

리튬이온 배터리 수명추정을 위한 용량예측 머신러닝 모델의 성능 비교

유상우·신용범*·[†]신동일**

명지대학교 재난안전학과 석사과정, *명지대학교 화학공학과 석사과정,

**명지대학교 화학공학과 교수

(2020년 12월 09일 접수, 2020년 12월 23일 수정, 2020년 12월 24일 채택)

Comparison of the Machine Learning Models Predicting Lithium-ion Battery Capacity for Remaining Useful Life Estimation

Sangwoo Yoo·Yongbeom Shin*·[†]Dongil Shin*

Dept. of Disaster and Safety, Myongji University, Yongin, Gyeonggi-do 17058, Korea

**Dept. of Chemical Engineering, Myongji University, Yongin, Gyeonggi-do 17058, Korea*

(Received December 09, 2020; Revised December 12, 2020; Accepted December 24, 2020)

요 약

리튬이온 배터리(LIB)는 다른 배터리에 비해 수명이 길고, 에너지 밀도가 높으며, 자체 방전율이 낮아, 에너지 저장장치(ESS)로 선호되고 있다. 하지만, 2017~2019년 기간 동안 국내에서만도 28건의 화재사고가 발생하였으며, LIB의 운영 중 안전성 및 신뢰성을 보장하기 위해 LIB의 정확한 용량추정은 필수요소이다. 본 연구에서는 LIB의 충전 cycle에 따른 용량변화를 예측하는 기계학습 기반 모델의 설계에 있어 중요한 요소인 최적 머신러닝 모델의 선정을 위해, Decision Tree, 앙상블학습법, Support Vector Regression, Gaussian Process Regression (GPR) 각각을 이용한 예측모델을 구현하고 성능비교를 실시하였다. 학습을 위해 NASA에서 제공하는 시험데이터를 사용하였으며, GPR이 가장 좋은 예측성능을 보였다. 이를 바탕으로 추가 시험데이터 학습을 통해 개선된 LIB 용량예측과 잔여 수명추정 모델을 개발하여, 운영 중 이상 감지 및 모니터링 성능을 높여, 보다 안전하고 안정된 ESS 운용에 활용하고자 한다.

Abstract - Lithium-ion batteries (LIBs) have a longer lifespan, higher energy density, and lower self-discharge rates than other batteries, therefore, they are preferred as an Energy Storage System (ESS). However, during years 2017 - 2019, 28 ESS fire accidents occurred in Korea, and accurate capacity estimation of LIB is essential to ensure safety and reliability during operations. In this study, data-driven modeling that predicts capacity changes according to the charging cycle of LIB was conducted, and developed models were compared their performance for the selection of the optimal machine learning model, which includes the Decision Tree, Ensemble Learning Method, Support Vector Regression, and Gaussian Process Regression (GPR). For model training, lithium battery test data provided by NASA was used, and GPR showed the best prediction performance. Based on this study, we will develop an enhanced LIB capacity prediction and remaining useful life estimation model through additional data training, and improve the performance of anomaly detection and monitoring during operations, enabling safe and stable ESS operations.

Key words : machine learning, lithium-ion battery, capacity prediction, remaining useful life

[†]Corresponding author:dongil@mju.ac.kr

Copyright © 2020 by The Korean Institute of Gas

I. 서론

자동차 및 교통의 전기화, 환경을 위한 신재생에너지 활용 등이 증대됨에 따라 효과적이고 경제적인 에너지 저장장치가 요구되고 있다. 이에 따라 국내 에너지 저장장치 설치 사업장 수는 2019년 기준, 총 1,622개소로 급증하고 있다 [1]. 하지만, 급증하는 추세에 비해 에너지 저장장치의 안전관리는 잘 이루어지지 않고 있다. 그중 에너지 저장장치 화재사고는 국내에서 2017년 8월부터 2019년 10월까지 총 28건의 화재사고가 발생하였다 [2]. 에너지 저장장치 화재사고는 배터리와 큰 연관이 있다.

