

풍력발전 시스템을 위한 인공 신경망 기반의 고장검출기법에 대한 연구

Study on Artificial Neural Network Based Fault Detection Schemes for Wind Turbine System

문대선* · 김성호**

Dae-Sun Moon and Sung-Ho Kim[†]

*군산대학교 전자정보공학부

**군산대학교 제어로봇공학과

요 약

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 유지보수에 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.

키워드 : 풍력발전 시스템, CMS(Condition Monitoring System), SCADA(Supervisory Control and Data Acquisition), 정상동작 모델, 인공신경망

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. Its aim is to provide operators with information regarding the health of their machines, which in turn, can help them improve operational efficiency. 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 Beung port were utilized.

Key words : wind turbine system, Condition Monitoring System, SCADA(Supervisory Control and Data Acquisition), normal behavior model, artificial neural network

1. 서 론

최근 풍력발전기에 대한 시장의 주된 동향은 대용량화이다. 일례로 5MW급 풍력발전기의 블레이드의 지름과 타워의 높이는 약 120m이며 따라서 대형화로 인한 설계상의 기술적 문제 및 유지관리상의 문제가 대두되

고 있다. 일반적으로 대용량 풍력발전기에는 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 정기검사로 인한 운전비용의 절감을 도모할 수 있으며, 또한 고장의

접수일자: 2012년 6월 28일

심사(수정)일자: 2012년 10월 7일

게재확정일자: 2012년 10월 8일

† 교신 저자

본 연구는 교육과학기술부와 한국연구재단의 지역혁신인력양성 사업으로 수행된 연구 결과임.

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 얻기 힘들뿐만 아니라 경우에 따라서 존재하지 않는 경우도 많다. 이러한 이유로 풍력발전용 CMS 설계와 관련된 연구들은 풍력발전기의 운영을 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 인공신경망을 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 비유항에 설치되어 운전되고 있는 Vestas사의 풍력발전기로부터의 SCADA 데이터를 사용하여 제안된 인공신경망의 학습 데이터 선정 기법의 유용성을 확인하고자 한다. 또한 5장에서는 결론에 대해 기술하고자 한다.

2. 풍력발전 시스템의 전체 구성

풍력발전 시스템은 블레이드, 타워 및 너셀로 구성되며 메인 샤프트, 증속을 위한 기어박스 및 발전기는 타워상단에 설치되는 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 고속축 샤프트의 회전속도, ⑤는 발전기 베어링 온도, ⑥은 발전기의 고정자 권선의 온도, ⑦은 전력량, ⑧은 외부 대기온도 등의 측정을 위한 센서를 나타내며 이들 센서로부터의 정보는 표 1과 같이 10분간 평균값으로 가공되어 SCADA 데이터베이스에 저장된다.

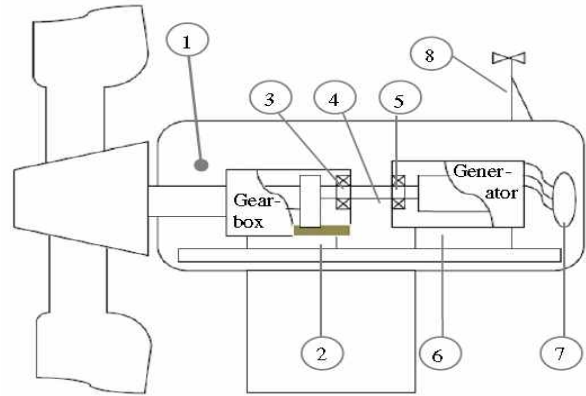


그림 1. 풍력발전 시스템의 너셀 내부 구조 및 각종 센서 배치도

Fig. 1. Internal structure of nacelle and deployment of various sensors

표 1. 풍력발전용 SCADA 데이터베이스

Table 1. SCADA data base for wind turbine system

Timestamps	WindSpeed	Power	Pitch	GenRPM	RotorRPM	EnvirTemp	NacelTem	GearOilTe	GearBearT	GenPh1Te	GenPh2Te	GenPh3Te	GearBearT
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

3. 고장 검출을 위한 인공신경망 기반의 정상 동작 모델(normal behavior model)

