

에너지 효율 증대를 위한 에너지 사용량 예측과 에너지 수요이전 모델 연구[☆]

A Study on the Energy Usage Prediction and Energy Demand Shift Model to Increase Energy Efficiency

김재환¹ 양세모² 이강윤^{2*}
JaeHwan Kim SeMo Yang KangYoon Lee

요약

현재, 에너지 효율 향상으로 소비감축을 시행하는 새로운 에너지 시스템이 대두되고 있다. 이에 스마트그리드가 확산되면서 계시별 요금제가 확대되고 있다. 계시별 요금제는 계절별 / 시간별로 요금을 다르게 적용해 사용량에 따라 요금을 내는 요금제이다. 본 연구에서는 에너지 전력 사용량 데이터를 예측하기 위해, 온도/요일/시간/계절 등 외부 요인을 고려하고 시계열 예측 모델인 LSTM을 활용한다. 이러한 에너지 사용량 예측 모델을 기반으로 기기별 사용패턴을 분석하여 전력 에너지를 최대부하시간대에서 경부하시간대로 수요이전 함으로써 에너지 사용요금을 절감한다. 기기별 사용패턴을 분석하기 위해서는 시간대별로 기기의 사용량 패턴을 학습 및 분류하는 clustering 기법을 사용한다. 정리하자면, 본 연구에서는 사용자의 전력 데이터 사용량을 기반으로 사용량과 사용 요금을 예측 및 기기별 사용패턴을 분석하고 분석 기반의 맞춤형 수요이전 서비스를 제공함으로써 사용자에게 요금 절감 효과를 가져다 준다.

☞ 주제어 : 에너지, 에너지 사용요금, LSTM, Clustering, Time Series K-means, 수요이전

ABSTRACT

Currently, a new energy system is emerging that implements consumption reduction by improving energy efficiency. Accordingly, as smart grids spread, the rate system by timing is expanding. The rate system by timing is a rate system that applies different rates by season/hour to pay according to usage. In this study, external factors such as temperature/day/time/season are considered and the time series prediction model, LSTM, is used to predict energy power usage data. Based on this energy usage prediction model, energy usage charges are reduced by analyzing usage patterns for each device and transferring power energy from the maximum load time to the light load time. In order to analyze the usage pattern for each device, a clustering technique is used to learn and classify the usage pattern of the device by time. In summary, this study predicts usage and usage fees based on the user's power data usage, analyzes usage patterns by device, and provides customized demand transfer services based on analysis, resulting in cost reduction for users.

☞ keyword : Energy, Energy usage fee, LSTM, Clustering, Time Series K-means, shift of demand

1. 서론

우리나라는 빠른 GDP 성장과 함께 에너지 소비량이 계속해서 증가(그림 1)하고 있다. 이에 따라 에너지 효율

화가 중요시되고 있다. 에너지 효율화는 지속 가능한 에너지 시스템의 연료라고도 불린다. 이렇듯 에너지 효율화를 통하여 환경 가치 뿐만 아니라 경제성의 확보도 가능하다. 효율적인 에너지 활용이 이슈화됨에 따라 일반 가정에서 전력 사용량을 시간단위로 측정 가능한 AMI(Advanced Metering Infrastructure)가 보급되고 있다. 이에 주택용 전기요금은 누진세에서 계절별 / 시간별 요금제로 변화하고 있는 추세이다.


¹ Dept. of Medical Management, Gachon University, Seongnam, 13120, Korea

² Dept. of Computer Engineering, Gachon University, Seongnam, 13120, Korea

* Corresponding author (keylee@gachon.ac.kr)

[Received 10 February 2023, Reviewed 2 March 2023, Accepted 8 March 2023]

☆ 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 한국연구재단의 지원 (NRF-2022R1F1A1069069)과 중소기업기술정보진흥원(맞춤형기술파트너지원) 과제(RS-2022-00155256)로 수행된 연구임.



