

선형회귀 및 ARIMA 모델을 이용한 배터리 사용자 패턴 변화 추적 연구

박종용* · 유민혁** · 노태민*** · 신대건** · 김성권****

A study of Battery User Pattern Change tracking method using Linear Regression and ARIMA Model

Jong-Yong Park* · Min-Hyeok Yoo** · Tae-Min Nho*** · Dae-Kyeon Shin** · Seong-Kweon Kim****

요약

전기자동차는 운전자가 바뀌거나 운전자의 주행습관이 바뀔에 따라 SOH가 급격하게 감소할 수 있고, 이러한 운전습관은 배터리에 과부하를 주어 배터리 수명의 단축 및 안전 문제를 일으킬 수 있다. 본 논문에서는 전기자동차의 계기판에 사용자 패턴 변화에 따른 SOH의 변화를, 실시간으로 나타내기 위하여, NASA에서 제공하는 배터리 데이터 세트를 학습하고, 기계학습 모델을 구축 후, 변화된 사용자 패턴을 포함한 배터리에 대해 선형회귀와 ARIMA 모델로 예측하는 실험을 진행하였다. 그 결과, 변화된 사용자 패턴에 따른 변경된 수명을 예측하는 경우, 배터리 데이터가 많이 확보되었다면 선형회귀가 유용하고, 데이터가 많이 확보되지 않은 경우는 ARIMA 모델이 대안이 될 수 있다는 연구결과를 얻을 수 있었다.

ABSTRACT

This paper addresses the safety concern that the SOH of batteries in electric vehicles decreases sharply when drivers change or their driving patterns change. Such a change can overload the battery, reduce the battery life, and induce safety issues. This paper aims to present the SOH as the changes on a dashboard of an electric vehicle in real-time in response to user pattern changes. As part of the training process I used battery data among the datasets provided by NASA, and built models incorporating linear regression and ARIMA, and predicted new battery data that contained user changes based on previously trained models. Therefore, as a result of the prediction, the linear regression is better at predicting some changes in SOH based on the user's pattern change if we have more battery datasets with a wide range of independent values. The ARIMA model can be used if we only have battery datasets with SOH data.

키워드

Battery, SOH, User Pattern Change, Linear Regression, ARIMA
배터리, 건전성 지표, 사용자 패턴 변경, 선형 회귀, 자동 회귀 통합 이동 평균

* 서울과학기술대학교 정보통신미디어공학과
(jongyong.ryan.park@gmail.com)

** 서울과학기술대학교 정보통신미디어공학과
(dbalsgur94@gmail.com, then0925@naver.com)

*** 서울과학기술대학교 미디어IT공학과
(taemin.nho@seoultech.ac.kr)

**** 교신저자 : 서울과학기술대학교 정보통신미디어
공학과

• 접수일 : 2022. 04. 07

• 수정완료일 : 2022. 05. 12

• 게재확정일 : 2022. 06. 17

• Received : Apr. 07, 2022, Revised : May. 12, 2022, Accepted : Jun. 17, 2022

• Corresponding Author : Seong-Kweon Kim

Dept. of Information Technology & Media Engineering, Seoul National University
of Science & Technology,

Email : kim12632@seoultech.ac.kr

1. 서 론

현재, 친환경 에너지 정책에 따라 전기 자동차가 점차 대중화되고 있으며 이에 따라 배터리의 사용이 급격히 증가되고 있다. 배터리 사용에서 중요한 것은 배터리를 효율적으로 오래 사용하는 것인데, 이에 대한 주요한 지표로 건전성 지표(State of Health, SOH)가 사용되고 있다. 이 SOH를 통해 배터리의 남은 수명 (Remaining Useful Life, RUL)을 예측하며, 안전 문제의 발생 위험을 예측한다.

