

## Gaussian Process Regression을 이용한 배터리 수명예측에 관한 연구

황건하, 신경섭

상명대학교

cromany@naver.com, ksshin@smu.ac.kr

## Battery Life Prediction using Gaussian Process Regression

Hwang Guon Ha, Shin Kyung Seop

Sangmyung University

## 요 약

최근 수요가 급증하고 전기차의 에너지 저장장치와 재충전이 가능한 2차 전지(Secondary Cell)로 각광받고 있는 리튬 이온 배터리에 대하여 신뢰성의 필요가 대두되면서, 배터리 수명을 예측하기 위한 기법이 활발히 개발되고 있다. 본 논문에서는 battery management system으로부터 추정된 충,방전 cycle 별 discharge capacity를 입력으로 하여 확률적인 머신러닝 기법으로 Gaussian Process Regression을 사용한다. 실험에 사용된 dataset은 실제 배터리 제조과정과 동일한 배터리의 정량적 데이터를 이용하였다. 이를 통해 GPR 모델에 학습하는 데이터양에 따른 예측 성능을 비교 분석한 결과 GPR 모델 학습에 사용된 배터리 정보가 누적될수록 예측의 성능이 증가하는 경향성을 보임을 확인하였다.

## I. 서론

리튬 이온 배터리는 다양한 시스템의 핵심 구성 요소로 리튬이온 배터리의 신뢰성은 전자 산업계의 큰 관심 대상이다. 그 중 대표적인 리튬이온 배터리의 적용대상은 전기차로 국토교통부에 따르면 2021년 7월 기준 등록된 친환경 자동차가 100만대 중 전기차는 18만대로 약 18%를 차지한다. [1] 이렇듯 리튬 배터리가 자동차에 사용되면서 안정성 관련한 문제와 함께 다양한 환경에서의 배터리 수명 예측의 필요성이 대두되고 있다.

일반적으로 사용 중 배터리의 신뢰성 추정에는 State of Charge (SOC) 와 State of Health (SOH)라는 두 가지 상태 지표가 사용된다. 현재 연구 주제로 주목을 받고 있는 SOC 추정 방법에 대한 연구에 비해 SOH 추정 및 예측에 대한 연구는 아직 초기 단계에 있다. 리튬 이온 배터리에 대한 수요가 증가함에 따라 SOH 추정은 배터리가 시스템에 에너지를 저장하고 전달하는 정성적 측정으로서 배터리 예측에서 중요한 역할을 한다. SOH의 예측은 성능 저하를 나타내어 열폭주와 같은 사고를 예방할 수 있기 때문에 SOH 추정을 위한 배터리 상태 예측 알고리즘 개발에 대한 더 많은 연구가 필요하다.

자동차 배터리의 SOC 및 SOH의 실시간 예측을 위해 배터리 상태 센서 데이터에서 파생된 특징 벡터를 융합하여 SOC, SOH 및 수명 상태(SOL), 회귀, 신경망, 퍼지 논리 및 분산 확률 학습의 조합과 같은 접근 방식으로 배터리의 잔여 유효 수명(RUL)을 예측하는 데 사용되었다. 그러나 이러한 예측 방법들의 공통적인 단점은 예측을 위한 불확실성 표현 및 관리가 부족하다는 것이다. 산업 응용 분야에서 모델 및 데이터의 불확실성으로 인해 신뢰성 예측의 성능이 저하될 수 있다. 이 문제를 해결하기 위해 예측 모델로 Gaussian Process Regression(GPR)을 사용한다. [2] GPR 모델은 물리적 모델이 없는 경우에도 불확실성 표현을 제공하고 정확한 예측을 용이하게 하는 유연성과 능력 때문에 특히 유용하다. GPR 모델을 사

용하여 각 충방전 사이클에 따라 배터리의 내부 매개변수에 대한 regression을 수행하고 예측 값을 사이클에 따른 용량 감소로 나타낸다.

본 논문에서 사용된 Dataset은 [3] Michigan Battery Laboratory 대학에서 제작한 별도의 Stress Factor 적용이 없는 10개의 프리즘형 리튬 이온 파우치 전지로 셀의 공칭 용량은 2.36Ah이며 NCM111의 음극과 흑연으로 이루어진 양극으로 구성되어있다. 이를 이용하여 본 논문에서는 각 GPR 모델이 학습한 배터리의 개수에 따른 Discharge Capacity의 변화 예측의 정확도를 비교 분석하려 한다.

## II. 본론

일반적인 머신러닝 기법에서의 classification이나 regression과 같은 supervised learning은 parametric 모델을 통해 해결되고 있다. 여기서 말하는 parametric 모델은 모델 학습 동안 training data의 정보를 모델과 그 모델의 파라미터를 통해 표현하는 방법을 의미한다. 이러한 모델들은 설명 가능하다는 장점을 가지나 복잡한 데이터 셋에서는 제대로 작동하기 힘든 단점이 있다. 이러한 단점을 개선하기 위하여 본 논문에서는 GP (Gaussian Process)와 같은 kernel 기반 모델이 등장하게 되었다.