(출처: bp statistical review of world energy & embe)
 (그림 1) 증가하는 에너지 사용량
 (Figure 1) Increasing Energy Usage

본 연구는 계절별 / 시간별 요금제(표 1)를 적용하여 사용자가 같은 전력량을 사용하더라도 전력 사용요금을 절감할 수 있도록 하는 맞춤형 수요이전 시스템을 제안한다. 이러한 시스템은 아래와 같은 기여를 한다.

1. 미래 에너지 전력 사용량을 예측하기 위해 시계열 예측 모델을 생성한다. 예측 모델은 시계열 데이터 처리에 적합한 LSTM 모델을 활용하였다. 이는 데이터를 시퀀스로 처리하면서, 단기 메모리와 장기 메모리를 나누어서 학습하기 때문에 과거 데이터를 잘 반영한다.
2. 기기별 전력 사용량 패턴 분석을 위해 클러스터링을 수행한다. 이는 지속적으로 전기를 공급해야하는 기기들(ex.냉장고)을 분류할 수 있다. 또한, 시계열 데이터를 클러스터링을 수행해야하기 때문에 TimeSeriesKmeans 클러스터링을 활용하였다. 이러한 클러스터링 알고리즘은 시간에 따른 군집화가 가능하기 때문에 시간정보를 보존할 수 있다.
3. 효율적인 요금 절감을 위한 수요이전 시스템을 구현하였다. 수요이전 시스템은 에너지 요금 절감 뿐만 아니라, 최대수요와 최저 수요의 차이를 축소시켜 부하 평균화와 이용 효율을 향상시켜 준다. 이렇듯 예측 모델을 기반으로 최대부하시간대에서 경부하시간대로 전력 사용량을 수요이전하였다.
4. 수요이전 서비스를 적용한 요금과 기존 요금 비교를 통해 20% 이상의 절감률을 달성하였다. 수요이전한 전력 사용량과 기존 전력 사용량을 계절별 요금제에 적용하여 사용자의 사용요금을 절감한다.

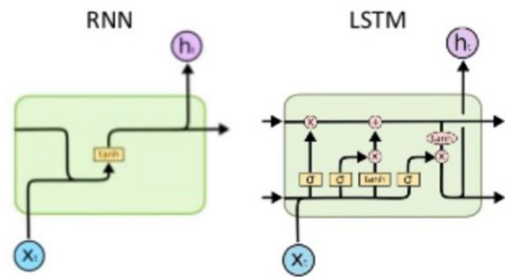
(표 1) 2022 대한민국의 계절별 요금제
 (Table 1) Seasonal/Time Rates in South Korea

| 주택용 계절별/시간대별 전기요금 | | | |
|--------------------|--------------|----------------|-------|
| 구분 | 기본요금 (원/kwh) | 전력량 요금 (원/kwh) | |
| | | 여름, 겨울 | 봄, 가을 |
| 경부하 (22:00~08:00) | 4,310 | 107.0 | 94.1 |
| 중간부하 (08:00~16:00) | | 153.0 | 122.1 |
| 최대부하 (16:00~22:00) | | 188.8 | 140.7 |

2. 관련 연구


2.1 Multivariate LSTM 모델

LSTM은 RNN 의 한 종류이다. RNN(순환신경망)모델은 입력과 출력을 시퀀스(Sequence) 단위로 처리한다. 여기서 시퀀스는 연관된 연속의 데이터를 의미하고, 시계열 데이터 예측에 적합한 신경망 모델이다. 하지만, RNN에서 장기간의 시계열 데이터를 사용할 때 과거 정보가 점차 소실되는 장기 의존성 문제를 해결하기 위해 설계되었다. 여기서 장기 의존성 문제란 입력과 출력 사이의 거리가 멀어질수록 정확도가 줄어드는 문제이다.



(그림 2) LSTM 모델 구조
 (Figure 2) LSTM Model Structure

LSTM(그림 2)은 RNN의 hidden state에 cell-state를 추가함으로써 데이터의 기간이 길어지더라도 과거의 정보를 잃지 않도록 구현된 모델이다. 여기서 cell-state는 과거의 정보를 변화시키지 않고 그대로 유지시켜주는 역할을 수행한다.




