Journal of Hydrogen and New Energy, Vol. 36, No. 5, 2025, pp. 569~579
DOI: https://doi.org/10.7316/JHNE.2025.36.5.569
JHNE
pISSN 1738-7264 • eISSN 2288-7407

수정 확장 칼만 필터(M-EKF)를 이용한 건물용 연료전지 성능 예측 및 열화 원인 진단

김수진[1,2] · 함성현[2] · 김민진[2,3†] · 홍종섭[1†]

[1]연세대학교 대학원 기계공학부, [2]한국에너지기술연구원 연료전지연구실, [3]과학기술연합대학원대학교 수소에너지공학

Performance Prediction and Degradation Diagnosis of PEM Fuel Cells Applied to Buildings Using the Modified Extended Kalman Filter

SUJIN KIM[1,2], SEONGHYEON HAM[2], MINJIN KIM[2,3†], JONGSUP HONG[1†]

[1]Department of Mechanical Engineering, Yonsei University Graduate School, 50 Yonsei-ro, Seodaemun-gu, Seoul 03722, Korea
[2]Fuel Cell Research Center, Korea Institute of Energy Research, 152 Gajeong-ro, Yuseong-gu, Daejeon 34129, Korea
[3]Hydrogen Energy Engineering, University of Science and Technology, 217 Gajeong-ro, Yuseong-gu, Daejeon 34113, Korea

†Corresponding author :
minjin@kier.re.kr

Received 18 September, 2025
Revised 16 October, 2025
Accepted 21 October, 2025

Abstract >> In this study, a methodology for predicting the degradation and performance variations of Building-integrated fuel cells under different operating conditions is proposed using the Modified Extended Kalman Filter (M-EKF). To enhance the accuracy of degradation modeling, the existing degradation model was improved by incorporating exchange current density and individually modeling each degradation factor according to operating conditions. The application of the M-EKF achieved an RMSE of 0.0003 V, an NRMSE of 0.0004, and an R^2 of 0.99, demonstrating the model's excellent capability in accurately reproducing the measured fuel-cell voltage behavior. In particular, the analysis of degradation rates under different operating conditions revealed that temperature is the most dominant factor influencing degradation, highlighting the importance of temperature management.

Key words : Building-integrated Fuel Cell(건물용 연료전지), Modified Extended Kalman Filter(수정 확장 칼만 필터), Degradation model(열화 모델), Performance prediction(성능 예측), State of Health(건강 상태), Long-term operation strategy(장기 운전 전략)

Nomenclature

E_0	: 개회로 전압 (V)
i	: 전류밀도 $(A \cdot cm^{-2})$
F	: 패러데이 상수 $(C \cdot mol^{-1})$
L_c	: 촉매 사용량 $(mg \cdot cm^{-2})$
P_r^{ref}	: 기준 압력 (atm)
E_c	: 활성화 에너지 $(J \cdot mol^{-1})$
R_0	: 내부 저항 $(\Omega \cdot cm^2)$
i_0	: 교환전류밀도 $(A \cdot cm^{-2})$

i_o^{ref} : 기준 교환전류밀도 ($A \cdot cm^{-2}$)
R : 기체상수 ($J \cdot mol^{-1} \cdot K^{-1}$)
n : 참여 전자 수
i_L : 한계전류밀도 ($A \cdot cm^{-2}$)
a_c : 촉매 표면적 ($m^2 \cdot g^{-1}$)
P_r : 반응물 분압 (atm)
γ : 압력 계수
T_{ref} : 기준 온도 (K)

1. 서 론

수소 기반 고분자 전해질 연료전지(Proton Exchange Membrane Fuel Cell, PEMFC)는 수소와 산소의 전기화학 반응을 통해 전기를 생산하는 친환경 에너지 장치로, 지속 가능한 에너지 시스템에서 중요한 역할을 한다[1]. 특히, 높은 에너지 효율과 친환경적 특성 덕분에 건물용, 차량용, 항공용 등 다양한 분야에 적용되고 있으며, 응용 분야에 따라 요구되는 운전 특성도 차이를 보인다. 예를 들어, 건물용의 경우 수천 시간 이상의 장기 연속 운전이, 차량용 연료전지는 운행 패턴에 따라 수십 분에서 수시간 단위의 운전이 반복되는 특성을 가진다[2,3].

연료전지 장시간 운전은 시간 경과나 운전 조건 변화에 따라 성능이 점차 저하되는 현상인 열화를 누적시켜, 궁극적으로 시스템의 내구성 저하를 초래한다. 열화가 진행되면 설계 수명보다 빠르게 성능이 저하되며, 이에 따라 수명 단축과 에너지 효율 감소가 발생한다[4]. 특히, 고가의 핵심 부품인 스택의 수명이 단축될 경우, 단순한 부품 교체를 넘어 전체 시스템의 가동 중단까지 유발할 수 있다. 이에 따라 추가적인 유지비용이 발생하고, 운영 효율성 저하로 이어져 전체 시스템 운용에 큰 부담이 된다. 따라서 연료전지 시스템의 경제성과 장기 성능 유지를 위해서는 성능 예측 모델을 기반으로 한 최적 운전 전략이 유용한 해결책이 될 수 있다. 연료전지는 운전 조건 변화에 따라 성능 저하 속도가 달라지므로, 이러한 특성을 반영하지 못하는 경우 효과적인 유지보수 계획 수립이 어렵다. 이에 따라, 다양한 운전 조건 하에서의 성능 저하를 예측하고, 사전에 유지보수를 계획할 수 있는 접근 방식이 요구된다.

이와 같은 필요성에 기반하여 최근 PEMFC의 예지 및 건강관리(Prognostics and Health Managment, PHM) 예측 기법을 활용한 연구가 활발히 진행되고 있으며, 이러한 기술들은 시스템 안정성을 확보하고 경제적 손실을 최소화하는 데 중요한 역할을 하고 있다[5-10]. 연료전지의 실시간 상태를 모니터링하여 성능 저하를 조기에 감지하고 유지보수를 최적화하는 상태 추정(State of Health, SOH)과 함께, 잔여 수명(Remaining Useful Life, RUL) 예측을 활용하면 효율적인 운영과 유지보수 계획을 수립할 수 있다. 이에 따라 다양한 연구에서 연료전지의 성능을 보다 정밀하게 예측하기 위한 방법론이 제안되었으며, 이는 데이터 기반, 모델 기반, 하이브리드 접근 방식으로 분류된다.

