JDCS
디지털콘텐츠학회논문지
Journal of Digital Contents Society
Vol. 20, No. 1, pp. 189-197, Jan. 2019

유효 및 무효 전력 변화를 이용한 비접촉식 가전기기 부하 식별

홍 철 의[1] · **박 경 모**[2*]
[1]상명대학교 휴먼지능정보공학과
[2]가톨릭대학교 컴퓨터정보공학부

The Nonintrusive Appliance Load Monitoring using Real and Reactive Powers

Chuleui Hong[1] · **Kyeongmo Park**[2*]
[1]Department of Human Intelligence Information, Sangmyung University, Seoul 03016, Korea
[2]Department of Computer Science and Information Engineering, The Catholic University of Korea, Bucheon 14662, Korea

[요 약]

분할 측정 알고리즘을 이용한 비접촉식 개별 가전기기 부하 식별이란 각 가정으로 공급되는 전력의 변화를 분석해서 사용하는 가전제품들의 에너지 소비량을 유추하는 기술이다. 본 연구에서 제시하는 기술을 사용하여 소비자에게는 각 제품별 에너지 사용량 및 시간대를 알려 주어 대기전력 차단, 기기 이상 여부, 절전형 제품 구매 등 에너지 절감 방법을 제시할 수 있으며 사업자에게는 에너지 효율이 높은 기기 개발에 대한 자료를 제공하고 국가 정책 및 공익사업에 활용할 수 있는 방안을 제시할 수 있다. 본 논문에서는 사용되는 총 전력량으로부터 유효 및 무효 전력량을 측정하여 각 가전기기의 전력 시그너처와 비교하여 사용되고 있는 가전기기를 식별한다. 7가지 서로 다른 가전기기에 대한 실험 결과 평균 기기식별 정확도는 95.3%로 우수한 성능을 나타내었다.

[Abstract]

The nonintrusive appliance load monitoring analyzes the changes in power supplied to each home and identifies the currently used household appliances using energy disaggregation. The presented technology in the paper give information to the consumers on their energy usage and saving methods such as standby power cut off, abnormality of devices, and purchase of energy saving products, etc. It also provides the appliance manufacturers with development data on energy-efficient devices and suggests ways to utilize it in national policy and public services. We measure the total amount of electric power used, and compare it with the power signature of each electric appliance to identify the appliances being used. Experimental results on seven different home appliances show that the average identification accuracy is 95.3%.

색인어 : 가전기기 식별, 전력 분할 측정, 비접촉식 부하 측정, 유효 무효 전력, 에지 변화량

Key word : Appliances Identification, Disaggregation, NILM, Real and Reactive Power, Steady-State Change

http://dx.doi.org/10.9728/dcs.2019.20.1.189

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-CommercialLicense(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.

Received 14 November 2018; **Revised** 25 November 2018
Accepted 20 January 2019

***Corresponding Author; Kyeongmo Park**

Tel: +82-2-2164-4365
E-mail: kpark@catholic.ac.kr

Ⅰ. 서 론

비접촉식 개별 가전기기 부하 식별 (NILM, Nonintrusive load monitoring) 이란 가정으로 공급되는 전력의 변화를 분석해서 사용하는 가전 제품 들은 물론 제품별 에너지 소비량을 유추하는 기술이다[1][2]. 이러한 NILM 기술을 장착한 미터기는 전력회사에서 소비자 가정의 다양한 가전기기 사용량을 조사할 때 사용된다. 이 방법은 각 가전제품에 측정기를 장착하여 전류 소비량을 측정하는 것 보다는 비용 면에서 절약이 되지만 개인정보 보호 문제가 있기도 하다.

NILM은 디지털 AC 모니터가 집으로 들어가는 인입선에 연결되어 있고 전력 및 전류 변화량이 측정되고 정규화 과정을 거친 후 기록 된다. 이후 군집 분석기가 개개의 가전기기의 작동 여부를 판별한다. 한 예로 60와트 전구가 켜지고, 100와트 전구가 그 후에 켜지고, 후에 60와트 전구가 꺼지고 다음에 100와트 전구도 꺼지면 비접촉식 개별가전기기 부하 식별 기기는 해당 전력 변화를 감지해서 60와트와 100와트 전구가 켜지고 꺼지는 과정을 모두 구분해서 60와트 전구를 언제부터 얼마동안 100와트 전구를 언제부터 얼마동안 쓰였는지를 알 수 있다.