그림 1은 SOH의 개념도를 나타낸다. 배터리의 SOH는 배터리 사용 사이클에 따른 배터리 용량 및 내부저항의 변화를 알려주며, INACTIVE로 표시된 영역이 배터리 사용 사이클이 증가함에 따라 점차 증가하게 되며, SOH는 점차 감소한다. 수식 (1)은 SOH의 정의를 보여주며 이는 설계된 용량 대비 현재 완충된 용량의 비율이다.

$$SoH = C_{fullcharge} / C_{design} \times 100\% \quad (1)$$

SOH는 현시점의 SOC(: State of Charge)를 예측하는데 중요한 요소이다. 수식 (2)에서와 같이, 현재 남아있는 용량 ($C_{remaining}$)을 측정하면 고정된 설계용량(C_{design})과 SOH를 통해 현시점의 SOC가 계산된다.[1]

$$SoC = C_{remaining} / (SoH \times C_{design}) \times 100\% \quad (2)$$




그림 1. 배터리의 SOC 및 SOH
Fig. 1 SOC and SOH of Battery

전기자동차의 경우, 운전자나 운전자의 주행 패턴이 바뀌어 배터리에 과부하를 주게 되면 SOH가 급격하게 감소하고 배터리의 과부하에 따라 배터리의 수명이 급격하게 짧아지며 폭발 및 화재 등의 사고를 일으킬 수 있다[2]. 그러나 배터리의 사용자는 배

터리 사용자 패턴이 어떻게 배터리의 수명과 안전 문제에 직결되는지 알 수 없다. 이를 해결하기 위해 본 논문에서는 배터리 사용자의 패턴을 분석하여, 전기자동차의 계기판에 배터리 수명 예측 내용을 나타낼 수 있는 방법에 대해 연구하였다.

SOH 측정을 위해서는 다양한 분석방법이 사용되고 있다[3]. 기존의 분석방법 중, 첫 번째는 배터리의 전기화학적 동작을 수학적으로 모형화하여 배터리의 내부저항과 배터리 용량을 분석하는 방법이다. 이는 전기화학적 수식에 배터리 사용자의 사용자 패턴을 반영할 수 없어 정확한 모델을 구현하기 어렵다.

두 번째 방법은 특정 배터리를 전기 등가회로로 모형화해서 분석하는 것이다. 이 모델도 사용자의 다양한 사용자 패턴 변화에 따른 부하 전압, 전류의 변화를 반영하기는 어렵다는 단점을 가지고 있다.

세 번째는 기존의 배터리 사용 데이터를 기반으로 기계학습을 통해 SOH를 예측하는데 방법인데, 배터리 사용자의 사용자 패턴 변화에 따른 부하 전압, 전류의 변화를 예측할 수 있는 모델을 생성할 수 있다는 장점이 있다.

기계학습을 통해 SOH를 예측하는 방법으로는 주로, 선형회귀, 다중 선형회귀, 다항 선형회귀, 주성분 분석 (Principal Component Analysis, PCA) 기반의 회귀, SVR(: Support Vector Regression), GPR (: Gaussian Process Regression), 시계열 예측모델 기반의 자기 회귀 통합 이동 평균(ARIMA), 독립변수 간의 독립성이 약한 경우 사용하는 벡터 자기 회귀 모형 (Vector Auto Regressive, VAR) 등이 있으며, 또한, Kalman Filter와 Particle Filter와 같은 필터 기반의 방법도 사용되고 있다[4-6].

본 논문은 사용자의 급격한 사용자 패턴의 변화를 추적하여 배터리의 SOH를 예측하는 방법에 관한 연구로, 기계학습 기법을 이용하였으며, 사용자 패턴에 따라 변경된 SOH의 변화를 기반으로 남은 배터리 사이클을 전기자동차의 계기판에 표시하도록 하였다. 이를 위해 기존의 데이터를 선형회귀와 ARIMA로 학습하여 모델을 생성하고, 이 모델들을 데이터베이스에 보관한다. 사용자 패턴이 변경되는 경우 보관된 모델 중 변화된 사용자 패턴에 따라 SOH 용량의 변화를 잘 추정하는 모델을 선정하여 미래의 SOH 변화를 예측한다.

기계학습의 방법은 다양하다. 본 논문에서 선형회귀와 ARIMA를 선택한 이유는 딥러닝 방법과 Kalman filter 등의 filter를 사용한 방법과 달리 연산량이 적어서 리소스가 제한된 내장형 시스템인 자동차 계기판에 적용하기에 적합하기 때문이다.

기존의 SOH 예측 방법들은 특정 데이터로 학습된 모델은 다른 데이터를 가지고 예측하는 경우 정확도가 많이 떨어진다. 또한, 동일한 데이터를 사용하더라도 데이터 중 일부만으로 학습하여 모델을 생성하는 경우, 같은 데이터의 나머지 부분을 예측할 때 정확도가 떨어진다[7-8].