(그림 3) Multivariate LSTM 모델 구조
(Figure 3) Multivariate LSTM Model Structure

LSTM모델은 과거 값을 사용하여 미래에 대한 값을 하나만 예측한다면, Multivariate LSTM모델(그림 3)은 변수 자체의 이전 값을 사용할 뿐만 아니라 다른 변수(온도, 강수량, 습도 등)의 이전/현재 값도 사용하여 변수의 미래 값을 예측할 수 있다. 본 연구의 데이터셋에는 각 기기의 전력 사용량뿐만 아니라 외부요인에 대한 변수들도 포함하고 있다. 따라서 앞서 언급한 데이터 예측 모델을 사용하는 것이 타당하다.

2.2 최대수요 이전(Load Shifting)

현재, 에너지 낭비를 줄이고 효율을 높이는 전력수요 관리의 중요성이 커지고 있다. 전력 시장 가격은 역동적이며 전력 공급 및 수요의 거시적 변동에 따라 결정된다. 전기 부하가 최대 수요에 도달하면 전기 시장 가격이 최대가 되므로 부하 평준화가 필요하다. 수요관리(DSM: Demand Side Management)는 소비자의 에너지 사용 패턴을 합리적인 방향으로 유도하여 에너지 소비를 최적화하고 전기 비용을 줄일 수 있다.



(그림 4) 수요이전 구조
(Figure 4) Load Shifting Structure

최대수요 이전(그림 4)은 이러한 수요관리 유형 중 하나이다. 이는 하루 최대부하시간에서(피크 시간)에서 경부하시간으로 수요를 전환하는 전기 부하 관리(DR-Demand Response) 기술이다. 단순히 전기수요를 다른 시간 간격으로 이동하는 것으로 총 소비는 일정하게 유지되지만, 최대수요와 최저수요의 차이를 감소시켜 부하를 평준화시킨다. 뿐만 아니라, 계시별 요금제에 의해서 본 연구의 목표인 사용자 측면에서 전기 에너지 비용을 절약할 수 있다.

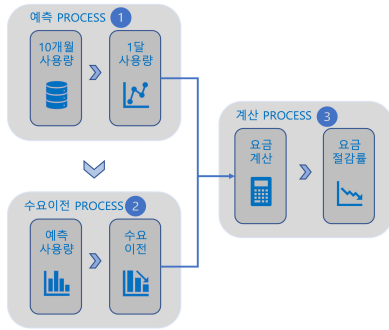
2.3 TimeSeries K-means 클러스터링

수요이전을 하기 위해서는 클러스터링이 필요하다. 클러스터링은 비지도학습으로 유사한 성격을 가진 개체를 묶어 그룹으로 구성하는 것이다. 여기서 K-Means 클러스터링은 클러스터 개수 k와 초기값을 입력하여 각 데이터의 그룹을 할당해 나간다. 이는, 데이터 사이의 거리를 구해서 군집마다 중앙에 가장 가까운 데이터끼리의 패턴을 찾는다. 하지만 본 연구는 시계열이 추가된 3차원 데이터를 사용하기 때문에 Time Series K-means를 사용하는 것이 타당하다. 이는 시간축을 기준으로 중심점을 추출하면 각 군집별로 시간 축에 따라 중심점의 변화를 알 수 있다.



(그림 5) Euclidean과 DTW 차이
(Figure 5) Difference in Euclidean and DTW

K-Means에서는 데이터사이의 거리를 계산할 때 Euclidean방법을 사용한다. 이는 각 벡터의 원소 간의 차이를 제공하여 합한 값이다. 하지만, 같은 시간을 기준으로 계산하기 때문에 시계열 데이터에는 적합하지 않다. 이에 해결방법은 DTW(Dynamic Time Warping)로 계산하는 것이다. 이는 동적 시간 왜곡 거리 측정법(그림 5)으로써 속도 또는 길이를 반영하여 움직임이 다른 두 시계열 간의 유사성을 측정한다. 동일한 시간전상의 데이터 뿐만 아니라 주변 데이터까지 비교함으로써 정확도를 높여준다.



