

지능형 클러스터링 기법에 기반한 풍력발전 고장 검출 시스템

A Fault Detection System for Wind Power Generator Based on Intelligent Clustering Method

문 대선, 김 선 국, 김 성 호*
(Dae-Sun Moon¹, Seon-Kook Kim¹, and Sung-Ho Kim¹)
¹Kunsan National University

Abstract: Nowadays, the utilization of renewable energy sources like wind energy is considered one of the most effective means of generating massive amounts of electricity. This is evident in the rapid increase of wind farms all over the world which comprise a huge number of wind turbines. However, the drawback of utilizing wind turbines is that it requires maintenance, which could be a costly operation. To keep the wind turbines in pristine condition so as to reduce downtime, the implementation of CMS (Condition Monitoring System) and FDS (Fault Detection System) is mandatory. The efficiency and accuracy of these systems are crucial in deciding when to carry out a maintenance process. In this paper, a fault detection system based on intelligent clustering method is proposed. Using SCADA data, the clustering model was trained and evaluated for its accuracy through rigorous simulations. Results show that the proposed approach is able to accurately detect the deteriorating condition of a wind turbine as it nears a downtime period.

Keywords: wind power generation, condition monitoring system, fault detection, clustering method, SCADA

I. 서론

최근 화석에너지의 고갈에 대비한 친환경적인 대체 에너지원으로 풍력 발전이 주목받고 있다. 독일, 덴마크를 중심으로 하는 서유럽 여러 나라에서는 1970년대부터 풍력발전이 많은 연구를 진행해 왔으며, 그 결과 최근에는 수 MW 급 풍력 발전 시스템을 상용화하기에 이르렀다. 국내에서도 다수의 연구기관을 중심으로 풍력 발전 시스템의 실용화와 관련된 연구개발이 활발히 진행되고 있으며, 정부차원의 지원을 받아 제주도 등 다수의 지역에서 중대형 풍력 발전 시스템을 설치·운영함으로써 국내 풍력 발전의 가능성을 검토하고 있다[1].

풍력 발전기는 수십 미터 이상 높이의 타워 상단에 설치되는 너셀에 핵심 부품들인 증속기, 발전기 등이 블레이드와 한축으로 연결되어 있는 복잡한 시스템으로 고 신뢰성을 갖는 고가의 부품들이 다량으로 사용되고 있다. 때문에 이들 부품에 대한 상태 모니터링의 중요성이 더욱 증가되고 있는 실정이다. 특히, 고장이 발생되었을 경우 접근성의 제약을 갖는 해상 풍력 발전 시스템에 있어서는 상태 모니터링은 필수적이라 할 수 있다.

실시간 상태 모니터링 시스템(Condition Monitoring System)은 설치된 각종 센서들로부터의 정보를 기반으로 기계의 운전 상태를 모니터링 하고 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 발생을 적기에 예측함으로써 부품수명의 증가와 안정성을 확보할 수 있다는 장점을 갖는다.

일반적으로 CMS를 설계하기 위해서는 고장 검출 대상에 대한 고수준의 수학적 정보가 요구되나 이들 정보는 얻기에 힘들뿐만 아니라 경우에 따라서는 존재하지 않는 경우도 많다. 이러한 이유로 풍력 발전용 CMS 설계와 관련된 연구들은 풍력발전기의 운영을 통해 얻어지는 SCADA (Supervisory Control and Data Acquisition) 데이터를 기반으로 한 것이 대부분이다[2-5]. 특히, E. Lapira 등은 SCADA 데이터에 기반한 다양한 고장검출 기법에 대한 비교 연구를 수행한 바 있다[6]. Lapira의 연구에서는 정상적으로 운전되고 있는 풍력발전기로부터 얻어지는 SCADA 데이터를 이용하여 퍼지 클러스터링 및 인공신경망 등과 같은 지능형 모델링 기법을 활용하여 정상 동작에 대한 모델을 얻은 후, 정상 동작 모델과 실제 측정된 데이터간의 잔차에 대한 통계학적 처리 기법을 사용함으로써 각 모델링 기법에 대한 고장 검출의 성능에 대해 고찰하였다.

