

배터리 감가상각을 고려한 강화학습 기반 Multi ESS 운용 최적화

정태경, 박재민, 심민규*
서울과학기술대학교

jtk5959@seoultech.ac.kr, jmpark@g.seoultech.ac.kr, mksim@seoultech.ac.kr*

Reinforcement Learning-Based Multi ESS Operation Optimization Considering Battery Degradation

Tae Kyeong Jeong, Jae Min Park, Min K. Sim*
Seoul National University of Science and Technology

요약

에너지 저장 시스템 (ESS)은 산업 분야에서 전기 비용을 절감하는 데 효과적으로 활용될 수 있다. 특히, 단일 ESS 보다 여러 이점을 제공하는 멀티 ESS 시스템이 주목받고 있다. 본 연구에서는 두 개의 ESS 를 활용하여 공장의 감가상각 요금과 전기요금을 절감할 수 있는 모델을 제안한다. 모델의 최적 전략을 찾기 위해 강화학습을 사용하여 복잡한 운용 조건과 의사결정 요소를 고려한 최적의 운용 전략을 제안한다. 연구 결과는 일반적인 방법들에 비해 비용을 약 4% 절감하는 효과를 보여주었다.

I. 서론

에너지 저장 시스템(ESS)은 전력을 저장할 수 있는 장비로 전기 요금 절감을 목적으로 많이 사용된다. 국내 산업용 전기 요금 체계(TOU)는 피크 시간대 전기요금과 일반 시간대 전기요금이 차이가 크기에 산업에서 ESS 를 효율적으로 운용한다면 전기 요금을 절감할 수 있다 [1].

ESS 는 고가의 장비로, 사용에 따른 감가상각도 고려해야 한다. 하지만 복잡한 감가상각 메커니즘을 매번 계산하여 운용하는 것은 현실적으로 어려운 일이다. 본 연구에서는, 리튬 이온 전지의 감가상각을 추정하는 모델 [2],[3]을 사용하여 리튬이온 기반 ESS 의 최적 운용 방안을 제안한다.

또한, 대용량 단일 ESS 대신 분산된 ESS 시스템을 사용하는 것은 시스템 복원력, 공간 효율성 등 여러 이점을 제공한다 [4]. 본 연구는 두개의 분산된 ESS 를 사용하는 것이 가장 효율적이라는 결과[5]에 주목하여 두개의 ESS 운영을 최적화하는 모델을 제시한다.

ESS 운용 의사결정 과정에는 TOU, 감가상각, 전기 수요 등 다양한 요소를 고려해야 한다. 이를 모두 고려하여 최적의 운용 방안을 찾는 건 복잡한 과제이다. 이러한 문제를 해결하기 위해 본 연구에서는 강화학습을 활용한다. 강화학습의 여러 학습 방법 중 Q-learning 기반 학습 방법들은 안정성과 효율성 측면에서 높이 평가되고 있다[3]. 따라서 본 연구에서는 대표적인 Q-learning 기반 학습 방법인 Deep-Q-Network(DQN) [4] 에이전트를 사용해 최적의 운용 전략을 학습시키는 방법을 제안한다.


본 연구에서는 강화학습을 이용해 두개의 분산된 ESS 의 감가상각을 고려한 ESS 운용 모델을 제안한다.

II. 본론

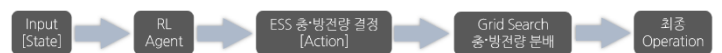
1. 시스템 모델

[그림 1]은 본 연구에서 제안하는 시스템 모델을 나타내는 그림이다. 공장은 전력 수요를 만족하기 위해 크게 두가지 방식 1)전력을 공급자에게 직접 구매하는 방식, 2) ESS 에 저장된 전력을 사용하는 방식을 사용할 수 있다. 배터리는 구매한 전력으로 충전할 수 있으며, 필요에 따라 공장의 수요를 위해 방전한다. [그림 2]는

시스템 모델의 작동 흐름을 나타내는 그림이다. 에이전트는 주어진 정보를 토대로 비용을 최소화하면서 전력 수요를 만족하는 최적의 배터리 충·방전량을 결정한다. 에이전트가 공급자로부터 ESS 에 충전하는 충·방전량을 결정하면 Grid Search 를 통해 전기 요금을 최소화할 수 있도록 2개 ESS 에 충·방전량을 분배한다.