비접촉식 개별가전기기 부하식별 시스템은 유효전력(real power) 뿐만 아니라 무효전력(reactive power)도 측정 할 수 있다. 따라서 그림 1에서 보듯이 전기모터는 전원을 켜고 끄는 순간 무효전력에서 큰 차이가 나지만 히터는 거의 차이가 없으므로 무효전력에 관한 자료는 사용 가전 기기를 판별 할 수 있는 또 다른 방법을 제공한다.

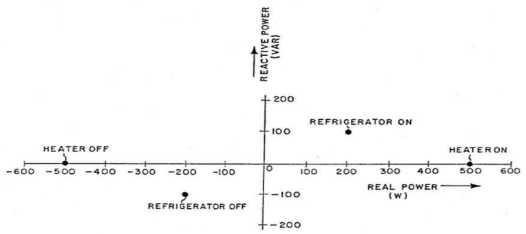

그림 1. 냉장고와 히터의 무효/유효 전력
Fig. 1. The real/reactive power of a refrigerator and heater

비접촉식 개별가전기기 부하 식별 시스템은 그림 2에서와 같이 여러 종류의 가전기기의 전력 사용을 연속적인 개별 기기의 변화로 감지 할 수 있다. 이러한 가전기기는 유한 상태 기계처럼 모델 되어 에너지 분할 측정 (Energy Disaggregation) 알고리즘을 통하여 사용되고 있는 기기를 판별한다.

에너지 분할 측정 (Energy Disaggregation) 알고리즘은 통합적 시설에서 발생된 전체적인 에너지 신호로부터 통계적인 접근으로 현재 사용되고 있는 각 가전 제품들의 개별 전력 사용량에 관한 데이터를 추출하는 방법이다. 이러한 방법은 기존의 스마트 미터를 포함한 다른 접근법들 보다 적은 비용 및 설치에 대한 부담이 적으며 다음과 같은 3가지 혜택을 제공한다[3].

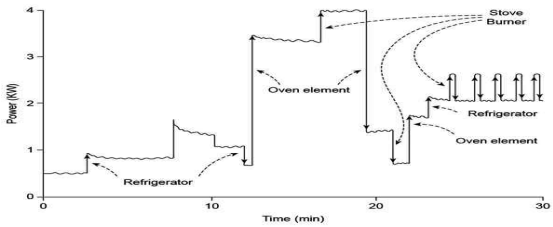

그림 2. 개별 가전기기 부하 식별 모델
Fig. 2. The Disaggregation of electric appliances

1) 소비자 측면에서의 혜택

개별 가전 제품의 사용 전력량에 관한 정보는 소비자 본인들이 에너지 사용이 많은 특정 제품과 사용 시간대에 따른 에너지가 낭비되는 경우를 알게 되어 과도한 사용을 자제하게 하며 비절전형 제품에 대해서는 절전형 제품을 구매하여 대체할 방법을 고려하게 할 것이다. 대부분의 소비자들은 본인들이 얻을 이득이 자명해질 때까지 그러한 장치들에 대한 투자를 꺼려하는 경향이 있다. 특정 가전 제품의 사용 전력량 정보를 제공하는 시스템을 도입함으로써 거주지 영역에서 뿐만 아니라 상업지 영역에서도 에너지 절감을 효과적으로 이룰 수 있다.

2) 연구 및 개발 혜택

에너지 효율에서의 혁신은 개별적인 사용 정보에 의해 가속될 것이다. 연구소 및 학계에서는 개별적인 가전 제품들의 전기 사용량에 관련된 데이터를 이용하여 절전형 제품 개발에 대한 연구를 진행할 수 있게 하며 기업들도 에너지 효율이 높은 가전기기 사용으로 발생하는 비용 절감을 계산할 수 있고, 투자 전략이나 마케팅 전략을 구축할 수 있게 한다.

3) 공익적 사업 및 정책에 관한 혜택

공익사업 및 정책 결정자는 시간에 따라 사용되는 에너지의 소비 패턴을 전략적으로 이용해서 개별적인 소비자 및 지역별로 좀 더 구체적인 사용 시간대 권장 및 절전형 제품을 제공할 수 있다. 따라서 시장의 효율적인 투자를 늘릴 수 있고 궁극적으로 더 많은 에너지 감소 목표를 달성할 수 있다. 또한 상업지 및 거주지마다 소비되는 에너지 사용 패턴을 분석해서 에너지 수요량을 매년마다 또는 계절마다 예측할 수 있으므로 정책적으로 적절한 에너지 프로그램들을 검토할 수 있고 지원금을 더 효율적으로 분배 할 수 있다.