데이터 기반 접근 방식은 과거에 축적된 대량의 데이터를 활용하여 비선형 관계를 학습하고, 성능을 예측하는 방법이다. 이 방식은 구현이 비교적 단순하다는 장점이 있으나, 물리적 메커니즘에 대한 설명이 부족하여 열화 원인 분석이나 시스템의 근본적인 동작 이해에 한계가 있다. 초기 연구에서는 주로 경험적 데이터와 간단한 회귀 모델을 사용하여 열화 상태를 분석하였으며, 최근에는 Auto-Encoder나 LS-SVMR (Least Squares Support Vector Machine Regression)[11]과 같은 데이터 처리 기술을 활용한 정교한 방법론이 도입되고 있다. Liu 등[12]은 LSTM (Long Short-Term Memory) 네트워크를 활용하여 PEMFC의 열화와 잔여 수명을 장기 시계열 데이터로 모델링하는 연구를 진행하였다.

모델 기반 접근 방식은 전기화학적 법칙에 근거한 물리적 및 경험적 열화 모델을 활용함으로써 열화 메커니즘 분석이 가능하다는 점에서 강점을 가진다[13-20]. 이 방식은 시스템의 물리적 특성을 상세하게 반영할 수 있으나, 구현 시 높은 계산 복잡성과 매개변수 설정의 어려움이 존재한다. 칼만 필터 계열 기법은 이러한 물리 기반 모델링의 핵심 도구로 활용되고 있으

며, Bressel 등[20]은 EKF (Extended Kalman Filter)를 이용해 PEMFC의 열화 상태를 실시간으로 추적하고 잔여 수명을 예측하는 방법을 제시하였다. 또한, Song 등[21]은 AEKF (Adaptive Extended Kalman Filter)를 통해 차량용 연료전지의 주요 작동 변수를 모니터링하고 잔여 수명을 예측하는 모델을 제안하였다.

하이브리드 접근 방식은 데이터 기반과 모델 기반의 장점을 결합하여 복잡한 작동 조건에서도 높은 예측 정확도를 제공하는 방법이다[22-29]. Cheng 등[30]은 최소 자승 서포트 벡터 머신(LSSVM, Least Squares Support Vector Machine)과 정규화 입자 필터(Regularized Particle Filter, RPF)를 결합한 예측 기법을 통해 PEMFC의 잔여 수명을 추정하였으며, Liu 등[31]은 신경-퍼지 추론 시스템(ANFIS, Adaptive Neuro-Fuzzy Inference System)과 진화 알고리즘을 결합하여 잔여 수명을 예측하는 방법을 제시하였다.

기존 연구들은 주로 가혹한 환경에서 운전되는 차량용 연료전지를 대상으로 운전 패턴에 따른 열화 및 성능 예측에 초점을 맞추고 있다. 반면, 비교적 장시간 안정적으로 운전되는 건물용 연료전지를 대상으로, 운전 조건이 성능 열화에 미치는 영향을 정량적으로 분석한 연구는 부족한 실정이다. 현재까지는 연료전지의 상태 및 수명을 예측하는 데 초점을 맞춘 연구가 대부분으로, 이를 기반으로 한 수명 연장 전략 수립에 대한 연구가 추가적으로 필요하다.

본 연구에서는 기존 EKF를 개선한 M-EKF (Modified-Extended Kalman Filter) 기반 성능 예측 모델을 제안하여, 운전 조건에 따른 열화 속도를 정량적으로 평가하고, 장기 운전에 적합한 운전 조건을 분석함으로써, 연료전지의 장기 성능 유지를 위한 기초적인 예측·제어 방법론을 정립하고자 한다. 이를 위해, M-EKF는 다양한 운전 조건에서 실시간으로 열화 및 성능 저하를 추정할 수 있도록 설계되었다.

2. 실 험

2.1 대상 시스템

본 연구에서는 A사가 제작한 5kW급 건물용 연료전지 시스템을 대상으로 실험을 진행하였다. 연료전지 스택은 약 150개의 셀로 구성되며, 각 셀의 MEA 활성 면적은 200cm²로 설계되었다. 약 10,000시간의 장기 운전 데이터를 확보하였으며, 실험 기간 동안 스택 전압 및 전류, 내부 온도, 애노드/캐소드 입구 압력 등 주요 운전 변수가 실시간으로 모니터링되었다. 해당 데이터는 Fig. 1에 제시하였다.

2.2 연구 방법

본 논문에서 제안하는 연료전지 스택 성능 예측 기법은 Bressel 등[20]의 연구를 기반으로 하여, 연구 목적에 맞게 변형된 방법론을 적용한다. 연료전지 성능 진단과 열화 예측을 위해, 장시간 운전 데이터를 기반으로 운전 조건에 따른 열화 특성을 분석하고, 열화 모델을 구축하였다. 이를 반영한 M-EKF 알고리즘을 구현하여 연료전지의 상태를 정밀하게 추정하였다. 이후, 성능 예측 모델의 예측 정확도를 검증하고, 각 운전 조건에 따른 성능 열화량과 열화 속도를 정량적으로 분석하였다. 운전 조건에 따른 연료전지 성능 관계를 나타내기 위해 식 (1)과 (2)가 적용되었다.

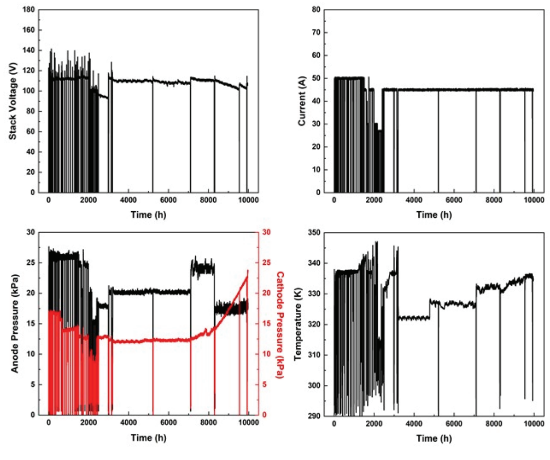

Fig. 1. Actual operational data of a building-integrated fuel cell system

$$V_{cell} = E_0 - Ri - \frac{RT}{a_c F}\ln\left(\frac{i}{i_{o,c}}\right) - \frac{RT}{a_a F}\ln\left(\frac{i}{i_{o,a}}\right) - \frac{RT}{nF}\ln\left(\frac{i_L}{i_L - i}\right) \tag{1}$$

$$i_{o,c} = i_o^{ref} a_c L_c \left(\frac{P_r}{P_r^{ref}}\right)^{\gamma} \exp\left[-\frac{E_c}{RT}\left(1-\frac{T}{T_{ref}}\right)\right] \tag{2}$$

2.2.1 데이터 수집 및 전처리

총 10,000시간의 연료전지 운전 데이터의 샘플링 주기는 1시간으로 설정하였다. 수집된 데이터는 연료전지 시스템에서 실시간으로 측정된 전압 (V), 전류 (A), 스택 내부 온도 (K), 애노드/캐소드 입구 압력 (kPa) 등 주요 운전 변수들을 포함하고 있다.

