

전력소비행위 변화를 위한 전력소비패턴 분석 및 적용

장민석¹ · 남광우¹ · 이연식^{1*}

Analysis and Application of Power Consumption Patterns for Changing the Power Consumption Behaviors

MinSeok Jang¹ · KwangWoo Nam¹ · YonSik Lee^{1*}

^{1*}Professor, School of Computer Info. & Comm., Kunsan National University, Kunsan, 54150 Korea

요약

본 논문에서는 사용자의 전력소비패턴을 추출하고 사용자의 환경 및 감성을 적용한 최적 소비패턴을 모델링한 후, 이 두 가지의 패턴을 비교 적용하여 사용자의 전력소비행위 변화를 통한 전력의 효율적 사용 방법을 제시한다. 유의미한 소비패턴을 추출하기 위하여 벡터 표준화 및 이진 데이터 변환방법을 사용하고, k-평균 군집화를 적용한 앙상블의 합집합에 대한 학습과 k값에 따른 지지도를 적용하였으며, 최적 전력소비패턴 모델은 상대적 평균 소비량이 적은 앙상블 합집합에 대한 학습 결과를 기준으로 강제 및 감성 제어를 적용하여 생성하였다.

실험을 통하여 전력소비행위 변화 유도대상 추출 시 클러스터의 수와 일치율 간의 상관관계를 파악함으로써, 사용자의 의도에 따라 강제 및 감성 기반의 제어가 가능하도록 클러스터의 수나 크기 조절을 통한 다양한 윈도우에 적용할 수 있음을 검증하였다.

ABSTRACT

In this paper, we extract the user's power consumption patterns, and model the optimal consumption patterns by applying the user's environment and emotion. Based on the comparative analysis of these two patterns, we present an efficient power consumption method through changes in the user's power consumption behavior. To extract significant consumption patterns, vector standardization and binary data transformation methods are used, and learning about the ensemble's ensemble with k-means clustering is applied, and applying the support factor according to the value of k. The optimal power consumption pattern model is generated by applying forced and emotion-based control based on the learning results for ensemble aggregates with relatively low average consumption.

Through experiments, we validate that it can be applied to a variety of windows through the number or size adjustment of clusters to enable forced and emotion-based control according to the user's intentions by identifying the correlation between the number of clusters and the consistency ratios.

키워드 : 전력소비패턴, 분류 기반 패턴 탐지, k-평균 군집화, 강제 및 감성제어, 사용자 행위 변화

Keywords : Power consumption patterns, Classification-based pattern detection, K-means clustering, Forced and emotion-based control, User's behavior change

Received 16 March 2021, Revised 24 March 2021, Accepted 1 April 2021

* Corresponding Author YonSik Lee(E-mail: yslee@kunsan.ac.kr, Tel:+82-63-469-4553)

Professor, School of Computer Info. & Comm., Kunsan National University, Kunsan, 54150 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.4.603>

print ISSN: 2234-4772 online ISSN: 2288-4165

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

국내외적으로 전력소비량의 급격한 증가에 따라 전력 사용의 효율성 및 절감 기술에 큰 관심을 가지게 되었다. 전력 사용 효율성 및 절감은 전력 인프라의 비효율성에 의해 발생하는 낭비요소를 제거하는 기술적 방법과 사용자의 행위 및 감성을 적용한 비기술적 방법을 적용함으로써 얻을 수 있다[1]. 그러나 기술적 방법은 낭비의 완화가 일부 가능하지만 효과적 제어는 불가능하며, 비기술적 방법은 전력 사용자의 행위패턴 분석 및 감성을 적용하는 체계적이고 실질적인 방법이 부재한 실정이다[1,2].