풍력발전 시스템은 풍속에 따라 두 가지의 모드로 운전된다. 하나는 시동 풍속에서 정격 풍속 사이에서의 최대 전력점 추종제어(토크 제어)이며 다른 하나는 정격 풍속에서 차단풍속 사이에서의 일정한 전력 제어(피치 제어)이다. 최

* 책임저자(Corresponding Author)

논문접수: 2012. 11. 24., 수정: 2012. 12. 7., 채택확정: 2012. 12. 26.

문대선, 김선국: 군산대학교 전자정보공학부

(nalba01@kunsan.ac.kr/engtop00@naver.com)

김성호: 군산대학교 제어로봇공학과(shkim@kunsan.ac.kr)

※ 본 연구는 지식경제부의 재원으로 한국에너지 기술평가원(KETEP)의 지원을 받아 수행한 연구 과제임 (NO.201230210 20010).

※ 본 논문은 2012년 ICROS 전북제주지부 학술대회에서 초안이 발표되었음.

대 전력점 추종 제어는 풍속의 변화에 따라 발전기로부터 최대 전력의 인출을 위해 로터의 회전수를 조절하는 기법이며 일정 전력 제어는 정격 풍속이상으로 바람이 불 때, 풍력발전시스템의 안정성 확보를 위해 블레이드의 피치각을 변화시켜 고의적으로 변환효율을 저하시키는 기법이다. 따라서 풍력발전기로부터 생산되는 전력은 풍속, 로터의 회전수 및 피치각 등과 같은 여러 변수에 의해 영향을 받게 된다.

이에 본 논문은 2012년 ICROS 전북제주시부 학술대회에서 우수논문으로 선정된 “클러스터링 기법에 기반한 풍력발전기 고장 검출 시스템 개발” 논문의 내용을 확장한 논문으로 풍력발전기의 정상 동작시 얻어지는 SCADA 데이터로부터의 다양한 변수를 사용하여 정상동작에 대한 모델을 구하고자 하였다. 특히, Lapira 등의 연구에서는 풍속 및 발전량 데이터에 기반한 퍼지 클러스터링 기법을 사용하였으나 본 연구에서는 풍속이외에도 로터의 회전수 및 피치각 등을 모델링에 사용할 수 있는 방법을 제안하고자 한다[7].

본 논문의 구성은 다음과 같다. II 장에서는 대형 풍력발전 시스템의 구성 요소 및 SCADA 데이터 측정을 위해 설치되는 각종 센서의 종류에 대해 기술하고자 하며, III 장에서는 Gustafson-Kessel 퍼지 c-means 클러스터링 기법을 소개하고, 클러스터링 기법에 기반한 고장 검출 시스템을 제안하고자 한다. IV 장에서는 다양한 시뮬레이션 고찰을 통해 제안한 기법의 유용성을 확인하고자 하며, V 장에서는 결론을 기술한다.

II. 풍력 발전 시스템의 전체 구성

풍력 발전 시스템은 블레이드, 타워 및 너셀로 구성되며 메인 샤프트, 증속을 위한 기어박스 및 발전기는 타워 상단에 설치되는 너셀에 장착된다. 너셀 내부에는 각종 부품 및 이들의 상태 측정을 위해 다양한 센서들이 설치되며, 이의 실제적 구현으로 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

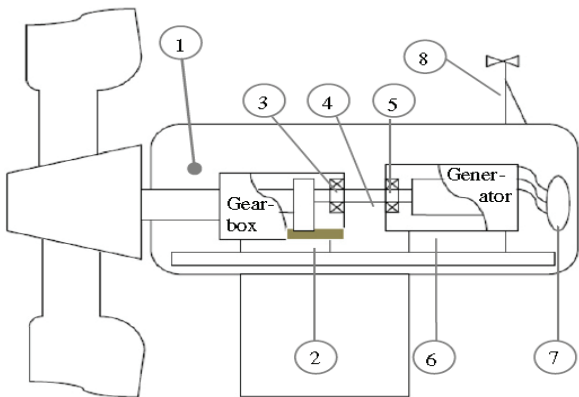


그림 1. 풍력 발전 시스템의 너셀 내부 구조 및 각종 센서 배치도.

Fig. 1. Internal structure of the nacelle showing the deployment of various sensors.

표 1. 풍력발전용 SCADA 데이터 베이스.

Table 1. SCADA data base for wind turbine system.

