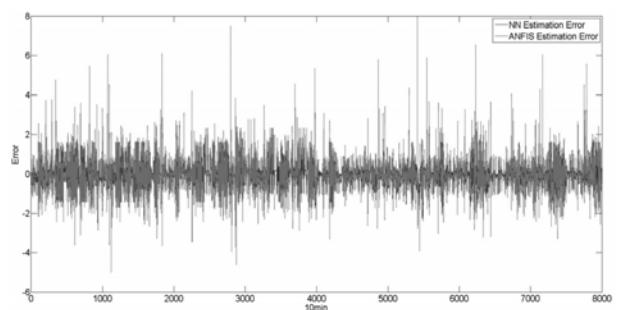


그림 8. 각 인공신경망의 모델링 오차

그림 7, 8은 인공신경망의 학습 변수의 선정 시 변수들 간의 상관관계를 고려한 것이며, 만일 인공신경망의 학습변수의 선정을 임의로 하였을 경우의 모델링 특성을 살펴보면 그림 9,10과 같다.

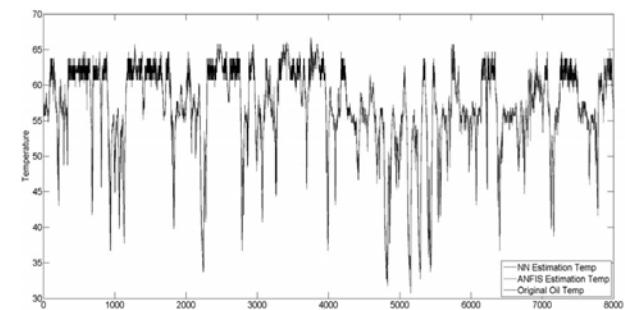


그림 9. 임의로 선정된 인공신경망 학습 변수의 모델링 특성

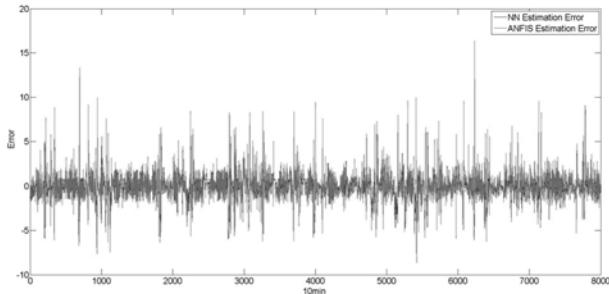


그림 10. 임의로 선정된 인공신경망 학습 변수에 따른 모델링 오차

그림 8 및 10으로부터 인공신경망의 입력 데이터를 상관관계를 고려하여 선정한 경우에 대한 풍력발전기 오일 온도 고장 검출 모델링 편차의 SSE는 3층 인공신경망의 경우 약 4,665이고, ANFIS 신경망의 경우 약 6,310이며, 그렇지 않은 경우의 모델링 편차에 대한 SSE는 3층 인공신경망의 경우 약 20,613이고, ANFIS 신경망의 경우 약 21,712이다. 따라서, 신경망 학습에 사용될 변수의 상관관계를 고려하여 인공신경망의 학습 데이터를 선정하는 것이 바람직함을 알 수 있으며, 3층 인공신경망이 ANFIS 신경망보다 모델링 특성이 좋은 것을 알 수 있다.

또한 측정 데이터간의 상관관계를 고려하여 학습된 인공신경망의 정상 동작 모델링 특성을 확인하기 위해 고장이 발생되었을 때의 SCADA 데이터에 적용한 경우의 응답 특성을 나타내면 그림 11과 같다.

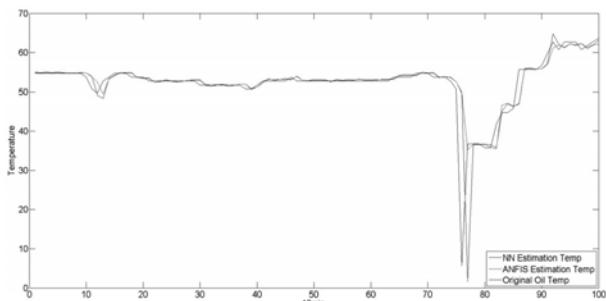


그림 11. 각 인공신경망의 정상 동작 모델링 특성

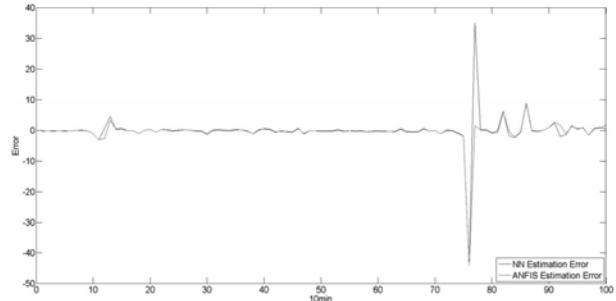


그림 12. 각각의 인공신경망의 출력과 실제 측정값과의 잔차

그림 12에서 약 7~80번째에서 잔차의 크기를 알 수 있으며 이 경우의 SCADA 데이터를 분석해 보면 정전으로 인해 약 3시간동안 시스템이 정지된 경우에 해당된다.

