

기본 요금 절감을 위한 기계학습 기반 건물 최대 부하 예측

손예지, 백승준, 윤성국
 송실대학교

Building Peak Load Forecasting Based on Machine Learning
 for Reducing the Demand Charge

Ye-Ji Son, Sung-Jun Baek, Sung-Guk Yoon
 Soongsil University

Abstract - 에너지에 대한 관점은 기존에 공급 위주의 관리에서 수요 중심의 관리로 초점이 변화되었다. 본 연구에서는 소비자의 합리적인 전력 소비 형태를 유도하기 위한 기계학습 기반 최대 부하 예측 기법을 제안한다. 현행 전기 요금 중 기본 요금에 영향을 끼치는 요금적용전력이 갱신되는 여름 및 겨울의 평일에 대해 예측을 진행하며, 피크가 갱신될 것 같은 상황을 경보로 알려 소비자가 스스로 피크를 저감시킬 수 있다. 송실대학교 사례 분석을 통해 제안하는 기법의 기본 요금 절감 효과 유효성을 확인하였다.

2.2 전력 사용량 패턴 분석

그림 1은 일주일간의 송실대학교 시간별 전력 수요 패턴(2016.12.05.~12.11.)을 나타낸다. 주말 전력 사용량은 평일에 비해 현저히 낮으므로, 요금적용전력은 평일 전력 사용량에 의해 갱신된다. 따라서 본 논문은 평일 및 결과 분석을 대상으로 수요 예측을 실시한다.

그림 2와 3은 각각 여름(2016.08.01) 및 겨울(2016.12.05)의 송실대학교 하루 전력 수요 패턴을 보여준다.

1. 서 론

에너지에 대한 관점은 기존 공급 위주의 관리에서 수요 중심의 관리로 초점이 변화되었다. 우리나라에서도 제 2차 에너지 기본 계획에서부터 소비자 전력 사용 패턴을 고려한 합리적인 소비 유도 및 피크 저감을 통해 전기 요금 조정을 추진하고자 하였다.[1] 현재 계획 단계인 제 3차 에너지 기본 계획에서도 이를 기조로 에너지 절약 확대를 위한 가격제도 개편 방향 및 최종 에너지 소비 감축 목표를 논의 중에 있다.[2][3]

이에 따라 본 연구에서는 소비자가 전기 요금을 절감하기 위한 방법으로 기계 학습 기반 건물 최대 부하 예측을 제안하였다. 제안 기법을 활용하면 요금적용전력 갱신이 예상되는 날에 미리 경보를 울림으로써 갱신을 방지하여 기본 요금을 절감할 수 있다. 본 연구에서는 k-means clustering과 인공신경망의 두 가지 기계 학습 기법을 사용하였다.

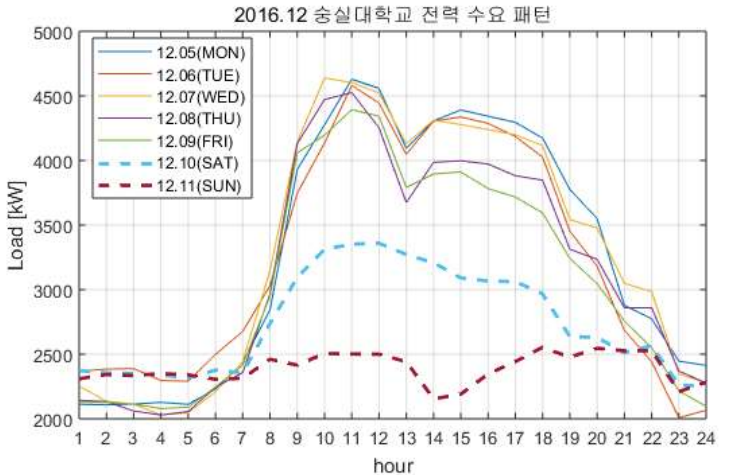
실험의 타당성을 검증하기 위해 송실대학교 전력 데이터로 사례분석을 진행하였다. 경보 유무와 전력 갱신 여부에 따른 민감도 및 정확도를 분석하였으며, 제안하는 기법이 기본 요금 절감을 수행하는 것을 확인하였다.