데이터의 신뢰성을 확보하고 정확한 열화 분석을 수행하기 위해 두 가지 전처리 과정을 적용하였다.

1. 초기 시동 및 정지의 반복 구간을 제거하여, 불안정한 시동 과정에서 발생하는 급격한 성능 변화를 제외한다.

2. 정지 후 재시동에 따른 성능 회복 효과를 제외함으로써, 시스템 운전 중 발생하는 성능 열화 경향을 보다 신뢰성 있게 분석한다.

두 가지 전처리 과정 적용 후 얻게 된 약 6,500시간의 운전 데이터(Fig. 2)를 통해 연료전지의 장기 운전 특성을 반영한 열화 분석을 수행하였다.

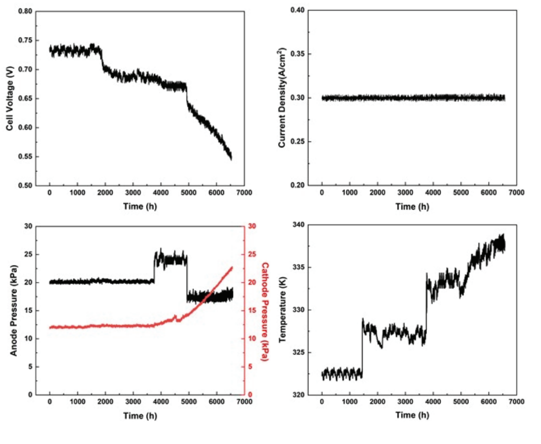

Fig. 2. Preprocessed operational data of a building-integrated fuel cell system

2.2.2 열화 모델링

Bressel 등[20]은 연료전지 열화 모델에 저항(R)과 한계전류밀도(i_L)만을 고려하여, 시간에 따라 동일한 비율로 증감한다고 가정하는 단순한 경험적 모델을 사용하였다. 그러나 실제 연료전지의 저항과 한계전류밀도는 동일한 비율로 변화하지 않는다.

기존 접근법은 성능 변화를 나타내는 주요 지표인 교환전류밀도의 변화를 고려하지 않을 뿐만 아니라, 온도, 압력 등 운전 조건의 변화가 열화 메커니즘에 미치는 영향을 반영하지 못하는 한계를 가진다. 따라서, 본 연구에서는 1) 기존 열화 지표에 교환전류밀도(i_o)를 포함하고, 2) 열화 지표가 열화 파라미터 α, β, γ에 의해 서로 독립적으로 계산될 수 있도록 식 (3), (4), (5)와 같이 모델링하여 물리적 상관관계를 반영하였다.

열화 파라미터 α, β, γ는 t (Time)와 운전 조건인 온도(T, Temperature), 캐소드 압력(CP, Cathode Pressure), 애노드 압력(AP, Anode Pressure)의 영향을 개별적으로 반영하기 위해 열화 계수를 도입하여 실시간으로 업데이트되도록 설계되었으며, 이는 각각 식 (6), (7), (8), (9)로 수식화된다.

$$R(t) = R_0(1+\alpha(t)) \tag{3}$$

$$i_{o,c}(t) = i_{o,c}(1-\beta(t)) \tag{4}$$

$$i_L(t) = i_{L0}(1-\gamma(t)) \tag{5}$$

$$\alpha(t) = (a_1 \times t) + (a_2 \times T) + (a_3 \times CP) + (a_4 \times AP) \tag{6}$$

$$\beta(t) = (b_1 \times t) + (b_2 \times T) + (b_3 \times CP) + (b_4 \times AP) \tag{7}$$

$$\gamma(t) = (c_1 \times t) + (c_2 \times T) + (c_3 \times CP) + (c_4 \times AP) \tag{8}$$

$$a_1, b_1, c_1 = \text{상수} \tag{9}$$

연료전지의 성능과 열화 파라미터를 동시에 추정하기 위해, 다음과 같이 EKF의 시스템 모델 식 (10)

을 기반으로 한 비선형 모델을 적용한다.

$$x_{k+1} = Ax_{k|k} + w_k \tag{10}$$

$$y_k = g(x_k, u_k) + v_k \tag{11}$$

여기서 x_k는 시스템 상태, u_k는 입력(전류, 온도 등), y_k는 출력(전압), w_k,v_k는 각각 프로세스 잡음과 관측 잡음이다. x_k는 식 (12)와 같이 열화 파라미터와 열화 계수를 포함하는 벡터로 구성된다.

$$x_k = [\alpha_k, a_1, a_2, a_3, a_4, \beta_1, b_1, b_2, b_3, b_4, \gamma_1, c_1, c_2, c_3, c_4] \tag{12}$$

$$\mathrm{A} = \begin{bmatrix} 1 & t & T & CP & AP & \cdots & 0 \\ 0 & 1 & 0 & 0 & 0 & \cdots & 0 \\ 0 & 0 & 1 & 0 & 0 & \cdots & 0 \\ 0 & 0 & 0 & 1 & 0 & \cdots & 0 \\ 0 & 0 & 0 & 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & 0 \\ 0 & 0 & 0 & 0 & 0 & \cdots & 1 \end{bmatrix} \tag{13}$$

동적 상태 전이 행렬 A는 운전 변수를 실시간으로 업데이트할 수 있는 형태로 정의된다. 이를 기반으로 운전 조건과의 상관관계를 반영하여 성능을 예측할 수 있도록 기존 식 (1)을 변형하여, 식 (14)를 도출하였다. 식 (14)는 T, CP, AP 등 운전 조건에 따라 독립적으로 계산되는 열화 파라미터를 포함함으로써, 연료전지의 성능을 운전 조건에 따라 보다 정밀하게 설명하는 데 활용된다.

$$\begin{aligned} & g(x_k, u_k) \\ & = E_0 - R_0(1+\alpha(t))i - \frac{RT}{a_c F}\ln\left(\frac{i}{i_{o,c}(1-\beta(t))}\right) \\ & \quad - \frac{RT}{a_a F}\ln\left(\frac{i}{i_{o,a}}\right) - \frac{RT}{nF}\ln\left(\frac{i_{L0}(1-\gamma(t))}{i_{L0}(1-\gamma(t))-i}\right) \end{aligned} \tag{14}$$

2.2.3 M-EKF 적용

EKF는 비선형 시스템의 상태를 실시간으로 추정하기 위해 개발된 알고리즘으로, 시스템 모델을 선형 근사한 뒤 예측과 업데이트 단계를 반복 수행한다. 본 연구에서는 기존 EKF에 운전 조건에 따른 열화 특성을 반영한 열화 모델을 결합하여 M-EKF를 구성하였다. M-EKF는 다음과 같은 특징을 갖는다.