이 논문에서는 이를 해결하기 위해 데이터들의 전체 사이클을 학습시켜 모델로 만들고, 각 데이터에 따른 모델들을 데이터베이스에 저장하였다. 사용자 패턴의 변화가 포함된 데이터로 기존의 보관된 모델 중 예측 정확도가 높은 모델을 선정하고 이에 따른 RMSE를 비교하였다.

본 논문에서는 2장에서 선형회귀 및 ARIMA 모델에 대하여 설명하며, 3장에서는 배터리의 데이터 세트 선정에 대하여 설명하고, 실험 진행을 위한 배터리 데이터의 생성을 설명한다. 그리고, 4장에서는 선형회귀 및 ARIMA 모델을 사용하여 배터리 사용자 패턴에 따라 SOH 용량의 변화를 추정하는 실험 결과를 제시하며, 5장에서 결론을 기술한다.

II. 선형회귀 및 ARIMA 모델

자동차 계기판에 배터리 수명 예측 내용을 나타낼 수 있도록, 본 연구에서는 입력된 독립변수 (정전류 충전시간)의 변화에 따라 관심 대상인 종속변수 (SOH)의 변화를 예측하는데 선형회귀모델을 사용하였으며, 또한, 시계열 데이터의 관점에서 독립변수가 없더라도 종속변수(SOH)의 시간적 변화를 예측하는데 사용하는 ARIMA 모델을 사용하였다.

선형회귀(linear regression)는 종속변수 y 와 한 개 이상의 독립변수 X 와의 선형 상관관계를 모형화하는 회귀분석 기법이다[9].

$$y_i = c + \beta_1 x_{1,i} + \beta_2 x_{2,i} + \dots + \beta_k x_{k,i} + \varepsilon_i, \quad (3)$$

$$i = 1, \dots, n$$

$$\hat{y}_i = \hat{c} + \hat{\beta}_1 x_{1,i} + \hat{\beta}_2 x_{2,i} + \dots + \hat{\beta}_k x_{k,i} \quad (4)$$

$$i = 1, \dots, n$$

위 식(3)과 같은 n 개의 데이터 집합에 대해서 잔차인 ε_i 의 제곱 오차 합을 최소화하는 계수를 학습하여 식 (4)와 같이 종속변수의 추정값을 독립변수 간의 선형 결합으로 나타낸 식을 통하여 종속변수의 값을 추정하는 것이 선형회귀 모델이다.

선형회귀 모델을 통해 값을 추정하기 위해서는 독립변수와 종속변수가 높은 상관관계를 가져야 하고 이는 독립변수와 종속변수의 상관계수가 1에 가까워야 함을 의미한다.

ARIMA 모델은 시계열 데이터를 분석하고 예측하는데 사용되는 기법이다. ARIMA는 AutoRegressive Integrated Moving Average(자기회귀 누적 이동 평균)의 약자로 AR 모델과 MA 모델을 결합한 ARMA 모델에 차분(differencing)을 추가로 적용한 모델이다.

AR(자기 회귀)는 목표 예상 변수의 현재 값을 과거 값들의 선형 결합을 통해 예측하는 모델이다. 차수 p 의 자기 회귀 모델은 식 (5)와 같이 쓸 수 있다.

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (5)$$

식 (5)에서 차수 p 는 어느 정도 과거 시점까지의 데이터를 사용해서 현재의 값을 추정할지를 나타내는 값이다.

MA(이동 평균)는 목표 예상 변수의 현재 값을 추정하는데 과거의 예측 오차 값들을 이용하는 모델이다. q 차 이동 평균 모델인 MA(q) 모델은 식 (6)과 같이 나타낸다.

$$y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (6)$$

식 (6)에서 ε_t 는 백색잡음으로 나타낸 오차항이고, 각 시점의 오차항들은 평균을 0으로 하는 독립항 등분포로 가정한다. q 는 어느 정도 과거 시점까지의 오차항을 사용해서 현재의 값을 추정하는지 나타내는 값이다.