2. 본 론

2.1 전기 요금 제도


주택용 전기요금을 제외한 현 전기요금은 기본 요금과 전력량 요금으로 구성된다. 최대수요전력을 계량할 수 있는 전력량계를 설치한 고압 고객의 경우, 검침당월을 포함한 직전 12개월 중 12월분, 1월분, 2월분, 7월분, 8월분, 9월분 및 검침당월분의 최대 수요 전력 중 가장 큰 최대 수요 전력을 요금적용전력으로 하여 기본 요금을 산정하고 있다. 기본 요금 계산식은 식(1)과 같으며, 산정된 기본 요금은 최장 1년 동안 유지되므로 전기요금에 큰 영향을 미친다. [4]

$$\text{기본요금(원)} = \text{요금적용전력}(kW) * \text{기본요금단가(원/kW)} \quad (1)$$




〈그림 1〉 송실대학교 전력수요 패턴

하루 전력 사용량은 큰 폭으로 감소하는 점심시간(12~13시)을 기준으로 두 구간으로 나눌 수 있다. 과거 데이터 분석을 통해 여름의 경우 2구간(13:00~24:00), 겨울의 경우 1구간(01:00~12:00)에서 최대 전력 수요가 발생하는 것을 확인하였다. 따라서 본 논문에서는 계절적 특성 및 최대 수요 전력과 시간대별 전력의 상관성을 고려하여 여름 13:00~17:00, 겨울 08:00~12:00의 시간대별 최대 수요 전력 데이터를 예측 모델의 입력 데이터로 선정하였다.



〈그림 2〉 여름 전력수요 패턴



〈그림 3〉 겨울 전력수요 패턴

2.3 예측 기법

2.3.1 k-means clustering

k-means clustering 기법은 다차원 입력 데이터를 1개 이상의 데이터가 포함된 K 개의 클러스터로 분류하는 기계 학습 기법이다. 분류 과정에서 동일 클러스터 내 데이터의 유사도는 증가하고, 타 클러스터와의 유사도는 감소하므로 패턴 유사도에 따른 데이터 분류가 가능하다.[5]

N 개의 데이터 집합 (x_1, x_2, \dots, x_N) 을 K 개의 클러스터로 분류할 때 클러스터 분류 과정은 다음과 같다.

Step 1. 초기 클러스터 중심 μ_k ($2 \leq k \leq K$)을 임의로 설정한다. 다음 목적 함수(2)를 최소로 만들고자 하며, 이는 클러스터 내 데이터와 해당 클러스터 중심의 제곱 합이다. n 번째 데이터가 k 번째 클러스터에 속하는 경우 $r_{nk} = 1$, 속하지 않는 경우 0의 값을 가진다.

$$\sum_{n=1}^N \sum_{k=1}^K r_{nk} \|x_n - \mu_k\|^2 \quad (2)$$

Step 2. 각 데이터와 클러스터 중심 사이의 유클리드 거리가 가장 가까운 클러스터에 데이터를 할당하며, r_{nk} 는 식(3)에 의해 결정된다.

$$r_{nk} = \begin{cases} 1, & k = \operatorname{argmin} \sqrt{(x_n - \mu_k)^2} \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

Step 3. 할당된 데이터를 바탕으로 클러스터 중심을 식(4) 해당 클러스터 내 데이터의 무게중심 값으로 재설정한다. 이를 클러스터 중심이 더 이상 변화하지 않을 때까지 반복한다.

$$\mu_k = \frac{\sum_{n=1}^N r_{nk} x_n}{\sum_{n=1}^N r_{nk}} \quad (4)$$

본 논문에서는 동일 계절에 해당하는 이전 30일의 최대 수요 전력 데이터와 피크가 발생한 시간대의 기온에 당일 예측 시점 전력과 예보 기온을 추가하여 2개 클러스터로 나눈다.