특정 가전 기기에 대한 전력량 데이터를 확보할 수 있는 방법은 크게 네 가지가 있다.

1) 플러그 장치

가장 기본적인 방법으로 플러그 장치들을 개별적인 기기들에 꽂아 놓는 것이다. 하지만 이런 접근법은 여러 가지 단점들을 지니고 있다. 일단 플러그 장치들은 고비용인데다가 설치 및 관리도 쉽지 않다. 그 외에 플러그 모니터의 이동에 대한 제한으로 설치에 어려움을 겪을 수 있다. 또한 지속적으로 작동하기

위해 더 많은 에너지 및 하드웨어 설치를 요구한다.

2) 스마트 가전 제품

스마트 기기들의 에너지 절감 효과는 아직 불확실하다. 스마트 기기들은 백색 가전제품에 국한 될 것이며 에너지 절약이 실체화될 때까지 걸리는 시간이 매우 길며 판매가 또한 높다. 더 나아가서, 이런 스마트 기능들은 전형적으로 유틸리티 수요 증가에 영향을 미칠 수 있으나 이에 대한 활용법이 없는 경우에 그 효과는 미미할 수밖에 없다.

3) 가구별 모니터링 장치

가구단위의 모니터링 장치들은 이미 시장에 나와 있다. 하지만 이런 것들은 비용이 비쌀 뿐만 아니라 설치도 매우 어렵고 제대로 된 기능 수행이 어려우며 아파트와 같은 특정 종류의 건축물과 호환되지 않을 수 있다. 또한, 이런 하드웨어 해결책들은 기술적인 개선이 힘든 문제점들을 가지고 있으며 제조에 소모되는 자원들은 많을 수밖에 없어 그것을 작동시키기 위한 에너지 소모도 불가피하다.

4) 스마트 미터

반면에 스마트 미터들은 최저 비용과 최저 노동력이라는 장점을 가지고 있다. 분할 측정 기술 개발에 대한 비용과 미래에 얻을 수 있는 이득을 고려할 경우, 스마트 미터들이 고효율을 낼 수 있을 것으로 예상되어 향후 사용량이 증가할 것으로 기대된다.

Ⅱ. NILM에서의 부하 식별 알고리즘

분할 측정 알고리즘은 가전제품들에 대한 물리적인 측정을 통해 구축된 가전제품별 소요 전력에 대한 시그니처(Signatures) 비교 기술을 사용한다. 임의의 신호들이 감지되었을 때 기존의 시그너처 정보들과 비교하여 가장 유사한 패턴을 찾는다.

이런 통계적 접근은 전력이나 주기와 같은 전기 데이터 특성을 활용한다. 전력에 있어서 유효 전력과 무효 전력은 둘 다 유용하다. 유효 전력과 함께 무효 전력은 60 Hz이하의 샘플링 주기를 갖는 저주기에서 수집된 데이터를 이용한 알고리즘에서 비슷한 유효 전력을 가진 가전기기들을 구분하는 데에 도움을 준다[4][5][6]. 그 이유는 가전제품들은 유효 전력과 무관하게 서로 다른 무효 전력을 가지고 있기 때문이다.

2-1 데이터 수집 빈도

출력 레벨에 대한 상세 및 선호도는 주기에 따라 달라진다. 이상적으로 개발자들은 고주기(60 Hz이상의 샘플링 주기) 범위에서 연구를 하고 있으며 0.1W 차이로 넓은 범위의 다양한 가전제품들을 분할 측정하고자 한다. 이것이 중요한 이유는 가정에 있는 매우 전력량이 작은 가전 기기들까지 감지할 수 있게 해주기 때문이다. 이런 높은 상세도에 필요한 조건들은 저 주기에서 수집하는데 어려움을 겪는다. 대체로 대부분의 알고리즘들은 미시적인 자료 양이 적어질수록 성능이 더 좋아진다. 이는 가정집에서 전력 소요량이 큰 가전제품들을 감지할 수 있지만, 작은 가전제품들을 감지하는 데에 어려움을 겪을 수밖에 없기 때문이다.