차분은 정상성(stationarity)을 나타내지 않는 시계열 데이터에서 추세나 계절성을 제거하여 정상성을 나타내도록 하는 과정이다. 정상성이란 시계열의 특징이 시계열이 관측된 시간에 무관한 성질을 말한다. 자기 회귀 모델은 정상성을 나타내는 데이터에만 사용하기 때문에 ARIMA 모델에도 정상성을 나타내는 데이터를 사용하기 위해 차분하는 과정이 포함된다. 차분이란 원래의 시계열에서 연이은 관측값의 차이로 식(7)과 같이 쓸 수 있다.

$$y_t' = y_t - y_{t-1} \quad (7)$$

차분을 한 번 했는데도 정상성이 나타나지 않는 데이터는 식 (8)과 같이 2차 차분을 진행하는 경우도 있다.

$$\begin{aligned} y_t'' &= y_t' - y_{t-1}' \\ &= (y_t - y_{t-1}) - (y_{t-1} - y_{t-2}) \\ &= y_t - 2y_{t-1} + y_{t-2} \end{aligned} \quad (8)$$

전체 ARIMA 모델은 식(9)와 같이 쓸 수 있다.

$$y_t' = c + \phi_1 y_{t-1}' + \dots + \phi_p y_{t-p}' + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (9)$$

식 (9)에서 y_t' 는 차분을 구한 시계열이고 우변에는 y_t' 의 시차 값과 시차 오차 모두를 포함하고 있다. 이것을 ARIMA(p, d, q) 모델이라 한다. 여기서 p는 자기 회귀 부분의 차수이며 d는 사용된 차분의 차수이고 q는 이동 평균 부분의 차수이다.

배터리의 실제 사용에서 독립변수를 측정하기 어려운 경우, 종속변수의 시간적 변화만으로 예측이 가능한 ARIMA 모델은 유용하다고 할 수 있다.

성능을 측정할 때 RMSE나 MAE(Mean Absolute Error)등이 많이 사용된다. MAE는 예측의 정확도를 위해 많이 사용되는 방법으로 식 (10)과 같이 예측값과 실제값의 차이를 평균한 값이다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (10)$$

RMSE는 식 (11)과 같이 MAE를 제공하여 제곱근을 구하는 것으로, MAE에 비해 큰 잔차에 큰 패널티를 부과하는 방법이다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (11)$$

한두 개의 큰 잔차가 발생하는 경우 이것이 전체적인 예측모델의 신뢰성에 영향을 미치므로 큰 잔차에 패널티를 부과하는 RMSE를 사용하는 것이 좋다고 판단하였다[10-11].

본 논문에서는 배터리 사용자의 패턴 변화에 따른 SOH 변화를 잘 추정하는지에 대한 측정방법으로 Root Mean Square Error(RMSE)를 사용한다.

III. 실험용 배터리 데이터의 생성

본 연구에서는 미국 NASA에서 제공되는 총 6개의 리튬이온 배터리 데이터 세트 중에서 첫 번째 데이터 세트의 #5과 #6 배터리 데이터를 사용하였다.[12]

배터리 #5과 #6은 동종의 리튬이온 배터리 모델이며, 부하전류 2A, 실내 온도 24℃에서 CCCV(Constant Current Constant Voltage) 충전 방식으로 측정된 결과를 나타내고 있으며, 부하전류 2A 조건에서 배터리 #5의 최저 사용전압은 2.7V이고 배터리 #6의 최저 사용전압은 2.5V이다.

그림 2는 배터리 #5과 #6 충전 사이클에 대한 배터리의 용량변화를 나타낸다. x축은 충전 사이클의 횟수를 나타내고, y축은 배터리의 용량을 나타내며, 단위는 Ah로 나타내어, 충전된 전하량을 표시한다.

그림 2에서는 사이클의 횟수가 증가함에 따라 배터리의 용량이 점차 감소되는 것을 확인할 수 있으며, 1.4Ah 점선은 배터리의 용량의 한계를 나타내며 이보다 작아지는 경우 급격한 열화현상이 발생하여 계속 사용할 때 배터리의 화재 등이 발생할 수 있으므로, BMS(Battery Management System)는 배터리 사용의 중지를 사용자에게 통지해야 하고 배터리를 전체 시스템에서 분리해야 한다. 또한, 이 그림에서 서로 다른 기울기를 나타내고 있는데 이는 SOH가 다르게 변화하는 것을 보여준다.[13]