2.3.2 인공신경망

인공신경망은 인간의 신경망을 모사하여 기계를 학습시키기 위해 고안된 알고리즘이다. 전력 수요 예측과 같은 비선형 문제를 해결하기 위해 기존 단층 퍼셉트론에 은닉층을 추가한 다층 퍼셉트론(MLP)이 주로 사용된다.

다층 퍼셉트론은 입력값 x 에 가중치 w 를 곱한 후, 그 합에 활성화함수를 이용해 식(5)와 같이 출력값 y 을 산출한다. 이 때 b 와 f 는 각각 바이어스와 활성화 함수를 의미하며, 본 논문은 활성화 함수로 시그모이드 함수를 사용하였다.

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (5)$$

출력값과 실제값 t 사이의 오차는 식(6)와 같이 계산된다.

$$E(y, t) = \frac{1}{N} \sum_{k=1}^N |y_i - t_i|^2 \quad (6)$$

인공신경망의 학습은 경사하강법을 통해 오차를 최소화하는 방향으로 가중치를 조절하는 역전파 알고리즘을 이용한다.[6]

2.4 예측 모델

예측 모델의 입력 데이터는 기온의 영향을 반영하기 위해 서울 지역의 평균 기온 데이터와 한국전력공사의 iSmart에서 제공하는 시간대별 최대 수요 전력 데이터를 사용한다. 최대 수요 전력은 15분 단위로 측정되는 전력 사용량 중 최대 사용량의 4배로 계산된다. 예측의 정확도를 높이며 부하 절감을 시도할 여유 시간을 주기 위하여 최대 전력 수요 발생 시점의 한 시간 전인 겨울 10시, 여름 13시에 예측을 진행한다. 이는 한국 전력의 긴급 절전 수요 제도의 절전 시행 전 예고 기준과 동일하다.[7] 동일 클러스터 내 전일(d-1)데이터를 인공 신경망의 입력으로 사용해 예측일의 최대 전력 수요 P 를 예측한다. 인공신경망의 학습 기간은 2일이다. 표 1은 예측 계절별 입·출력 파라미터이다. L 과 T 는 각각 시간대별 최대 수요 전력, 시간대별 평균 기온을 의미한다. 당일 평균 기온은 예보 기온을 사용하였다.

<표 1> 계절별 입·출력 파라미터

	여름		겨울	
입력	$T_{(d-1, h)}$	$L_{(d-1, h)}$	$T_{(d-1, h)}$	$L_{(d-1, h)}$
	$T_{(d, h)}$	$L_{(d, 13)}$	$T_{(d, h)}$	$L_{(d, h')}$
출력	$P_{(d)}$			

2.5 사례 연구

제안하는 최대 부하 예측 기법의 유효성을 검증하기 위해 숭실대학교의 최대 부하를 예측하는 사례 연구를 진행하였다. 숭실대학교는 교육용전력(을) 고압B 선택II 요금제를 사용하며 요금적용전력은 겨울에 갱신된다. 그러나 본 논문은 여름철 경보의 정확성을 분석하기 위해 여름 피크 갱신 여부도 분석하였다.


표 2에서는 본 논문에서 예측을 진행한 월을 표시하였다. 요금적용전력은 기준월에 갱신된 요금적용전력이다. iSmart에서 제공하는 2015년 이후 기간 중 실제 요금적용전력이 갱신된 달로 하계 및 동계의 기준월을 선정하였다.

예측 결과의 정확도는 식(7)의 MAPE(Mean Absolute Percentage Error)로 평가하였다. A_t 는 실제 값, F_t 는 예측 값을 뜻한다.

