

가정용 고분자전해질 연료전지 공기공급시스템의 모델 기반 고장 검출 기술

원진연^{1,2} · 김민진^{2,3} · 이원용² · 최윤영² · 홍종섭^{1,†} · 오환영^{2,†}

¹연세대학교 대학원 기계공학부, ²한국에너지기술연구원 연료전지연구실, ³과학기술연합대학원대학교 신에너지 및 시스템 공학

Model-based Fault Detection Method for the Air Supply System of a Residential PEM Fuel Cell

JINYEON WON^{1,2}, MINJIN KIM^{2,3}, WON-YONG LEE², YOON-YOUNG CHOI², JONG SUP HONG^{1,†}, HWANYEONG OH^{2,†}

¹Department of Mechanical engineering, Yonsei University, 50 Yonsei-ro, Seodaemun-gu, Seoul 03722, Korea

²Fuel Cell Research Center, Korea Institute of Energy Research, 152 Gajeong-ro, Yuseong-gu, Daejeon 34129, Korea

³Department of Advance Energy and System engineering, Korea University of Science and Technology, 217 Gajeong-ro, Yuseong-gu, Daejeon 34113, Korea

†Corresponding author :
hyoh@kier.re.kr

Received 27 September, 2019

Revised 18 December, 2019

Accepted 30 December, 2019

Abstract >> Recently, as the supply of residential polymer electrolyte membrane fuel cells (PEMFCs) increases, the durability and lifetime of the PEMFC system are becoming important. The related studies have been mainly focused on the durability and lifetime of materials while the research on the durability and maintenance of the system level is insufficient. In this paper, a model-based fault detection method is developed considering an air supply system that is dominant to the system performance and efficiency. A commercial 1 kW residential fuel cell system is built, and experiments are conducted under various operation loads and states (normal, 6 faults). From the experimental data, nominal models and residuals are generated. With the residual pattern obtained from real-time data, the detection and classification of various faults can be possible. The technical importance of this paper is to minimize extra sensor installation by using the empirical model rather than a complex mathematical model, and to decrease the number of models by using the applicable model at three loads. Finally, the model-based fault detection method for the air supply system of a PEMFC is established and is expected to be applicable to other subsystems.

Key words : Polymer electrolyte membrane fuel cell(고분자전해질막 연료전지), Air supply system(공기공급계), Fault detection(고장 검출), Model based(모델기반), Residual pattern(잔차 패턴)

Nomenclature

- y : measured predictor variable value
 \hat{y} : predicted predictor variable value
 \bar{y} : average of measured predictor variable value
 P : pressure, kpa
 T : temperature, °C
 U : blower control signal, %
 Q : air mass flow rate, lpm
 σ : standard deviation of normal state residuals
 I : current, A
 V : voltage, V

1. 서론

최근 세계적으로 온실가스 감축을 위한 정책이 각국에서 활발히 진행됨에 따라, 수소 연료전지의 시장이 매우 커지고 있으며, 그 중에서도 지속적인 연구를 통해 상업화 실증 및 공급 단계에 있는 고분자 전해질 연료전지(polymer electrolyte membrane fuel cell, PEMFC)의 공급이 활발해지고 있다. PEMFC 기술은 소재기반의 내구성 및 수명향상을 위한 연구는 활발히 이루어지고 있으나, 시스템 측면의 내구성 및 유지관리 기반의 연구는 미흡한 상태이다. PEMFC 시스템은 운전 시 일부 부위의 고장이 시스템 전체 고장으로 확대되고, 나아가 스택에 치명적인 열화를 유발하여, 성능저하로 이어지는 단점이 있다. 이 부분을 예방하기 위하여 고장 검출 및 진단에 대한 연구가 불가피하며 수명 및 내구성 향상을 통한 PEMFC의 합리적 공급 가격을 기대할 수 있다¹⁻⁴⁾.

고장 검출 기술은 크게 Data-driven 방법과 Model-based 방법 두 가지로 구분할 수 있다. Data-driven 방법은 실제 운전 및 실험을 통해 수집한 데이터를 기반으로 서로 다른 특성을 가지는 특성 값을 추출하여 수치가 비슷한 데이터들끼리 군집화(clustering)를 통해 분류하는 방법이다. 이 방법은 학습 시 모델링이 필요 없는 장점이 있지만, 많은 양의 학습 데이터가 필요하기 때문에 고장의 종류가 다양하고, 모델

을 통해 연관성을 찾기 어려운 데이터에 적용하기 용이하다^{5,6)}. LI⁷⁾는 1 kW, 10 kW급 가정용 연료전지에서 전체 시스템 중 일어날 수 있는 고장을 data-driven 방법을 이용하여 검출하였으며, principle component analysis (PCA), fisher discriminative analysis (FDA)를 통하여 특성을 추출하고, gaussian mixture model (GMM), k-nearest neighbor (k-NN), support vector machine (SVM)을 통하여 분류하는 방법을 사용하였다. Mao 등⁸⁾은 flooding 상태를 여러 가지 센서들로 측정하여, kernel principal component analysis (KPCA)를 통해 데이터셋 차원(dataset dimension)을 줄이고, wavelet packet analysis로 특성 추출 후, singular value decomposition (SVD)을 이용하여 가장 많은 정보를 포함하는 두 개의 특성을 결정하여 진단하였다. Ibrahim 등⁹⁾, Pahon과 Moçoteguy¹⁰⁾는 신호해석 방법 중 wavelet transform (WT)을 사용하였고, [9]에서는 연속 데이터(continuous data)에서 정상인 아닌 다른 상태를 고장으로 인지하고 그 상태의 WT 특성을 비교하였다. [10]에서는 [8]과 같이 하나의 고장(high air stoichiometry ratio fault)에서 운전 중 얻을 수 있는 센서들의 값을 WT로 변환하여 고장 검출 및 진단하였다.

