

# PNP 모델을 이용한 리튬이온 배터리 잔존 수명 예측

이정구\* · 박귀만\*\* · 이은서\*\* · 진병진\*\*\* · 배영철\*\*\*\*

## Remaining Useful Life of Lithium-Ion Battery Prediction Using the PNP Model

Jeong-Gu Lee\* · Gwi-Man Bak\*\* · Eun-Seo Lee\*\* · Byung-jin Jin\*\*\* · Young-Chul Bae\*\*\*\*

### 요약

본 논문은 초기 리튬이온 배터리의 충·방전 데이터를 활용하여 리튬이온 배터리의 잔존 수명을 예측할 수 있는 딥러닝 모델을 제시한다. PNP(Positive and Negative Perceptron) 모델을 사용하여 DMP(Deep learning Model using PNP model)를 구축하였으며, DMP의 성능을 증명하기 위해 LSTM 모델을 사용하여 DML(Deep learning Model using LSTM model)을 구성하였다. DMP와 DML의 리튬이온 배터리의 잔존 수명 예측 성능을 비교하며, 오차 측정 방법은 RMSE(Root Mean Square Error)와 RMSPE(Root Mean Square Percentage Error)이다. 시험 데이터로 오차를 측정된 결과 DMP와 DML의 RMSE 차이는 144.62[Cycle]이며, RMSPE 차이는 3.37[%]로 DMP의 오차가 낮게 측정되었다. 이를 통해 우리는 DMP의 성능이 높은 것으로 증명하였으며, 이는 리튬이온 배터리 분야에서 PNP 모델이 LSTM 모델보다 성능이 뛰어남을 나타내었다.

### ABSTRACT

In this paper, we propose a deep learning model that utilizes charge/discharge data from initial lithium-ion batteries to predict the remaining useful life of lithium-ion batteries. We build the DMP using the PNP model. To demonstrate the performance of DMP, we organize DML using the LSTM model and compare the remaining useful life prediction performance of lithium-ion batteries between DMP and DML. We utilize the RMSE and RMSPE error measurement methods to evaluate the performance of DMP and DML models using test data. The results reveal that the RMSE difference between DMP and DML is 144.62 [Cycle], and the RMSPE difference is 3.37 [%]. These results indicate that the DMP model has a lower error rate than DML. Based on the results of our analysis, we have showcased the superior performance of DMP over DML. This demonstrates that in the field of lithium-ion batteries, the PNP model outperforms the LSTM model.

### 키워드

PNP, LSTM, RUL, Prediction, Lithium-ions Battery  
긍정&부정 퍼셉트론, 장단기 메모리, 잔존 수명, 예측, 리튬이온 배터리

\*한국과학기술정보연구원 (jglee@kisti.re.kr)

\*\*전남대학교 전기 및 반도체공학과  
(qkrrend@naver.com, ciel0678@naver.com)

\*\*\*온테스트 (bjjin@on-test.co.kr)

\*\*\*\*교신저자 : 전남대학교 전기컴퓨터공학부

• 접수일 : 2023. 10. 23  
• 수정완료일 : 2023. 11. 17  
• 게재확정일 : 2023. 12. 27

• Received : Oct. 23, 2023, Revised : Nov. 17, 2023, Accepted : Dec. 27, 2023

• Corresponding Author : Young-Chul Bae  
Division of Electrical and Computer Eng. Chonnam National University,  
Email : ycbae@chonnam.ac.kr