III. 결 론

본 연구에서는 풍력발전 시스템과 관련된 기어박스 오일 냉각 시스템의 정상 동작을 모사할 수 있는 인공신경망 기반의 고장 검출 기법을 제안하였으며, 인공신경망 모델의 학습을 위해 사용되는 입출력 변수의 최적 선정 기법을 제시하였다. 또한 인공신경망 기반의 모델링 기법의 특성 고찰을 위해 실제 850KW급 풍력발전 시스템의 SCADA 데이터에의 적용을 수행하였다.

인공신경망 학습은 과거-스텝 데이터들로 현-스텝만을 추정 하지만, 시스템 적용 시에는 현-스텝 데이터 값과 과거-스텝 데이터 값을 이용하여 미래-스텝 값을 추정하게 되며, 이렇게 설계된 각 인공신경망 기반의 정상 동작 모델과 SCADA 데이터와의 출력비교를 통한 실시간 고장검출이 가능함을 입증하였다. 향후, 인공신경망 기반의 정상 동작 모델과 실측 데이터간의 잔차를 이용한 지능화된 고장검출 및 진단 시스템 설계와 관련된 연구를 진행할 계획이다.

참 고 문 헌

- [1] 이종원, 남용운, “풍력발전기 상태 모니터링 기술 개발 현황,” *기계와 재료*, vol. 19, pp. 71-81, 2007.
- [2] Hameed Z, Hong YS, Cho YM, Ahn SH, Song CK, “Condition monitoring and fault detection of wind turbines and related algorithms: a review,” *Renewable Sustainable Energy Reviews*, vol. 13(1), pp. 1-39, 2009.
- [3] Sanz-Bobi, M.A., Garcia, M.C., “SIMAP: intelligent system for predictive maintenance application to the health condition monitoring of a wind turbine gearbox,” *Computers in Industry*,

- vol. 57, pp. 552–568, 2006.
- [4] Zaher, A., McArthur, D.D.J., "Online wind turbine fault detection through automated SCADA data analysis," *Wind Energy*, vol. 12, pp. 574–593, 2009.
- [5] Zahyers, R.W., McGowan, J.G., "Condition monitoring and prognosis of utility scale wind turbine," *Energy Material*, vol. 1, No. 3, pp. 187–203, 2006.
- [6] M. Schlechtingen, "Comparative analysis of neural network and regression based condition monitoring approaches for wind turbine fault detection," *Mechanical systems and signal processing*, vol. 25, pp. 1849–1875, 2011.
- [7] Hatch, C., "Improved wind turbine condition monitoring using acceleration enveloping", *Machinery Massage*, pp. 59–61, 2004.
- [8] Giebel, G., Juhl, Al., "CleverFarm-A Super SCADA system for wind farms", Report, Riso-R-144(EN), Risoe National Laboratory, Denmark, August, 2004.
- [9] Krug, F., Rasmussen, J.R., "Wind turbine /generator drive train condition based monitoring", *Proceedings of European Wind Energy Conference*, London, UK, 2004.
- [10] R. Iserman., "Process fault detection based on modelling and estimation methods", *Automatica*, vol. 20, pp. 387–404, 1984.



김성호

1984년 고려대학교 전기공학과 학사 졸업.
 1986년 고려대학교 전기공학과 석사 졸업.
 1991년 고려대학교 제어공학과 박사 졸업
 1991년~현재 군산대학교 제어로봇공학과 교수

<주관심분야 : 풍력발전, 인공신경망, 센서 네트워크, 공장 자동화, 고장진단>

저자 소개



문대선

2010년 군산대학교 전자정보공학부 학사 졸업.
 2012년 군산대학교 전자정보공학부 석사 졸업.
 2012년~현재 군산대학교 전자정보공학부 박사 과정.

<주관심분야 : 풍력발전, 고장진단, 뉴럴 네트워크, DSP, 마이크로 컨트롤러, 하드웨어 설계 및 개발>



나인호

1988년 울산대학교 전자계산학과 이학사
 1991년 중앙대학교 컴퓨터공학과 공학 석사
 1995년 중앙대학교 컴퓨터공학과 공학 박사
 1995년~현재 군산대학교 정보통신공학과 교수

<주관심분야 : Ad hoc and Sensor Network, Ubiquitous Computing, Smart Grid, Smart Work>