Model-based 방법은 각 상태별로 수집한 데이터셋을 통하여, 상태를 잘 분류할 수 있는 특성값들 사이의 모델을 생성하고, 생성된 모델을 실시간 데이터에 적용한 뒤 잔차값을 통하여 고장 검출 및 진단하는 방법이다¹¹⁻¹³⁾. Escobet 등¹⁴⁾은 연료전지 시스템 전체에서 일어날 수 있는 고장 6가지를 진단하기 위하여 해석적 중복(analytical redundancy) 방법을 사용, 고장과 잔차의 관련도를 나타내는 fault sensitivity를 사용하였다. Yang 등¹⁵⁾은 공기공급계에서 일어날 수 있는 고장 3가지를 다수의 센서를 이용하여 측정하였고, 복잡한 수학적 회귀식(regression model)을 이용하여 연료전지 특성을 보여주는 모델식의 계수를 비교하여 검출 및 진단하였다. Aitouche 등¹⁶⁾은 전체 시스템에서 일어날 수 있는 고장 4가지를 진단하였으며 비선형적인 관계를 모델링하기 위해 다수의 센서를 이용한 복잡한 수학적식을 이용하여 비선형적 관

계를 모델링하고 검출 및 진단하였다.

본 논문에서는 고장 검출 및 진단 기술개발을 위한 상용 1 kW급 PEMFC 시스템을 구성하였다. 그 중에서도 스택 성능, 시스템 전체 전력 소비량에 큰 영향을 미치고 블로워가 포함 되어 있는 공기공급계를 고장 검출 목표 시스템으로 결정하였다. 가정용 연료전지에서 운전되는 3가지 부하 조건(50%, 75%, 100%)에서 각 상태(정상상태, 6가지 고장)별 실험을 진행하였다. 이에 각 부하별 데이터를 다량으로 필요로 하는 data-driven 방법보다 model-based 방법을 이용하였다. 사전 연구들에서 복잡한 수학적 모델식을 사용한 것과 달리 모델 생성에 필요한 종속변수와 예측변수의 개수를 최소화 하여 경험적 모델식을 결정하였기 때문에 고장 검출에 필요한 센서의 개수를 줄일 수 있고, 시스템 측면에서 전체 설비비용을 감소를 기대할 수 있다. 그리고 3가지 운전 부하 조건의 데이터를 모두 적용시킬 수 있는 모델을 생성했기 때문에, 각 운전 부하 조건마다 모델을 생성할 때보다 모델의 개수를 1/3개 감축시킬 수 있었다. 또한, 공기공급계에서 발생할 수 있는 6가지 부위 별 고장을 검출 및 분리하여 진단 시 시스템 상 어떤 부위에서 고장이 일어났는지 확인할 수 있다.

2. 이론적 배경

2.1 모델기반 고장검출

Model-based 고장 검출 방법은 상태별로 라벨링된 학습 데이터를 통해 모델을 형성하고, 테스트 데이터에 생성된 모델을 적용시켜 예측된 결과가 적절히 적용되었는지 모델 검증 과정을 통해 모델을 평가한 뒤, 실제 실시간 데이터를 적용시켜 고장을 검출하는 방법이다¹⁷⁻²⁰.

본 논문에서는 각 상태를 잘 구분하기 위한 종속 변수(input)와 예측변수(output)를 결정하고, 결정된 변수들 사이의 연관성을 모델로 생성한다. 생성한 모델을 데이터에 적용시켜 종속 변수를 통해 예상한 예측 변수와 실제 측정된 예측 변수의 차이인 잔차

(residual)를 생성하였다. 생성된 잔차 값이 결정한 경계 값 기준 미만일 때는 0, 이상일 때는 ± 1 로 표시하여 각 상태별 잔차 패턴을 얻어 학습하였다. Fig. 1은 model based 고장 검출 알고리즘을 도식화 한 모습이다. 모델을 생성하는 방법으로는 회귀(regression)와 분류(classification)로 구분할 수 있으며, 본 논문에서는 linear regression, decision trees, support vector machine (SVM), gaussian process regression (GPR), multi polynomial regression (MPR)을 사용하여 회귀모델을 생성하였고, R^2 (결정계수), root mean square error (RMSE)를 통해 가장 적합한 모델을 결정하였다.