최근 지능형 전력 계량 인프라(AMI)의 스마트 계량기를 이용한 실시간 전기 소비 정보를 이용한 전기 절도 탐지에 대한 연구는 활발히 이루어지고 있으나[2,3], 사용자의 행위 변화를 이용한 절전기술에 대한 연구는 미흡한 실정이다. 또한, 최근 정부의 스마트 계량기 보급정책을 기반으로 이들을 통하여 수집된 데이터로 위약 탐지 또는 예방에 대한 연구를 수행하고 있지만, 이들 연구는 탐지를 위한 데이터의 불균형 문제로 인한 어려움을 내포하고 있으며, 사용자에게 의한 직간접적인 소비 절감 방법은 포함하지 않고 있다. 본 논문은 스마트 계량기를 통해 수집한 전력소비 데이터스트림을 분석하여 사용자의 전력소비패턴을 추출하고, 사용자의 환경(시간, 위치, 온도 등)과 감성을 적용한 최적 소비패턴을 모델링한 후, 이 두 가지의 패턴을 비교 분석하여 사용자의 행위 변화 유도를 통한 전력소비 절감 방법을 제안한다.

본 논문 구성은 다음과 같다. 2장에서는 분류 기반의 전력소비패턴 탐지와 관련된 기존 연구들의 적용 기술 특징들을 분석하고, 3장에서는 사용자의 전력소비패턴 추출 및 변환 등의 전처리 과정을 설명한다. 4장에서는 사용자의 전력소비행위 변화 유도대상 추출을 위한 실험과 그 결과를 분석 제시하고, 5장에서 결론을 맺는다.

II. 분류기반 전력소비패턴 탐지

본 논문에서 사용하고자 하는 전력소비패턴 추출은 분류 기반 탐지 방법[4]을 사용하며, 이는 사용자의 일반적 전력소비패턴을 추출하고, 동일 환경에서의 최적 소비패턴을 모델링하여, 최적 소비패턴을 벗어나는 사

용자 소비패턴을 분류하여 행위 변화 유도에 적용하는 것이다. 기계 학습과 데이터마이닝 기법들의 적용이 가능한 이 방법은 약간의 오추출율이 발생하는 문제점이 있지만[4,5], 본 논문에서 구현하고자 하는 사용자의 전력소비패턴을 최적화하기 위한 목적에는 적용 가능성과 활용 가치가 있다.

분류 기반 탐지 방법은 주로 SVM(Support Vector Machine) 모델[6,7]을 사용하는데, 이는 사용자의 전력소비패턴 데이터를 이용하여 SVM 모델을 학습하고, 분석 결과 최적 소비패턴과 차이가 발생하는 데이터를 규칙 기반으로 세분화 시켜 분류하는 방법이다. SVM 모델을 적용한 비기술적 전력 절감 방법은 SVM 모델에 의해 주어진 기간 내의 각 전원에 대한 최적 소비 전력량과 사용자의 일반적 소비 전력량의 차이를 계산하여 사용자의 전력소비에 대한 행위 변화를 유도함으로써 이루어진다. 참고논문[6]에서는 전력 사용자의 환경(사용 전원 수, 사용자 수, 시각, 온도 등) 변수를 입력 변수로 사용하는 결정 트리 모델을 통하여 최적 패턴을 예측하고, 예측된 최적 소비패턴을 입력 변수들과 함께 SVM 모델의 입력으로 사용하여 소비패턴의 차이를 결정할 수 있으나, 이는 수집되는 소비패턴 데이터의 양에 따라 정확도가 차이가 나는 문제점이 있다. 참고논문[8]에서는 전력소비량의 평균과 편차, 비정상 소비 정도 등을 계산하여 사용자의 전력소비량 정보를 구하고, 퍼지 c-mean clustering를 통하여 전력소비패턴을 군집화하고, 각 군집과 사용자의 소비패턴과의 거리를 나타내는 퍼지 멤버십 행렬의 차이 값을 이용하여 사용자의 소비패턴의 변화를 추출한다. 그러나 이 방법은 장기간의 전력소비 이력 데이터가 필요한 한계를 지닌다[9]. 이와 같이 분류 기반 탐지에 대한 기존 연구는 전력소비패턴을 추출하기 위한 데이터가 학습되거나 소비 이력을 필요로 하지만, 본 논문에서 제안하는 전력소비패턴 추출 방법은 전력 사용자의 전력소비 데이터스트림의 표준화된 벡터 값을 학습하여 추출하고, 강제 및 감성제어를 적용한 최적 전력소비패턴 모델과의 차이 값 발생 예측을 기반으로 행위 변화 유도대상을 추출하는 것이다.