(그림 6) 연구 과정 구성도
(Figure 6) Research Process Structure

3. 예측모델을 이용한 수요이전 알고리즘

3.1 연구 계획

연구는 아래의 방법(그림 6)으로 진행된다.

1. 1~10월(10개월) 데이터를 학습시켜 예측 모델을 생성하고 11월(1개월) 값을 예측한다.
2. 기기별 클러스터링을 통해 예측한 11월 데이터를 수요이전한다.
3. 계시별 요금제를 적용하여 기존 11월 사용요금과 수요이전한 사용 요금 계산 후, 2가지 사용요금 비교를 통한 절감률을 확인한다.

(표 2) 연구 알고리즘의 Pseudo-code
(Table 2) Pseudo-code for Research Algorithm

```

Algorithm: 수요이전을 통한 요금절감
1 Input: devices Ds
2 Output: Savingsrate
3 Definition of peak hours by T
4  $T_{(07\sim12)}$ :IMax &  $T_{(23\sim06)}$ :IMid &  $T_{(13\sim22)}$ :ILight
5 For D in Ds {
6   TrainD = M(1~10)LSTMtrainbyD(usage)
7   TestD = M(11)LSTMtestbyD(usage)
8   ClusterD = ClusteringbyTestD
9   ClusterD ← TimeseriesKmeans (clusters = 2,
   metric = dtw) in result is 0 OR 1 {
10     if ClusterDis0
11       S0D.append(TestD)
12     Else
13       S1D.append(TestD)}
14 Case D1 Max:
15   if ClusterDis0
16     { S0D*188.8
17     Else
18     S1D*107.0}
19 Total =
   TestDMax*188.8+TestDMid*153.0+TestDLight*107.0
20 Shifting =
   (S0D*188.8+S1D*107.0)+TestDMid*153.0+TestDLight*107.0
21 Savingsrate = (Total-Shifting) / Total * 100
    
```

본 연구는 (표 2)와 같이 12개의 기기데이터를 사용하여 Savingsrate(요금절감률)라는 결과물을 산출하고자 한다. 먼저, T(시간)에 따라 부하시간대를 정의해준다. 여기서 Max는 최대부하시간, Mid는 중간부하시간, Light는 경부하시간대를 의미한다. D(기기)별로 TrainD(학습데이터)를 M_(1~10)(1월~10월)까지 LSTM 모델로 학습시켜 M₍₁₁₎(11월)의 TestD(예측데이터)를 구해준다. 기기별 TestD(예측데이터)를 가지고 수요이전을 하기 위해 TimeseriesKmeans 클러스터링을 통해 ClusterD(0,1)값을 추출한다.

Max(최대부하시간)에 해당하는 S_{0D}(클러스터가 0인 예측데이터)와 SID(클러스터가 1인 예측데이터)를 추출한다. 이에 S_{0D}에는 최대부하시간대 요금을 S_{1D}에는 경부하시간대 요금을 적용하여 계산한다. 이러한 요금을 가지고 Total(기존요금), Shifting(수요이전요금), Savingsrate(요금절감률)를 산출할 수 있다.

3.2 사용 데이터

Kaggle데이터의 미국 뉴욕 Smart Home 데이터(표 3)를 사용하였다. 주택의 전력사용량을 기기별로 1분마다 1년치를 kw로 측정되었다. 기기는 12개, 변수는 11개를 가지고 있다.

우리나라의 요금을 적용하기 위해서 시차를 적용하여 시간별 요금표를 재정의(표 4)해주었다. 기존 최대부하시간인 16시~22시를 미국시간에 적용하여 07~12시로 변경해주었다.