2.2 Multivariate polynomial regression (MPR)

모델 생성 시 회귀(regression)방법 중 한가지이며, 독립변수가 2가지 이상의 회귀 모델을 2차식 이상의 모델로 형성하는 방법이다. MPR은 위에서 언급한 decision trees, SVM, GPR과는 다르게 모델이 종속변수와 예측변수 사이의 함수로 나타나게 되므로 두 변수 사이의 기계적 특성을 함수의 차수, 계수 상수항을 통해 직관적으로 확인할 수 있다. 그러나 MPR은 선형 회귀에 비하여 모델의 정확도는 높아지나, 많은 변수와 고차식의 사용으로 과적합(overfitting)될 수 있다. 따라서 모델 생성 뒤 상태별 테스트 데이터를 적용시켜 각 상태를 잘 분리하는지 검증하는 것이 좋다.

2.3 모델 검증

위 과정에서 생성한 회귀 모델의 예측력이 얼마나 좋은지 평가하기 위하여 여러 가지 평가기준이 있다. 일반적으로 모델의 종속변수에 따른 예측변수의 설




Fig. 1. Model based fault detection algorithm

명력을 보여주는 결정계수가 있고, 모델을 통해 생성된 오차의 판별 정도를 분별할 수 있는 평균오차 (absolute error, AE), 평균 절대 오차(mean absolute error, MAE), 평균 절대 비율 오차(mean absolute percentage error, MAPE), 루트 평균 제곱 오차(root mean square error, RMSE)가 있다.

2.3.1 결정계수(R-square)

회귀 모델(regression model)의 적합도를 평가하거나, 종속 변수에 대한 독립변수들의 설명력을 알고자 할 때 사용한다. 실제 종속 변수와 예측 변수사이 회귀 모델의 특성을 수식으로 나타낸 것을 eq.1에서 볼 수 있다.

$$\sum (y - \bar{y})^2 = \sum (\hat{y} - \bar{y})^2 + \sum (y - \hat{y})^2 \quad (\text{eq.1})$$

SST (total sum of square) = SSR (regression sum of square) + SSE (error sum of square)

또한, 그 중에서 총 변동량 중 회귀 모델로 설명 가능한 변동의 비율을 나타내는 R^2 는 eq.2로 표현 가능하다.

$$R^2 = \sqrt{\frac{\sum (\hat{y} - \bar{y})^2}{\sum (y - \bar{y})^2}} \quad (\text{eq.2})$$

2.3.2 Root mean square error (RMSE)

RMSE는 모델이 예측한 값과 실제 측정된 값과의 차이를 다룰 때 사용하는 기준이며, MSE에 루트를 적용한 값이다. RMSE의 일반식은 eq.3에서 나타나고 있다.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum (\hat{y} - y)^2} \quad (\text{eq.3})$$

Mean absolute error (MAE)에서 잔차값에 절대 값을 적용시키는 것보다 오차의 판별 정도를 크게 볼 수 있는 장점이 있고, 일반적으로 RMSE가 작을수록 종속변수에 따른 모델의 예측값과 측정값의 오차가 작기 때문에 모델의 예측력이 좋다고 볼 수 있다.

3. 실험

3.1 공기공급계

공기공급계는 연료전지 운전에 필요한 공기를 연료전지 스택의 환원극(cathode)에 주입하는 역할을 하며, Fig. 2에서 보이는 것과 같이 스택의 안정적 성능확보를 위해 외부공기의 불순물을 걸러주기 위한 필터, 걸러진 공기를 일정 유량으로 주입시켜주기 위한 블로워, 건조 공기의 가습을 위한 막 가습기, 물과 함께 스택에서 나오는 공기가 막 가습기를 거쳐 외기로 배출되기 전 물을 분리하기 위한 기수 분리기로 구성되어있다.

그리고 스택으로 주입되는 공기의 유량은 블로워의 제어신호에 따라 mass flow meter (MFM)에서 측정되는 유량을 제어하는 페루프 PID (closed loop PID) 제어를 사용하였다.

3.1.1 공기공급 시스템 고장 시나리오

고장(fault)이란, 시스템 운전과 관련하여 스택의 열화(degradation)를 유발하는 상태를 말하며 balance of plants (BOP)의 성능 저하나 측정 센서 고장과 같은 기능적 부분과 관련된다.

본 논문에서 PEMFC 공기공급계에서 발생할 수 있는 고장은 총 6가지로 결정하였고, 블로워로 들어가는 공기의 불순물을 걸러주기 위한 필터 막힘, 블로워 후단과 MFM 전단 사이의 공기 누설, MFM 후단 라인 공기 누설, 블로워 고장으로 인해 목표유량

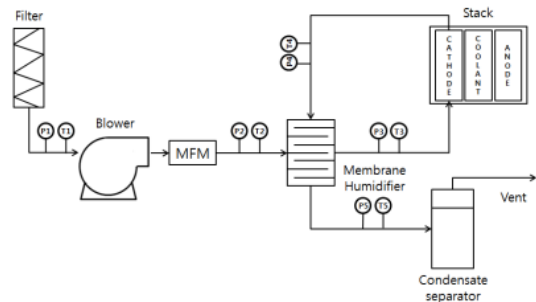


Fig. 2. PEMFC air supply system

을 공급하기 위한 제어신호의 증가, 데이터를 얻기 위한 유량센서, 압력센서 고장으로 정의한 것을 Table 1에 표기하였다.