1. 연료전지의 실시간 열화 매개변수 변화를 통해 성능 저하를 정밀하게 예측한다.
2. 운전 조건별로 열화 파라미터를 독립적으로 추정할 수 있어, 조건 변화에 따른 열화 경향 분석이 가능하다.

EKF 알고리즘은 다음과 같은 과정을 반복하게 된다.

<u>초기화 단계</u>

시스템의 초기 상태를 정의하기 위해 초기 상태 벡터와 공분산 행렬을 설정한다.

$$x_{0|0} = E[x(t_0)] \tag{15}$$

$$P_{0|0} = Var[x(t_0)] \tag{16}$$

<u>예측 단계</u>

시스템의 현재 상태를 기반으로 다음 시점에서의 상태를 예측하며, 동시에 공분산 행렬을 갱신한다. 이 과정은 시스템 모델 식 (10)을 고려하여 수행되며, 예측된 상태 값은 이후 보정 단계에서 관측 데이터와의 차이를 통해 비교 보정된다.

$$x_{k|k-1} = Ax_{k-1|k-1} \tag{17}$$

$$P_{k|k-1} = AP_{k-1|k-1}A^T + Q \tag{18}$$

<u>보정 단계</u>

보정 단계에서는 실제 관측 데이터를 활용하여 예측된 상태 값을 보정함으로써 상태 추정의 정확도를 높인다. 이때, 관측값과 예측값 사이의 오차를 기반으로 칼만 이득(K_k)을 계산하고, 이를 통해 상태 추정치를 수정한다. 이 과정은 시스템 모델과 측정 모델의 비선형성을 고려하여 선형화된 야코비안 행렬을 사용해 수행된다.

$$K_k = P_{k|k-1}H_k^T(H_kP_{k|k-1}H_k^T + R)^{-1} \tag{19}$$

$$x_{k|k} = x_{k|k-1} + K_k(y_k - g(x_k, u_k)) \tag{20}$$

$$P_{k|k} = (I - K_kH_k)P_{k|k-1} \tag{21}$$

2.2.4 열화 원인 진단

본 연구에서는 연료전지의 열화 지표인 R, i_o, i_L을 반영한 전압 모델을 기반으로, 각 운전 조건 변화에 따른 성능 저하를 정량적으로 분석한다.

예를 들어, 온도(T)의 영향을 분석하기 위해 연료전지 스택 전압을 예측하는 물리 모델에 온도 변화와 이에 따른 열화 계수를 반영하여 성능 저하를 계산한다. 온도에 의한 성능 저하를 반영한 모델은 식 (22)와 같이 정의된다. 여기서 a_2, b_2, c_2는 온도 변화에 따른 열화 계수를 나타내며, 해당 식을 통해 온도 변화가 스택 전압에 미치는 영향을 예측할 수 있다.

$$\begin{aligned} g(x_k,u_k)_T \\ = E_0 - R_0(1+(a_2\times T))i - \frac{RT}{a_cF}\ln\left(\frac{i}{i_{o,c}(1-(b_2\times T))}\right) \\ - \frac{RT}{a_aF}\ln\left(\frac{i}{i_{o,a}}\right) - \frac{RT}{nF}\ln\left(\frac{i_{L0}(1-(c_2\times T))}{i_{L0}(1-(c_2\times T))-i}\right) \end{aligned} \tag{22}$$

관측 전압($V_{Measured}$) 또는 운전 조건에 따라 예측된 전압과, 열화가 발생하지 않은 이론 전압($V_{Theoretical}$)간의 차이를 전압 열화량(V_d, Voltage degradation)으로 정의하며, 식 (23)과 같이 표현된다.

$$V_d = V_{Theoretical} - V_{Measured} \tag{23}$$

각 운전 조건 변화 구간에 따른 V_d 변화율을 분석함으로써, 열화 속도를 정량적으로 도출할 수 있으며, 이는 각 운전 조건이 연료전지의 성능 열화에 미치는 영향을 평가할 수 있는 지표로 활용된다. 이러한 방법론은 온도뿐만 아니라, 애노드/캐소드 압력 등 운전 조건과 시간 등에 동일하게 적용되어, 전체 열화 경향성과 주요 열화 요인을 종합적으로 분석할 수 있도록 설계되었다.

3. 결과 및 토의

3.1 M-EKF 모델 성능 평가

M-EKF 모델을 기반으로 예측된 성능을 평가하기 위해 실제 운전된 $V_{Measured}$와 M-EKF를 통해 예측된 예측 전압($V_{Predicted}$)을 비교하였다(Fig. 3). 그 결과, 예측 전압이 관측 전압과 매우 유사한 형태임을 볼 수 있다. 이는 제안된 M-EKF가 실제 연료전지 운전 조건과 관측 전압 사이의 상관관계를 효과적으로 반영하고 있음을 의미한다.

M-EKF 모델의 관측 전압과 예측 전압 간의 오차를 정량적으로 평가하기 위해 RMSE (Root Mean Square Error), NRMSE (Normalized Root Mean Square Error)와 R^2를 사용하였다. 식 (24-26)과 같이 RMSE는 예측 오차의 절대적인 크기를, NRMSE는 평균 전압 대비 상대 오차를, R^2는 모델의 설명력을 각각 나타낸다. 여기서, n은 데이터 샘플의 총 개수, y_i는 관측 전압, $\hat{y}_i$는 M-EKF 모델의 예측 전압, $\bar{y}$는 평균 전압이다.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \tag{24}$$

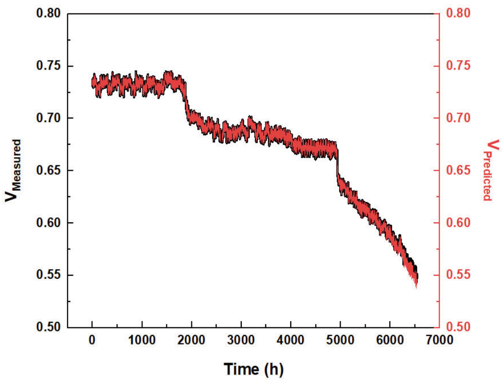

Fig. 3. Comparison of measured voltage and M-EKF predicted voltage

$$NRMSE = \frac{RMSE}{\bar{y}} \tag{25}$$

$$R^2 = 1 - \frac{\sum_{t=1}^{n}(y_t - \hat{y}_t)^2}{\sum_{t=1}^{n}(y_t - \bar{y})^2} \tag{26}$$

분석 결과, M-EKF 모델의 RMSE는 0.0003으로 매우 낮게 나타났으며, NRMSE는 0.0004, R^2은 0.9997에 달하였다. 이는 M-EKF가 연료전지 운전 조건을 기반으로 열화 정도와 성능 저하를 정밀하게 예측할 수 있음을 보여준다.