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

일반적으로 SCADA 데이터로부터 얻어지는 센서 데이터들 간에는 상호 연관성이 존재한다. 일례로 풍력발전기에 사용되는 3상 권선형 유도발전기의 고정자 권선의 온도는 풍속, 생산전력, 발전기의 회전속도 및 발전기의 베어링 온도 등과 밀접한 관계를 갖는다. 이들 데이터 간에 존재하는 연관성을 상관관계를 통해 정량화하는 것이 가능하다. 그림 2는 MATLAB 프로그램을 이용하여 발전기 베어링의 온도와 발전기 권선 온도간의 상관관계를 나타낸 것으로 두 변수 간에는 적색으로 표현되는 1차 직선의 관계가 존재함을 알 수 있다.

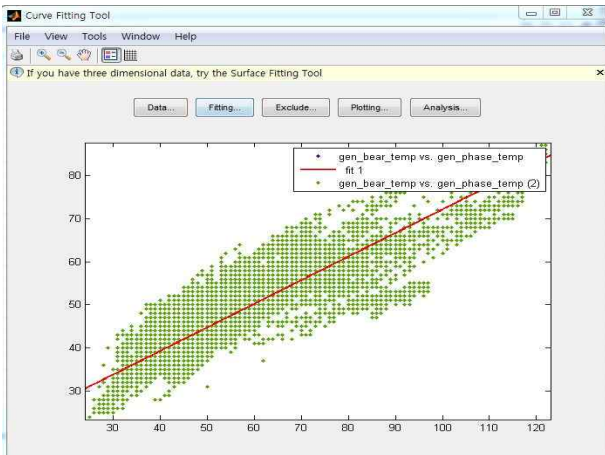


그림 2. 발전기 베어링의 온도와 발전기 고정자 권선 온도간의 상관관계

Fig. 2. Correlation between generator bearing temperature and stator temperature

풍력발전기에 설치되는 각종 장치에 대한 정상 동작 모델링에는 비선형 시스템의 모델링에 효과적으로 도입되고 있는 인공신경망이 널리 사용되고 있으며, 또한 인공신경망의 입력은 되도록이면 상호 연관성이 높은 것을 사용하는 것이 바람직하다. 이에 본 연구에서는 풍력발전기의 각종 장치의 정상 동작 모델링에 사용되는 입력 변수의 체계적인 선정을 위한 방법을 제시하고자 한다.

3.1 인공신경망 기반의 고장 검출 기법

학습이 완료된 인공신경망은 해당 장치에 대한 정상 동작의 모사가 가능하며 따라서 인공신경망의 출력과 실제 계측된 값과의 잔차를 이용한다면 해당 장치의 고장검출이 가능하게 된다. 본 연구에서는 그림 3과 같은 인공신경망 기반의 고장검출 시스템을 사용하였다.

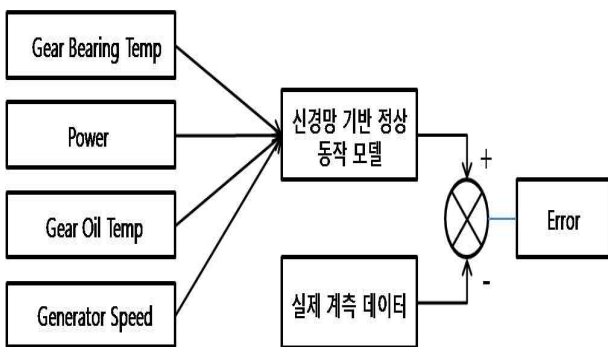


그림 3. 인공신경망 기반의 고장 검출 시스템의 구조
Fig. 3. Structure of artificial neural network based fault detection system

3.2 인공신경망 기반의 정상동작 모델링

본 연구에서는 다음과 같은 세 종류의 풍력발전 장치에 대한 정상 동작 모델링에 대해 고찰하고자 한다.

3.2.1 기어박스용 오일 냉각 시스템의 정상 동작 모델

풍력발전기 너셀 내부에는 블레이드로부터의 저속회전을 고속회전으로 만들기 위한 기어박스가 존재한다. 기어박스는 톱니바퀴로 연결되어 있기 때문에 원활한 회전을 위해서는 오일 순환장치가 필요로 된다. 만일 오일의 정제와 순환이 정상적으로 이루어지지 않는다면 오일의 온도는 상승하게 되고 이로 인해 오일의 점도가 떨어져 효율적인 윤활작용이 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 4와 같다.