3.2 실험 조건

PEMFC 고장검출에 필요한 모델을 생성하기 위해 실험을 진행하였고, Fig. 2에서 보이는 것과 같이 Air가 필터를 통해 들어오는 부분부터 기수분리기의 벤트라인으로 나가는 부분까지 순서대로 압력센서(P), 온도센서(T)를 1-5번까지 설치하였다. 그리고 블로워를 동작시키는 전압신호인 제어신호(%)와 MFM에서 측정되는 유량(lpm), 스택에 필요한 전류를 공급해주는 로터기의 전압(V), 전류(I)를 측정하여 정상 및 고장상태 스테디(steady) 데이터를 수집하였다.

3.2.1 정상상태 운전 조건

본 논문에서 목표로 하는 1 kW급 가정용 연료전지의 고장검출 기술의 확립을 위해, 상용 1 kW급 가정용 연료전지에서 운전하는 3가지 부하조건에서 각 상태별 steady 데이터를 수집하였다. 각 부하별 운전 조건을 Table 2에서 보여주고 있다.

3.2.2 고장상태 모사실험 조건

위 3.1.1에서 정의한 총 6가지 공기공급계 고장의 실험 방법을 Table 3에서 설명하였다. 각 닫힘 밸브(close valve)는 공기가 공급되는 라인에 직렬로 연결하였고, 열림 밸브(open valve)는 바이패스 라인에 설치하여 외기로 누설될 수 있도록 하였다.

Table 1. PEMFC air supply system fault condition

Fault	Explanation
F1	Blocked filter
F2	Leak between Blower and MFM
F3	Leak Air flow line after MFM
F4	Decrease of measured flow value (MFM)
F5	Decrease of air mass flow rate at the same U
F6	Decrease measured pressure value

4. 고장 검출

연료전지 해석은 비선형성이 강한 복잡한 시스템을 정밀하게 분석하기 위해 다량의 파라미터와 시간이 필요하다. 따라서 본 논문에서는 기존의 완전한 수학적 모델을 통한 해석적 방법보다 상대적으로 간단한 실험 기반의 모델을 생성하여 3가지 부하조건에서의 정상상태와 6가지 고장상태를 검출하였다.

4.1 데이터 학습

먼저, 정상 및 각 고장별 상태 기반의 학습 데이터를 정상상태 4,620샘플, 각 부하조건 및 고장상태에서는 120샘플씩 수집하였다. 여기서 측정된 데이터를 기반으로 상태특성을 잘 나타낼 수 있는 특성 값을 결정하였다. 특성값을 결정하는 데 있어 개수를 늘릴수록 여러 상태를 구분하기는 좋지만 실제 시스

Table 2. PEMFC normal operation conditions active area: 200 cm², number of cell : 35 cell stoichiometry ratio (fuel:1.5, Air: 2.0)

Parameter	Current density (A/cm ²)		
	0.1	0.15	0.2
Current (A)	20	30	40
Operation condition (%)	50	75	100
Operation temperature (°C)	60	60	60
Fuel flow rate (lpm)	14.6	10.98	7.32
Air flow rate (lpm)	46.5	34.8	23.2

Table 3. PEMFC simulated fault condition

Fault	Experimental condition
F1	Close valve (between filter and blower)
F2	Open valve (between blower and MFM)
F3	Open valve (between MFM and humidifier)
F4	Decrease of indicated Air mass flow rate value (in Labview front panel)
F5	Increase of indicated blower control signal (in Labview front panel)
F6	Decrease of indicated P2 value (in Labview front panel)

템에 설치해야 할 센서의 개수가 늘어나 전체 시스템 비용이 늘어나는 단점이 있기 때문에 검출을 위한 추가 센서의 개수를 최소화 하는 방향으로 결정하였다. Table 4는 학습 데이터에서 측정된 파라미터의 패턴을 보여주고 있으며, 온도센서, 유량센서의 측정값은 상태별 변화가 크지 않아 제외하고 표시하였다. Table 4의 결과로 P1, P2, air (%)를 각 상태를 구분하기 적절한 특성값으로 결정하였다.

4.2 회귀 모델

위 학습 데이터를 통해 얻은 특성값들을 이용하여 총 3개의 회귀 모델의 종속변수(input)와 예측변수(output)를 결정하였고, 각 모델의 특성 값을 Table 5에 표기하였다. 그리고 대표적인 회귀 학습 방법들을 사용하여 모델을 생성하였고 모델 검증을 위한 테스트 데이터(1,080샘플)에 모델을 적용시켜 각 방법별 결정계수와 RMSE를 비교한 것을 Table 6에서 보여주고 있다. 일반적으로 R^2 가 높고, RMSE가 가장 작은 방법이 예측력이 가장 좋은 모델로 볼 수 있으나, 결과를 보면 R^2 가 가장 높다고 해서 RMSE가 가장 낮은 경향을 보여주고 있지 않았다. 이러한 경향을