(표 3) 에너지 데이터셋 정보
(Table 3) Energy Datasets Information


| Smart Home Dataset (kw) | |
|-------------------------|--|
| Index (503909) | 2016.01.01~2016.12.16 (1min) |
| Device (12) | Dishwasher, Home office, Fridge, Wine cellar, Garage door, Barn, Well, Microwave, Living room, Furnace, Kitchen, Solar |
| Feature (11) | 실내온도, 외부온도, 습도, 가시성, 압력, 풍속, 운량, 풍향, 강수량, 이슬점, 강수확률 |

(표 4) 최대부하시간 재정의
(Table 4) Override Load Time

| | |
|--------|-------------------------------|
| Light | 13,14,15,16,17,18,19,20,21,22 |
| Medium | 23,00,01,02,03,04,05,06 |
| Peak | 07,08,09,10,11,12 |

3.3 예측모델

11월 한달의 전력사용량을 예측하기 위해서 Multivariate LSTM모델을 사용하였다. 여기서 1월부터 10월까지의 시계열 데이터와 11개의 변수를 학습시켜 예측(그림 8)하였다. epoch은 20을 두고 학습시켰으며 학습을 반복할수록 오차율이 감소(그림 7)하는 것을 확인할 수 있다.



(그림 7) Epoch에 따른 Train loss
(Figure 7) Train loss according to Epoch


Multivariate LSTM모델의 성능평가는 변수를 사용하지 않은 Univariate LSTM과 비교해보았다. 다변량 LSTM모델이 일변량 LSTM모델보다 성능이 우수하다(표 5)는 것을 확인할 수 있다. 11월 실제 전력사용량은 28978.59kWh, 예측 전력사용량은 28299.85kWh로 높은 정확도를 가지고 있다.

(표 5) 일변량 모델, 다변량 모델의 성능비교


(Table 5) Performance Comparison of Univariate and Multivariate Models

| Model | MSE | RMSE | MAE | MAPE | R ² |
|-------------------|-----------------|-------|-------|-------|----------------|
| | LSTM_Univariate | 0.051 | 0.214 | 0.143 | 0.238 |
| LSTM_Multivariate | 0.011 | 0.102 | 0.046 | 0.096 | 0.979 |


수요이전은 최대부하시간의 전력사용량을 당일 경부하시간대로 옮겨야 하므로 하루 예측 데이터(그림 9)를 추출하였다. 최대부하시간에 전력사용량이 많은 것을 확인할 수 있다.



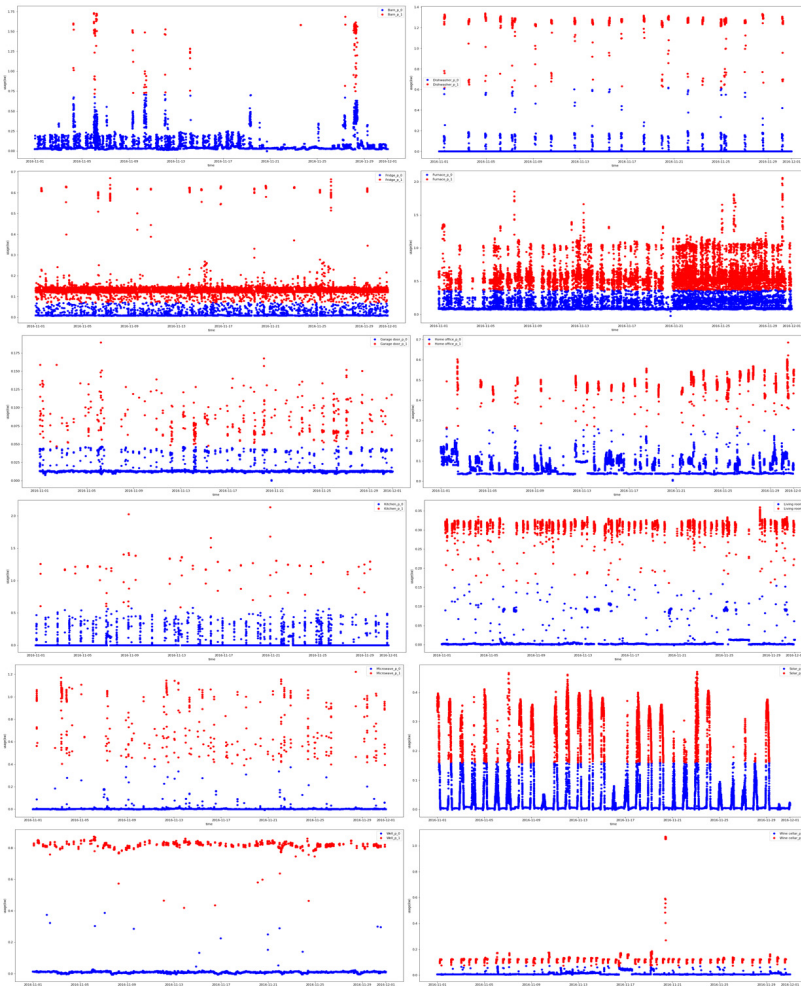
(그림 8) Multivariate LSTM 모델 구현 (kw)
(Figure 8) Implementing Multivariate LSTM Models