[그림 1] 시스템 모델 구조도




[그림 2] 시스템 모델 흐름

[표 1]은 본 연구에서 사용되는 표기를 정의한다.

[표 1]

표기법	설명
$\tilde{X}_t^1, \tilde{X}_t^2$	t 시점 1 번, 2 번 ESS 의 최대 용량
\tilde{X}_t	t 시점 각 ESS 최대 용량의 합
X_t^1, X_t^2	t 시점 1 번, 2 번 ESS 에 충전된 전력량
X_t	t 시점 각 ESS 에 충전된 전력량의 합
D_t	t 시점 공장 전력 수요
h_t	t 시점 해당 시간 (24 시간 기준)
A_t	t 시점 에이전트가 선택한 행동
R_t	t 시점에 받은 보상
c_h	h 시점 구매 전력 단가 ($h = t \bmod 24$)
P_t	t 시점 공급자로부터 구매한 전력량
P_t	t 시점 공급자로부터 구매한 전력량
C_{ESS}^1, C_{ESS}^2	1 번, 2 번 ESS 의 초기 가격

[그림 3]은 본 연구에 사용된 시간대별 산업용 전기요금과 공장의 일일 수요를 나타낸다. 전기요금은 한국전력의 산업용 전기요금(을)을 사용하며, 수요는 출근시간 90KWh, 이외 시간은 20KWh를 가정하였다.



[그림 3] 산업용 TOU(왼쪽), 전력 수요(오른쪽)

2. 감가상각 모델

해당 장에서는 리튬 이온 전지의 감가상각과 수명에 대해 설명한다.

리튬 이온 전지는 사용에 따라 degradation 과 전지의 수명감소가 발생한다. [2]에서 정의한 수명 추정 식을 사용하기 위해서는 전지의 모든 활동 기록으로 사이클 횟수를 추정해야 한다. 이는 마코프 속성을 활용한 강화학습에 적절하지 않다. 따라서 본 연구에서는 [3]에서 제시한 감가상각 모델을 활용하였다. [3]에서 제시한 모델 $f^{deg}(\cdot)$ 은 현재 배터리 상태 $\tilde{X}_t, X_t, X_{t+1}$ 를 이용하여 감가상각을 추정할 수 있다.

$$\tilde{X}_{t+1} = f^{deg}(\tilde{X}_t, X_t, X_{t+1})$$

3. MDP 모델

MDP 모델은 상태(state), 행동(action), 보상(reward), 전환(transition)으로 정의되며, 해당 장에서는 MDP 모델 설정과 각 요소에 대한 논의가 진행된다.

3.1 상태

$$S_t = (\tilde{X}_t, X_t, D_t, h_t)$$

상태 정보는 위와 같이 4 개의 변수를 포함한 벡터이다. 4 개 변수는 각각 1) 모든 ESS 의 최대 충전량의 합, 2) 모든 ESS 의 충전량의 합, 3) 현재 공장의 전력 수요, 4) 24 시간 단위의 현재 시각이다.

3.2 행동

$$A_t \in [0, 0.25, 0.5, 0.75, 1.0]$$

본 연구에서 행동은 최소값인 0 과 최댓값인 1 사이에서 값이 정해지며 A_t 는 P_t 를 결정한다. 행동은 0 부터 1 까지 이산적인 5 개 값으로 구성되어 있다.

3.3 보상(reward)

$$R_t = -\left(c_k \cdot P_t + \sum_{i=1}^2 f^{deg}(\tilde{X}_t^i, X_t^i, X_{t+1}^i) \cdot C_{ESS}^i\right)$$

본 연구에서 정의한 보상은 전기 요금과 감가상각 비용의 합으로, 위 식과 같이 나타낼 수 있다. 본 연구의 목적은 전기 요금의 최소화이기 때문에 전기 요금을 음수로 정의하여 보상을 최대화하도록 했다.