Table 4. Training data parameter pattern

Fault	V	P1	P2	P3	P4	P5	Air (%)
N	-	-	-	-	-	-	-
F1	-	↓	-	-	-	-	↑
F2	-	↓	-	-	-	-	↑
F3	↓	-	↓	↓	↓	↓	↓
F4	↑	↓	↑	↑	↑	↑	↑
F5	-	-	-	-	-	-	↑
F6	-	-	↓	-	-	-	-

Table 5. Regression model input/output

Model	Output	Input	Function
1	$\Delta P (P2 - P1)$	Q, I	$\Delta P = f_1(Q, I)$
2	$U(\text{control signal})$	Q	$U = f_2(Q)$
3	$P1$	Q, I	$P1 = f_3(Q, I)$

보임에 따라 R^2 와 RMSE가 다른 회귀학습법과 크게 차이나지 않고, 종속변수와 예측변수 사이의 물리적 특성을 모델식의 차수, 계수, 상수항의 수치값으로 설명하기 좋은 MPR을 고장 검출 기술에 사용하였다.

4.3 잔차 생성

결정한 회귀 모델을 데이터에 적용시켜 종속변수 값에 따른 예측변수의 예측 값과 예측변수의 측정값의 차이를 잔차(residual)라 하며, 각 상태별로 R1, R2, R3의 패턴을 도출한다. Table 7은 결정된 회귀 모델의 parity equation을 보여주고 있다.

4.4 정규화

학습 데이터에 모델을 적용시켜 생성한 잔차는 한 상태에서 각 잔차들을 결정하는 특성 값들의 단위가 다르기 때문에 상태별 잔차의 상관관계를 비교하려 할 때 연관성을 찾기 힘들다. 또한, 정상상태의 잔차

Table 6. R-square, RMSE from regression learning method

Regression learning method	R1		R2		R3	
	R^2	RMSE	R^2	RMSE	R^2	RMSE
Linear regression	1	0.339	1	0.907	1	0.085
Decision trees	0.91	0.275	0.99	0.406	0.78	0.081
SVM	1	0.283	0.99	0.939	1	0.085
GPR	1	0.291	0.99	0.384	0.97	0.08
MPR	1	0.314	1	0.41	1	0.088

Table 7. Regression model (parity equation)

Residual	Output	Parity equation
R1	$\Delta P_{predicted} - \Delta P_{measured}$	$\Delta P = -0.1026Q^2 + 0.1192QI + 4.377Q - 4.829I + 4.85$
R2	$U_{predicted} - U_{measured}$	$U = 0.01089Q^2 + 0.2914Q + 12.54$
R3	$P1_{predicted} - P1_{measured}$	$P1 = 0.005103Q^2 - 0.00649QI + 0.02957Q - 0.005031I - 0.7239$

값의 정량적 지표가 부하에 따라 크기가 다르다. 따라서 각 부하별 정상상태 학습 데이터들의 잔차값들 사이에 최댓값을 결정하고, 최솟값은 0으로 결정하여 정규화(normalization)한 것을 eq.4에서 볼 수 있다.

$$\bar{R} = \frac{R - R_{min}}{R_{max} - R_{min}} \quad (eq.4)$$

4.5 경계값 결정

정상과 고장상태를 결정하는 잔차의 경계값을 정상상태 잔차값들의 표준편차의 n배수로 결정하였다. 또한, 각 부하 및 상태별 잔차값을 생성하여 정상상태 잔차값들을 초과하지 않고, 고장 상태의 잔차값이 정상의 범위에 들어가지 않는 경계값을 결정하기 위해 상태별 잔차 패턴이 잘 분리될 수 있는 3배수로 결정하였다. Table 8은 각 잔차별 경계값을 보여주고 있다.

4.6 잔차 패턴 결정

각 부하 및 상태별 학습 데이터에서 생성한 잔차값들을 정규화하고 결정한 경계 값을 기준으로 하여 정상상태는 0, 고장상태는 ±1로 나타내어 잔차 패턴을 얻은 것을 Table 9에서 볼 수 있다. 잔차 패턴을 학습한 결과 각 부하별 상태별 패턴이 동일하게 나오고, 모든 상태가 다른 패턴으로 분리된 것을 볼 수 있다. 하지만, MFM 후단 누설(F3), 20A 모사실험 시의 필요한 공기의 유량이 적고, 제어신호의 변화가 고장이라고 인지할만큼 큰 변화가 일어나기 전 스택의 과도한 성능 저하로 인하여 더 이상 모사 실험을 진행할 수 없었다.

따라서 F3, 20A 조건에서 R2는 정상상태(0)로 표

Table 8. Threshold value (R1, R2, R3)

Threshold	R1	R2	R3
value	±1.158823	±1.198661	±1.282693

기했고 압력센서 고장(F6)과 같은 잔차 패턴을 나타내고 있다.

