

국민수요반응을 위한 기계학습 예측 모델 기반 고객기준부하 산정 방법

이현용, 고석갑, 이병탁
한국전자통신연구원

{hyunyonglee, softgear, bytelee}@etri.re.kr

A Method for Calculating Customer Baseline Load using Machine Learning Prediction Model for National Demand Response

HyunYong Lee, Seok-Kap Ko, and Byung-Tak Lee
Electronics Telecommunications Research Institute (ETRI)

요 약

본 논문은 국민수요반응을 위한 고객기준부하 산정 방법에 대해서 연구한다. 특히, 국민수요반응 프로그램의 참여자들이 보이는 다양하며 동적인 전력사용 패턴을 잘 반영할 것으로 기대되는 기계학습 예측 모델 기반 고객기준부하 계산 방법을 연구한다. 4 만여 세대의 아파트 전력사용량에 가볍고 빠른 기계학습 예측 모델들을 적용하여, 고객기준부하 계산 측면에서의 각 모델의 타당성을 검증한다.

I. 서 론


수요반응(Demand Response)이란 전력거래소가 전력 감축 지시를 발령하고 참여자들이 전력 사용량을 감소시키면 전력거래소에서 이에 상응하게 금전적으로 보상해주는 서비스이다 (그림 1). 초기 수요반응은 대규모 공장 중심으로 시작되었으며, 2018년에는 개별 세대 및 상가 등을 포함하는 소규모 수요자원을 중심으로 하는 국민수요반응이 도입되었다[1][2].

수요반응 프로그램의 참여를 독려하는데 있어 중요한 것은 인센티브이다. 인센티브 계산에 있어 사용되는 것은 고객기준부하(Customer Baseline Load)로 전력거래소의 지시 등으로 전력 소비를 절감하지 않았다면 사용했을 평상시 전력사용량을 예측한 값이다. 따라서, 인센티브는 전력감축 지시가 적용된 시간 내에서의 고객기준부하와 실제 전력 사용량의 차이에 기반하여 계산된다.

초기 수요반응의 대상이었던 대규모 공장 등은 전력사용에 있어 뚜렷한 패턴이 있어서 전통적인 고객기준부하 계산 함수(예. MidXofY 등)를 적용할 수 있었다. 하지만, 전력사용 패턴이 다양한 요소에 의해 영향을 받을 뿐 아니라 매우 동적인 패턴을 보이는 국민수요반응 프로그램의 참여자의 경우에는 전통적인 계산 방법을 그대로 적용할 수 없다. 따라서, 국민수요반응 참여자의 전력사용 패턴을 고려한 고객기준부하 계산 방법이 필요하다.

본 논문에서는 국민수요반응을 위한 고객기준부하 계산 방법을 연구한다. 특히, 여러 기계학습 예측모델의 고객기준부하 계산 성능을 비교함으로써 각 방법의 적용 타당성을 검증하고자 한다.

II. 본론




(그림 1) 국민수요반응 개념도.


국민수요반응 고객기준부하. 국내에서 서비스 중인 수요반응 프로그램은 표준수요반응, 중소형수요반응, 국민수요반응이다. 국민수요반응을 제외한 두 프로그램에서는 인센티브를 참여자별로 계산한다. 반면, 국민수요반응에서는 일부 참여 세대들을 한 그룹으로 간주하고 그룹 단위로 인센티브를 계산한다. 이는 국민수요반응 참여자들의 전력 사용량이 적기 때문이다. 국민수요반응을 위한 그룹 단위의 고객기준부하 계산에는 Mid8of10 이 사용되고 있다. Mid8of10 은 고객기준부하 계산 대상이 되는 일을 기준으로 공휴일, 국민수요반응 적용일을 제외한 최근 10 일의 전력사용량 중에서 최소, 최대 전력사용량을 보이는 2 일을 제외한 나머지 8 일의 전력사용량을 평균하여 고객기준부하를 도출하는 방식이다.

기계학습 예측 모델. 본 논문에서 고려하는 기계학습 예측 모델은 online ARIMA[3], LightGBM[4], XGBoost 이다. 위 세 모델을 고려하는 이유는, 간단한 통계 기반의 전통적인 고객기준부하 계산 함수를 고려했을 때, 국민수요반응용 고객기준부하 계산 함수 또한 가벼워야 하기 때문이다. 위 세 모델은 GPU 를 필요로 하지 않으며, 빠른 장점이 있다.