Time	Wind Speed	Power	Pitch	Gen. Rpm	Rotor Rpm	Nacell Temp	Gear Oil Temp	Gear Bear Temp	Gen. Bear Temp
2011-07-28 7:40	9.9	545.2	-1.8	1940	25.9	37	67	76	70
2011-07-28 7:30	9.9	539	-1.9	1940	26	37	67	76	70
2011-07-28 7:20	9.8	539	-1.9	1939	25.9	37	67	76	70
2011-07-28 7:10	10.6	627.4	-1.4	1940	26	37	68	77	70
2011-07-28 7:00	10.2	587.9	-1.6	1939	25.9	37	68	77	70
2011-07-28 6:50	10.3	611.4	-1.5	1940	26	37	68	77	70
2011-07-28 6:40	10.6	635.7	-1.2	1939	25.9	37	67	76	70
2011-07-28 6:30	11	707.4	-0.9	1939	25.9	37	67	76	69
2011-07-28 6:20	11	697.6	-1	1940	25.9	37	65	75	68

고정자 권선의 온도, ⑦은 전력량, ⑧은 외부 대기온도 등의 측정을 위한 센서를 나타내며 이들 센서로부터의 정보는 표 1과 같이 10분 평균값으로 가공되어 SCADA 데이터 베이스에 저장된다.

III. 클러스터링 기법을 이용한 풍력발전기의 고장 검출 시스템

본 연구에서는 II 장에서 설명한 풍력발전시스템으로부터 제공되는 SCADA 데이터를 이용한 퍼지 클러스터링 기반의 풍력 발전기 고장 검출 시스템을 제안하고자 하며, 제안된 고장 검출 시스템의 전체 구성도를 나타내면 그림 2와 같다.

1. Gustafson-Kessel 퍼지 c-means 클러스터링

퍼지 c-means 클러스터링은 주어진 데이터를 여러 개의 클러스터로 분류 가능함에 기반을 두고 있다. 만일 주어진 데이터가 n개의 p차로 구성된 경우, 퍼지 c-means 클러스터링은 식 (1)과 같이 표현되는 비유함수를 추차적으로 최소화하는 과정이다.

$$J = \sum_{k=1}^n \sum_{i=1}^c (\mu_{ik})^2 (d_{ik})^2 \tag{1}$$

$$d_{ik} = \|x_k - v_i\| \tag{2}$$

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m-1}}} \tag{3}$$




그림 2. 클러스터링 기반의 고장 검출 시스템 전체 구성도.

Fig. 2. Overall architecture of the fault detection system based on clustering method.

여기서 n 은 데이터 개수이며, c 는 클러스터 개수, x_k 는 k 번째 데이터 포인트, v_i 는 i 번째 클러스터 중심이며, μ_{ik} 는 i 번째 클러스터 중심과 k 번째 데이터의 멤버십의 정도이며, d_{ik} 는 i 번째 클러스터 중심과 k 번째 데이터간의 거리이다. 또한 m 은 1보다 큰 상수이며, 일반적으로 $m = 2$ 로 정한다.

퍼지 c-means 클러스터링 기법은 초기에 선정된 클러스터 중심과 개수에 의해 그 특성이 결정되며, 모든 데이터는 주어진 클러스터에 할당되며 그 정도는 0과 1사이의 값을 갖게 된다[8].

이에 반해 Gustafson-Kessel 퍼지 c-means 클러스터링 기법은 퍼지 c-means 클러스터링 기법을 확장한 것으로 퍼지 c-means 기법에서 식 (2)로 표현된 클러스터 중심과 데이터간의 거리 d_{ik} 를 식 (4)로 대체한 경우에 해당한다.

$$(d_{ik})^2 = (x_k - v_i)^T A_i (x_k - v_i) \quad (4)$$

여기서 행렬 A_i 는 식 (1)에 정의된 비용함수 최적화를 위한 변수로 각 클러스터마다 개별적으로 결정되며, 식 (4)에 정의된 클러스터 중심과 데이터간의 거리를 조절하여 최적화에 기여한다. 그러나 Gustafson-Kessel 퍼지 c-means 클러스터링 기법은 퍼지 c-means 클러스터링 기법에 비하여 행렬 A_i 의 계산이 추가로 필요하며 이로 인해 계산량이 증가하게 된다는 단점을 갖는다.