(그림 9) 11/1의 하루 예측 그래프 (kw)
(Figure 9) Daily Forecast Graph of 11/1



(그림 10) 기기별 11월 사용량 예측 그래프
(Figure 10) Graph of November Usage Forecast by Device



(그림 11) 기기별 Timeseries K-means Clustering 그래프
(Figure 11) Timeseries K-means Clustering Graph by Device

3.4 기기별 클러스터링

효율적인 수요이전을 위하여 총전력에서 수요이전이 아닌 기기별로 수요이전을 하기위해 기기별로 클러스터링을 진행하였다. 예를 들면, 냉장고와 같이 계속해서 대기전력을 필요로 하는 기기들이 있기 때문이다. 기기별로 클러스터링을 하기 위해 앞에 사용했던 **Multivariate LSTM**모델을 기기의 개별 데이터에 사용하여 기기별 11월 한달예측 모델(그림 10)을 구현한다. 이렇게 추출한 기기별 예측 데이터들을 사용하여 수요이전을 진행하였다.

따라서 수요이전할 사용량을 추출하기 위해서 **Timeseries K-means** 를 사용하여 기기별 클러스터링을 진행하였다. 클러스터의 개수 **K=2**로 정의해준다. 이는 각 데이터 사이의 거리(DTW)를 구하여 군집마다 중앙에 가까운 데이터끼리의 패턴을 찾는다. 이렇게 클러스터링을 진행하면 경부하시간대로 수요이전할 전력량과 최대부하시간대에 남아야할 전력량 2개의 클러스터로 구분(그림 11)되어진다.


위 그래프의 빨간색 점들이 수요이전할 전력량이다.

그래프에서 최대부하시간대에 해당하는 빨간점들만 추출하여 수요이전을 진행하였다. 11월 그래프이므로 여름/겨울용 요금표를 적용하여 최대부하시간대에서 파란색 점들은 최대부하 요금인 188.8원을 빨간색점들은 경부하 시간 요금인 107.0원을 적용하여 계산해보았다. 11월 1일부터 30일까지 하루마다 수요이전 수행 전 전력요금과 수요이전 수행 후 전력요금을 비교하여 절감률을 계산하였다. 1달 절감률의 평균은 29.48%임을 알 수 있다.


3.5 수요이전

총 사용량 예측데이터의 11/1의 최대부하시간대 전력 사용량(그림 12)의 빨간 그래프에서 수요이전할 전력량을 빼면 파란색 그래프처럼 전력량이 줄어든 것을 확인할 수 있다.