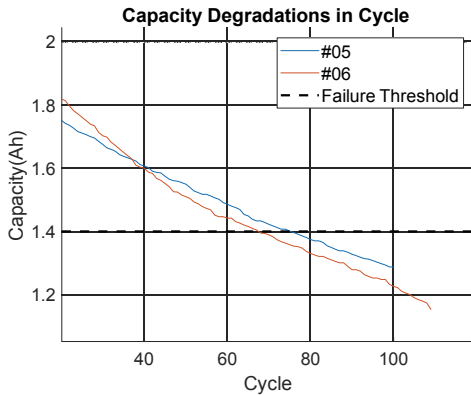



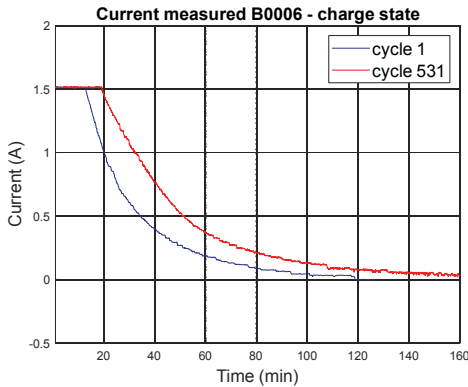
그림 2. 충전 사이클에 대한 용량저하
Fig. 2 Capacity degradation in cycle

그림 3의 (a)와 (b)는 배터리 용량 재상산을 포함한 배터리 #5와 #6의 데이터에서 충전 전류 변화에 따른 배터리의 충전 전류 변화를 나타낸다. x축은 시간 (분)을 나타내고, y축은 전류 [A]를 나타낸다. 충전 사이클의 횟수가 증가함에 따라 충전 시 정전류 1.5A 충전 동작이 멈추는 시간이 점차 늦어지며 이는 내부저항이 증가되고 SOH가 감소함을 보여준다.

배터리 용량을 예측할 때 방전, 즉 부하사용 시의 패턴은 매우 다양하여 지표로 사용하기 어렵다. 전기자동차의 경우 실생활에서 가속과 브레이크 페달을 밟는 정도와 빈도 및 주행거리에 따라 패턴이 매우 다양하기 때문이다.



(a)



(b)

그림 3. 배터리 #5와 #6의 패턴
Fig. 3 Patterns of Battery #5 and #6

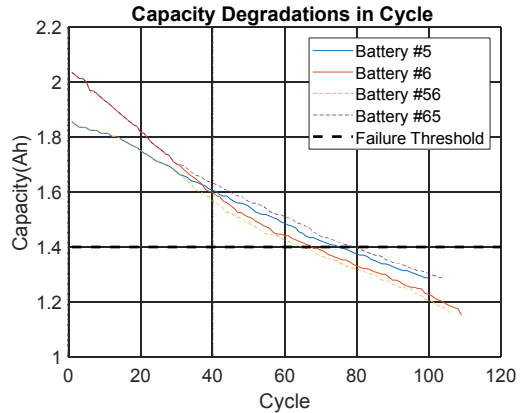


그림 4. 배터리 #5,#6,#56,#65의 패턴
Fig. 4 Patterns of Battery #5,#6,#56,#65

그림 4는 배터리 #5과 #6을 바탕으로 사용자 패턴이 변화된 배터리 #56과 배터리 #65 데이터를 나타낸다. 이 경우, 배터리 #56과 배터리 #65 데이터는 배터리의 사용자 패턴이 변화된 경우를 상정한다.

배터리 #56은 그림 2에서 1.7Ah를 기준으로 cycle의 앞부분은 배터리 #5에서 가져오고 cycle의 뒷부분은 배터리 #6에서 가져와 가공된 데이터를 나타낸다. 배터리 #65는 1.7Ah를 기준으로 cycle의 앞부분은 배터리 #6에서 뒷부분은 배터리 #5의 cycle #31부터 마지막 cycle까지 가져와 가공된 데이터를 나타낸다.

IV. 배터리 사용자 패턴에 따른 SOH 예측

표 1. 은 배터리 #5과 #6의 충전 시작점부터 정전류 충전이 끝나는 점까지의 시간 cCcEnd(sec)과 용량(Ah)과의 상관계수를 나타낸다. 이 값이 1에 근접하므로 선형회귀로 정전류 충전시간을 통해 용량을 예측할 수 있다[14].

표 1. 충전 시간과 용량의 상관계수
Table 1. Correlation value between ccEndTime and Capacity

Battery Number	Correlation Value
#5	0.89
#6	0.94

표 2. 는 사용자 패턴의 변화가 포함된 배터리 #5과 #6의 배터리 용량을 선형회귀 모델로 예측한 결과를 나타낸다.