데이터 수집 빈도에 따라서 다양한 알고리즘과 인식 될 수 있는 가전기기들이 다르게 나타난다. 일반적으로 수집빈도가 낮으면 가전기기를 인식하는데 많은 시간이 걸리고 수집빈도가 높으면 실시간으로도 인식이 가능하다. 데이터 수집 빈도에 따라서 두 가지의 두드러진 특징을 발견할 수 있다. 첫째, 고주기 방법은 항상 켜져 있는 가전제품들도 확인할 수 있는 능력을 제공해줄 수 있지만 저주기 방법으로는 어렵다. 이는 많은 장치들은 고유의 파형을 가지고 있고 60 Hz이상의 샘플링 주기들은 실제 교류 전류와 전압 파형들을 볼 수 있으며 hamonic 특성을 이용할 수 있기 때문이다. 둘째, 가전제품을 분류하는 데에 있어서 60 Hz 이하의 저주기 방법은 분류에 필요한 충분한 데이터를 얻기 위해서는 더 많은 시간이 걸린다. 그러므로 일예로 저주기로 수집된 데이터는 사용된 기기 분류를 위해서 일주일에서 몇 달까지의 데이터가 필요할 수도 있다. 본 연구에서는 저주기 범위의 초당 20번의 샘플링을 수행하였다.

2-2 부하 식별 알고리즘의 성능

특정 시구간(t) 동안 가전기기들로부터 집계된 총 전력소비량($P(t)$)로부터 각 기기의 특정 전력 신호(P_i)를 분해하여 가전기기의 종류 및 동작 상태를 식별한다.

$$P(t) = p_1(t) + p_2(t) + p_3(t) + \ldots + p_n(t) \qquad (1)$$

비접촉식 형태의 전력모니터링을 이용하여 수집된 가전기기별 전력 사용 데이터를 학습 및 훈련을 통해 각 기기별 전력 사용 특성을 분석하며 시그니처를 생성하여 개별기기를 식별한다. 가정 내 전체 전력 사용량을 측정하는 것만으로 사용되는 가전기기들을 식별할 뿐만 아니라 각 기기가 소비하는 전력량을 추정, 기기들의 동작 상태를 판별하는 최적의 추론 시스템을 개발한다. 확률적 기법과 최적화 기법을 결합하여 알고리즘의 기기식별 정확도(Accuracy) 향상시킨다.

그림 3에서와 같이 최적화 기법(Optimization approach)은 기기특성 데이터베이스에 분류된 데이터 셋 또는 로드 시그니처들(Labeled or disaggregated data sets or Load signatures)을 저장한 후 가전기기들에 관한 전력 수요들(power demands)의 가능한 모든 조합을 계산하여 데이터 셋으로부터 측정된 로드 $P(t)$와 가장 근접한 기기 전력 시그널들의 조합을 탐색하여 에러(Error)를 최소화한다. 새로운 로드로부터 추출된 특성 v를 데이터 셋으로부터의 트레이닝 인스턴스 v_n의 클래스로 할당한다.

$$Class(v_n) = \min \| v_n - v \|$$

(2)

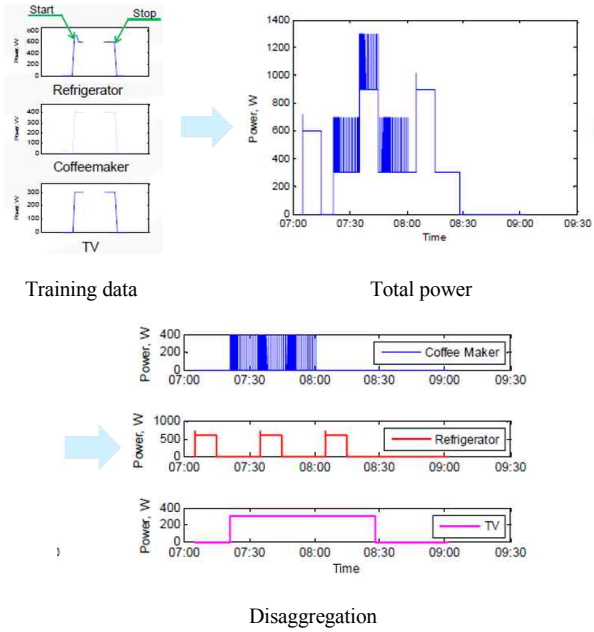

그림 3. 기기별 전력신호 분해 예시
Fig. 3. The example of power signature disaggregation for each appliances

최적화 기법은 알려진 장치들의 가능한 모든 조합으로 이루어진 정보를 기반으로 기기를 식별하므로 알려지지 않은 로드들은 식별 알고리즘의 성능을 저하시킬 수 있으므로 확률적 기법(Probabilistic approach)을 이용하여 최적화 방법을 보완한다. 각 기기의 전력사용 상태 변화, 즉 에지(Steady-state change, edge)를 측정하고 미리 저장되어 있는 탐지된 특성(Detected features)에 대응시킴으로써 기기들의 동작과 연관된 이벤트를 식별한다. 통계적 모델의 학습을 통하며 새로운 로드에서의 기기 예측 정확도를 높인다.