III. 전력소비패턴 추출 및 변환

스마트 계량기에 의해 측정되는 사용자의 전력소비

데이터스트림에서 소비패턴을 추출하는 방법은 패턴 추출의 성능 향상과 적용이 용이한 장점이 있다. 스마트 계량기는 일일 전기 소비량을 1시간 간격으로 일정하게 측정하므로 24차원 벡터로 표시가 가능하지만, 본 논문에서는 실험실 사용자의 재실 시간인 09:00 ~ 19:00시 사이의 전기 소비량을 30분 단위의 20차원 벡터로 표시하고, 실험실 내의 3개의 전원에서 스마트 미터기를 통해 수집한 1개월간의 데이터를 사용한다. 데이터는 전원 ID, 측정 시간, 전원 사용 시간(소비 전력량)을 포함한다. 전원 사용시간은 30분 단위의 20개의 데이터로 변환하고, 15분미만 사용시간은 0으로 산정하여 벡터 표준화를 수행한다. 다음 그림 1은 실험대상 전원 3개 중 전원 #1에 대한 4주간의 사용자 전력소비 데이터를 30분 간격의 이진 데이터스트림으로 변환하여 그래프로 표시한 것이다.

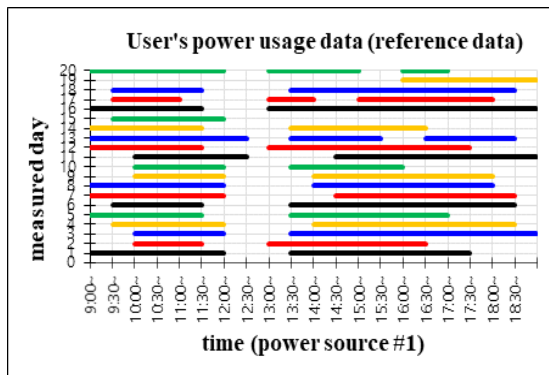


Fig. 1 Graphic representation of power consumption data for power source #1

표준화된 벡터 값을 이용하여 학습한 후 사용자의 전력소비패턴을 추출하고, 강제 및 감성제어를 적용한 최적 전력소비패턴 모델과 비교하여 차이 값에 의한 행위 변화를 유도할 수 있는 대상을 탐지하는 알고리즘은 다음과 같다. 여기서, 강제제어는 시간대 별 상대적으로 소비량이 적은 경우에 강제적으로 전원을 제어하는 것이며(반대의 경우에도 적용 가능), 감성제어는 위치 또는 용도에 따른 기준 조도 대비 실제 조도가 높게 측정되는 시간대에 대한 사용자의 감성을 적용하여 자동 제어함을 의미한다.

Algorithm Pattern Detection

Input : Power consumption vectors

Output : User's behavior change

Process :

a : Construction of clustering model representing power consumption pattern for each power source #1~#N.

b : Transformation of each clustering model to a binary stream.

c : Applying with the optimal power consumption pattern represented by a binary stream.

d : Difference detection & providing information on behavior change.

전력소비패턴에 대한 데이터 분포 모델을 구성하기 위하여 3개의 전원 사용에 대한 4주간의 표준화된 벡터 값을 학습 데이터로 설정하고, 3개의 각 전원에서 발생하는 소비 데이터를 각 그룹으로 구분하고 이들에 해당하는 데이터를 Algorithm Pattern Detection의 a와 같이 k-mean clustering을 수행하여 입력 데이터로 사용한다. 표 1은 측정대상 3개의 전원 각각의 사용 데이터에 대한 k-mean clustering(k=2, 3, 4)을 통한 클러스터 구성 예를 보인다.