표 2. 선형회귀 모델의 SOH 예측 결과
Table 2. SOH Prediction Result by Linear Regression Model

Model learned using battery #	Predicted Battery Number	RMSE from change point to end
#5	#56	0.0845
#6	#56	0.0231
#5 + #6	#56	0.0249
#5	#65	0.0276
#6	#65	0.0353
#5 + #6	#65	0.0235

여기서는 이미 학습된 모델에서 배터리 #5과 #6를 사용자 패턴이 변환 시점부터 마지막 사이클까지의 RMSE를 구하였다. 실험에서 사용된 학습된 모델의 종류는 배터리 #5로 학습한 모델, 배터리 #6으로 학습된 모델, 배터리 #5와 #6의 모든 변수를 합쳐서 학습한 모델이다.

실험 결과를 보면 새로 생성된 배터리 #5은 사용자 패턴이 변경된 시점부터의 RMSE를 비교하면 배

터리 #6으로 학습된 선형회귀 모델에서 0.0231을 나타내며, 새로 생성된 배터리 #65는 사용자 패턴이 변경된 시점부터 RMSE를 비교하면 배터리 #5로 학습된 선형회귀 모델에서 0.0276을 나타내었다.

선형회귀에서는 배터리 #5와 #6을 각각 학습시키고 배터리 #65과 #56에서 사용자 패턴이 변환한 시점 이후부터 예측하면 RMSE 값이 각각 0.0231과 0.0276을 보이며 비교적 잘 예측된 SOH 값을 보였다.

중요한 점은 배터리 #5과 #65에 대해 모두 성능이 좋은 것은 배터리 #5와 #6을 합쳐서 학습한 선형회귀 모델로 각 RMSE는 배터리 #56에 대해 0.0249로 배터리 #6으로 학습된 모델보다 성능이 좋다. 배터리 #65에 대해서는 RMSE 값이 0.0235로 배터리 #5로 학습된 모델보다 성능이 좋다.

선형회귀모델에서는 더 많은 변수로 학습할 경우 사용자 패턴에 따른 용량의 변화를 더욱더 예측이 정확해짐을 알 수 있다.

그림 5의 (a)는 배터리 #56을 사용자 패턴이 변경된 시점부터 학습된 ARIMA 모델로 예측한 결과인데 observed는 측정된 데이터, predicted by model using #5는 배터리 #56의 용량을 배터리 #5의 ARIMA(1, 1, 3) 모델로 예측한 데이터, predicted by model using #6은 배터리 #56의 용량을 배터리 #6의 ARIMA(3, 1, 2) 모델로 예측한 데이터이다. 그림 5의 (b)는 위와 동일하게 배터리 #65에 대한 실험값 및 배터리 #5와 #6으로 학습한 모델에서 예측한 값이다.

ARIMA 모델은 장기간 축적된 시계열의 종속변수가 존재하고, 미래의 독립변수를 알지 못할 때 적용할 수 있다. 배터리 사용자의 사용자 패턴이 변화되면 배터리의 전압, 전류 및 온도도 변화하는데, 이와 같은 독립변수가 주어지지 않을 때, 종속변수인 SOH를 예측할 수 있는 장점이 있다.

ARIMA 모델은 시계열분석의 대표적인 모델로, 기존 ARMA 모델에 차분을 추가해서 비정상적인 데이터에 대한 시계열분석을 가능하게 한 모델이다.

ARIMA 모델에서 주요한 인자는 p, d, q로 ARIMA(p, d, q)로 기술하며 이는 d차 차분한 데이터 위에 AR(p) 모형과 MA(q) 모형을 합친 모형이다.

여기서 사용한 배터리 데이터 #5와 #6에서는 1차 차분한 후의 데이터를 ACF(AutoCorrelation Function) 및 PACF(Partial AutoCorrelation Function)를 통해 검증하여 정상성이 있음을 확인하였다. ARIMA 모델에서 p 값과 q 값을 선정하기 위해 0부터 3까지의 값 중에 최소의 BIC(Bayes Information criterion)를 갖는 값으로 p와 q 값을 선정하였고 선정된 값들은 표 3. 과 같다.