## I. 서론

리튬이온 배터리는 전기 자동차 및 신재생에너지 시스템 및 스마트 그리드 분야에서 널리 사용되고 있다[1]. 특히 리튬이온 배터리는 핸드폰, 노트북 전기 자동차와 같은 모바일 환경에서의 이동수단에 많이 적용되고 있다[2-3]. 일반적으로 리튬이온 배터리의 용량이 초깃값의 80%로 저하되면 배터리의 안전성을 담보하기 어려워지며, 빈번하게 충전해야 하는 문제로 인한 사용자의 편리성이 저하되어 경제성이 떨어지므로 교체해 주는 것이 바람직하다. 리튬이온 배터리의 교체를 위해서는 리튬이온 배터리의 잔존 수명을 정확하고 효과적으로 예측하여 사용자가 배터리 사용을 최적화 할 수 있는 방법을 제공해야 한다. 인공지능 분야에서 리튬이온 배터리의 잔존 수명 예측 연구가 진행되고 있으며 특히, 딥러닝으로 리튬이온 배터리의 초기 운영 데이터를 이용하여 잔존 수명을 예측하는 연구가 최근 몇 년 동안 인기를 얻고 있으며, 주로 LSTM과 CNN(: Convolution Neural Network) 등의 방식이 있다[4-8]. PNP 모델은 유량을 초점으로 물의 순환계를 고려하여 개발된 모델이며 LSTM 모델보다 정확한 성능을 가지고 있다[9]. 본 논문은 리튬이온 배터리의 관점에서 PNP 모델을 적용하여 리튬이온 배터리의 수명을 예측할 수 있는 DMP를 제시한다. 제시한 모델의 성능을 증명하기 위해 시계열 예측에서 가장 많이 사용되는 LSTM 모델을 사용한 DML의 예측 성능을 비교하여 DMP의 우수성을 나타낸다.

## II. PNP 모델

PNP 모델은 딥러닝 모델이며, 유량을 초점으로 물의 순환계를 고려하여 개발된 모델이다. 딥러닝 모델에서 PNP 모델은 은닉층의 노드로 구성된다. 그림 1은 딥러닝 모델에서의 노드를 보여준다.

PNP 모델은 Positive 뉴런과 Negative 뉴런으로 이루어져 있으며, 이들은 하천의 주위의 환경 변수를 고려한 수문, 토양 및 기상학적인 요인의 복합적인 상호작용을 반영한다. Positive 노드는 강수가 발생하여 댐이 갖고 있는 유량의 증가를 계산하고, Negative 노드는 강수가 발생하지 않아 댐의 방류 등을 통해 감소된 유량을 계산한다.




그림 1. 딥러닝 모델에서의 노드  
Fig. 1 Node of Deep-learning model

리튬이온 배터리의 관점에서, PNP 알고리즘의 이론은 강수가 발생하여 유량이 증가할 때 리튬이온 배터리를 충전 상태, 강수가 발생하지 않아 댐의 유량을 방류할 때 리튬이온 배터리를 방전 상태로 치환하면 이론이 적합하다. 그림 2는 PNP 알고리즘의 구성도이다. PNP 알고리즘에는 Conveyor belt가 있으며 이는 Positive 뉴런과 Negative 뉴런 사이에 연결되어 있는 선이다. Conveyor belt는 각 뉴런의 결과값을 다음 뉴런으로 전달하며 이를 통해 과거 데이터를 전달한다.




그림 2. PNP의 구성도  
Fig. 2 Configuration of PNP

PNP 모델의 입력 데이터는 3차원으로 입력되며 LSTM 알고리즘과 유사하다. PNP 모델 입력 데이터의 차원은 'Date number, Variable, Time step'으로 구성된다. 'Date number'는 데이터의 개수를 나타내며, 'Variable'은 변수의 개수를 나타내며, 'Time step'는 사용되는 과거 데이터 수를 나타낸다. 그림 3은 Positive 뉴런을 나타내고 그림 4는 Negative 뉴런을 나타낸다.




그림 3. Positive 뉴런  
Fig. 3 Positive neuron




그림 4. Negative 뉴런  
Fig. 4 Negative neuron

### III. 리튬이온 배터리 충·방전 데이터

우리는 Severson가 온라인으로 제공하는 리튬이온 배터리 충·방전 데이터셋을 사용하였다[10]. 데이터셋은 124개의 LFP/graphite A123APR18650M1A 셀을 사용하였다. 리튬이온 셀은 공칭용량이 1.1Ah이고, 공칭전압은 3.3V이다. 124 개의 배터리셀 중 이상이 있는 배터리셀 6개를 제외하고 118개의 배터리셀 데이터를 사용하였다. 리튬이온 배터리셀은 다양한 고속충전 시나리오로 충·방전하여 배터리의 용량이 80% 미만으로 저하될 때까지 충·방전을 진행한다. 리튬이온 배터리 충·방전 데이터셋은 전압 및 전류, 온도가 10 초 단위로 수집 되었으며 배터리의 수명은 배터리의 용량이 80% 미만으로 저하될 때의 Cycle로 정의하였다. 본 연구의 DMP, DML은 배터리의 초기 충·방전 데이터(전압, 전류, 온도)를 활용하여 리튬이온 배터리의 잔류수명을 예측한다.