Table. 1 Example of the experimental clusters

Number of cluster	Example of clustering
2ea. (power source #1)	11111 10001 11111 11000
3ea. (power source #2)	00011 11 001 111 11 11100
4ea. (power source #3)	00000 00011 11111 11100

최적 전력소비패턴이 주어지면, 최근접 클러스터를 찾아 최적 전력소비패턴이 해당 클러스터의 영역 밖에 있을 때 전력소비패턴 변화대상으로 판단하는데, 이때 k-mean clustering에서 k값의 크기에 따라 비교대상 소비패턴 영역이 너무 크거나 작아질 수 있으므로 유의미한 변화대상을 추출하기가 어려울 수 있다[9,10]. 따라서 본 논문에서 추출하고자 하는 사용자의 행위 변화 유도대상을 찾기 위하여 적용하는 사용자 전력소비패턴과 최적 전력소비패턴 모두에 손쉽게 적용 가능한 이진 데이터스트림을 분류 값으로 사용한다. 이진 데이터스트림으로의 변환은 사용자의 매일 전력소비패턴이 스

트림 형태로 생성되므로, 그에 대한 데이터 분포를 클러스터링 모델로 구성하여 전력소비 여부를 이진 데이터 스트림으로 변환한다.

또한, 유의미한 소비패턴 추출을 위하여 각 전원 별로 사용 요일이 동일한 데이터 4개를 해당 전원의 앙상블로 정하고, k-mean clustering을 적용하여 전원 별 요일별 앙상블의 합집합을 구한다[10,11]. 이때, k값이 2일 경우 사용자 소비 전력 데이터에서 패턴의 추출 범위가 상대적으로 크기 때문에 유의미한 소비패턴 추출이 어려우며, k값이 4일 경우에는 패턴 추출 범위가 상대적으로 작아져서 최적 패턴 대비 일치 패턴이 많이 추출될 수 있으므로[12, 13], 상대적으로 유의미한 변화대상을 추출하기 위하여 k값에 따라 지지도(k=2: 0.25, k=3: 0.5, k=4: 0.75)를 적용한다. 다음 표 2는 전원별 요일별 소비전력에 대한 앙상블 합집합을 나타낸다. 본 논문에서는 유의미한 대상을 추출하기 위하여 k=3인 클러스터링을 적용한 후의 앙상블 합집합을 학습하여 사용자의 전력소비패턴으로 사용한다.

또한, 최적 전력소비패턴 데이터는 전력소비패턴 데이터 학습 결과와 5일간의 강제적 최적 소비패턴을 적용하여 생성한다. 소비패턴 데이터는 상대적 평균 소비량이 적은 k=4(지지도 0.75)인 앙상블 합집합을 기준으로 설정하고, 시간별 상대적 소비량을 적용한 강제 제어와 기준 조도를 적용한 감성 제어를 적용하여 생성한다.

Table. 2 Summary of the ensemble's combination for each power source

		power sources		
day	k	# 1	# 2	# 3
mon	2	11111 11011 11111 11111	00011 11111 11111 11110	00000 00111 11111 11111
	3	11111 10001 11111 11111	00000 00011 11111 11100	00000 00011 11111 11111
	4	01111 00001 11111 11110	00000 00011 11111 11100	00000 00011 11111 11100
tues	2	11111 10011 11111 11110	11111 11011 11111 11111	00111 10011 11111 11111
	3	11111 10010 11111 11110	11111 10010 11111 11110	00111 10001 11111 11111
	4	11111 10000 11111 11000	11111 10000 11111 11000	00111 10000 11111 11111
wed	2	11111 11001 11111 11111	11111 10001 11111 11111	00111 11111 11111 11110
	3	11111 10001 11111 11110	11111 10001 11111 11111	00111 11000 11111 11100

		power sources		
day	k	# 1	# 2	# 3
	4	01111 10001 11111 11110	11111 10001 11110 01110	00111 10000 01111 10100
thur	2	11111 11001 11111 11111	01111 10011 11111 11110	00111 11001 11111 11111
	3	01111 10000 11111 11110	00111 10001 11111 11100	00011 10000 11111 11110
	4	00111 00000 11111 11100	00111 10000 11111 10100	00011 10000 01111 11100
fri	2	11111 10011 11111 10000	11111 11011 11111 11100	00111 11001 11111 00000
	3	11111 10001 11111 10000	11111 10001 11111 11100	00111 11000 11000 00000
	4	01111 10001 11000 00000	01111 10000 01110 00000	00111 11000 11000 00000