다음은 본 연구에서 수행한 알고리즘에 대한 내용을 자세히 기술한다.

2-3 유/무효 전력 평면상에서 분류

측정된 기기별 전력사용 데이터를 확률적 레벨 기반 분배 알고리즘을 통해 학습하여 분석한 뒤 각 기기에 대한 분류자(classifier)를 생성하고 전력 로드를 분해하기 위하여 분류자들을 조합하여 복합 로드에 대한 새로운 분류자를 생성한다.

유효전력(P)와 무효전력(Q) 평면상에서 분류를 실행하며 분류자를 생성하기 위하여 빈도수 히스토그램(histogram) 사용한다. 조합된 분류자를 이용하여 총 전력 로드를 기기 레벨 전력 사용 추정치로 분해하여 기기를 분류하고 각 기기의 종류와 동작 상태를 식별한다. 각 기기별 일정 시간구간의 전력 데이터를 대상으로 220V 전압에 대한 정규화(Normalization)를 수행하고, *P-Q*평면상에서 각 기기별 전력 데이터에 대해 1 와트(Watt) 단위의 2D 히스토그램을 생성한다.

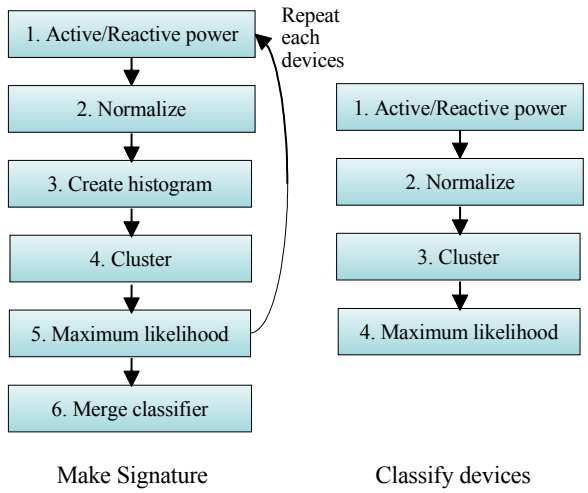

그림 4. 유/무효 전력 평면상에서 분류
Fig. 4. The classification on a P-Q Plane

그림 4에서와 같이 알고리즘의 수행 과정은 다음과 같다.

1) 각 기기 상태들에 대한 클러스터(Clusters)를 구성, 클러스터들의 수와 위치를 계산하여 기기 상태수를 결정하기 위하여 히스토그램 시닝(thinning) 프로세스를 적용한다.
   - 유효전력(P)와 무효전력(Q), 전압(V)을 측정한 후 220V 전압에 대해 정규화를 수행한다.
   - 빈도수 0.1% 미만의 샘플은 제거한다.
   - 지역 피크(local peaks)를 계산하기 위하여 인접 셀(Cell)들보다 높은 값을 가지는 지역 피크를 탐색, 인접 셀들의 값이 0이 될 때까지 피크 값을 증가시키고 인접 셀들의 값을 감소시키는 과정을 반복한다.
   - 계산된 각 피크는 기기 상태에 대한 최빈 가능 측정치(Most likely measurement)를 나타내며 피크들의 수는 기기 상태수를 결정한다.

2) 각 히스토그램 셀을 분류하고 상태 셀들에 대한 확률 질량 함수(Probability Mass Function:PMF)를 계산한다.

3) 각 기기별로 위의 단계를 반복하고, 각각에 대한 최대 공산 분류자(Maximum likelihood classifier)를 계산한다.

4) 각 기기 상태들의 가능한 모든 조합을 계산하고, 각 기기의 확률 질량 함수를 이용하여 각 조합에 대한 결합 확률(Joint Probability)을 계산함으로써 복합기기에 대한 단일 분류자 생성한다.

5) 조합된 분류자를 이용하여 총 전력 로드를 기기별 전력 로드 추정치로 분해하여 기기들의 종류와 동작 상태를 식별한다.