DMP와 DML의 입력데이터는 전압, 전류, 온도 데이터를 1개의 데이터셋으로 합치지 않고 입력하였으며 [리튬이온 배터리, Cycle, time]으로 구성하여 입력하였다. DMP와 DML의 과적합, 안전성 등을 위해 표준화를 적용하였다. 식(1)은 표준화를 나타낸다.




그림 5. 리튬이온 배터리의 충·방전 데이터  
Fig. 5 Charge and discharge data of Lithium-ions battery

$$\text{Standardization} = \frac{x - \bar{x}}{\rho} \quad \dots (1)$$

여기서  $x$ 는 데이터,  $\bar{x}$ 는 데이터의 평균,  $\rho$ 는 데이터의 표준편차이다. 그림 5는 리튬이온 배터리의 충·방전 데이터를 나타낸다.

116개의 리튬이온 배터리 데이터는 학습 데이터와 시험 데이터로 나뉜다. 학습 데이터는 전체 데이터의 70%를 사용하였고 시험 데이터는 전체 데이터의 30%를 사용하였다. 특정 리튬이온 배터리의 충·방전 방식이 학습 데이터에 몰리는 것을 방지하기 위해 데이터셋을 랜덤하게 셔플하여 학습, 시험 데이터로 분리하였다. 학습 데이터는 모델을 학습할 때 사용하며 시험 데이터는 모델의 성능을 평가할 때 사용한다.

### IV. 딥러닝 모델 구성 및 학습

DMP와 DML의 공평한 성능 측정을 위해 은닉층의 개수와 은닉층의 노드의 개수, 학습횟수 등을 동일하게 구성하였다. 은닉층의 개수는 3개로 구성하였으며, 은닉층 노드의 개수는 50개이다. 학습 횟수는 2,000회로 설정하였으며, 최적화 함수는 Adam을 사용하였고 오차 함수는 MSE(Mean Square Error)를 사용하였다. 표 1은 DMP와 DML의 하이퍼파라미터를 나타낸다. DMP의 입력 데이터는 3개(전압, 전류, 온도)이며, 입력 노드는 3개로 구성되어 있다. 전압, 전류, 온도의 입력층은 PNP 모델로 이루어진 은닉층으로 연결되어 있다. 두 번째 은닉층은 입력층에 의해 구분된 은닉층들이 하나의 은닉층으로 합쳐지며 FNN(Feed forward Neural Network)로 구성된 은닉층으로 연결된다. 마지막 층은 출력층으로 최종적으로 계산할 리튬이온 배터리의 RUL(Remaining Useful Life)를 출력한다. 그림 6은 DMP의 구조를 나타낸다.

표 1. DMP와 DML의 하이퍼파라미터

Table 1. Hyper-parameters of DMP and DML

Hyper parameter	DMP	DML
Number of Hidden layer	3	3
Number of node in one hidden layer	50	50
Epochs	2,000	2,000
Optimizer function	Adam	Adam
Error function	MSE	MSE




그림 6. DMP의 구조  
Fig. 6 Structure of DMP




그림 7. DML의 구조  
Fig. 7 Structure of DML

그림 6의 흰색 원은 노드를 나타내며 입력층의 노드와 출력층의 노드를 나타낸다. 은닉층에는 PNP 모델과 FNN 모델로 구성된다. DML의 구조는 DMP와 거의 동일하다. 두 모델의 차이점은 PNP 모델이 구성된 위치를 대신해 LSTM 모델이 구성한다. 그림 7은 DML 모델의 구조를 나타낸다. 그림 8은 DMP와 DML의 학습 횟수에 따른 오차 그래프를 나타낸다. DMP의 오차 그래프는 학습 횟수가 증가할수록 감소하는 추세를 보이지만 잡음이 심한 것을 볼 수가 있다. 반면에 DML은 DMP에 비해 잡음이 없으며 오차가 급격하게 떨어지는 것을 볼 수 있다.