에너지 저장장치에서 사용되는 여러 배터리 중에서 리튬이온 배터리(LIB)는 다른 배터리에 비해 수명이 길고 에너지 밀도가 높으며, 자체 방전율이 낮은 장점을 갖기 때문에 에너지 저장장치에 많이 사용되고 있다. 하지만, LIB는 폭발을 일으키는 여러 원인을 갖고 있다. 그중 하나로 배터리가 특정 용량 이상 충전시키는 과충전의 경우가 있다. 과충전은 전지 내부 전해액의 분해를 일으켜 가연성 가스를 발생시키며 폭발할 수 있다. 또한, 배터리는 노화됨에 따라 반복되는 내부 화학반응에 의해 출력전력 및 배터리 용량에 영향을 미치는 활성 물질이 감소하여 성능이 저하된다. 이처럼 LIB의 안전성, 신뢰성 및 유지 보수를 보장하기 위해 LIB의 정확한 용량(수명)추정은 필수적 요소이다 [3]. 하지만, 배터리 용량은 복잡한 배터리 내부 물리화학적 반응 및 열적 효과와 관련이 있으며, 직접 측정할 수 없다. 직접 측정할 수 없는 LIB 용량추정을 위해 전기 모델 기반 방법과 데이터 기반 방법이 있다. 그중 데이터 기반 방법은 Machine Learning (ML)을 활용한 방법으로 다양한 ML 모델들이 있으며, 배터리 용량추정을 위해 활용되고 있다.

기존의 데이터 기반 방법들로 Support Vector Machine (SVM) [4], 앙상블 학습 [5], Gaussian Process Regression (GPR) [6] 등이 연구되었다. 이처럼 지금까지 각기 다른 배터리 실험, 배터리 모델, 데이터 전처리, 모델 훈련방법, 모델 성능평가 방법 등 배터리 용량추정에 있어서 다양한 환경조건에서 연구가 진행되었다. 이러한 연구를 통해, 현재 다양한 ML 기반 용량추정 예측모델이 제시되고 있다 [4], [5]. 하지만, 이런 각기 다른 환경조건에서 개발된 용량추정 예측모델은 개발된 모델 간의 성능을 객관적으로 비교 분석할 수 없다.

본 연구는 ML 기반 용량추정 예측모델의 객관적 성능 비교를 하고자 한다. 이를 위해 기존의 각기 다른 다양한 환경조건을 동일시하고, ML 모델

만을 달리하여 객관적인 용량추정 예측모델 성능 비교분석을 진행하고자 한다. 이를 통해 기존의 객관적 ML 모델 성능 비교가 어려운 부분을 해결하여, 용량추정 예측모델 성능 일반화된 비교정보를 제공하고자 한다.

II. 적용 머신러닝 모델

2.1. Decision Tree

Decision Tree (DT)는 지도학습에서 가장 일반적으로 사용되는 기계학습방법 중 하나이다. DT 구조는 root node, interior node, leaf node로 구성된다. 결과적으로 특정 데이터 포인트를 사용하며, leaf node에 도달할 때까지 참/거짓 질문에 답하여 전체 트리를 완전히 실행한다. 최종 예측은 특정 leaf node에서 종속변수 값의 평균이며, 여러 번의 반복을 통해 트리는 데이터 포인트에 대한 적절한 값을 예측한다 [7].

2.2. Ensemble 학습 (bagging, boosting)

Bagging은 샘플을 여러 번 뽑아 각 모델을 학습시켜 결과를 집계하는 방법이다. 데이터로부터 부트스트랩 한 뒤, 부트스트랩한 데이터로 모델을 학습시키고 학습된 모델의 결과를 최종 결과값을 구한다. Boosting은 가중치를 활용하여 약 분류기를 강 분류기로 만드는 방법이다. Bagging은 DT 1과 DT 2가 서로 독립적으로 결과를 예측하지만, boosting은 모델 간 팀워크가 이루어진다. 처음 모델이 예측하면, 그 예측 결과에 따라 데이터에 가중치가 부여되고, 부여된 가중치가 다음 모델에 영향을 끼친다. 앙상블 학습법을 통해 기존의 DT 모델이 개별 DT의 성능이 낮은 것인지, 아니면 과적합 된 것인지 확인할 수 있다 [7].

2.3. Support Vector Regression

Support Vector Regression (SVR)은 ML기법 중 잘 알려진 SVM의 회귀 모델이다. SVR은 임의의 실수값을 예측할 수 있도록 SVM을 일반화한 방법으로, 저차원 입력 공간에 있는 비선형 회귀 문제를 고차원 형상공간에 있는 선형 회귀로 전환시킨다. 결과적으로 SVR은 임의의 실수값들을 회귀함수를 사용하여 예측할 수 있도록 일반화한 방법이다 [8].