데이터. 실험을 위해 36 개의 아파트 단지에 속한 4 만여 세대의 전력사용량 데이터를 사용하였다. 실험의 편의상 동일 아파트 단지에 속한 세대들을 국민수요반응을 위한 한 참여그룹으로 간주하였다. 그룹의 참여 세대 수는 13 부터 4,210 까지 다양하다.



(그림 2). Online ARIMA 에 의한 고객기준부하 계산 성능 개선 정도.



(그림 3). Boosting 알고리즘에 의한 고객기준부하 계산 성능 개선 정도.

데이터는 2016 년 11 월부터 2019 년 11 월까지 획득하였다. 하지만, 세대 별로 누락된 데이터가 있어 실험에 사용가능한 데이터 수는 이보다 적다. 고객기준부하 계산 대상의 시간은, 실제 국민수요반응이 가장 빈번하게 발생한 17시부터 18시로 하였다.

실험 결과. 세 가지 기계학습 예측 모델의 고객기준부하 계산 성능은 그림 2 와 그림 3 에 표현하였다. 그림 2 와 그림 3 은 현재 국민수요반응에서 사용되고 있는 Mid8of10 대비하여 실제 전력사용량 예측이 얼마나 더 개선되었는지를 보여준다. 양의 값이면 더 나은 예측 성능을, 음의 값이면 더 나쁜 예측 성능을 의미한다. 참고로, 본 실험에 사용한 데이터는 국민수요반응 이벤트가 미적용된 것으로, 고객기준부하 계산 함수를 통해 계산된 값을 실제 전력사용량과 비교하여 각 계산 방법의 성능을 용이하게 파악할 수 있다. 그림 2 는 online ARIMA 의 성능을 보여주는데 거의 모든 경우에 저하된 예측 성능을 보인다. Online ARIMA 는 비록 가볍고 빠르지만, 과거 데이터의 유용한 패턴을 잘 활용하지 못하기 때문에, 예측 측면에서는 안 좋은 성능을 보인다. 그림 3 은 LightGBM 과 XGBoost 의 예측 성능을 보여준다. 총 36 개의 경우에 대해서, 26 개의 경우에 LightGBM(8 경우) 또는 XGBoost(18 경우)가 더 나은 예측 성능을 보인다. 특히, 계산 대상 일수가 클수록 LightGBM 이나 XGBoost 가 더 나은 성능을 보이는 경우가 더 많아진다. 이는, 활용가능한 학습 데이터가 많을수록 예측 모델의 성능이 증가함을 보여준다. 특히, 특정 계산 일수(199 일)이상의 경우에는 XGboost 나 LightGBM 이 모든 경우에 더 나은 성능을 보인다. 또한, XGBoost 가 LightGBM 보다 더 많은 경우에 성능 향상을 보이는 것을 확인할 수 있다.

III. 결론

본 논문에서는 국민수요반응을 위한 고객기준부하 계산 측면에서 3 가지 기계학습 예측모델의 타당성을 실제 데이터에 기반하여 검증하였다. 실험 결과 부스팅 알고리즘, 특히 XGBoost 가 기존 Mix8of10 뿐 아니라 다른 모델보다 더 나은 성능을 보이는 것을 확인하였다. 또한, 가용한 학습 데이터가 많을수록 그 성능이 더 증가하는 것을 확인하였다.

ACKNOWLEDGMENT

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술 평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20181210301570)

참 고 문 헌

- [1] 정은아, 이정은, 김화영, 정소라, 이효섭, 서봉원, 이원종 "확장된 기술수용모델을 이용한 가정용 에너지 수요반응 프로그램 실증분석", 한국 HCI 학회 논문지, vol. 12, no.4, pp.65-73, 2017.
- [2] 오승훈, 이형욱, 박지원, 이병탁 "국민 DR 서비스를 위한 사물인터넷 표준화 연구", 2020, 대한전자공학회 하계학술대회 논문집
- [3] Liu, C., et al. "Online ARIMA algorithms for time series prediction" in Proc. of AAAI, 2016.
- [4] Guolin K., et al. "LightGBM: A highly efficient gradient boosting decision tree," in Proc. of NIPS, 2017.
- [5] Tianqi X., et al. "XGBoost: A scalable tree boosting system," in Proc. of KDD, 2016.