연료전지의 성능 향상을 위해서는 일반적으로 셀 내부 온도를 상승시키거나, 애노드/캐소드 압력을 증가시키는 등의 방식으로 운전 조건을 조정한다. 이러한 변화는 i_o의 증가를 유도하는데, 이는 촉매 활성 부위에서 전극의 산화·환원 반응이 가속화되어 전극 반응성이 향상되는 등의 전기화학적 활성도 증가가 주된 원인으로 작용하기 때문이다.

본 연구에서는 Fig. 2의 운전 조건 변화 데이터를 활용하여 분석을 진행하였으며, 그 결과 i_o가 증가하는 경향을 보였다. 그러나 Fig. 4에서 확인할 수 있듯이, 식 (2)를 이용해 계산된 이론 교환전류밀도($i_{o,c,Theoretical}$)에 비해 M-EKF를 통해 예측된 교환전류밀도($i_{o,c,M-EKF}$)가 시간이 지남에 따라 감소하는 형태를 보인다. 이는 성능 유지를 목표로 한 운전 조건의 변화가 단기적으로는 성능 유지에 기여하지만, 장기적으로는 성능 열화 완화에 효과적이지 않음을 확인할 수 있다. Fig. 5에는 M-EKF을 통해 예측된 R과 i_L를 나타내었다. Fig. 5(a)에서 R이 점진적으로 증가하는 형태로, 전해질막의 내구성 저하로 인한 양성자 전도성(H^+) 저하, 전극-전해질 계면에서의 물 분포 변화로 인한 내부 저항 증가 등을 고려해 볼 수 있다. 또한, Fig. 5(b)에서 i_L의 감소는 장기 운전 중 전극 구조 변화로 인한 확산층 및 촉매층 내 물질 전달 저항의 증가와 관련이 있을 수 있다.

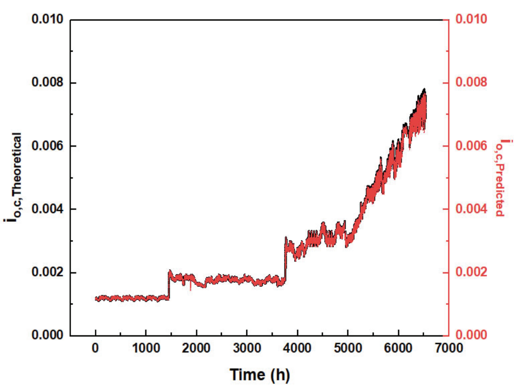

Fig. 4. Comparison of theoretical and M-EKF predicted exchange current density ($i_{o,c}$)

3.2 운전 조건에 따른 열화 상대량 분석

연료전지는 장시간 운전하는 과정에서 내부 구성 요소의 누적 열화로 인해 필연적으로 성능 저하가 발생한다. 그러나 동일한 운전 시간이라 하더라도 운전 조건의 설정 방식에 따라 열화의 정도는 달라질 수 있으며, 적절한 운전 조건 조정을 통해 성능

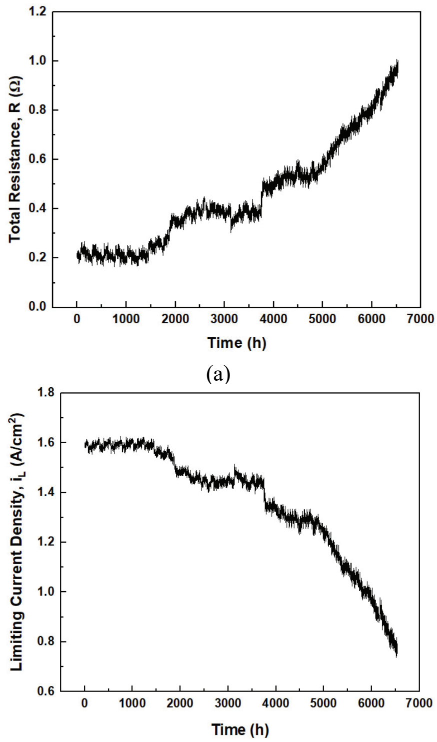

Fig. 5. Comparison of (a) total resistance (R) and (b) limiting current density (i_L) predicted by M-EKF

저하를 완화하는 것이 가능하다. 일반적으로 온도 및 압력을 상승시키면 전기화학 반응의 활성도가 증가하고, 연료 공급이 개선됨에 따라 단기적인 성능 향상이 나타난다. 그러나 이러한 운전 조건의 변화가 항상 긍정적인 결과를 가져오는 것은 아니며, 과도한 온도 상승은 전해질막의 탈수, 촉매 손실, 탄소 지지체 부식과 같은 부작용을 유발할 수 있다. 또한, 압력이 과도하게 증가할 경우 전해질막 손상이나 시스템 부하 증가로 이어질 수 있다.

Fig. 6은 제안된 M-EKF 모델로 예측한 열화 파라미터를 활용하여, 운전 조건별 (a) 스택 전압 변화와 (b) 이에 따른 열화 정도를 비교 분석한 결과를 나타낸다. (a)에서 $V_{Measured}$는 실제 운전 전압 데이터를, $V_{Theoretical}$은 식 (1)을 통해 계산된 이론 전압을 의미한다. 또한, V_t, V_T, V_{CP}, V_{AP}는 시간, 온도, 캐소드 압력, 애노드 압력에 따른 열화 계수를 각각 식 (14)

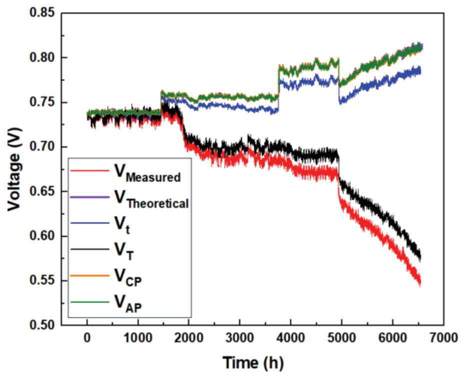

(a) Performance analysis by operating condition

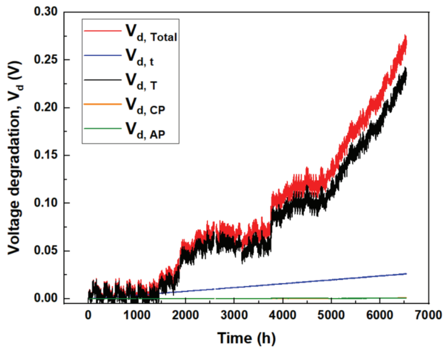

(b) Voltage loss due to degradation

Fig. 6. PEMFC performance and degradation analysis under different operating conditions

에 대입하여 계산된 운전 조건별 예측 전압이다. (b)에서는 이론 전압과 관측 전압 간의 차이를 총 열화량 $V_{d,Total}$로 정의하였다. 동일한 방식으로 이론 전압과 운전 조건별 전압과의 차이를 통해 $V_{d,t}$, $V_{d,T}$, $V_{d,CP}$, $V_{d,AP}$를 도출하였으며, 이를 각각 운전 조건별 열화량으로 나타내었다. 이러한 전압 열화량 비교를 통해 각 운전 조건이 전압 손실에 미치는 영향을 개별적으로 분석할 수 있다.