2.4. Gaussian Process Regression

GPR은 비모수 kernel 기반의 확률적 모델이며, 테스트를 위해 일부 또는 전체 교육 데이터를 저장

하는 메모리 기반 방법이다. GPR은 베이지안 관점에서 비선형 회귀에 접근한다. 베이지안 패러다임은 비선형 회귀의 확률적 모델링을 제공하며, 베이지안 확률 모델은 최적 추정 함수와 추정과 관련된 공분산을 모두 생성한다. 그리고 베이지안 모델은 비 베이지안 모델보다 추정된 매개 변수에 더 많은 정보를 제공한다 [6].

III. 예측모델 모델링

3.1. 예측모델의 개발 및 성능비교

본 연구에서 비교 대상으로 선정한 예측모델들은 Fig. 1의 흐름도에 따라 개발되고 평가가 진행되었다.

3.2. NASA dataset (2007)

NASA Prognostics Center of Excellence Data Repository에서 제공하는 배터리 데이터 세트를 사용한다. 데이터 세트는 실온에서 충전, 방전 및 휴지 기간의 세 가지 작동 프로필을 통해 실행되는 8개의 리튬 이온 배터리로 구성된다. 실험은 18650 리튬 이온 전지에 반복적인 충전 및 방전주기를 적용한다. 배터리는 정전류 정전압으로 충전된다. 전압이 cell 상한인 4.2 V에 도달할 때까지 1.5 A의

정전류로 충전한 다음 전류가 20 mA로 떨어질 때까지 정전압을 적용된다. 배터리의 차이는 # 5, # 6, # 7에 대해 셀 전압이 각각 2.7 V, 2.5 V, 2.2 V로 떨어질 때까지 2 A의 정전류에서 방전이 수행된다. 실험은 배터리가 정격 용량의 30 %, 즉 1.4 Ah를 잃을 때까지 수행된다 [9].

본연구에서는 # 5, # 6, # 7번 배터리의 616개의 cycle 중 169개의 충전 데이터 중 전압, 전류, 온도, 용량(capacity)을 사용하며, 충전 데이터만 사용한다. 왜냐하면, 방전 데이터의 경우 전류가 시간에 따라 빠르게 변하기 때문에 내부 파라미터를 정확

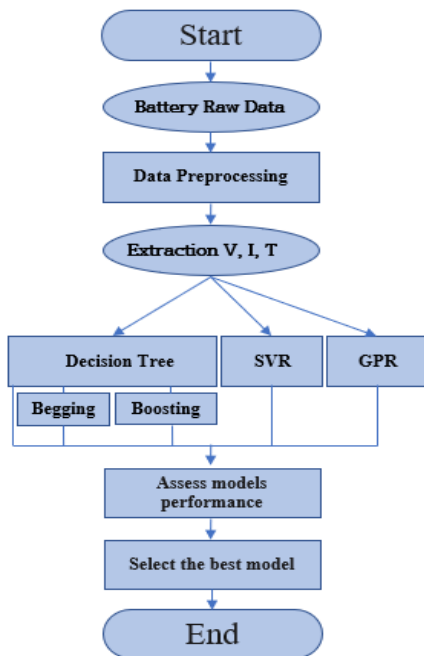


Fig. 1. 용량추정 예측모델 성능 비교 흐름도.




Fig. 2. 시간에 따른 전압, 전류, 온도 변화.

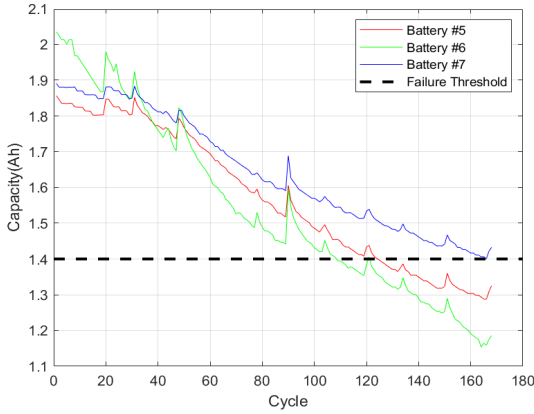


Fig. 3. Cycle에 따른 capacity 변화.