2. 클러스터링 기법을 이용한 풍력발전기 고장 검출

풍력 발전기의 정상 동작 상태일 때의 동작점이 각 클러스터 중심으로부터 갖는 거리는 다음 식 (5)와 같이 정의된다.

$$d_{ij} = \|x_i - v_j\| \quad (5)$$

여기서 x_i 는 i 번째의 동작점, v_j 는 j 번째 클러스터 중심이다. 풍력발전기가 동작되고 있을 경우, SCADA 데이터로부터 매 순간 구해지는 동작점(x_i)들은 Gustafson-Kessel 퍼지 c-means 클러스터링 알고리즘에 의해 구해진 클러스터들의 중심과의 거리를 기반으로 정상 또는 비정상 동작점으로 분류되는 것이 가능하며 이는 그림 3에 의해 설명될 수 있다. 그림 3은 클러스터 중심으로부터 두 개의 동작점간의 거리를 나타낸 것이다. 그림 3에서 보는 것과 같이 정상 상태에 대한 풍력발전 시스템의 전력 대 풍속 특성 곡선은 5




그림 3. 클러스터 중심과 동작점과의 거리.
Fig. 3. The distance of the operating points from the cluster centers.

개의 클러스터 중심 및 클러스터의 반경에 의해 표현될 수 있다. 이와 같은 정상 동작 모델에 임의의 동작점 P1, P2는 다음과 같이 설명되어 진다.

P1의 경우 클러스터 중심으로부터 거리가 세 번째 클러스터(C3)에 제일 가깝기 때문에 정상 동작에 포함된다고 판단할 수 있다. 그러나 P2의 경우, 각 클러스터 중심으로부터 거리가 크기 때문에 비정상적으로 동작한다고 판단할 수 있다.

일반적으로 정상 또는 비정상을 판단하기 위해서는 판단의 기준이 되는 임계치의 설정이 매우 중요하다. 이에 본 연구에서는 클러스터링에 사용된 정상 동작점들과 각 클러스터의 중심들과의 최소 거리 값들 중 가장 큰 값을 임계치로 선정하고자 하였다. 따라서 임의의 동작점에 대한 각 클러스터 중심과의 거리가 규정된 임계치보다 크다면 현재의 동작점은 비정상으로 판정하고 임계치보다 작다면 정상으로 판정한다. 또한 그림 3의 동작점 P2는 실제 풍력발전 시스템의 고장에 의해 발생할 수도 있으나 난류특성의 바람과 10분 평균 데이터로 저장되어진 SCADA 데이터의 측정 오류에 의해 발생할 수도 있다. 따라서 하나의 동작점에 대한 임계치 검사를 통해 고장의 유무를 판단하는 것은 바람직하지 못하다. 이에 본 연구에서는 매 순간 임계치 검사에 의해 비정상 동작의 발생횟수를 고려하여 고장검출을 수행하는 통계학적 기법을 사용하고 하고자 하였다.

IV. 실험 및 결과 고찰

1. 풍력 발전기의 동작 특성에 따른 클러스터 구성

본 연구에서는 풍력 발전기의 동작 특성을 표현 가능한 클러스터로 구성하기 위하여 II 장에서 소개한 표 1과 같이 10분간 평균값으로 가공되어 저장된 군산 비응항의 Vestas사의 850kW급 풍력발전기의 SCADA 데이터를 사용하고자 하였다.

실험에는 그림 4와 같이 2011년 2월부터 11월까지 약 10개월간의 10분 평균 SCADA 데이터를 사용하고자 하였다.

또한 본 연구에서 사용된 Gustafson-Kessel 퍼지 c-means 클러스터링 모델링을 위해 정기적인 오일 교환 및 센서 고장 등으로 인해 발전기의 가동이 중단되었을 경우에 해당되는 데이터를 제거한 그림 5와 같이 표현되는 14,457개의 데이터를 모델링에 사용하였다. 정상동작시의 각 측정변수(풍속, 로터의 회전수 및 피치각)를 나타내면 그림 5와 같다.

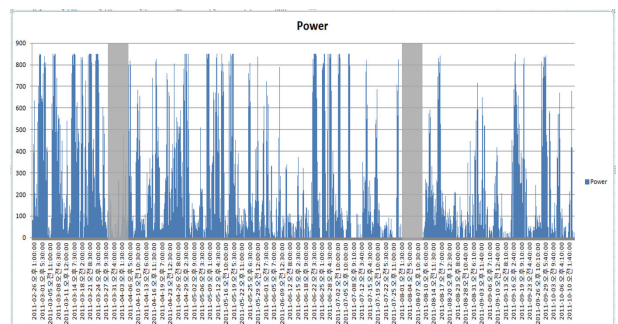


그림 4. 10개월 동안의 10분간 평균 전력 그래프.
Fig. 4. 10 minute average power graph during 10 months.