Fig. 6 분석 결과, 연료전지의 운전 시간 경과에 따라 누적 열화가 진행되어 전압 손실이 점진적으로 증가하는 경향이 나타났다. 특히, T는 전압 저하 및 열화량에 미치는 영향이 지배적인 변수로 분석되었다. 반면, Fig 6(a)에서 AP와 CP 변화에 따른 예측 전압은 이론 전압과 유사한 수준으로 분포하며 세 곡선($V_{Theoretical}$, V_{CP}, V_{AP})이 시각적으로 중첩되는 경향을 보였다. 이와 유사하게 Fig. 6(b)에서도 압력 조건의 변화에 따른 열화량($V_{d,CP}$, $V_{d,AP}$)이 거의 동일하게 나타났다. 이러한 결과는 AP, CP 영향이 성능 열화에 미치는 영향이 상대적으로 미미함을 의미하며, 연료전지 성능 저하를 최소화하기 위해서는 온도 제어의 최적화가 핵심적인 운전 인자임을 보여준다.

3.3 열화 속도 분석

Fig. 7에서는 실제 운전 조건별 변화 구간을 바탕으로 스택 전압의 열화 속도를 나타내었다. 시간에 따른 열화 속도의 경우, 외부 환경 변화나 운전 조건의 영향을 배제한 상태에서, 시간 경과에 따른 열화만을 반영했기 때문에 전반적으로 일정한 경향을 보인다. 온도에 따른 열화 속도는 온도가 상승할수록 증가하는 경향을 나타내며, 이는 전해질막 내부의 수분 증발이 일어남에 따라 프로톤 전도성이 저하되어 내부 저항이 증가하고 출력 전압이 감소해 열화가 가속화되었을 가능성이 있다. 압력 변수 분석 결과, 캐소드 압력은 증가할수록 열화 속도가 증가하는 경향을 보인 반면, 애노드 압력은 열화 속도를 완화하는 효과를 나타냈다. 다만, 애노드 압력이 일정 수준을 초과할 경우, 추가적인 완화 효과는 제한적

으로 나타났다. 이러한 현상은 캐소드 측에서 과도한 압력 증가가 전극과 촉매층에 기계적 스트레스를 유발하고, 물 관리 불균형 및 전해질막의 화학적 안정성 저하를 야기하여, 장기적으로 전극 구조 손상과 막 열화를 가속화시켰을 가능성이 있다. 반면, 애노드 압력 증가는 연료 및 산화제의 공급 균일성을 개선하고, 전극 내 반응 활성도를 향상시켜 일정 수준까지 열화 속도 완화에 기여했을 수 있다. 하지만, 전반적으로 온도에 비해 압력의 영향은 상대적으로 작기 때문에, 과도한 압력 증가가 없는 한, 압력 변화로는 성능 저하 속도가 유의미하게 증가하지는 않을 것으로 보인다. Table 1에서는 Fig. 7에서 보인 운전 조건별 열화 속도를 정량적으로 제시하였다. 온도의 경우 335 K 이상에서 온도에 의한 열화 속도가 급격히 증가하는 경향을 보였으며, 캐소드 압력은 대체로 일정한 비율로 열화 속도가 증가하였다. 반면, 애노드 압력의 경우 약 16 kPa 이상부터는 열화 속도가 일정한 수준을 유지하며, 그 이상의 압력 증가에 따른 추가적인 완화 효과는 뚜렷하게 나타나지 않았다.

본 연구에 사용된 건물용 연료전지 시스템의 성능 열화 특성상, 운전 조건 변화 시 온도 설정이 가장 열화 속도에 민감하게 작용하는 변수임을 확인할 수 있다. 또한, 애노드 압력은 일정 범위 내에서 열화 속도 완화에 긍정적인 영향을 미치는 요인으로 작용할 수 있음을 보여준다.

4. 결 론

본 연구에서는 M-EKF 기반 성능 예측 모델을 활용하여 건물용 연료전지의 실제 장기 운전 데이터를 바탕으로 운전 조건에 따른 성능 저하 및 열화 특성을 분석하였다. 제안된 모델은 RMSE 0.0003, NRMSE 0.0004, R^2 0.9997를 나타내며, 연료전지의 실시간 상태 추정에 효과적임을 확인하였다.

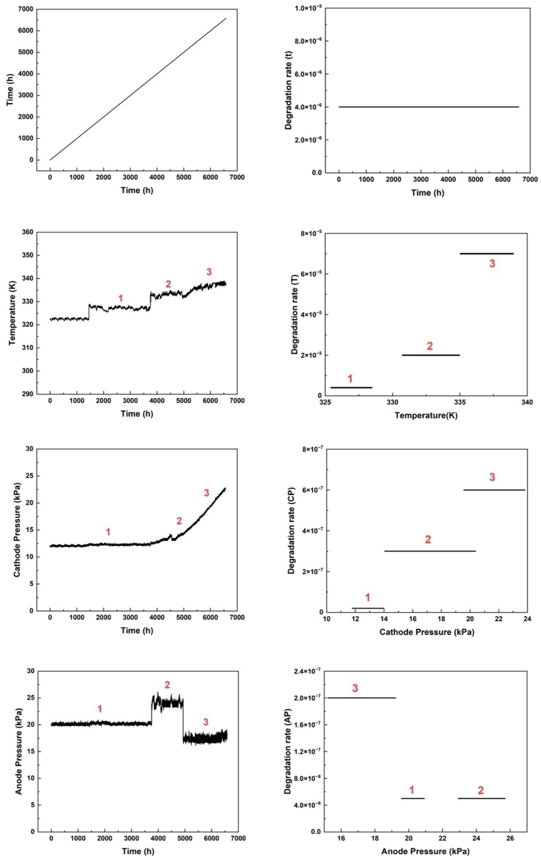

Fig. 7. Degradation rates by operating-condition segment

셀 성능 분석 결과, 본 연구 대상 시스템은 운전 시간의 경과에 따라 누적된 열화로 인해 전압 손실이 점진적으로 증가하는 경향을 보였으며, 온도는 성능 저하와 열화 속도에 지배적인 영향을 미치는 변수로 확인되었다. 특히 335K 이상의 온도 구간에서는 열화 속도가 급격히 증가하는 경향을 보여, 온도 설정이 장기적인 성능 유지에 있어 핵심적인 운