하게 측정하거나 계산하기 어렵다. 또한, 일상생활에서의 방전 패턴의 경우 배터리를 사용하는 사용자의 일상에 의존하며, 불완전 방전의 가능성도 있기 때문이다.

3.2.1. 데이터 분석

Fig. 2를 보면, 노화된 전지의 전압은 초기 전지에 비해 4.2 V에 빨리 도달하며, 노화된 전지는 초기 전지보다 전류가 더 빨리 Constant Current (CC) 프로세스에서 감소한다. 온도는 배터리가 CC 프로세스로 충전될 때 내부 저항이 증가하므로 capacity가 감소한 노화된 전지가 더 일찍 증가한다.

또한, cycle 증가에 따라 실제로 capacity 값도 점점 감소하는 것을 Fig. 3을 통해 볼 수 있다.

3.2.2. 데이터 전처리

데이터 전처리를 위해 충전프로세스의 전압, 전류, 온도, capacity 데이터를 더 나은 훈련을 위해 모든 데이터를 최소값 0으로, 최대값 1로 변환하고 0과 1사이로 min-max normalization을 적용하였다. min-max normalization은 식 (1)로 표현된다 [10].

$$z_i^k = \frac{x_i^k - \min(X)}{\max(X) - \min(X)} \quad i \in (1, \dots, n) \quad (1)$$

여기서 X 는 전체 충전주기의 모음을 의미하며, x_i^k 와 n 은 주기당 샘플수를 나타낸다.

3.3. ML 모델링

모델 성능 비교를 위한, 각 ML 모델의 개발을 위해 MATLAB의 Statistics and Machine Learning

Toolbox 회귀알고리즘을 사용하여 기계학습을 진행하였다. LIB 수명예측을 위해 적용한 기계학습 방법은 DT, DT를 기반으로 한 앙상블 학습법 (bagging, boosting), SVR, GPR을 사용했다. DT 모델, DT 기반 앙상블 모델은 최소 리프를 8로 진행하였다. SVR 모델은 Gaussian kernel을 사용하였으며, GPR 모델은 Matern 5/2 kernel을 사용하여 진행하였다. 공통적으로 모든 기계학습 모델은 전처리 과정을 거친 직전 cycle까지의 전압, 전류, 온도 각 10개 값을 입력값으로 받아 현재 cycle의 capacity를 출력값으로 예측한다.

IV. 결과

4.1. 모델 성능 평가방법

정확한 모델 성능 평가를 위해 k겹 교차검증을 진행하였으며, 본 연구에서는 $k=5$ 로 설정하였다. 또한, 모델의 추정 정확도를 평가하기 위해 평균 제곱근 오차를 사용한다. 여기서 평균 제곱근 오차는 Mean Square Error (MSE)에 루트를 씌워 연산 속도가 느려지는 것을 방지한다. MSE는 식 (2)로 표현된다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (2) \quad \text{여기서 } \hat{Y}_i \text{는 예측값을}$$

의미하며, Y_i 는 실제값을 의미하며, Root Mean Square Error (RMSE)는 식 (3)으로 표현된다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \quad (3) \quad \text{여기서 } \hat{Y}_i \text{는 예측}$$

값을 의미하며, Y_i 는 실제값을 의미한다.

또한, 결정계수 (R^2)와 Mean Absolute Error (MAE)를 통한 성능 평가도 진행된다. R^2 는 독립 변수가 종속변수를 얼마나 잘 설명하는지를 나타내는 값으로 1에 가까울수록 설명력이 높고 0에 가까울수록 설명력이 낮다. MAE은 평균 절대값 오차로 식 (4)로 표현된다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (4) \quad \text{여기서 } Y_i \text{는 측정값이고 } \hat{Y}_i \text{는 실제값이다.}$$

4.2. DT와 DT 앙상블 모델 성능 비교

Table 1을 보면, RMSE, R^2 , MAE 3개의 성능 비교 지표에서 DT-bagging > DR-boosting > DT 순의 모델 성능을 알 수 있었다. 또한, DT-bagging이 DT, DT-boosting에 비해 실제값과 일치하는 것을 볼 수 있다 (Fig. 4). DT와 DT 앙상블 모델의 경우 DT는 기본적으로 회귀보다 분류에 더욱 맞춰진 알

Table 1. 모델 성능 비교

모델	DT	DT-bagging	DT-boosting
RMSE	0.0974	0.0864	0.0906
R^2	0.92	0.93	0.93
MAE	0.0510	0.0400	0.0420




Fig. 4. DT, DT 앙상블 모델 capacity 예측.