표 3. ARIMA 모델의 p,d,q,BIC 값
Table 3. p,d,q,BIC values of ARIMA model

Battery #	p	d	q	BIC
#5	1	1	3	-841.4085
#6	3	1	2	-857.3249


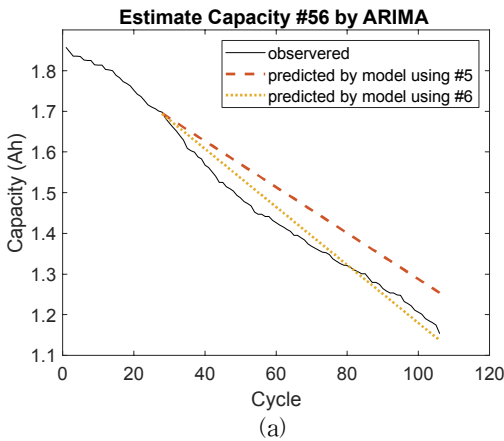


그림 5. ARIMA 모델의 사용자 패턴 변화 후 SOH 예측 결과

Fig. 5 User Pattern Changed SOH Prediction by ARIMA model

표 4. 는 사용자 패턴의 변화가 포함된 배터리 #56과 #65의 배터리 용량을 ARIMA 모델로 예측한 결과이다. 배터리 #5와 #6의 ARIMA 모델만이 존재한다고 할 때 표 4. 와 같이 RMSE 결과를 보면 배터리 #56은 사용자 패턴이 #6으로 변경된 것이므로 배터리 #6으로 학습된 모델이 변화된 사용자 패턴을 잘 예측하였으나, 배터리 #65는 사용자 패턴이 #5로 변경된 것이므로 배터리 #5로 학습한 모델이 변화된 사용자 패턴을 잘 예측하였다고 볼 수 있다.

표 4. ARIMA 모델의 SOH 예측결과
Table 4. SOH Prediction Result by ARIMA Model

Model learned using battery #	Predicted Battery Number	RMSE from change point to end
#5	#56	0.0767
#6	#56	0.0309
#5	#65	0.0203
#6	#65	0.0501

V. 결론

선형회귀에서는 배터리 #5와 #6의 데이터를 합쳐서 학습한 모델로 배터리 #56과 #65를 예측할 때, RMSE 값이 0.0249와 0.0235를 보이며, 개별적으로 학습한 모델보다는 전체적으로 좋은 예측결과를 보였다. 이는 선형회귀가 독립변수에 따른 종속변수 SOH를 예측하는데 데이터가 많으면 많을수록 정확한 예측이 가능함을 보여주며 다양한 배터리의 데이터를 학습한 경우 더 정확한 예측이 가능함을 나타낸다.

ARIMA 모델에서는 배터리 #5로 학습한 모델로 배터리 #56을 예측한 경우, 사용자 패턴이 변화한 시점부터의 배터리 #6과 비슷한 값을 가지는 데이터를 예측해야 하므로 RMSE 값이 0.0767로 예측 정확도가 떨어졌으며, 이는 배터리 #6으로 학습한 모델로 배터리 #65를 예측한 경우도 마찬가지이며 이때 RMSE가 0.0501로 예측의 정확도가 떨어졌다.

따라서 변화된 사용자 패턴에 따른 변경된 수명을 바로 전기자동차의 계기판에 표시하고자 할 때 배터리 데이터가 많이 확보된 경우에는 선형회귀가 유용하고, 배터리의 데이터가 많이 확보되지 않은 경우 ARIMA 모델이 대안이 될 수 있다는 결론을 얻을 수 있었다.

본 연구 결과는 전기자동차의 계기판에 사용자 운전 패턴 변화 혹은 배터리 사용자 변화에 대해 배터리의 기대수명을 표시하는 실용화 연구에 기여할 것으로 기대한다.

감사의 글

이 연구는 서울과학기술대학교 교내 일반 과제 연구비 지원으로 수행되었습니다.