5. 결 과

5.1 스테디 상태 고장 검출

생성한 모델을 통해 생성한 잔차를 기반으로 학습한 패턴이 각 상태별 스테디(steady) 데이터에 모델을 적용시켜 얻은 잔차 패턴과 일치하게 나오는지 검증해보았다. 부하별 정상상태 스테디 데이터는 총 1,200샘플을 얻었고, 부하 및 고장별 스테디 데이터는 100샘플씩 수집하여 잔차 패턴을 얻었고 3차원 공간에 스캐터링한 모습을 Fig. 3에서 보여주고 있다. 검증 결과 부하별 R1, R2, R3의 잔차값들이 정상

Table 9. Residual pattern (normal, fault)

Class	I	R1	R2	R3
N	20A	0	0	0
	30A	0	0	0
	40A	0	0	0
F1	20A	-1	-1	1
	30A	-1	-1	1
	40A	-1	-1	1
F2	20A	0	-1	1
	30A	0	-1	1
	40A	0	-1	1
F3	20A	1	0	0
	30A	1	1	0
	40A	1	1	0
F4	20A	-1	-1	0
	30A	-1	-1	0
	40A	-1	-1	0
F5	20A	0	-1	0
	30A	0	-1	0
	40A	0	-1	0
F6	20A	1	0	0
	30A	1	0	0
	40A	1	0	0

상태를 기준으로 상태별로 같은 방향성을 가지고 위치할 것을 볼 수 있었다. 또한, 각 부하 및 상태별 잔차값들이 서로 다른 군집을 형성하며 모여있는 것을 볼 수 있고, 3가지 부하에서 정상상태와 총 6가지 고장 상태를 구분할 수 있는 모델을 생성하였음을 검증할 수 있다.

5.2 실시간 고장 검출

실시간 데이터를 수집하기 위하여, 정상 및 고장




Fig. 3. Cluster of steady state faults (a) 20A, (b) 30A, (c) 40A

상태를 번갈아 가며 실험을 진행(N, F1, N, F2, N, F3, N, F4, N, F5, N, F6, N)하였고, 300샘플씩 수집 후 상태를 변화시켜 데이터를 수집하였다. Fig. 4는 수집한 실시간 데이터에 모델을 적용시켜 잔차를 생성한 그래프이다. 위에서 결정한 경계값을 기준으로 상태 변화에 따른 각 잔차들의 패턴을 -1, 0, 1로 결정하였고, 모델을 통해 학습한 잔차 패턴과 실시간 데이터를 통해 생성한 잔차 패턴이 일치함을 볼 수 있었다. 그리고, 저부하(20A) 운전에서도 MFM 후단 누설(F3) R2의 잔차 패턴은 정상상태(0)로 검출되어 압력센서 고장(F6)과 잔차 패턴이 같음을 Fig. 4에서 확인하였다.

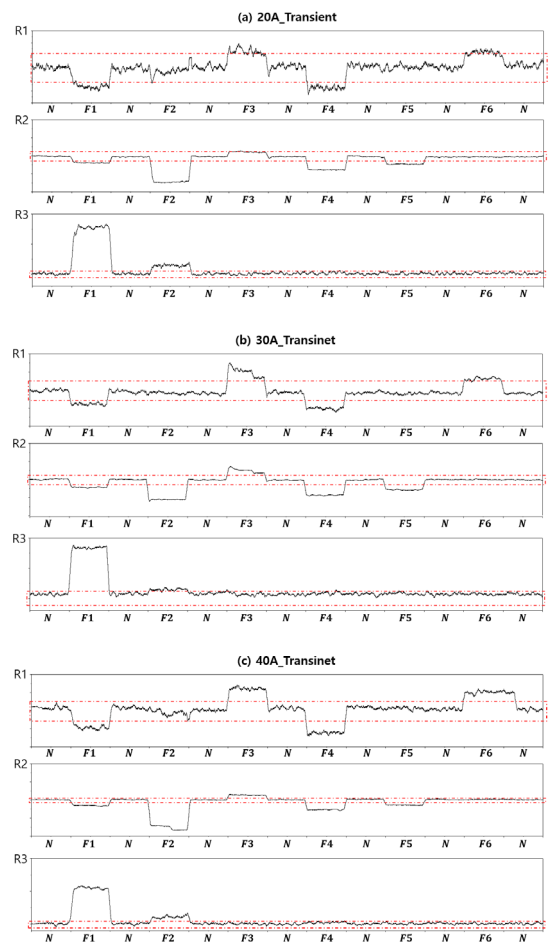


Fig. 4. Real-time data fault detection (a) 20A, (b) 30A, (c) 40A

6. 토 의

고장 검출 결과에서 확인한 것과 같이 저부하(20A) 운전에서 MFM 후단 누설(F3) R2의 값은 정상상태(0)로 나타나게 되고, 압력센서 고장(F6)과 같은 잔차 패턴을 보여주게 된다. 이러한 문제를 해결하기 위하여 새로운 모델을 적용시켜 R4를 추가하였다. R4는 공기공급계의 고장을 검출하기 위한 측정값이 아닌 시스템 전체 측면의 측정값인 로더의 전압, 전류를 이용하여 모델을 생성하였다. 모델 결정은 R1, R2, R3의 모델생성과 같은 MPR를 이용하였고, Table 10에서는 생성 모델의 패리티 식(parity equation)과 잔차값의 경계값을 3σ 로 결정한 것을 보여주고 있다. Table 11에서는 새로운 모델을 적용한 부하조건 및 상태별 학습 데이터의 R4 잔차 패턴을 볼 수 있다.