고리듬이기 때문에 가장 높은 RMSE값을 보였다. 앙상블 모델의 경우 개별 DT의 낮은 성능이 문제면 boosting이 적합하며, 과적합이 문제면 bagging이 적합하다. 이를 기반으로 DT 앙상블 모델인 DT-bagging, DT-boosting의 결과를 통해 개별 DT가 과적합이 되었다는 것을 알 수 있었다.

4.3. DT-bagging, GPR, SVR 모델 성능 비교

앞에서 가장 좋은 성능을 보인 DT-bagging과 SVR, GPR의 성능 비교를 진행하였다. Table 2에서 보듯이, RMSE, R^2 , MAE 3개의 성능 비교 지표에서 $GPR > SVR > DT\text{-bagging}$ 순의 모델 성능을 알 수 있었다. 또한, GPR이 SVR, DT-bagging에 비해 실제값에 잘 일치하는 것을 볼 수 있다 (Fig. 5).

DT는 기본적으로 분류 모델에 적합하기에 SVR, GPR에 비해 낮은 성능 지표를 보인다. SVR 모델과 GPR 모델의 경우 RMSE값을 기준으로 비교했을 때 두 모델의 성능은 약간의 차이로 GPR이 더 우수하다. 이는 모두 강력한 kernel 기반 회귀 모델로 kernel 함수가 모델 성능에 결정적인 영향을 끼친다. SVR은 기존 ML 모델의 목적인 오차를 최소화 줄이는 것과는 달리 최대의 마진인 오차의 범위

Table 2. 모델 성능 비교

모델	DT-bagging	GPR	SVR
RMSE	0.0864	0.0615	0.0644
R^2	0.93	0.97	0.96
MAE	0.0400	0.0222	0.0401




Fig. 5. DT-bagging, GPR, SVR 모델 capacity 예측.

를 주어 가장 일반적인 예측모델을 형성한다는 점으로 보아 모델 성능 비교에서 GPR보다 조금 높은 오차율을 보인 것으로 판단된다. 단일 매개 변수가 일반적으로 선택되는 비 베이지안 방식인 SVR과 달리 GPR은 예측을 얻기 위해 가능한 모든 매개 변수값에 대해 사후 확률로 가중치를 부여한다는 점이 SVR보다 GPR이 더 좋은 성능을 보여주는 이유로 보인다.

4.4. 비훈련 데이터를 입력값으로 넣었을 때의 성능 평가

앞서 개발한 모델에 새로운 데이터인 #6, #7번 배터리 데이터를 입력값으로 넣었을 때의 성능 평가를 진행하였다. 진행결과 Table 3을 보면, DT-bagging의 경우 RMSE 값이 $DT\text{-bagging}(\#7) > DT\text{-bagging}(\#6) > DT\text{-bagging}$ 순으로 새로운 데이터를 입력값으로 넣었을 때의 RMSE 값이 높았다. GPR의 경우 RMSE 값이 $GPR(\#7) > GPR(\#6) > GPR$ 순으로 새로운 데이터를 입력값으로 넣었을 때의 RMSE 값이 조금 높아진 것을 알 수 있었다. SVR의 경우 역시 RMSE 값이 $SVR(\#7) > SVR(\#6) > SVR$ 순으로 새로운 데이터를 입력값으로 넣었을 때의 RMSE

Table 3. NASA data set #6, #7 예측성능 비교

모델	DT-bagging	GPR	SVR
RMSE (#6)	0.0880	0.0665	0.0693
RMSE (#7)	0.0924	0.0781	0.0745

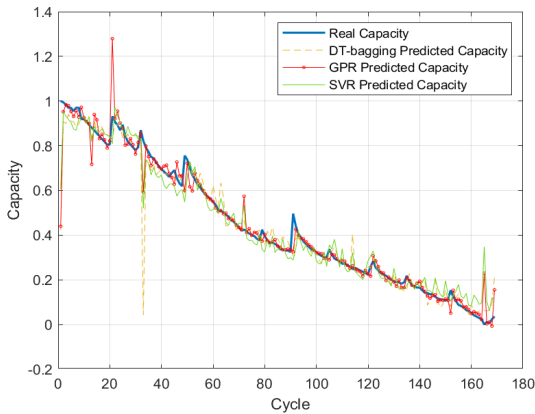


Fig. 6. DT-bagging, GPR, SVR의 NASA data set #6 예측 비교.