소비패턴 변화대상을 추출하기 위하여 Algorithm Pattern Detection의 a ~ c 단계에서 사용자의 소비패턴을 참조 윈도우로 구성하고, 최적 소비패턴을 최적 윈도우로 구성한다. 고정된 최적 윈도우에 참조 윈도우를 비교하여 윈도우 내에 있는 0과 1의 분포가 지지도 이상 다르게 나타나는 부분을 소비행위 변화 유도 가능 부분으로 설정한다. 두 비교 윈도우 사이의 데이터 분포 비교는 상대적으로 간단하다. 전력소비패턴의 특성상 각 윈도우의 크기를 동일하게 설정하므로 모 비율과 그 차이에 대한 가설 검정이 필요 없이 두 윈도우의 데이터 분포를 검증할 수 있다. 따라서 유의 수준을 특정하여 소비 형태 변화 유도를 위한 대상의 추출이 가능하다.

IV. 전력소비행위 변화 유도대상 추출 실험 및 분석

본 장에서는 실험을 통하여 전력 사용자들의 소비패턴 변화를 유도하여 전력소비를 최적화하기 위한 제안 방법의 유효성을 검증한다.

본 실험에서 사용하는 전력소비 데이터는 요일 별로 동일하게 주어진 시간 동안의 측정 데이터를 사용하고, 실험의 편의성을 위하여 요일 별 하루 20개의 최적 전력 소비패턴 데이터에 대해 k-mean clustering을 수행하여 최적 전력소비패턴을 생성한다. 생성된 최적 전력소비패턴은 k개의 클러스터들의 합으로 구성되며, 사용자 소비 데이터에 대하여 동일한 방법을 적용한 소비패턴

을 추출하여 비교한 결과의 차이를 행위 변화 유도대상으로 판정한다.

제안된 전력소비패턴 변화 유도 방법을 위한 시험 데이터는 요일 별 4개의 사용자 소비 참조 데이터를 학습하여 구성하고, 정상으로 예측할 수 있는 비율인 Specificity를 사용하여 측정하였다. 학습 모델 구조는 4개층(각층의 노드 수는 16, 8, 8, 16개)으로 구성하고, 파라미터들은 디폴트값으로 설정하였다. 히든층의 활성화 함수는 Relu 함수, 출력층의 활성화 함수는 Sigmoid 함수를 사용하였고, 시험 데이터 셋의 정확도 향상을 위한 overfitting을 제거하기 위하여 dropout rate는 출력층을 포함한 모든 층에서 학습 시 60%, 평가 시 1로 설정하였다.

본 논문에서 클러스터링 방법은 클러스터링 영역을 중심과 반경으로 표현함으로써 영역 비교를 수월하게 할 수 있는 k-mean clustering을 사용하였으며, 클러스터의 수 k값을 2, 3, 4로 변화시키면서 두 전력소비패턴을 추출하였다. 클러스터의 수 k는 비교의 정확성과 밀접한 관계를 가지는데, k값이 커질수록 클러스터 반경이 작아지므로 두 패턴의 비교 차이가 커지고, k값이 작을수록 그 반대현상이 발생한다. 본 논문에서는 20개로 표현된 하루의 전력소비 데이터에 대한 무의미한 작은 크기의 노이즈 문제 발생을 제거하고 패턴 비교의 효율적 모델 구성을 위하여 클러스터 수를 2, 3, 4로 구분하여 실험하였다.