Table 1. Quantitative analysis of degradation rates by operating-condition interval

T(K)	Degradation rate	CP(kPa)	Degradation rate	AP(kPa)	Degradation rate
325-329	4×10^{-6}	11.8-13.5	3×10^{-8}	16-19.2	8×10^{-8}
331-335	2×10^{-5}	15-19.3	4×10^{-7}	19.5-21	8×10^{-8}
335-339	7×10^{-5}	20-22.69	8×10^{-7}	22-26.1	2×10^{-7}

전 조건임을 알 수 있다. 반면, 압력 변수는 상대적으로 영향이 작게 나타났으며, 캐소드 압력의 경우 열화를 가속하는 요인으로, 애노드 압력은 열화 속도를 완화하는 데 기여하는 요인으로 작용하였다. 그러나 일정 압력 이상에서는 이러한 완화 효과가 더 이상 뚜렷하게 나타나지 않는 것으로 분석되었다.

이러한 결과는 단기 성능 향상을 위한 운전 조건의 변화가 반드시 장기적인 내구성 향상으로 이어지지는 않음을 보여주며, 단기 성능과 장기 안정성 간 균형을 고려한 운전 전략 수립이 필요함을 보여준다. 특히, 본 연구에서 도출된 성능 열화량 및 속도 분석 결과는 시스템별 운전 전략 수립의 기초자료로 활용될 수 있다. 예를 들어, 열화가 가속화되는 335 K 이상으로의 장시간 운전을 제한하거나, 캐소드 압력 제어를 통한 열화 완화 구간 유지 등과 같은 실시간 운전 조건 관리 전략으로 확장할 수 있다.

본 연구에서는 열화 지표를 저항, 한계전류밀도, 교환전류밀도로 세분화하고, 각 열화 지표가 운전 조건의 영향을 독립적으로 반영하도록 열화 모델을 설계하였다. 이를 기반으로 구축한 M-EKF 기반 성능 예측 모델을 통해, 기존 연구에서 별도의 실험을 통해 정량화하던 열화 속도를 실제 장기 운전 데이터를 활용해 분석함으로써, 시간과 비용 측면에서의 효율성을 기대할 수 있다.

향후 연구에서는 본 연구를 기반으로 한 잔여 수명 예측 기술의 고도화와 더불어, 다양한 운전 조건 시나리오에 대한 시뮬레이션을 통해 최적 운전 전략을 도출하는 연구가 추가적으로 수행될 필요가 있다.

후 기

본 연구는 2025년도 산업통상자원부의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제이다(No.RS-2025-25447258).

References

1. Y. Wang, K. S. Chen, J. Mishler, S. C. Cho, and X. C. Adroher, “A review of polymer electrolyte membrane fuel cells: technology, applications, and needs on fundamental research”, Applied Energy, Vol. 88, No. 4, 2011, pp. 981-1007, doi: https://doi.org/10.1016/j.apenergy.2010.09.030.
2. R. Ma, T. Yang, E. Breaz, Z. Li, P. Briois, and F. Gao, “Data-driven proton exchange membrane fuel cell degradation prediction through deep learning method”, Applied Energy, Vol. 231, 2018, pp. 102-115, doi: https://doi.org/10.1016/j.apenergy.2018.09.111.
3. D. E. Park, K. S. Cha, and Y. G. Jung, “Study on applicability of household fuel cell system with operating methods”, Journal of Hydrogen and New Energy, Vol. 25, No. 2, 2014, pp. 139-144. doi: https://doi.org/10.7316/KHNES.2014.25.2.139.
4. R. E. Silva, R. Gouriveau, S. Jemeï, D. Hissel, L. Boulon, K. Agbossou, and N. Y. Steiner, “Proton exchange membrane fuel cell degradation prediction based on Adaptive Neuro-Fuzzy Inference Systems”, International Journal of Hydrogen Energy, Vol. 39, No. 21, 2014, pp. 11128-11144, doi: https://doi.org/10.1016/j.ijhydene.2014.05.005.
5. L. Fan, J. Gao, Y. Lu, W. Shen, and S. Zhou, “Empirical degradation models of the different indexes of the proton exchange membrane fuel cell based on the component degradation”, Energies, Vol. 16, No. 24, 2023, pp. 8012, doi: https://doi.org/10.3390/en16248012.
6. M. Chandesris, R. Vincent, L. Guetaz, J. S. Roch, D. Thoby, and M. Quinaud, “Membrane degradation in PEM fuel cells: From experimental results to semi-empirical degradation laws”, International Journal of Hydrogen Energy, Vol. 42, No. 12, 2017, pp. 8139-8149, doi: https://doi.org/10.1016/j.ijhydene.2017.02.116.
7. M. W. Fowler, R. F. Mann, J. C. Amphlett, B. A. Peppley, and P. R. Roberge, “Incorporation of voltage degradation into a generalised steady state electrochemical model for a PEM fuel cell”, Journal of Power Sources, Vol. 106, No. 1-2, 2002, pp. 274-283, doi: https://doi.org/10.1016/S0378-7753(01)01029-1.
8. X. Zhang, D. Yang, M. Luo, and Z. Dong, “Load profile based empirical model for the lifetime prediction of an automotive PEM fuel cell”, International Journal of Hydrogen Energy, Vol. 42, No. 16, 2017, pp. 11868-11878, doi: https://doi.org/10.1016/j.ijhydene.2017.02.146.
9. J. T. Pukrushpan, A. G. Stefanopoulou, and H. Peng, “Control of fuel cell power systems: principles, modeling, analysis and feedback design”, Springer, USA, 2004, pp. 1-336, doi: https://doi.org/10.1007/978-1-4471-3792-4.
10. Z. Hua, Z. Zheng, E. Pahon, M. C. Péra, and F. Gao, “Remaining useful life prediction of PEMFC systems under dynamic operating conditions”, Energy Conversion and Management, Vol. 231, 2021, pp. 113825, doi: https://doi.org/10.1016/j.enconman.2021.113825.
11. S. Hong, L. Sun, J. Yin, T. Yu, Y. Wang, and W. Zhu, “PEMFC

power prediction based on deep auto-encoder and LS-SVMR", in Proc. of the International Conference on Big Data Analysis (ICBDA), Shanghai, China, 2018, doi: https://doi.org/10.1109/ICBDA.2018.8367714.