그림 5. 시뮬레이션에 사용된 10분 평균 SCADA 데이터.
Fig. 5. SCADA data used for simulation.

기록된 SCADA 데이터의 풍속, 발전기 회전수, 그리고 발전량을 이용하여 하나의 데이터 포인트로 구성하였으며, 구성된 데이터 포인트는 다음과 같은 벡터로 표현하였다.

$$x_k = [u_1 \ u_2 \ u_3] \quad (6)$$

여기서 u_1 은 풍속, u_2 는 발전기 회전수, u_3 는 발전량이다. 클러스터 구성을 위하여 사용된 SCADA 데이터의 모든 데이터 포인트는 정상 동작 상태의 데이터만의 추출을 위하여 정상 동작 상태의 데이터를 제외한 나머지 고장 및 점검 등에 의한 데이터들은 모두 제거하였으며, 정상 상태의 각 변수들은 절대치의 최대값을 이용하여 정규화 하였다. 그림 6은 본 논문에서 사용된 데이터를 풍속, 발전기 회전수, 그리고 발전량을 이용하여 정상 동작상태의 발전기 특성을 3차원 그래프로 나타낸 것이다. 풍속, 발전기 회전수, 그리고 발전량의 단위는 [m/sec], [rpm], [kW]이나 본 논문에서는 나타내지 않는다.

Gustafson-Kessel 퍼지 c-means 클러스터링 기법을 사용하여 주어진 데이터를 표현할 수 있는 클러스터의 중심을 구하기 위하여 먼저 클러스터의 개수를 지정하여야 한다. 그림 7은 학습시 지정된 클러스터의 개수에 따른 클러스터




그림 6. 풍력발전기 동작 특성.
Fig. 6. The power curve of the wind turbine derived from the normalized SCADA data.




그림 7. 클러스터 중심의 개수 및 위치 변화.
Fig. 7. Variation of position and number of cluster centers.

중심을 나타내고 있다. 그림 7에서 ‘x’로 표시된 중심은 클러스터의 개수를 5로 지정한 경우 Gustafson-Kessel 퍼지 c-means 클러스터링 기법을 이용하여 얻어진 클러스터 중심이며, ‘o’로 표시된 중심은 클러스터의 개수를 8로 지정한 경우에 클러스터링 기법을 이용하여 얻어진 클러스터 중심이다.

그림 6과 그림 7로부터 풍력발전기의 동작 특성은 클러스터 중심의 개수를 5로 지정한 후 얻어진 클러스터 중심보다 클러스터 중심의 개수를 8로 지정한 후 얻어진 클러스터 중심이 훨씬 효과적으로 표현하고 있음을 알 수 있다.

클러스터의 개수 선정은 데이터 특성의 표현의 중요한 요소임을 알 수 있으며, 본 논문에서는 클러스터 개수를 8로 선정하여 얻어진 클러스터 중심을 이용하여 풍력 발전기의 고장 검출을 수행하고자 한다.

2. 클러스터링 기법을 이용한 풍력 발전기 고장 검출 기법

4.1절에서와 같이 풍력 발전기로부터의 SCADA 데이터를 사용하여 정상동작에 대한 클러스터링이 완료된다면, 클러스터링에 사용되지 않은 임의의 동작점(풍속 = 5.8 [m/s], 발전기회전수 = 1,319 [rpm] 및 발전량 = 103.6 [Kw])에 대한 각 클러스터의 중심으로부터의 거리를 구하면 표 2와 같다.

표 2의 임의의 동작점에 대한 각 클러스터 중심과의 거리들로부터 현재의 동작점은 4번째 클러스터에 속한다고 판단할 수 있다. 만일 임의의 동작점에 대한 각 클러스터 중심과의 최소 거리가 규정된 임계치보다 크게 된다면 현재의 동작점은 정상동작 범위 밖에 존재한다고 판단될 수 있다.

임계치의 체계적인 선정을 위해 본 연구에서는 그림 5의 정상 동작 상태의 데이터(14,457개)를 이용하여 각 클러스터 중심과의 최소거리(표 3 참조)를 사용하고자 하였다.