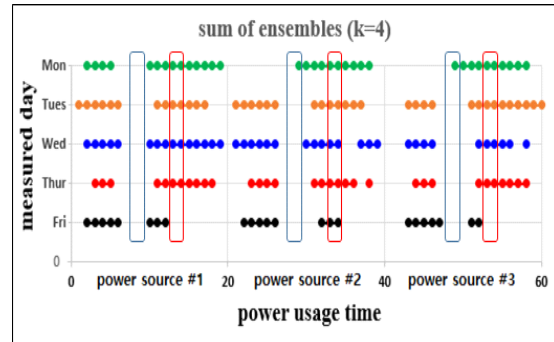



Fig. 2 Ensemble's combination after clustering(k=3) for each power source

본 논문에서는 유의미한 대상을 추출하기 위하여 표 2의 k=3인 경우의 클러스터링을 적용한 후의 앙상블 합집합을 학습하여 사용자의 전력소비패턴으로 사용하며, 이는 그림 2와 같다.



(a)



(b)

Fig. 3 (a) Ensemble's combination(k=4) (b) Optimal power consumption patterns with forced and emotion-based control

최적 전력소비패턴 데이터는 4주간의 소비패턴 데이터 학습 결과와 5일간의 강제적 최적 소비패턴을 적용하여 생성한다. 4주간의 소비패턴 데이터는 상대적 평균 소비량이 적은 k=4인 앙상블 합집합(그림 3(a))을 기준 데이터로 설정하였다. 최적 전력소비패턴 추출을 위하여 사용한 임계값은 강제 제어를 통하여 실험실 내의 정해진 인원의 소비 행태와 조도에 대한 사용자의 감성을 적용하여 설정하였다. 임계값은 실험의 편의성을 위하여 설정한 것이므로, 전력소비 환경에 따른 차이로 인하여 절대 값으로 사용하기에는 부적절하다.

본 논문에서는 전력소비량이 상대적으로 적은 시간대(12:30~13:30, 그림 3(a)의 파란색 표시)에 대한 강제 제어와 기준 조도 대비 실제 조도가 높게 측정되는 시간대(14:30~15:30, 그림 3(a)의 붉은색 표시)에 대한 감성 제어를 적용하여, 그림 3(b)와 같은 최적 전력소비패턴을 생성하여 사용하였다.

사용자의 전력소비 데이터로부터 소비패턴 변화를

위한 부분을 추출하기 위하여, 4주간의 매 요일 별 데이터 집합 4개를 4개의 앙상블 모델로 설정하고, 모든 앙상블 모델에서 최적 전력소비패턴의 각 클러스터의 환경을 벗어날 경우 행위 변화 유도대상으로 판정한다. 이와 같은 방법을 적용한 행위 변화 유도대상 범위는 다음 그림 4와 같다. 이때, 각 앙상블 모델의 클러스터들의 합집합과 최적 전력소비패턴과 비교하게 되므로, 앙상블 모델의 생성 시점과 개수에 따라 적용 목적 대비 다소 부정확한 결과를 유도할 수도 있다.




Fig. 4 Range of target capable of inducing behavior change

그림 5는 1번 전원에 대한 specificity 기준 클러스터 수에 따른 요일별 최적 전력소비패턴 대비 사용자 전력소비패턴의 일치율을 나타낸다.




Fig. 5 Consistency ratios of user's power consumption patterns versus optimal power consumption patterns

그림 6은 실험에서 사용한 3개의 전원 모두에 대한 클러스터 수에 따른 각각의 일치율을 평균과 비교한 결과를 나타낸다.