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (7)$$

<표 2> 예측 월 정보


기준월	요금적용전력(kW)	예측월
2015.09	4606.08	2016.08, 2016.09
2015.12	5166.72	2016.01, 2016.02, 2016.12
2016.12	5443.20	2017.01, 2017.12



<그림 4> 2016년 12월 예측 결과

제안하는 기법을 사용한 2016년 12월의 실제 예측 결과는 그림 4와 같다. 약 5.20%의 MAPE 결과를 보여주는 것을 확인하였다.

요금적용전력 갱신은 기본 요금 증가와 직결되므로 이를 방지하기 위해 예측 결과에 이전달의 예측 오차만큼 마진을 두어 경보를 울린다. 예로, 2017년 1월 최대 부하 예측 시 예측값의 5.20%의 마진을 두어 갱신 여부를 판정한다.



〈그림 5〉 경보 결과 분류

경보의 결과는 그림 5에서 보여주는 것과 같이 경보의 유무와 요금적용전력 갱신 여부에 따라 요금적용전력이 갱신된 날에 경보를 울려 이를 방지한 경우(TP), 경보를 울리지 않아 전력이 갱신된 경우(FN), 요금적용전력이 갱신되지 않은 날에 경보를 울리지 않았을 경우(TN) 및 경보를 울렸을 경우(FP)의 4가지로 구분할 수 있다. 이 중 가장 중요한 것은 FN으로, 경보의 발령이 없었음에도 피크가 갱신되어 요금이 상향 조정되었기 때문이다. 이를 토대로 요금적용전력이 갱신된 날에 경보가 울렸을 확률을 나타내는 민감도와, 경보의 신뢰도를 나타내는 정확도를 구한다. 민감도와 정확도가 높을수록 제안 모델이 유효함을 의미하며, 계산식은 식(8) 및 식(9)과 같다. 표3-4는 월별 경보 결과 및 민감도, 정확도이다.

$$\text{민감도} = \frac{TP}{TP + FN} * 100(\%) \quad (8)$$

$$\text{정확도} = \frac{TP + TN}{TP + TN + FP + FN} * 100(\%) \quad (9)$$

〈표 3〉 월별 경보 결과 (단위:일 수)

예측월	TN	TP	FN	FP
2016.01	14	4	1	1
2016.02	17	1	0	0
2016.12	20	2	0	0
2016.08	12	4	1	5
2016.09	14	2	0	2
2017.01	19	0	1	0
2017.12	6	9	0	5

〈표 4〉 월별 민감도 및 정확도

예측월	민감도(%)	정확도(%)
2016.01	80	90
2016.02	100	100
2016.12	100	100
2016.08	80	72.73
2016.09	100	88.89
2017.01	0	95
2017.12	100	75

실험 결과 예측월의 대부분이 높은 민감도와 정확도를 보이는 것을 확인했다. 2017년 1월이 높은 정확도에 비해 0의 민감도를 보인 것은 단 하루 동안 발생한 특별 이벤트로 인해 발생한 이상 전력 사용량으로 요금적용전력이 갱신되었으나 경보를 울리지 못했기 때문이다.

여름(2016.08.~2016.09.)과 2017년 12월은 낮은 정확도를 가진다. 여름의 경우 요금적용전력과 일별 최대 수요 전력과의 차이가 작으며, 2017년 12월의 경우 장기간의 한파와 같은 특수한 기상 상황이 전반적인 전력 사용량을 크게 증가시켰다. 이는 마진을 두어 경보를 울렸을 때, 마진 내에 요금적용전력을 갱신시키지 않는 일별 최대 수요 전력이 다수 포함됨을 시사한다. 따라서 FP가 다수 발생하였고, 곧 낮은 정확도를 야기하였다. 그러나 여름과 2017년 12월은 높은 민감도를 기록했으며 이는 전력이 갱신된 날에 경보가 울렸음을 나타낸다. 따라서 여름 혹은 2017년 12월과 같은 특수한 기상상황의 경우 제안 기법이 유효함을 확인할 수 있다.