Table 11을 통하여 잔차 패턴을 확인한 결과 MFM 후단 누설(F3)과 압력센서 고장(F6)의 R4가 다름을 볼 수 있었고, 총 4개의 잔차를 적용시켜 모든 고장을 분류할 수 있었다. 그리고 실시간 데이터에도 R4를 적용시켜 고장을 검출하고, 잔차 패턴을 비교한 모습을 Fig. 5에서 보여주고 있다.

Table 10. R4 input/output, parity equation, threshold

Function (in/out)	Parity equation	Threshold
$V = f(I)$	$V = -0.001378I^2 + 0.03371I + 27.22$	± 1.23036

Table 11. Residual pattern (normal, fault)

Class	I		
	20A	30A	40A
N	0	0	0
F1	0	0	0
F2	0	0	0
F3	1	1	1
F4	0	0	0
F5	0	0	0
F6	0	0	0

7. 결 론

본 연구에서는 공기공급계 고장 검출 및 진단을 위한 상용 1 kW급 가정용 연료전지 전체 시스템을 구성하였으며, 실제 시스템에서 사용되고 있는 3가지 운전 부하조건에서의 정상 상태 및 고장 상태의 데이터를 취득해 학습 데이터로 사용하였기 때문에 기존의 연구들과는 달리 고장 검출 및 진단을 위해 생성한 모델의 응용력과 신뢰도가 높다. 그리고 특정 부위별 시스템(sub-system)인 공기공급계의 고장들을 정의하여 고장 검출 기술을 수립하였고, 복잡한 수학적 모델식이 아닌 실험을 통한 종속변수와 예측변수 사이의 경험적 모델식을 기반으로 하여 추가 센서의 개수를 최소화 하였다. 고장 검출에 필요한 2개의 압력센서를 추가로 설치하여 총 6개의 공기공급계 고장을 검출 및 분리하여 시스템 측면의 비용 경제성을 확보하였다. 각 운전 부하별로 모델을 생성하였을 때보다 모든 운전 조건에서 적용할 수 있는 모델을 생성하여 3가지 운전 부하, 6가지 고장 상태를 진단할 수 있는 모델을 만들었다. 결론을 정리하자면 다음과 같다.

1) 이론을 기반으로 한 수학적 모델이 아닌, 실제 시스템을 구성하여 실험을 기반으로 한 경험적 모델을 생성하였기에 검출 모델의 상용시스템 적용력이




Fig. 5. Real-time data fault detection R4 (normal, fault, 20A, 30A, 40A)

높은 장점이 있다.

2) 경험적 모델을 사용하여, 고장 검출에 필요한 추가 센서의 개수를 최소화 하였다. 추후 상용시스템 구축 시 센서 추가로 인한 비용을 최소화하는 고장 검출을 통해 유지보수 비용의 절감을 기대할 수 있다.

3) 상용시스템에서 운전하는 3가지 운전 부하 조건에서 PEMFC 공기 공급 시스템에서 일어날 수 있는 총 6가지 고장을 정의하고 실험을 하였다. 기존의 다른 논문에서는 하나의 운전조건을 고려하여 검출 모델을 수립하였으나, 본 연구에서는 3가지 운전 부하 조건에서 모두 검출 가능한 모델을 수립하였기 때문에 1가지 부하조건을 제외한 다른 부하조건에서도 상태별 6가지 고장 검출이 가능하였다.

나아가 공기공급계를 제외한 다른 PEMFC 부위별 시스템(연료공급계, 열관리계, 물관리계)들의 부위별 시스템 고장 검출 및 진단을 위해 제안 기술의 응용이 가능할 것으로 기대되며, 궁극적으로는 PEMFC 전체 시스템 측면에서 일어날 수 있는 모든 고장을 검출하고 그 원인을 진단하는 것을 향후 연구로 계획할 수 있다.

Acknowledgement

“본 연구는 2019년도 산업통상자원부의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제이다(No. 20173010032150).”