3.4 전환

전환은 특정 상태에서 행동을 취했을 때 상태변화를 정의한다. 본 연구에서 전환되는 값은 X_t 와 \tilde{X}_t 이다.

3.4.1 X_t 전환

X_t 의 전환은 P_t 를 포함한 식으로 정의할 수 있고, 이를 정리하면 다음과 같다.

$$X_{t+1} = X_t - D_t + P_t$$

$$X_{t+1} = X_t - D_t + (D_t - X_t)^+ + A_t(\tilde{X}_t + (D_t - X_t)^-)$$

X_{t+1} 를 구한 뒤, Grid Search 를 통해 최적의 $[X_{t+1}^1, X_{t+1}^2]$ 조합을 찾아 전력 구매량 및 사용량을 분배했다.

3.4.2 \tilde{X}_t 전환

\tilde{X}_t 의 전환은 다음과 같으며, \tilde{X}_{t+1}^i 은 $f^{deg}(\tilde{X}_t, X_t, X_{t+1})$ 로 계산된다.

$$\tilde{X}_{t+1} = \sum_{i=1}^2 \tilde{X}_{t+1}^i$$

III. 결론

[표 2]

구분	DQN	BM1	BM2
$\tilde{X}_0 = 200$	5221.90	5204.74	5203.31
$\tilde{X}_0 = 600$	4301.25	4353.27	4413.47
$\tilde{X}_0 = 1200$	4376.60	4533.75	4533.27

[표 2]는 서로 다른 \tilde{X}_0 을 가진 ESS 를 DQN 으로 학습한 모델의 최종 비용이다. 본 연구에서는 두 가지 벤치마크로 모델의 성능을 평가했다. BM1 은 단일 ESS 를 사용해 운영한 결과이며, BM2 는 충·방전을 2 개 ESS 에 동일하게 분배하는 방식으로 운영한 결과다. [표 2]에서 알 수 있듯이 ESS 의 용량이 수요를 충분히 만족시킬 정도가 되면($\tilde{X}_0 = 600, 1200$) ESS 를 2 개 사용해 충·방전을 분배하는 것이 1 개의 ESS 를 사용하는 경우에 비해 최대 약 3~4%의 비용을 절감한다는 사실을 알 수 있다. 또한 \tilde{X}_0 가 커질수록 벤치마크와의 비용 차이가 커지는 것으로 보아 비교적 큰 용량의 ESS 를 사용하는 대규모 산업체에 적용했을 때 비용을 더욱 효과적으로 절감할 수 있다.

ACKNOWLEDGMENT

This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (Grant Number: NRF-2021R1A6A1A03039981 and NRF-2020R1F1A107387912).

참 고 문 헌

- [1] Y. Guo and Y. Fang, "Electricity Cost Saving Strategy in Data Centers by Using Energy Storage," in IEEE Transactions on Parallel and Distributed Systems, vol. 24, no. 6, pp. 1149–1160, June 2013, doi: 10.1109/TPDS.2012.201.
- [2] Xu, B., Oudalov, A., Ulbig, A., Andersson, G., & Kirschnner, D. S. Modeling of lithium-ion battery degradation for cell life assessment. IEEE Transactions on Smart Grid, 9(2), 1131–1140. 2016.
- [3] Park, J., Kwon, T., & Sim, M. K. (2023). Optimal energy storage system control using a Markovian degradation model—Reinforcement learning approach. Journal of Energy Storage, 71, 107964.
- [4] Bozorgavari, Seyed Aboozar, et al. "Robust planning of distributed battery energy storage systems in flexible smart distribution networks: A comprehensive study." Renewable and Sustainable Energy Reviews 123 (2020): 109739.
- [5] Giannitrapani, Antonio, et al. "Optimal allocation of energy storage systems for voltage control in LV distribution networks." IEEE Transactions on Smart Grid 8.6 (2016): 2859–2870.
- [6] C. J. Watkins and P. Dayan, "Q-learning," Machine learning, vol. 8, no. 3–4, pp. 279–292, 1992.