12. Z. Liu, S. Xu, H. Zhao, and Y. Wang, "Durability estimation and short-term voltage degradation forecasting of vehicle PEMFC system: development and evaluation of machine learning models", Applied Energy, Vol. 326, 2022, pp. 119975, doi: https://doi.org/10.1016/j.apenergy.2022.119975.
13. M. Mayur, M. Gerard, P. Schott, and W. G. Bessler, "Lifetime prediction of a polymer electrolyte membrane fuel cell under automotive load cycling using a physically-based catalyst degradation model", Energies, Vol. 11, No. 8, 2018, pp. 2054, doi: https://doi.org/10.3390/en11082054.
14. M. Jouin, R. Gouriveau, D. Hissel, M. C. Pera, and N. Zerhouni, "Joint particle filters prognostics for PEMFC power prediction at constant current solicitation", IEEE Transactions on Reliability, Vol. 64, No. 1, 2015, pp. 1-14, doi: https://doi.org/10.1109/TR.2014.2362952.
15. S. D. Pene, A. Picot, F. Gamboa, N. Savy, C. Turpin, and A. Jaafar, "Aging modeling and lifetime prediction of a proton exchange membrane fuel cell using an extended Kalman filter", arXiv preprint arXiv:2406.01259, 2024, doi: https://doi.org/10.48550/arXiv.2406.01259.
16. H. Yuan, H. Dai, X. Wei, and P. Ming, "Model-based observers for internal states estimation and control of proton exchange membrane fuel cell system: a review", Journal of Power Sources, Vol. 468, 2020, pp. 228376, doi: https://doi.org/10.1016/j.jpowsour.2020.228376.
17. X. Zhang and P. Pisu, "An unscented Kalman filter based on-line diagnostic approach for PEM fuel cell flooding", International Journal of Prognostics and Health Management, Vol. 5, No. 1, 2014, pp. 1-18, doi: https://doi.org/10.36001/ijphm.2014.v5i1.2204.
18. Y. Ao, S. Laghrouche, D. Depernet, and K. Chen, "Proton exchange membrane fuel cell prognosis based on frequency-domain Kalman filter", IEEE Transactions on Transportation Electrification, Vol. 7, No. 4, 2021, pp. 2332-2343, doi: https://doi.org/10.1109/TTE.2021.3077506.
19. K. Chen, S. Laghrouche, and A. Djerdir, "Fuel cell health prognosis using Unscented Kalman Filter: postal fuel cell electric vehicles case study", International Journal of Hydrogen Energy, Vol. 44, No. 3, 2019, pp. 1930-1939, doi: https://doi.org/10.1016/j.ijhydene.2018.11.100.
20. M. Bressel, M. Hilairet, D. Hissel, and B. O. Bouamama, "Extended Kalman filter for prognostic of proton exchange membrane fuel cell", Applied Energy, Vol. 164, 2016, pp. 220-227, doi: https://doi.org/10.1016/j.apenergy.2015.11.071.
21. K. Song, Y. Wang, X. Hu, and J. Cao, "Online prediction of vehicular fuel cell residual lifetime based on adaptive extended Kalman filter", Energies, Vol. 13, No. 23, 2020, pp. 6244, doi: https://doi.org/10.3390/en13236244.
22. D. Zhou, F. Gao, E. Breaz, A. Ravey, and A. Miraoui, "Degradation prediction of PEM fuel cell using a moving window based hybrid prognostic approach", Energy, Vol. 138, 2017, pp. 1175-1186, doi: https://doi.org/10.1016/j.energy.2017.07.096.
23. Z. Li, S. Jemei, R. Gouriveau, D. Hissel, and N. Zerhouni, "Remaining useful life estimation for PEMFC in dynamic operating conditions", in Proc. of the IEEE Vehicle Power and Propulsion Conference (VPPC), Hangzhou, China, 2016, doi: https://doi.org/10.1109/VPPC.2016.7791762.
24. X. Wu, Q. Ye, and J. Wang, "A hybrid prognostic model applied to SOFC prognostics", International Journal of Hydrogen Energy, Vol. 42, No. 39, 2017, pp. 25008-25020, doi: https://doi.org/10.1016/j.ijhydene.2017.08.114.
25. Q. Tian, H. Chen, S. Ding, L. Shu, L. Wang, and J. Huang, "Remaining useful life prediction method of PEM fuel cells based on a hybrid model", Electronics, Vol. 12, No. 18, 2023, pp. 3883, doi: https://doi.org/10.3390/electronics12183883.
26. R. Pan, D. Yang, Y. Wang, and Z. Chen, "Performance degradation prediction of proton exchange membrane fuel cell using a hybrid prognostic approach", International Journal of Hydrogen Energy, Vol. 45, No. 55, 2020, pp. 30994-31008, doi: https://doi.org/10.1016/j.ijhydene.2020.08.082.
27. R. Ma, R. Xie, L. Xu, Y. Huangfu, and Y. Li, "A hybrid prognostic method for PEMFC with aging parameter prediction", IEEE Transactions on Transportation Electrification, Vol. 7, No. 4, 2021, pp. 2318-2331, doi: https://doi.org/10.1109/TTE.2021.3075531.
28. H. Liu, J. Chen, D. Hissel, and H. Su, "Remaining useful life estimation for proton exchange membrane fuel cells using a hybrid method", Applied Energy, Vol. 237, 2019, pp. 910-919, doi: https://doi.org/10.1016/j.apenergy.2019.01.023.
29. A. Jacome, D. Hissel, V. Heiries, M. Gerard, and S. Rosini, "PEMFC state-of-health estimation using a model-based state Bayesian observer under an automotive load profile", in Proc. of the 2020 IEEE Vehicle Power and Propulsion Conference (VPPC), Gijón, Spain, 2020, pp. 1-4, doi: https://doi.org/10.1109/VPPC49601.2020.9330963.
30. Y. Cheng, N. Zerhouni, and C. Lu, "A hybrid remaining useful life prognostic method for proton exchange membrane fuel cell", International Journal of Hydrogen Energy, Vol. 43, No. 27, 2018, pp. 12314-12327, doi: https://doi.org/10.1016/j.ijhydene.2018.04.160.
31. J. Liu, Q. Li, W. Chen, Y. Yan, Y. Qiu, and T. Cao, "Remaining useful life prediction of PEMFC based on long short-term memory recurrent neural networks", International Journal of Hydrogen Energy, Vol. 44, No. 11, 2019, pp. 5470-5480, doi: https://doi.org/10.1016/j.ijhydene.2018.10.042.