GP는 non-parametric Bayesian approach Regression 문제로서 이론적으로 무한한 크기의 매개변수를 활용하고 Bayesian 추론을 통해 데이터가 복잡성 수준을 결정하도록 함으로써 입력과 출력 사이의 다양한 관계를 도출할 수 있는 장점이 있다. GP에 대하여 구체적으로 표현을 하면 임의의 집합 S가 있을 때, GP는 S에 대하여 jointly gaussian distribution을 따르는 random variable set을 의미한다. 일반적인 Gaussian distribution과 비교한다면 Gaussian distribution은 평균과 분산에 특정 값이 들어가 있는 반면 GP는 평균과 분산에 함수의 형태가 들어간 것을 알 수 있다. 이를 수식으로 표현하면 다음과 같다.

$$P(m, k)$$

$$m(x) = \frac{1}{2}x, \quad k(x, x') = \exp\left(-\frac{1}{2}(x - x')^2\right). \quad (1)$$

위의 식에서 예시로 나온  $k$  함수는 kernel 함수를 의미하고 GP에서 의 공분산 행렬 함수 역할을 한다. 예시로 Squared exponential을 사용하였는데,  $x$  와  $x'$  이 유사한 값을 가질수록 1에 수렴하는 함수다. 다음으로  $m$  함수는 예측 결과 값의 평균함수이다. 이러한  $m, k$  함수에 의해 각 점마다 Gaussian distribution을 가지게 되면 특정 데이터를 가지는 것이 아닌 하나의 확률 분포를 가지게 된다. 이렇게 나온 확률 분포는 Bayesian inference과정에서 prior로 사용하여 최종적으로 posterior를 구하여 예측 값으로 사용된다.

일반적으로 GPR에서 사용하는 kernel 함수는 SE로 이는 고정 kernel 함수이다. 하지만 실제 환경에서 배터리를 사용하면서 발생할 수 있는 여러 가지 물리적 현상에 대해 대응할 수 있는 모델을 구성하기 위해서 이번 실험의 GPR에서 적용될 kernel 함수로는 Matérn 공분산 클래스를 사용하였다.

$$(x - x') = \sigma^2 \frac{2^{1-\nu}}{\Gamma(\nu)} \left( 2\nu \frac{(x - x')}{\rho} \right)^\nu \nu \left( \sqrt{2\nu} \frac{(x - x')}{\rho} \right). \quad (2)$$

$\nu$ 는 평활도 hyper parameter( $\nu$ 가 클수록 함수가 더 평활함을 의미함)를 의미하고  $R_\nu$ 는 수정된 베셀 함수를 의미한다. 이 방정식은 half-integer인  $\nu$ 에 의해 단순화할 수 있다. 또한 복합 kernel은 개별적인 Kernel의 점, 직선, 평면 등 기하학적인 성질을 Linear Mapping Method인 Affine Transformation으로 만들 수 있는데, 실험에서는 복합 Kernel 생성을 Kernel간 덧셈으로 제한하고 장단기적으로 예측하기에 적합한 Kernel 조합이며  $\nu$ 값이 각각 5/2와 3/2인 Matérn5와 Matérn3를 사용한다.[4]

실험에서의 입력 값으로는 실온에서 일반적인 제조과정을 거친 배터리의 충, 방전 사이클 동안에 측정된 방전 용량을 사용하였다. 출력으로는 GPR 모델이 예측한 결과 값을 나타낸다. 이를 통해 1개의 배터리의 사이클 별 방전 용량 데이터를 학습한 모델부터 9개의 배터리 데이터를 학습한 모델의 예측의 성능을 비교 분석한다.

그림 1의 데이터셋의 개수에 따른 실험 결과를 보면 cycle 별 discharge capacity 데이터를 1개 학습한 모델(blue plot)에 비해 5개 학습한 모델(orange plot)과 9개 학습한 모델(green plot)이 실제 데이터와 비슷한 정도를 보인다. 또한 모든 배터리 discharge capacity data를 보면 주기적인 충, 방전 rest time에 의한 이상 값이 관찰되는데, 이 또한 학습에 사용한 배터리가 증가함에 따라 예측에 잘 반영되는 것을 관찰할 수 있다.

### III. 결론

최근 각광받고 있는 전기차의 주요 에너지원으로 사용되고 있는 리튬이온 배터리의 수명예측은 자동차 사고를 예방하는 문제에서 중요한 역할을 한다. 실험에서 GPR를 사용하여 여러개의 배터리의 Cycle별 Discharge Capacity를 학습하여 이들의 예측 성능을 비교 분석하였다. 기존에 나와 있는 수명 예측 알고리즘을 살펴보면 입력 값에 종속적으로 결과를 고정적으로 예측하는 경향이 반면 GPR은 확률을 이용하여 나온 수치에 분




그림 1 학습에 사용된 배터리 수에 따른 GPR Model의 Cycle별 배터리 방전 용량 예측 값과 와 테스트에 사용된 배터리 방전 용량 값

산을 이용하여 불확실성을 고려하여 예측의 결과의 비 신뢰영역을 확인할 수 있어 이런 다양한 학습 데이터에도 적응을 해나가는 것을 알 수 있었다.

### ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학지원 사업의 연구결과로 수행되었음(2019-0-018801). 또한 본 연구는 과학기술정보통신부의 기본연구사업의 연구결과로 수행되었음(NRF-2021R1F1A1064059).

### 참 고 문 헌

- [1] Ministry of Land, Infrastructure and Transport (MOLIT), "Kona EV recall Press released," *Ministry of Land, Infrastructure and Transport (MOLIT)*, Aug, 2021.
- [2] EricSchulz et al, "A tutorial on Gaussian process regression: Modelling, exploring, and exploiting functions," *Journal of Mathematical Psychology*, Oct, 2017.
- [3] Weng et al, "Predicting the impact of formation protocols on battery lifetime immediately after manufacturing," *Joule*, Sep, 2021.
- [4] Robert R. Richardson et al, "Gaussian process regression for forecasting battery state of health," *Journal of Power Sources*, May, 2017.