표 2. 임의의 동작점에 대한 클러스터 중심과의 거리.
Table 2. The distance of an operating point from the various cluster centers.

	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5	Cluster 6	Cluster 7	Cluster 8
Distance	0.4411	0.3402	1.0784	0.1583	0.6589	0.7540	0.9824	1.5236

표 3. 정상동작점과 각 클러스터 중심 간의 거리.

Table 3. Distances between normal operating points and cluster centers.

	동작점 1	동작점 2	동작점 3	동작점 14457
클러스터 중심 1	11.0837012	7.5518735445	1.2291909339	4.5127005689
클러스터 중심 2	0.87813362	0.5842092216	0.0683292774	0.3301838022
클러스터 중심 3	0.25789263	0.1215953666	0.1808685867	0.1408746633
클러스터 중심 4	3.92193111	2.6736280541	0.4361409168	1.6003792897
클러스터 중심 5	0.07642294	0.0776658194	0.2554458011	0.1973885058
클러스터 중심 6	0.20499876	0.1267565585	0.0575455521	0.0748361645
클러스터 중심 7	0.20256583	0.0982852694	0.1324340182	0.1140249585
클러스터 중심 8	0.02126995	0.4589196881	1.2602688359	0.8552176908

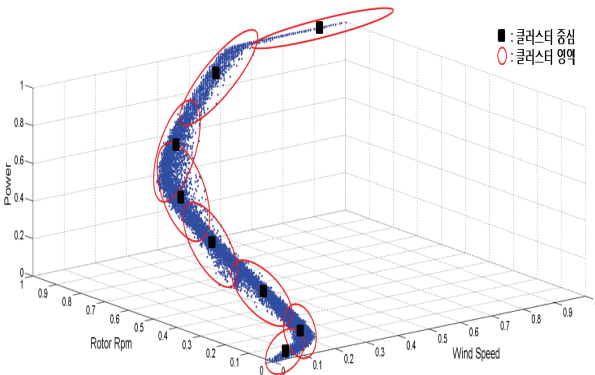


그림 8. 클러스터 중심으로부터 최소거리가 갖는 영역.

Fig. 8. The areas covered by the cluster centers, showing their respective minimum distance.

표 4. 동작점과 각 클러스터 중심 간의 최소 거리.

Table 4. The minimum distance of the operating points from the cluster centers.

	동작점 1	동작점 2	동작점 3	동작점 14457
최소 거리	0.0212699491	0.0776658194	0.0575455521	0.0748361645

표 3에서 클러스터 중심으로부터 최소거리가 갖는 영역을 표시하면 그림 8과 같으며, 각 동작점에 대한 클러스터 중심 간의 최소 거리는 표 4와 같다.

표 4로부터 각 동작점에 대한 클러스터 중심과의 최소거리 중 가장 큰 값을 갖는 값을 정상동작 범위의 임계치로 설정할 수 있으며, 표로부터 구해진 임계치는 0.12이나 다양한 시뮬레이션을 통해 경험적으로 임계치를 0.05로 선정하였다.

3. 제안된 기법의 유용성 확인

제안된 클러스터링 기법에 기반한 풍력 발전기의 고장 검출 기법의 유용성 확인을 위해 실제 풍력 발전기의 고장 시점을 기준으로 1주전, 2주전, 3주전에 해당하는 각각 1,000개의 SCADA 데이터를 시뮬레이션에 사용하였다.

또한 같은 고장 데이터를 이용하여 모델링시 사용된 파라미터의 개수를 달리 하였을 때 나타나는 고장 검출 성능에 대해서도 확인하고자 하였다.

3.1 모델링에 사용된 변수가 3개인 경우의 응답 특성

정상 동작 모델링에 3개의 파라미터(풍속, 발전기 회전수, 발전량)를 사용하여 얻어진 클러스터 중심에 대한 고장 데이터 각 1,000개의 동작점들에 대해 클러스터 중심과의 최소 거리가 규정된 임계치보다 크게 될 경우를 정상동작에서 벗어난 경우로 판단하였으며, 각 동작점들과 클러스터 중심 간의 최소 거리의 차이를 x축, 해당 x축에서의 발생 횟수를 y축으로 하는 히스토그램을 나타내면 그림 9와 같다.