그림 4. 기어박스용 오일 순환 시스템
Fig. 4. Oil Circulation system for gear box

그림 4와 같은 장치의 고장 검출을 위해 단지 오일 온도만을 고려하는 것은 바람직하지 않다. 왜냐하면 풍력발전 시스템의 경우 정격이상의 풍속에서는 피치제어가 동작되어 회전수 및 생산전력을 일정하게 조절하기 때문이다. 본 절에서는 인공신경망을 기반으로 하는 정상 동작 모델에 있어서 학습에 사용되는 입력 변수의 결정을 위해 입 · 출력 데이터들 사이에 존재하는 연관성을 확인하기 위해 변수들 간에 존재하는 상관관계를 분석하고자 한다.

기어박스 오일 순환시스템의 경우, 인공신경망 기반 정상동작 모델의 출력은 기어박스 오일 온도이다. 따라서 인공신경망 기반의 정상동작 모델의 입력으로 사용되는 변수를 무엇으로 선정하는 것이 바람직한지를 알기 위해 표 2와 같이 기어박스 오일온도와 SCADA 데이터들 간의 상관관계를 구하였다. 표 2는 인공신경망의 출력 변수인 기어박스 오일온도(Gear_Oil_Temp)와 발전량(Power), 발전기의 회전수(Gen_RPM), 기어박스 베어링 온도(Gen_Bearing_Temp) 등과의 상관관계를 구한 것이다. 또한 표 2에서 t-1 및 t-2 등은 해당 입력 변수들에 대한 시간지연을 의미하며 따라서 표2로부터 출력변수 Gear_Oil_Temp(t)와 Gen_RPM(t-1)과의 상관관계는 0.854843이고, Gear_Bearing_Temp(t-1)와의 상관관계는 0.973947임을 알 수 있다.

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

Table 2. Correlation between Gear_Oil_Temp(t) and related variables

데이터 \ 시간지연	t-1	t-2	t-3	t-4
Power	0.59581	0.58639	0.57827	0.57062
Gen_RPM	0.85484	0.83134	0.81190	0.79407
Nacelle_Temp	-0.14435	-0.14838	-0.15206	-0.15588
Gear_Oil_Temp	0.99198	0.98410	0.97566	0.96629
Gear_Bearing_Temp	0.97394	0.96431	0.95417	0.94341
Stator_Temp	0.75857	0.75663	0.75340	0.74922
Gen_Bearing_Temp	0.75690	0.75216	0.74522	0.73711

기어박스 오일 순환 시스템을 위한 인공신경망 기반의 정상 동작 모델의 입력은 표 2로부터 상관관계가 큰 변수를 선정하는 것이 바람직하다. 그러나 인공신경망의 입력의 개수 등은 다양한 시뮬레이션을 통해 최소의 모델링 오차를 발생시키는 것으로 선정하는 것이 일반적이며 시뮬레이션을 통해 선정된 입력 변수는 표 3과 같다.

표 3. 기어박스 오일 순환시스템을 위한 인공신경망 입 · 출력 변수

Table 3. Input-output variables for artificial neural network for Oil circulation system

Output	Inputs
Gear_Oil_Temp(t)	Gear_Oil_Temp(t-1)
	Gear_Oil_Temp(t-2)
	Gear_Oil_Temp(t-3)
	Power(t-1)
	Generator_RPM(t-1)
	Gear_Bearing_Temp(t-1)

3.2.2 풍력발전기 고정자 권선의 정상 동작 모델

풍력발전에서 사용되는 발전기의 고정자 권선의 온도는 발전기의 회전수, 발전량 및 발전기 베어링 등과 밀접한 관계를 갖는다. 앞서의 경우와 마찬가지로 인공신경망의 출력 변수 Stator_Temp(t)와 다른 변수의 지연시간에 따른 상관관계를 구한 결과를 나타내면 표 4와 같다.