그림 8. DML의 구조  
Fig. 8 Structure of DML

### V. 예측 결과 및 분석

우리는 학습한 DMP와 DML을 시험 데이터에 적용하여 성능을 평가하였다. 성능 평가 방법은 RMSE와 RMSPE를 사용하였다. 식(2)와 식(3)은 RMSE와 RMSPE를 각각 나타낸다.

$$RMSE = \sqrt{\frac{1}{n} \sum (A_t - F_t)^2} \quad \dots (2)$$

$$RMSPE = \sqrt{\frac{1}{n} \sum \left( \frac{A_t - F_t}{F_t} \right)^2} \times 100 \quad \dots (3)$$

여기서  $A_t$ 는 예측값으로 모델이 계산한 값을 나타낸다.  $F_t$ 는 관측값으로 실제 측정된 값을 나타낸다.  $n$ 은 관측값의 개수를 의미한다.

표 2. DMP와 DML의 오차  
Table 2. Errors of DMP and DML

Error function	Data	DMP	DML
RMSE (Cycle)	Train	34.91	8.58
	Test	144.62	160.21
RMSPE (%)	Train	5.00	1.19
	Test	18.17	21.54

학습된 딥러닝 모델을 학습 데이터와 시험 데이터를 입력하여 리튬이온 배터리의 RUL의 오차를 측정하였다. 학습 데이터로 예측하였을 때, DMP 모델의 오차가 RMSE는 34.91[Cycle]로 DML 보다 26.33[Cycle] 높게 나왔다. RMSPE는 5.00[%]로 DML 보다 3.81[%] 높게 나왔다. 시험 데이터로 예측하였을 때, DMP 모델의 오차가 DML 보다 낮게 나왔으며, RMSE는 144.62[Cycle], RMSPE는 18.17[%]로 측정되었다. DML과 비교하였을 때, RMSE는 15.59[Cycle], RMSPE는 3.37[%] 만큼 낮게 측정되었다. 그림 9는 시험 데이터의 예측 결과 그래프이다. X축은 관측값으로 리튬이온 배터리의 실제 RUL이며 Y축은 예측값으로 딥러닝 모델의 출력값을 나타낸다. 그래프의 파란색 원이 빨간색 직선에 가까워야 정확도가 높다.




그림 9. DMP와 DML의 결과  
Fig. 9 Results of DMP and DML

## VI. 결론

본 논문은 PNP 모델을 사용하여 이차전지의 수명을 예측할 수 있는 DMP를 제시하였다. 제시한 DMP의 우수성을 증명하기 위해 DML을 구성하여 초기 리튬이온 배터리의 충·방전 데이터를 이용하여 RUL을 예측하였다. 초기 리튬이온 배터리의 충·방전 데이터는 배터리의 전압, 전류, 온도로 구성하였다. DML과 DML의 공평한 성능 측정을 위해 하이퍼파라미터를 동일하게 구성하였다. 학습 데이터로 예측하였

을 때, DMP의 오차가 DML보다 높게 나왔지만, 시험 데이터로 예측하였을 때, DML의 오차가 DMP보다 높게 나왔다. 이는 DML의 과적합으로 학습하여 예측 성능이 낮아진 것으로 판단된다. 이를 통해 우리는 DMP의 성능이 높은 것으로 증명하였으며, 이는 리튬이온 배터리 분야에서 PNP 모델이 LSTM 모델보다 성능이 뛰어난을 확인하였다.