References

1. Ministry of Trade, Industry and Energy and Korea Energy Corporation, “New & renewable energy white paper”, 2018.
2. F. Barbir, “PEM fuel cells: theory and practice. Academic Press Series series editor”, Elsevier Academic Press, Netherlands, 2005.
3. W. Y. Lee, M. J. Kim, H. Y. Oh, Y. J. Sohn, and S. G. Kim, “A Review on Prognostics of Polymer Electrolyte Fuel Cells”, *Trans. of the Korean Hydrogen and New Energy Soc.*, Vol. 29, No. 4, 2018, pp. 339-356, doi: <https://doi.org/10.7316/KHNES.2018.29.4.339>.
4. W. Y. Lee, G. G. Park, Y. J. Sohn, S. G. Kim, and M. J. Kim, “Fault Detection and Diagnosis Methods for Polymer Electrolyte Fuel Cell System”, *Trans. of the Korean Hydrogen and New Energy Soc.*, Vol. 28, No. 3, 2017, pp. 252-272, doi: <https://doi.org/10.7316/KHNES.2017.28.3.252>.
5. Z. Zheng, R. Petrone, M. C. Péra, D. Hissel, M. Becherif, C. Pianese, N. Y. Steiner, and M. Sorrentino, “A review on non-model based diagnosis methodologies for PEM fuel cell stacks and systems”, *international journal of hydrogen energy*, Vol. 38, No. 21, 2013, pp. 8914-8926, doi: <https://doi.org/10.1016/j.ijhydene.2013.04.007>.
6. A. Benmouna, M. Becherif, D. Depernet, F. Gustin, H. S. Ramadan, and S. Fukuhara, “Fault diagnosis methods for Proton Exchange Membrane Fuel Cell system”, *International Journal of Hydrogen Energy*, Vol. 42, No. 2, 2017, pp. 1534-1543, doi: <https://doi.org/10.1016/j.ijhydene.2016.07.181>.
7. Z. LI, “Data-driven fault diagnosis for PEMFC systems”, 2014. Retrieved from <https://www.theses.fr/2014AIXM4335>.
8. L. Mao, L. Jackson, and B. Davies, “Investigation of PEMFC fault diagnosis with consideration of sensor reliability”, *International Journal of Hydrogen Energy*, Vol. 43, No. 35, 2018, pp. 16941-16948, doi: <https://doi.org/10.1016/j.ijhydene.2017.11.144>.
9. M. Ibrahim, U. Antoni, N. Y. Steiner, S. Jemei, C. Kokonendji, B. Ludwig, P. Moçotéguy, and D. Hissel, “Signal-Based Diagnostics by Wavelet Transform for Proton Exchange Membrane Fuel Cell”, *Energy Procedia*, Vol. 74, 2015, pp. 1508-1516, doi: <https://doi.org/10.1016/j.egypro.2015.07.708>.
10. E. Pahon and P. Moçotéguy, “A signal-based method for fast PEMFC diagnosis”, *Applied Energy*, Vol. 165, 2016, pp. 748-758, doi: <https://doi.org/10.1016/j.apenergy.2015.12.084>.
11. R. Isermann, “Model-based fault-detection and diagnosis – status and applications”, *Annual Reviews in Control*, Vol. 29, No. 1, 2005, pp. 71-85, doi: <https://doi.org/10.1016/j.arconrol.2004.12.002>.
12. N. Y. Steiner, D. Candusso, D. Hissel, and P. Moçotéguy, “Model-based diagnosis for proton exchange membrane fuel cells”, *Mathematics and Computers in Simulation*, Vol. 81, No. 2, 2010, pp. 158-170, doi: <https://doi.org/10.1016/j.matcom.2010.02.006>.
13. R. Petrone, Z. Zheng, D. Hissel, M. C. Péra, C. Pianese, M. Sorrentino, M. Becherif, and N. Yousfi-Steiner, “A review on model-based diagnosis methodologies for PEMFCs”, *International Journal of Hydrogen Energy*, Vol. 38, No. 17, 2013, pp. 7077-7091, doi: <https://doi.org/10.1016/j.ijhydene.2013.03.106>.
14. T. Escobet, D. Feroldi, S. de Lira, V. Puig, J. Quevedo, J. Riera, and M. Serra, “Model-based fault diagnosis in PEM fuel cell systems”, *Journal of Power Sources*, Vol. 192, No. 1, pp. 216-223, doi: <https://doi.org/10.1016/j.jpowsour.2008.12.014>.
15. Q. Yang, A. Aitouche and B. O. Bouamama, “Residuals

- Generation based on Nonlinear Analytical Redundancy Applied to Air Supply Sub-System of Fuel Cell”, 18th Mediterranean Conference on Control and Automation, MED'10, 2010. Retrieved from <https://pdfs.semanticscholar.org/a116/c96b73fc2ebbbb0b97871da4d74985967a26.pdf>.
16. A. Aitouche, Q. Yang, and B. O. Bouamama, “Fault detection and isolation of PEM fuel cell system based on nonlinear analytical redundancy”, *The European Physical Journal Applied Physics*, Vol. 54, No. 2, 2011, pp. 23408, doi: <https://doi.org/10.1051/epjap/20111100250>.
 17. J. Lunze, “A method to get analytical redundancy relations for fault diagnosis”, *IFAC PapersOnLine* Vol. 50, No. 1, 2017, pp. 1006–1012, doi: <https://doi.org/10.1016/j.ifacol.2017.08.208>.
 18. G. Nicchiotti, L. Fromageat, and L. Etienne, “Machine Learning Strategy for Fault Classification Using Only Nominal Data”, *European Conference of the Prognostic and Health Management Society*, 2016. Retrieved from https://www.phmsociety.org/sites/phmsociety.org/files/phm_submission/2016/phmec_16_010.pdf.
 19. I. Fagarasan and S. St. Iliescu, “Parity Equations for Fault Detection and Isolation”, 2008 IEEE International Conference on Automation, Quality and Testing, Robotics, 2008, doi: <https://doi.org/10.1109/aqtr.2008.4588715>.
 20. C. Damour, M. Benne, B. Grondin-Perez, M. Bessafi, D. Hissel, and J. P. Chabriat, “Polymer electrolyte membrane fuel cell fault diagnosis based on empirical mode decomposition”, *Journal of Power Sources*, Vol. 299, 2015, pp. 596–603, doi: <https://doi.org/10.1016/j.jpowsour.2015.09.041>.