표 4. Stator_Temp(t)와 각 변수들의 지연시간에 따른 상관관계

Table 4. Correlation between Stator_Temp(t) and related variables

	t-1	t-2	t-3	t-4
Power	0.85195	0.83850	0.82616	0.81416
Gen_RPM	0.66751	0.65813	0.64935	0.64060
Nacelle_Temp	-0.79434	-0.2006	-0.20706	-0.21355
Gear_Oil_Temp	0.75502	0.75053	0.74527	0.73942
Gear_Bearing_Temp	0.79307	0.78614	0.77886	0.77127
Stator_Temp	0.99714	0.99159	0.98418	0.97534
Gen_Bearing_Temp	0.87809	0.86883	0.85772	0.84546

표 4의 상관관계를 기반으로 고정자 권선의 정상 동작 모델을 위한 입 · 출력 변수는 표 5와 같이 선정하였다.

표 5. 고정자 권선의 정상 온도 모델링을 위한 인공신경망의 입 · 출력 변수

Table 5. Input-output variables for artificial neural network for stator temperature of generator

Output	Inputs
Stator_Temp(t)	Stator_Temp(t-1)
	Stator_Temp(t-2)
	Stator_Temp(t-3)
	Power(t-1)
	Generator_RPM(t-1)
	Generator_Bearing_Temp(t-1)

3.2.3 발전기용 베어링 온도 정상 동작 모델

발전기의 베어링 온도의 정상 동작 모델의 학습을 위해 앞서의 경우와 마찬가지로 각 변수들 간의 상관관계를 계산하였으며 그 결과를 나타내면 표 6과 같다.

표 6. Bearing_Temp(t)와 각 변수들의 지연시간에 따른 상관관계

Table 6. Correlation between Bearing_Temp(t) and related variables

	t-1	t-2	t-3	t-4
Power	0.66787	0.65787	0.64829	0.63863
Gen_RPM	0.67811	0.66344	0.65003	0.63726
Nacelle_Temp	-0.04951	-0.05545	-0.06203	-0.06901
Gear_Oil_Temp	0.75678	0.75355	0.74905	0.74366
Gear_Bearing_Temp	0.78126	0.77510	0.76805	0.76040
Stator_Temp	0.88647	0.88551	0.88211	0.87658
Gen_Bearing_Temp	0.99400	0.98196	0.96637	0.94884

발전기용 베어링 온도의 정상 동작 모델의 입력은 표 6으로부터 상관관계가 큰 것을 우선적으로 선정하였으며 개수는 다양한 시뮬레이션 통해 최소의 모델링 편차를 나타내는 것으로 선정하였다. 최적 선정된 인공신경망의 입 · 출력 데이터는 표 7과 같다.

표 7. 발전기 베어링 온도의 정상 동작 모델링에 사용된 입 · 출력 변수

Table 7. Input-output variables for artificial neural network for generator bearing temperature

Output	Inputs
Generator bearing temperature(t)	Generator_Bearing_Temp(t-1)
	Generator_Bearing_Temp(t-2)
	Generator_Bearing_Temp(t-3)
	Power(t-1)
	Generator_RPM(t-1)
	Stator_Temp(t-1)

3.3 인공신경망 기반의 정상 동작 모델

본 연구에서는 앞서 고찰한 세 종류의 정상 동작 모델링을 위해 아래의 그림 5와 같은 전형적인 3층 인공신경망을 사용하고자 하였다. 3층 인공신경망은 다수의 뉴런으로 구성되는 입력층, 은닉층 및 출력층으로 구성되며 각 뉴런들 간에 존재하는 연결강도는 학습에 사용되는 입력으로부터 식(1), (2)를 통해 얻어진 출력과 학습에 사용된 출력 데이터 간의 오차를 이용한 오류역전파 알고리즘에 의해 조정된다.

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

여기서 w_{ij} 는 입력층 뉴런 j 와 은닉층 뉴런 i 간의 연결강도이다.

해당 학습 입력에 대한 출력층으로부터의 출력은 식(2)에 의해 구할 수 있다.

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

여기서 w_{im} 은 은닉층 뉴런 i 과 출력층 뉴런 m 간의 연결강도이다.




그림 5. 정상동작 모델에 사용된 전형적인 3층 인공신경망의 구조

Fig. 5. Structure of typical 3-layer artificial neural network for normal behavior modeling

정상동작 모델링을 위한 인공신경망의 학습에는 표 3, 5, 7에서 선정된 변수가 사용된다.