## 감사의 글

본 논문은 KISTI의 자율도전 연구과제로 수행한 결과이며, 본 과제(결과물)는 2023년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다.(2021RIS-002)

## References

- [1] J. Joo, Y. Lee, K. Park, and J. Oh, "Battery Level Calculation and Failure Prediction Algorithm for ESS Optimization and Stable Operation," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 15, no. 1, 2020, pp. 71-78.
- [2] J. Park, M. Yoo, T. Nho, D. Shin, and S. Kim, "A study of Battery User Pattern Change tracking method using Linear Regression and ARIMA Model," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 17, no. 3, 2022, pp. 423-432.
- [3] G. Bak and Y. Bae, "Performance comparison of machine learning in the various kind of prediction," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 14, no. 1, 2019, pp. 169-178.
- [4] J. Kim, Y. Ju, and E. Kim, "Development of controllers and battery management systems(BMS) for underwater drones equipped with multi-channel BLDC motors," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 18, no. 3, 2023, pp. 405-411.
- [5] R. Schmuch, R. Wagner, G. Hörpel, T. Placke, and M. Winter, "Performance and cost of materials for lithium-based

rechargeable automotive batteries," *Nature Energy*, vol. 3, no. 4, 2018, pp. 267-278.

[6] J. Park, J. Kim, C. Kim, Y. Park, and G. Kim, "Prediction of battery remaining life based on sliding window-LSTM for camouflage therapeutic system," *J. of Korean Institute Of Information Technology*, vol. 21, no. 1, 2023, pp. 29-38.

[7] J. Lim, D. Kim, T. Noh, and B. Lee, "Remaining useful life prediction for lithium-ion batteries using EMD-CNN-LSTM hybrid method," *The Transactions of the Korean Institute of Power Electronics*, vol. 27, no. 1, 2022, pp. 48-55.

[8] J. Kim and J. Lee, "Application of regularized linear regression models using public domain data for cycle life prediction of commercial lithium-ion batteries," *The Transactions of the Korean Hydrogen and New Energy Society*, vol. 32, no. 6, 2021, pp. 592~611.

[9] G. Bak and Y. Bae, "Deep learning algorithm development for river flow prediction: PNP algorithm," *Soft Computing*, 2023, pp. 1-29.

[10] K. Severson, M. Attia, N. Jin, N. Perkins, B. Jiang, Z. Yang, M. Chen, M. Aykol, P. Herring, D. Fraggadakis, M. Bazant, S. Harris, and W. Chueh, "Data-driven prediction of battery cycle life before capacity degradation," *Nature Energy*, vol. 4, no. 5, 2019, pp. 383-391.

저자 소개



**이정구(Jeong-Gu Lee)**

1989년 충북대학교 전기 공학과 졸업(공학사)  
 1991년 충북대학교 대학원 전기 공학과 졸업(공학석사)

2008년 충북대학교 대학원 전기공학과 졸업(공학박사)  
 1991년~2000년 산업기술정보원 책임연구원  
 2001년~한국과학기술정보연구원 책임연구원  
 ※ 관심분야 : Data Analysis, Display, Battery, New Renewable Energy etc.



**박귀만(Gwi-Man Bak)**

2019년: 전남대학교 전기 및 반도체공학과 졸업(공학사)  
 2021년: 전남대학교대학원 전기 및 반도체 공학과 졸업 (공학석사)  
 2021년~ 현재 : 전남대학교대학원 전기 및 반도체 공학 박사과정

※ 관심분야 : Artificial intelligence



**이은서(Eun-Seo Lee)**

2017년: 배재대학교 스페인중남미학과 졸업(학사)  
 2021년~2022년: 전남대학교 시뮬레이션센터 연구원  
 2023년~현재: 전남대학교대학원 전기 및 반도체 공학과 석·박통합과정

※ 관심분야 : Artificial intelligence



**진병진(Byung-Jin Jin)**

1988년 경상대학교 기계공학과 졸업(공학사)  
 1998년 경상대학교 대학원 항공기 계공학부 졸업(공학석사)  
 2008~ (주)온테스트 대표이사

※ 관심분야 : Battery test, SOH, SOC



**배영철(Young-Chul Bae)**

1984년 광운대학교 전기공학과 졸업 (공학사)  
 1986년 광운대학교대학원 전기공학과 졸업 (공학석사)

1997년 광운대학교대학원 전기공학과(공학박사)  
 1986년~1991년 한국전력공사  
 1991년~1997년 산업기술정보원 책임연구원  
 1997년~현재 전남대학교 전기·전자통신·컴퓨터공학부 교수  
 2002년~2002년 Brigham Young University 방문 교수  
 2011년~2011년 University of Utah 방문교수  
 ※ 관심분야 : Chaos Control and Chaos Robot, Robot control etc.