References

- [1] J. Joo, Y. Lee, K. Park, and J. Oh, "ESS optimization and stable operation for battery level calculation and failure prediction algorithm," *Journal of the Korea Institute of Electronic Communication Sciences*, vol. 15, no. 1, 2020, pp. 71-78.
- [2] S. Park and J. Lee, "Design of Smart Off-Board Charge System for Neighborhood Electric Vehicle," *Journal of the Korea Institute of Electronic Communication Sciences*, vol. 8, no. 10, 2013, pp. 1499-1504.
- [3] P. Lee, S. Kwon, D. Kang, S. Han, and J. Kim, "SOH Estimation and Feature Extraction using Principal Component Analysis based on Health Indicator for High Energy Battery Pack," *The Korean Institute of Power Electronics*, vol. 25, no. 5, Oct. 2020, pp. 376-384.
- [4] S. Kim, J. Park, and J. Kim, "Prediction Algorithm for Lithium Ion Battery SOH Based on ARIMA Model," *Proceedings of the KIPE Conference, Yesan, Korea, July 2019*, pp. 56-58.
- [5] D. Andre, C. Appel, T. Soczka-Guth, and D. U. Sauer, "Advanced mathematical methods of SOC and SOH estimation for lithium-ion batteries," *Journal of power sources*, vol. 224, Feb 2013, pp. 20-27.
- [6] H. Go, S. Lee, and E. Kim, "LSTM Model-Based SOH Prediction for Lithium-Ion Battery," *Digital Contents Society*, vol. 22, no. 4, Apr. 2021, pp. 697-703.
- [7] S. Kwon, D. Han, S. Park, and J. Kim, "Long Short Term Memory-Based State-of-Health Prediction Algorithm of a Rechargeable Lithium-Ion Battery for Electric Vehicle," *The Trans. of the Korean Institute of Electrical Engineers(KIEE)*, vol. 68, no. 10, pp. 1214-1221.
- [8] K. M. Adib, C. Angela, and W. Lim, N. J. Nkechinyere, "SOH and RUL Prediction of Lithium-Ion Batteries Based on LSTM with Ensemble Health Indicators," *KICS Summer Conference 2020 Proceedings, Pyeongchang, Korea*, vol. 72, Aug. 2020, pp. 317-318.
- [9] B. Kim and J. Kim, "An Optimal Design Method of a Linear Generator for Conversion of Wave Energy," *Journal of the Korea Institute of Electronic Communication Sciences*, vol. 16, no. 6, Dec. 2021, pp. 1195-1204.
- [10] J. Choi, "Performance Comparison of Machine Learning in the Prediction for Amount of Power Market," *Journal of the Korea Institute of Electronic Communication Sciences*, vol. 14, no. 5, 2019, pp. 943-950.
- [11] G. Bak and C. Bae, "Performance Comparison of Machine Learning in the Various Kind of Prediction," *Journal of the Korea Institute of Electronic Communication Sciences*, vol.14, no.1, 2019, pp. 169-178.
- [12] K. Goebel, B. Saha, and A. Saxena, "Prognostics in battery health management," *IEEE Trans. Instrum. Meas.*, vol. 11, no. 4, Nov. 2008, pp. 33 - 40.
- [13] T. Qin, S. Zeng, J. Guo, and Z. Skaf, "A rest time-based prognostic framework for state of health estimation of lithium-ion batteries with regeneration phenomena," *Energies*, vol. 9 no. 11, 2016, pp. 896.

- [14] S. Kang, T. Noh, and B. Lee, "Machine Learning-based SOH Estimation Algorithm Using a Linear Regression Analysis," *The Trans. of the Korean Institute of Power Electronics*, vol. 26, no. 4, 2021, pp. 241-248.

저자 소개



박종용(Jong-Yong Park)

2000년 한국기술교육대학교 전자공학과 졸업(공학사)
2009년 한양대학교 공학대학원 컴퓨터학과 졸업(공학석사)

2015년 ~현재 서울과학기술대학교 나노IT디자인 융합대학원 박사과정
※ 관심분야 : 통신시스템, 임베디드 시스템 설계, 인공지능, 로봇, 농업-IT 융합



유민혁(Min-Hyeok Yoo)

2019년 서강대학교 수학과 졸업(이학사)
2021년 ~현재 서울과학기술대학교 대학원 석박사통합과정 재학

※ 관심분야 : AI용 아날로그 회로설계



노태민(Tae-Min Nho)

2020년 서울과학기술대학교 전자IT미디어공학과 졸업(공학사)
2020년 ~현재 서울과학기술대학교 대학원 미디어IT공학과 석사과정 재학

※ 관심분야 : AI용 아날로그 회로설계



신대건(Dae-Kyeon Shin)

2021년 한국산업기술대학교 컴퓨터융합공학과 졸업(공학사)
2021년 ~현재 서울과학기술대학교 대학원 석박사통합과정 재학

※ 관심분야 : 아날로그 회로 설계



김성권(Seong-Kweon Kim)

2002년 일본 TOHOKU대학 대학원 전자공학과(공학박사)
2002~2004년 일본 TOHOKU대학 Assistant Professor & Research Fellow

2004~2009년 목포해양대학교 해양전자통신공학부 조교수

2009년 ~현재 서울과학기술대학교 전자IT미디어 공학과 교수

※ 관심분야 : 아날로그 회로 및 시스템