〈표 5〉 월별 기본 요금 절감

예측월	기존 요금(원)	절감액(원)	절감비(%)
2016.01	40,580,044	3,752,448	9.25
2016.02	36,398,745	335,040	0.92
2016.12	37,993,536	1,929,831	5.08
2016.08	34,321,497	1,916,429	5.58
2016.09	34,656,537	2,506,099	7.23
2017.01	39,668,736	0	0
2017.12	44,533,516	6,539,980	14.69

표 5는 식(1) 계산한 기본요금의 절감액과 절감비를 나타낸다. 본 논문에서는 경보가 울린 경우 소비자가 스스로 사용 전력량을 줄였으며, 요금적용전력이 갱신되지 않았음을 가정한다. 앞서 기술한 2017년 1월의 특수한 경우를 제외하고 모든 달에서 기존보다 기본 요금을 절감시킬 수 있었다.

FN이 발생한 경우 요금적용전력은 갱신되었으나 이는 기존에 비해 2016년 1월 2.11%, 8월 0.75%, 2017년 1월 4.41% 증가한 것으로 실제 기본 요금 증가에 큰 영향을 미치지 않았다. 표 5의 절감비가 FN을 통해 증가된 요금적용전력을 반영하고 있음에도 절감액이 큰 것을 확인할 수 있다.

3. 결 론

본 논문에서는 기본 요금 절감을 위한 건물 최대 부하 예측 기법을 제안하였으며 송실대학교의 사례 분석을 통해 기법의 타당성을 검증하였다. 평일 및 주말 전력 사용량 분석을 통해 사용량이 적은 주말을 예측 대상에서 제외하였고, 요금적용전력이 갱신되는 여름과 겨울에 대한 수요 패턴 분석을 진행하여 입력 데이터를 선정했다. 예측 결과를 바탕으로 일별 경보 유무 및 요금적용전력 갱신 여부에 따라 결과를 분류하고 민감도와 정확도를 이용해 모델을 평가하였다. 대부분의 예측 결과는 높은 민감도와 정확도를 보였다.

특수한 기상 상황이 존재한 달이나 여름처럼 FP가 다수 발생한 경우 정확도는 다소 낮아지나 높은 민감도를 가지며, FN이 존재하는 경우 요금적용전력 증가로 절감비가 감소되나 여전히 비용 절감 효과를 갖는 것을 확인할 수 있었다. 주택용을 제외한 현행 전기 요금 제도는 기본 요금 및 전력량 요금으로 이루어지므로, 타 용도 역시 제안한 기법을 적용할 수 있다.

FP의 존재는 자체적으로 피크를 감축하는 소비자의 혼란을 가중시킨다. 따라서 후속으로 FP의 원인인 특수 기상 상황에서의 예측 오차를 줄이는 연구를 진행할 계획이다.

감사의 글

본 연구는 한국전력공사의 2016년 선정 기초연구개발과제 연구비에 의해 지원되었음 (과제번호 : R17XA05-62)

참고 문헌

- [1] 산업자원통상부, “제2차 에너지기본계획”, 2014
- [2] 에너지전환정보센터, “제3차 에너지기본계획 중간설명회 발표자료”, 2018
- [3] 에너지전환정보센터, “제3차 에너지기본계획 권역별 설명회 자료집”, 2018
- [4] 한국전력공사, “기본공급약관”, 2018
- [5] 윤태식, 심규석, “고차원 대규모 데이터 처리를 위한 K-means 클러스터링”, 정보과학회논문지, 18(1), 55-59, 2012
- [6] 백승준, 윤성국, “인공신경망을 활용한 캠퍼스 건물 단기 전력 수요예측”, 대한전기학회 하계학술대회 논문집, 2017
- [7] 한국전력공사, “선택공급약관”, 2018