그림 9로부터 고장이 발생되기 3주전의 히스토그램에는 정상 동작에 포함되는(임계치와 최소거리간의 차가 작은 경우에 해당됨) 데이터가 다수 존재하지만 고장 시점에 가까워질수록 정상 동작범위에 포함되는 발생 빈도가 점차 감소됨을 알 수 있다. 또한 고장 발생 1주 전의 히스토그램에서는 동작점과 클러스터 중심 간의 최소 거리와 임계치간의 차이가 큰 경우에 해당되는 동작점의 발생빈도가 크게 됨을 알 수 있다.

3.2 모델링에 사용된 변수가 4인 경우의 진단 특성

정상 동작 모델링에 4개의 파라미터(풍속, 발전기 회전수, 피치각 및 발전량)를 사용하였을 때의 고장 검출 성능




그림 9. 고장 발생 3주전부터 1주전까지의 최소거리에 대한 임계치 검사에 의해 얻어진 히스토그램.

Fig. 9. Histograms showing the deviation of the operation points from the threshold of minimum distance, 3 to 1 week before the failure.

표 5. 동작점과 클러스터 중심 간의 거리.

Table 5. Distances between operating points and cluster centers.

	동작점 1	동작점 2	동작점 3	동작점 14457
클러스터 중심 1	11.0837012	7.5518735445	1.2291909339	4.5127005689
클러스터 중심 2	0.87813362	0.5842092216	0.0683292774	0.3301838022
클러스터 중심 3	0.25789263	0.1215953666	0.1808685867	0.1408746633
클러스터 중심 4	3.92193111	2.6736280541	0.4361409168	1.6003792897
클러스터 중심 5	0.07642294	0.0776658194	0.2554458011	0.1973885058
클러스터 중심 6	0.20499876	0.1267565585	0.0575455521	0.0748361645
클러스터 중심 7	0.20256583	0.0982852694	0.1324340182	0.1140249585
클러스터 중심 8	0.02126995	0.4589196881	1.2602688359	0.8552176908

표 6. 동작점과 각 클러스터 중심간의 최소거리.

Table 6. The minimum distance of the operating points from the cluster centers.

	동작점 1	동작점 2	동작점 3	...	동작점 14457
최소 거리	0.0145	0.0481	0.0079		0.0178




그림 10. 고장 발생 3주전부터 1주전까지의 최소거리에 대한 임계치 검사에 의해 얻어진 히스토그램.

Fig. 10. Histograms showing the deviation of the operation points from the threshold of minimum distance, 3 to 1 week before the failure.

을 확인하기 위해 앞 절에서 설명한 방법과 동일하게 클러스터 중심을 구성하였으며, 각 클러스터 중심으로부터 각 동작점에 대한 거리는 표 5와 같다.

표 5를 이용하여 각 동작점에 대한 클러스터 중심 간의 최소 거리를 구하면 표 6과 같다.

표 6으로부터 각 동작점에 대한 클러스터 중심과의 최소 거리 중 가장 큰 값을 갖는 값을 정상 동작 범위의 임계치로 설정하였으며, 표로부터 구해진 임계치는 0.26이다.

그림 10은 그림 9와 마찬가지로 고장 데이터 각 1000개의 동작점들에 대한 클러스터 중심과의 최소거리를 히스토그램으로 나타낸 것이다. 그림 10으로부터 고장이 발생되기 2주 및 3주전의 히스토그램에는 정상 동작에 포함되는 데이터가 다수 존재하지만 고장 시점에 가까운 1주전의 히스토그램에서는 정상 동작 범위에 포함되는 발생 빈도가 적은 것을 알 수 있다. 또한 동작점과 클러스터 중심간의 최소거리와 임계치 간의 차이가 큰 경우에 해당되는 동작점의 발생빈도가 크게 됨을 알 수 있다. 뿐만 아니라 모델링시 3개의 파라미터를 사용했을 때보다 4개의 파라미터를 사용했을 경우가 고장 검출에 더욱 유리함을 알 수 있다.