Fig. 7. DT-bagging, GPR, SVR의 NASA data set #7 예측 비교.

값이 조금 높아진 것을 알 수 있었다. 결과적으로 새로운 데이터를 입력값으로 넣었을 때 오차값이 더 커졌다.

Fig. 6과 Fig. 7을 보면, #6, #7 데이터를 적용한 capacity 예측 곡선을 보면 실제 capacity 값과는 오차가 있지만, 곡선의 추이가 초반 30 cycle 이후로 상당히 비슷하다는 것을 볼 수 있었다. 결과적으로 새로운 배터리 데이터를 입력값으로 넣었을 경우 배터리 cycle이 증가함에 따라 곡선의 추이를 잘 따라간다는 것을 볼 수 있었다.

V. 결론

신재생에너지 보급 정책에 의해 신재생에너지의 보급률이 상승하고 있지만, 간헐적인 에너지 공급에 따른 전력망의 안정성 유지를 위한 에너지 저장장치가 필요하다. 본 연구에서는 다양한 머신러닝 및 앙상블 모델 중 DT, DT-bagging, DT-boosting, GPR, SVR을 활용하여 배터리 용량 예측을 진행하였다. 모델 성능 비교 결과 동일한 조건에서 GPR 모델이 가장 좋은 성능을 보인 것을 확인하였다: RMSE 기준 GPR > SVR > DT-bagging 순의 예측 성능을 보였다.

추후 추가 시험 데이터를 확보해 본 연구에서 선정된 GPR모델과 deep learning 모델 적용을 통해, NASA 시험의 제한점인, 균일하지 않고 변화하는 실제 사용환경조건에 있어서도 높은 정확성을 갖는 LIB 용량추정 모델의 개발과 더불어 이를 활용한 이상 감지 및 모니터링 시스템을 완성하고자 한다. 또한, 최근 수소를 연료로 작동되는 동력장치 및 발전설비에서도 ESS가 필수적으로 설치되기 때문에 수소 설비와의 연계개발도 검토 예정이다.

감사의 글

본 연구는 산업통상자원부 기능성 플라스틱 (전기자동차용, 차세대 디스플레이, 전자부품) 가상공학 플랫폼 구축사업의 연구비지원(20009265-K_G012000926501)과 산업통상자원부 스마트디지털엔지니어링 전문인력양성사업의 연구비지원(P0008475-G02P04570001901)에 의해 수행되었습니다. 이에 감사드립니다.

REFERENCES

- [1] 한국전기안전공사, 소방청, 화재예방, 소방시설 설치유지 및 안전관리에 관한 법률 시행령 규제영향분석, (2020)
- [2] 국내 ESS 산업 생태계의 위기 - 원인과 대응 방안, 현대경제연구원, (2020)

- [3] Lee, S. H., and Park, M. K., "Battery state of charge estimation considering the battery aging," *Institute of Korean Electrical and Electronics Engineers*, **18**, 298-304, (2014)
- [4] M. A. Patil, P. Tagade, K. S. Hariharan, S. M. Kolake, T. Song, T. Yeo, et al., "A novel multi-stage support vector machine based approach for Li ion battery remaining useful life estimation", *Appl. Energy*, **159**, 285-297, (2015)
- [5] Y. Li, S. Zhong, Q. Zhong and K. Shi, "Lithium-ion battery state of health monitoring based on ensemble learning", *IEEE Access*, **7**, 8754-8762, (2019)
- [6] Rasmussen, C. E. and C. K. I. Williams. *Gaussian Processes for Machine Learning*. MIT Press, (2006)
- [7] A.C. Muller and S. Guido. *Introduction to machine learning with Python*. O'Reilly Media, (2017)
- [8] V. Vapnik, *Statistical Learning Theory*, New York, NY : Wiley, (1998)
- [9] B. Saha and K. Goebel, "Battery data set," NASA AMES Prognostics Data Repository, (2007)
- [10] A. Jain, K. Nandakumar and A. Ross, "Score normalization in multimodal biometric systems", *Pattern Recognit.*, **38**(12), 2270-2285, (2005)