4. 인공신경망 기반의 정상 동작 모델의 모델링 및 고장 검출 특성

본 장에서는 제안된 인공신경망 기반의 모델 및 이의 고장검출 특성의 확인을 위해 군산 비응도에 설치

- 운영되고 있는 Vestas사의 850KW급 풍력 발전기의 SCADA 데이터에 적용하고자 하였다.

학습에 사용되는 데이터는 2011년 2월부터 4월까지 약 3개월간의 10분 평균 SCADA 데이터에서 정기적인 오일교환 및 센서고장 등으로 인해 발전기의 가동이 중단되었을 경우에 해당되는 데이터를 제거한 약 10,000개의 데이터가 사용되었으며 이를 나타내면 그림 6과 같다.




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

Fig. 6. SCADA data used for training artificial neural network

인공신경망의 효율적인 학습을 위해 선정된 입출력 변수들에 대한 평균 및 분산을 구한 후, 해당 변수에서 평균을 빼고 분산으로 나누어 데이터를 정규화 시킨 후 이들 데이터를 인공신경망의 학습에 사용하였다.

4.1 기어박스 오일 순환 시스템의 정상 동작 모델링 및 고장 검출 특성

기어박스 오일 순환 시스템의 정상 동작 모델의 학습을 위한 입출력 데이터는 데이터들 간의 상관관계를 고려하여 표 3과 같이 선정하였으며 학습이 완료된 인공신경망의 모델링 특성을 나타내면 그림 7과 같다.




그림 7. 인공신경망의 모델링 특성(a), 인공신경망의 모델링 오차(b)

Fig. 7. Modeling characteristic of artificial neural networks(a), Modeling error(b)

또한 학습 완료된 인공신경망의 모델링과 관련된 SSE(Sum Square Error)는 6.16e3 이다.

학습이 완료된 인공신경망의 고장검출 특성을 고찰하기 위해 고장이 발생되었을 시점의 SCADA 데이터를 인공 신경망에 입력하였을 경우의 출력 및 실제 출력간의 잔차를 나타내면 그림 8과 같다.




그림 8. 인공신경망 출력 특성(a), 실제 변수와 인공신경망 출력간의 잔차(b)

Fig. 8. Output characteristic of artificial neural network(a) and their residual(b)

그림 8(b)로부터 잔차가 400스텝이후 점차 증가됨을 알 수 있다. 이 부분에 대한 SCADA 데이터를 분석해 보면 과풍속에 의해 시스템의 운전이 중지된 경우에 해당된다. 따라서 그림 8(b)의 400스텝부터 650스텝의 잔차는 풍력발전기가 약 2일간 정지한 경우에 발생하는 것으로 잔차에 대한 임계치 검사를 통해 고장의 검출이 가능함을 알 수 있다. 일반적으로 고장검출을 위한 임계치는 경험적으로 구해지며 본 연구에서는 고장검출의 특성 확인을 위해 임계치를 0으로 선정하였다.

4.2 발전기 고정자 온도 정상 동작 모델링 및 고장검출 특성

발전기의 고정자 권선의 정상 동작 모델의 학습을 위한 입출력 데이터는 표 5와 같이 선정하였으며 학습이 완료된 인공신경망의 모델링 특성을 나타내면 그림 9와 같다.




그림 9. 인공신경망의 모델링 특성(a), 인공신경망의 모델링 오차(b)

Fig. 9. Modeling characteristic of artificial neural networks(a), Modeling error(b)

학습 완료된 인공신경망의 모델링과 관련된 SSE(Sum Square Error)는 7.36e3이다.

학습이 완료된 인공신경망의 고장검출 특성을 고찰하기 위해 고장이 발생되었을 시점의 SCADA 데이터를 인공 신경망에 입력하였을 경우의 출력 및 실제 출력간의 잔차를 나타내면 그림 10과 같다.




그림 10. 인공신경망 출력 특성(a), 실제 변수와 인공신경망 출력간의 잔차(b)

Fig. 10. Output characteristic of artificial neural network(a) and their residual(b)

그림 10의 (b)에서 350스텝부터 450스텝까지 잔차의 크기가 증가함을 알 수 있으며 이 경우 SCADA 데이터를 분석해 보면 오일교환으로 인해 시스템의 동작이 중지된 경우에 해당된다. 이 경우에도 고장검출을 위한 임계치는 0으로 선정하였다.