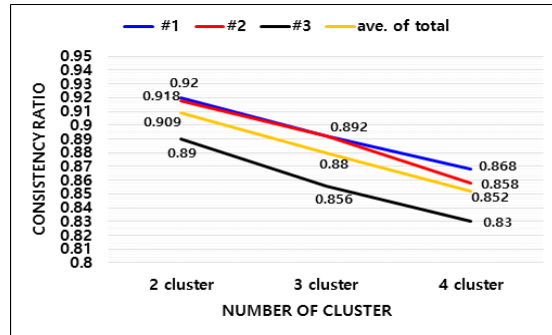


Fig. 6 Comparison of consistency ratios by number of clusters for all power sources

실험 결과에서 알 수 있듯이 클러스터의 수가 클수록 일치율이 낮아지며, 일치율이 작을수록 사용자의 전력 소비행위 변화대상이 많음을 의미한다. 본 논문에서는 사용자 행위 변화를 유도하기 위한 최적 전력소비패턴을 설정할 때 k=3 클러스터링 방법을 적용하였으므로, 사용 전원 및 요일에 대한 평균 일치율인 0.88을 적용하면 전력소비 단위 시간의 약 12%point에 대하여 사용자의 소비행위 변화를 유도할 수 있음을 나타낸다. 실제 그림 2의 k=3인 실제 전력소비 학습 데이터와 그림 3(b)의 최적 전력소비패턴을 비교하면, 45개(3클러스터 * 3 전원 * 5일)의 클러스터들 중 11개 클러스터가 일치함 (일치율 24.4%point)을 알 수 있다. 이는 전력소비 데이터를 이진 데이터스트림으로 표시 하였으므로 전력소비 단위 시간에 대한 행위 변화 유도대상에 대한 on/off와 off/on 제어를 포함하는 2배의 수치로 거의 정확하게 산출됨을 알 수 있다.

V. 결 론

본 논문은 전력 사용자의 행위 및 감성을 적용한 비기술적 방법을 적용하여 전력 사용의 낭비를 줄이고자 하는 제안으로, 지능형 전력 계량 인프라의 스마트 계량기를 통해 수집한 전력소비 데이터스트림으로부터 추출한 전력소비패턴과 사용자의 환경과 감성을 적용한 최적소비패턴 모델을 비교 분석하여, 사용자의 전력소비 행위 변화를 유도함으로써 전력의 효율적 사용 및 소비 절감 방법을 제시하였다.

이를 위하여, 전력소비 데이터에 대한 벡터 표준화 및

이진 데이터 변환방법을 사용하고, k-mean clustering을 적용한 앙상블의 합집합에 대한 학습과 k값에 따른 지도도를 적용하여 유의미한 소비패턴을 추출하였다. 최적 전력소비패턴 모델은 상대적 평균 소비량이 적은 k=4(지도도 0.75)인 앙상블 합집합에 대한 학습 결과를 기준으로 강제 및 감성 제어를 적용하여 생성하였다. 행위 변화 유도대상 추출에 있어서 제안 방법은 학습 데이터의 크기에 따른 클러스터 수와 환경적 변수에 일치율이 차이가 있을 수 있지만, 실험 결과를 통하여 전력소비행위 변화대상 추출 시 클러스터의 수와 일치율 간의 상관관계를 파악함으로써 전원의 개수나 사용 시간 변수 등과 관계없이 클러스터의 수나 크기 조절을 통한 다양한 윈도우에 적용이 가능함을 알 수 있다.

향후 전력소비기기의 특성에 따른 환경변수와 사용자의 행위패턴 및 감성 적용에 대한 연구와 패턴 추출에 대한 다양한 변수들을 적용한 학습 기반의 정확도 향상을 위한 연구가 요구된다.

ACKNOWLEDGEMENT

This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (2018R1D1A1B07051045) and supported by Academic Research Fund of Kunsan National University in 2020.