V. 결론

본 연구에서는 풍력 발전기로부터 얻어지는 SCADA 데이터를 활용하여 효율적인 고장검출을 수행할 수 있는 Gustafson-Kessel 퍼지 c-means 클러스터링 기법에 기반한

고장 검출 기법을 제안하고 다양한 시뮬레이션 고찰을 통해 제안된 기법의 유용성을 확인하였다. 시뮬레이션 결과 풍력 발전기의 정상 동작 범위를 규정하는 임계치의 설정이 제대로 이루어진다면 히스토그램에 의해 고장의 검출이 가능함을 확인할 수 있었다. 본 연구에서는 풍력 발전기의 정상 동작 모델링시 3개의 파라미터(풍속, 발전기 회전수 및 발전량)와 4개의 파라미터(풍속, 발전기 회전수, 피치각 및 발전량)를 비교하여 고장 검출의 유용성을 확인 하였으며, 보다 많은 파라미터를 클러스터링에 사용한다면 더욱 효율적인 고장의 검출이 가능할 것으로 기대된다.

참고문헌

- [1] S. D. Oh, "Current development trend of wind turbine system," *Journal of Fluid Machinery*, vol. 8, no. 3, pp. 65-72, 2005.
- [2] R. W. Hyers and J. G. McGowan, "Condition monitoring and prognosis of utility scale wind turbine," *Energy Material*, vol. 1, no. 3, pp. 187-203, 2006.
- [3] M. Lucente, "Condition monitoring system in wind turbine gearbox," *Master's Degree Thesis in KTH Electrical Engineering*, 2008.
- [4] Z. Hameed, Y. S. Hong, Y. M. Cho, S. H. Ahn, and C. K. Song, "Condition monitoring and fault detection of wind turbines and related algorithms: a review," *Renewable Sustainable Energy Reviews*, vol. 13, no. 1, pp. 1-39, 2009.
- [5] A. Zaher and D. D. J. McArthur, "Online wind turbine fault detection through automated SCADA data analysis," *Wind Energy*, vol. 12, pp. 574-593, 2009.
- [6] E. Lapira and D. Brisset, "Wind turbine performance assessment using multi-regime modeling approach," *Renewable Energy*, vol. 45, pp. 86-95, 2012.
- [7] D. S. Moon and S. H. Kim, "Development of clustering technique based wind turbine fault detection system," *2012 ICROS Jeonbuk and Jeju Regional conference (in Korean)*, vol. 1, pp. 205-207, 2012.
- [8] J. C. Bezdek, "Pattern recognition with fuzzy objective function algorithms," *Plenum Press*, 1981.
- [9] D. E. Gustafson and W. C. Kessel, "Fuzzy clustering with a fuzzy covariance matrix," *In Proc. of the IEEE CDC*, pp. 761-766, San Diego, CA, USA, 1978.
- [10] R. Babuska, P. J. van der veen, and U. Kayma, "Improved covariance estimation for Gustafson-Kessel clustering," *IEEE International Conference on Fuzzy Systems*, pp. 1081-1085, 2002.
- [11] S. Y. Kim, I. H. Ra, and S. H. Kim, "Design of wind turbine fault detection system based on performance curve," *International Symposium on Advanced Intelligent System*, vol. 13, pp. 2033-2036, 2012.
- [12] A. Kusiak and W. Li, "Short-term prediction of wind power with a clustering approach," *Renewable Energy*,

vol. 35, no. 10, pp. 2362-2369, 2010.

- [13] A. P. Leite and C. W. T. Borges, "Probabilistic wind farms generation model for reliability studies applied to brasilian site," *IEEE Transactions on Power Systems*, vol. 21, no. 4, pp. 1493-1501, 2006.



문 대선

2010년 군산대학교 전자정보공학부 졸업. 2012년 동 대학원 석사. 2012년~현재 동 대학원 박사과정. 관심분야는 풍력발전, 고장진단 및 검출, 지능형 시스템.



김 선 국

2005년 전북기능대학 전기계측제어과 졸업. 2009년 학점은행제 전기공학사. 2011년 군산대학교 산학대학원 전자정보공학부 석사. 2012년~현재 동 대학원 박사과정. 관심분야는 풍력발전, 고장진단 및 검출, 공장 자동화 시스템.



김 성 호

1984년 고려대학교 전기과 졸업. 1986년 동 대학원 석사. 1991년 동 대학원 박사. 1988년~1990년 고려대 생산기술연구소 연구원. 1995년~1996년 JAPAN HIROSHIMA University POST-DOC. 1991년~현재 군산대학교 제어로봇공학과 교수. 관심분야는 풍력발전, 인공지능경망, 센서 네트워크, 공장 자동화, 고장 진단.