최대부하에서 빠진 전력들은 기존 최대부하시간대(07~12)에서 9시간을 더하여 경부하시간대(13~22)로 이전하였다. 기존 그래프(빨간색)보다 수요이전을 완료한 그래프(파란색)에서 사용전력들이 골고루 분포되었음을



(그림 12) 11/1 최대부하시간의 수요이전
(Figure 12) 11/1 Load Shifting for maximum load time



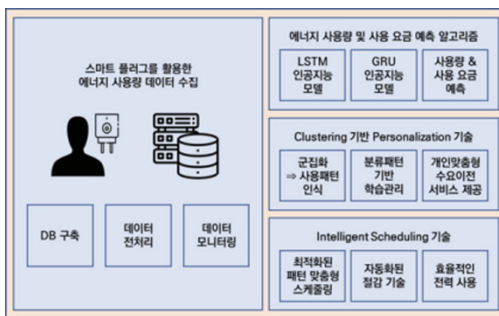
(그림 13) 수요이전 완료한 11/1 그래프
(Figure 13) 11/1 graph completed Load Shifting

확인(그림 13)할 수 있다. 이는 최대수요와 최저수요의 차이를 감소시켜 부하를 평균화할 뿐만 아니라, 하루에 같은 전력량을 사용하더라도 더 적은 에너지 요금을 지불함으로써 효율적인 에너지 사용이 가능하다.

4. 결 론

본 논문에서는 kaggle데이터의 뉴욕 에너지 데이터를 사용하여 요금절감을 위한 수요이전 시스템을 구현하는 방법에 대하여 연구하였다. 수요이전 시스템을 구현하기 위하여 시계열 데이터 처리에 적합한 **Multivariate LSTM** 모델을 사용하였다. 시계열 예측은 과거 정보를 기반으로 미래 가치를 예측하는 것으로 광범위한 과학 및 비즈니스 응용 분야에서 중요한 의미를 갖는다. 1분 단위로 11월 한달 간의 에너지 사용량을 예측하였다. 예측 결과는 **Univariate LSTM**모델보다 성능이 우수함을 앞서 확인하였다. 이러한 예측 모델을 가지고 사용 요금 예측 모델을 구현하여 요금 절감을 또한, 확인할 수 있었다.

위에서 구현한 예측 모델을 가지고 개인에게 맞춤형 수요이전을 제안하는 **Clustering** 기반 **Personalization** 기술을 구현하였다. 이는 클러스터의 수용가별/사용유형별 에너지 사용패턴을 학습 및 분류하는 알고리즘이다. 이러한 알고리즘은 수요이전할 전력량과 잔류 전력량에 대한 기준점을 제시해준다. 기준점을 중심으로 분류 패턴 기반의 효율적 전력 사용을 위한 맞춤형 수요이전 시스템을 설계(그림 14)하였다.



(그림 14) 맞춤형 수요이전 시스템 구성도

(Figure 14) Custom Load Shifting system configuration diagram

본 연구에서 제안하는 수요이전 시스템은 사용자의 개별적인 기기사용에 대한 요구 시나리오는 연구에 포함

하지 않았다. 기기별 최소 전력 요구 사항을 분석하기 위해 기기별 전력 사용 클러스터링을 진행하였으며, 클러스터링 결과값을 토대로 수요이전 시나리오를 수행하였다.

고객 맞춤형 수요이전 제안 시스템을 기반으로 전력 사용 최대부하시간대의 사용량을 분산하여 전력수급 안정 및 에너지 자원절약, 사용자에게도 효율적인 전력 사용과 자동화된 수요이전 시스템을 제공할 수 있다. 하루 동안 똑같은 전력을 사용함에도 우리는 모델을 통해 요금을 절감할 수 있는 것을 확인하였다.

이렇듯 예측 모델에 기반한 수요이전 제안 시스템의 적용을 통하여 글로벌 기술 경쟁력 확보 및 국내 기업 기술 강화뿐만 아니라, 에너지효율화 사업의 확산 및 소비자의 에너지 지출비용 절감, 전력 수요절감, 친환경 에너지 전환과 에너지 최적화 정책 및 국가에너지 총량 관리 등 여러가지 측면에서 기대할 수 있을 것이다.