4.3 발전기 베어링 온도 정상 동작 모델링 및 고장검출 특성

발전기의 베어링 온도의 정상 동작 모델의 학습을 위한 입출력 데이터는 표 7과 같이 선정하였으며 학습이 완료된 인공신경망의 모델링 특성을 나타내면 그림 11과 같다.




그림 11. 인공신경망의 모델링 특성(a), 인공신경망의 모델링 오차(b)

Fig. 11. Modeling characteristic of artificial neural networks (a), Modeling error(b)

학습 완료된 인공신경망의 모델링과 관련된 SSE(Sum Square Error)는 6.64e3이다.

학습이 완료된 인공신경망의 고장검출 특성을 고찰하기 위해 고장이 발생되었을 시점의 SCADA 데이터를 인공 신경망에 입력하였을 경우의 출력 및 실제 출력간의 잔차를 나타내면 그림 12와 같다.




그림 12. 인공신경망 출력 특성(a), 실제 변수와 인공신경망 출력간의 잔차(b)

Fig. 12. Output characteristic of artificial neural network(a) and their residual(b)

그림 12의 (b)로부터 400스텝에서 570스텝까지 잔차의 크기가 증가하는 것을 알 수 있으며 이 경우 SCADA 데이터를 분석해 보면 냉각팬용 릴레이의 고장으로 발전기의 가동이 멈춘 경우에 해당된다. 이 경우에도 고장검출을 위한 임계치는 0으로 선정하였다.

5. 결론

본 연구에서는 풍력발전시스템과 관련하여 기어박스 오일 냉각 시스템, 발전기 축 베어링 온도 및 유도 발전기 고정자 권선 온도에 대한 정상동작의 모사를 가능케 하는 인공신경망 기반의 정상동작 모델링 기법에 대해 고찰하였다. 특히, 인공신경망 기반의 정상동작 모델링시 학습에 사용되는 입력 변수의 선정은 정상동작 모델의 정확성에 큰 영향을 미치기 때문에 본 연구에서는 인공신경망의 입·출력변수들 간에 존재하는 상관관계를 이용하여 인공신경망 입력을 선정하는 방법을 제안하였다. 또한 제안된 기법의 유용성 확인을 위해 군산 비응도에 설치되어 운영되고 있는 850KW급 풍력발전기의 SCADA 데이터에의 적용 결과 제안된 기법의 유용성을 확인할 수 있었다.

References

[1] Young-Ghi Kim, Jae-Hee Byun, Tae-Sik Choi, Chol-Ho So, LS Cable, "A Study on Condition Monitoring for Wind Turbines," *The Korean Institute of Electrical Engineers*, vol. 41, pp. 1247-1248, 2010.

[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., Mc Arthur, D.D.J., "Online wind turbine fault detection through automated SCADA data analysis," *Wind Energy*, vol. 12, pp. 574-593, 2009.

[5] Za Hyers, R.W., Mc Gowan, J.G., "Condition monitoring and prognosis of utility scale wind turbine," *Energy Material*, vol. 1, no. 3, pp. 187-203, 2006.

[6] Giebel, G., Juhl, Al, "Clever Farm-A Super SCADA system for wind farms," *Report, Riso-R-144(EN)*, Risoe National Laboratory, Denmark, Aug. 2004.

[7] Krug, F., Rasmussen, J.R., "Wind turbine/generator drive train condition based monitoring," *Proceedings of European Wind Energy Conference*, London, UK, November 2004.

[8] Hatch, C., "Improved wind turbine condition monitoring using acceleration enveloping," *Machinery Massage*, 2004.

[9] Zaher, A., "Infield online wind turbine fault detection through automated SCADA data analysis," *Wind Energy*, pp. 574-593, 2009.

[10] M.A. Sanz-Bobi, "SIMAP: Intelligent system for predictive maintenance application to the health condition monitoring of a wind turbine gearbox," *Computer in Industry*, vol. 57, pp. 552-568, 2006.

[11] 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.

저자 소개

문대선(Moon Dae-sun)

제 22권 4호(2012년 8월) 참조

김성호(Kim Sung-ho)

제 22권 4호(2012년 8월) 참조