References

- [1] C. Chahla, H. Snoussi, L. Merghem, and M. Esseghir, "A Novel Approach for Anomaly Detection in Power Consumption Data," *Proc of ICPRAM 2019*, pp. 483-490, 2019.
- [2] P. Jokar, N. Arianpoo, and V. C. M. Leung, "Electricity Theft Detection in AMI using Customers' Consumption Patterns," *IEEE Trans. Smart Grid*, vol. 7, no. 1, pp. 216-226, 2016.
- [3] J. K. Noh and C. H. Park, "A Method to Detect Contract Violations by Analyzing Power Usage Patterns," Master Thesis, Chungnam National University Computer Science, pp. 1-28, 2018.
- [4] F. Wang, K. Li, L. Zhou, H. Ren, J. Contreras, S. Miadrea, and P. S. Catalão, "Daily Pattern Prediction based Classification Modeling Approach for Day-Ahead Electricity Price Forecasting," *International Journal of Electrical Power Energy Systems*, vol. 105, no. 2019, pp. 529-540, 2019.
- [5] T. G. Kim, J. I. Kim, and C. H. Park, "Anomaly Pattern Detection on Streaming Data," *Proc. of the KIISE 2018*, vol. 2018, no. 12, pp. 665-667, 2018.
- [6] A. Jindal, A. Dua, K. Kaur, M. Singh, N. Kumar, and S. Mishra, "Decision Tree and SVM-based Data Analytics for Theft Detection in Smart Grid," *IEEE Trans. Ind. Information*, vol. 12, no. 3, pp. 1005-1016, 2016.
- [7] S. J. Kwon, S. H. Kim, O. S. Tak, and H. H. Jeong, "A Study on the Clustering Method of Row and Multiplex Housing in Seoul using K-Means Clustering Algorithm and Hedonic Model," *Journal of Intelligence and Information Systems*, vol. 23, no. 3, pp. 95-118, 2017.
- [8] S. S. Kim, "Variable Selection and Outlier Detection for Automated K-means Clustering," *Communications for Statistical Applications and Methods*, vol. 22, no. 1, pp. 55-67, 2015.
- [9] T. G. Kim and C. H. Park, "Detection of Power Contract Violations using an Anomaly Pattern Detection Method on Power Consumption Data Streams," *Journal of the KIISE*, vol. 47, no. 5, pp. 504-512, 2020.
- [10] V. Fortin, M. Abaza, F. Anctil, and R. Turcotte, "Why Should Ensemble Spread Match the RMSE of the Ensemble Mean?," *Journal of Hydrometeorology*, vol. 15, no. 4, pp. 1708-1713, 2014.
- [11] A. Ahmad and L. Dey, "A k-mean clustering algorithm for mixed numeric and categorical data," *Data & Knowledge Engineering*, vol. 63, no. 2, pp. 503-527, 2007.
- [12] C. H. Park, T. G. Kim, J. I. Kim, S. M. Choi, and G. H. Lee, "Outlier Detection By Clustering-Based Ensemble Model Construction," *Journal of KIISE*, vol. 7, no. 11, pp. 435-442, 2018.
- [13] D. J. Kim and D. Sharma, "Implementation of Decision Based Fruits Protection System Using Classification and Clustering Techniques," *Asia-pacific Journal of Convergent Research Interchange, HSST*, vol. 2, no. 4, pp. 23-31, 2016.



장민석(MinSeok Jang)

연세대학교 전자공학과 공학사
연세대학교 대학원 전자공학과 공학석사
연세대학교 대학원 전자공학과 공학박사
군산대학교 공과대학 컴퓨터정보통신공학부 정교수
※관심분야: IoT 시스템, 드론 응용, 딥러닝



남광우(KwangWoo Nam)

충북대학교 컴퓨터과학과 이학사
충북대학교 대학원 전자계산학과 이학석사
충북대학교 대학원 전자계산학과 이학박사
2001년~2004년 한국전자통신연구원 선임연구원
2004년~현재 군산대학교 컴퓨터정보통신공학부 정교수
※관심분야: 모바일, 컨버전스, GIS, 빅데이터마이닝



이연식(YonSik Lee)

전남대학교 전자계산학과 이학사
전남대학교 대학원 전자계산학과 이학석사
전북대학교 대학원 전자공학과 전산응용공학 전공 공학박사
군산대학교 공과대학 컴퓨터정보통신공학부 정교수
※관심분야: 에이전트 시스템, S/W 미들웨어