References

[1] Fazle Karim, Somshubra Majumdar, Houshang Darabi, Samuel Harford. "Multivariate LSTM-FCNs for Time Series Classification", Neural Networks, Augustpp. 237-245, 2019. <https://doi.org/10.1016/j.neunet.2019.04.014>

[2] Vishal Kuber, Divakar Yadav, Arun Kr Yadav, "Univariate and Multivariate LSTM Model for Short-Term Stock Market Prediction", May 2022. <https://doi.org/10.48550/arXiv.2205.06673>

[3] Sen Zhou, Kwei-Jay Lin, Chi-Sheng Shih "Device clustering for fault monitoring in Internet of Things systems", IEEE, December 2015. <https://doi.org/10.1109/WF-IoT.2015.7389057>

[4] Ma, Q., Chen, C., Li, S., & Cottrell, G. W., "Learning Representations for Incomplete Time Series Clustering", Proceedings of the AAI Conference on Artificial Intelligence, 35(10), 8837-8846, 2021. <https://doi.org/10.1609/aaai.v35i10.17070>

[5] Mel Keytingan M.ShapiaNor. AzuanaRamlilLilik J.Awalinc, "Energy consumption prediction by using machine learning for smart building: Case study in Malaysia", Developments in the Built Environment, March 2021. <https://doi.org/10.1016/j.dibe.2020.100037>

- [6] Amri INaziraAbdul, Khaliq. ShaikhbAbdul SalamShahc, Ashraf Khalila, “Forecasting Energy Consumption Demand of Customers in Smart Grid Using Temporal Fusion Transformer (TFT)”, Results in Engineering, Available online 20 January 2023. <https://doi.org/10.1016/j.rineng.2023.100888>
- [7] Haoyi Zhou, Shanghang Zhang, Jieqi Peng, Shuai Zhang, Jianxin Li, Hui Xiong, Wancai Zhang, “Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting”, AAAI, 2021. <https://doi.org/10.48550/arXiv.2012.07436>
- [8] RobertoChiosaaMarco, Savino. Piscitellia, ChengFan, Alfonso Capozzolia, “Towards a self-tuned data analytics-based process for an automatic context-aware detection and diagnosis of anomalies in building energy consumption timeseries”, Energy and Buildings, 1 September 2022. <https://doi.org/10.1016/j.enbuild.2022.112302>
- [9] Antonio Liguori, Romana Markovic, Martina Ferrando, Jérôme Frisch, Francesco Causone, Christophvan Treeck, “Augmenting energy time-series for data-efficient imputation of missing values“, Applied Energy, 15 March 2023. <https://doi.org/10.1016/j.apenergy.2023.120701>
- [10] K.Purna Prakash, Y.V.Pavan Kumar, Ch. PradeepReddy, D. JohnPradeep, AymenFlah, Ali NasserAlzaed, Ahmad AzizAl Ahamdi, Sherif S.M.Ghoneim, “A comprehensive analytical exploration and customer behaviour analysis of smart home energy consumption data with a practical case study”, Energy Reports, pp. 9081-9093, November 2022. <https://doi.org/10.1016/j.egyr.2022.07.043>

● 저 자 소 개 ●



김 재 환(JaeHwan Kim)
2023년 가천대학교 의료경영학과(경영학사)
2023년 가천대학교 컴퓨터공학과(공학사)
관심분야 : 인공지능, 머신러닝
E-mail : jhsmart98@gachon.ac.kr



양 세 모(SeMo Yang)
2022년 가천대학교 컴퓨터공학과(공학사)
2022년~현재 가천대학교 컴퓨터공학과 석사과정
관심분야 : 인공지능, 머신러닝
E-mail : tpah20@gachon.ac.kr



이 강 윤(KangYoon Lee)
1986년 연세대학교 전자공학과 (공학사)
1996년 연세대학교 전자계산학과 (공학석사)
2010년 숭실대학교 IT정책경영학과 (공학박사)
1991년~2016년 한국 IBM 연구소(연구소장)
2016년~현재 가천대학교 컴퓨터공학과 교수
관심분야 : 인공지능, IoT, 빅데이터, 클라우드, 커그너티브컴퓨팅
E-mail :