- 측정된 전력 데이터에 대해 정규화를 수행하고 조합된 분류자를 이용 각 기기에 대한 최빈 가능 상태(Most likely state)를 분류한다.
- 히스토그램을 이용하여 각 기기의 전력 사용 추정치를 찾는다.

2-4 에지 상태변화를 이용한 분류

측정된 기기별 전력 사용 데이터를 나이브 베이지안 방법에 기반을 두어 학습하며 각 기기의 최빈 가능 상태(Most likely state)를 찾기 위하여 연산을 수행한다. 측정된 기기별 전력 사용 패턴을 분석하여 기기의 상태들(states)을 구분하고 각 기기의 전력 사용 상태 변화를 나타내는 에지 (Steady-state change, edge)를 측정하여 이용한다. 탐지된 에지가 있을 때 기기가 특정 상태일 확률을 계산하기 위해 베이즈의 이론(Bayes' theorem)을 적용하여 분류자를 생성한다. 다음 각 기기별 분류자들을 훈련시키고 훈련된 분류자들을 이용하여 전체 전력 사용량으로부터 기기들을 분해한다. 각 기기들의 상태는 완전히 독립적인 것으로 가정한다.

분류 알고리즘을 요약하면 다음과 같다.

1) 상태 집합 S는 각각의 기기(D_n)의 상태를 나타낸다. 즉, 알려진 상태 s_N에 있는 각 기기 D_n에 대한 분해(disaggregated) 상태를 표시한다.

$$S = \{D_1 = s_1, \ldots\ldots, D_n = s_N\} \tag{3}$$

2) 최빈 가능 해(Most likely solution)를 찾기 위해 트레이닝 데이터로부터 각 상태의 확률 계산한다.

- $Pr(S)$: 특정 상태 S에 있을 확률로, N개의 기기가 있고 각 기기는 독립적이라 할 때 가전기기D_n이 특정 상태 s_N 일 때의 곱으로 계산한다.

$$\Pi_{n=1}^{N} Pr(D_n = s_N) \tag{4}$$

- $Pr(S)$을 추정하기 위하여 1 와트(watt) 단위의 순간 전력 샘플(instantaneous power samples) 히스토그램 생성한다. 히스토그램은 각 가능한 상태 변화에 대해 생성한다.
- 기기의 순간 전력 사용에 대한 확률 밀도 함수(Probability Density Function) 계산 한다.

3) $Pr(E = e|S)$: 상태 S일 때 크기 e의 에지가 발생할 확률로 한 시점에 한 기기만이 상태 변화한다고 가정하면 에지 e에 의해 상태 S로 변화될 확률로 구할 수 있다. 상태 S를 만드는 모든 에지들 중 에지 e의 빈도수 계산한다.

$$Pr(E = e|S) \approx \frac{\sum_{i \in E_S} I(e = i)}{\sum_{i \in E_S} 1} \tag{5}$$

E_S : 상태 S에 대한 에지들의 집합

I: 조건이 참이면 1, 아니면 0을 리턴하는 함수

e : 에지

4) 알려진 기기들의 시그너처 생성: 각 기기별 에지의 변화에 대한 확률을 기반으로 시그너처 데이터베이스를 생성하고 분류자를 훈련시키고 측정된 전력 로드로부터 기기들을 분해한다.

- N개의 각 기기에 대한 전력 전이들(power transitions)의 집합 T를 정의한다.

$$T = \{t_1, t_2, t_3, \ldots\ldots, t_N\} \tag{6}$$

- 한 시점에 오직 한 기기만 상태 변화한다고 가정하면 단일 기기 i대하여 오직 하나의 t_i만이 0이 아닌 non-zero가 된다.
- 확률 $Pr(E = e|S)$을 계산하기 위하여 에지의 크기가 e인 모든 전이들을 탐색하여 각 전이에 대하여 상태 S가 되는 전이 확률을 찾는다.
- 각 기기는 독립적이라는 가정 하에 e가 되는 모든 0이 아닌(non-zero) 기기 상태 변화들을 참조한다.
- 예) 전이 T가 각각 전력 변화 e_a와 e_b의 두개의 0이 아닌 기기 상태 변화 a와 b를 가질 때 T_S의 확률

$$Pr(T|S) = Pr(a|S) \times Pr(b|S - e_a) + Pr(b|S) \times Pr(a|S - e_b) \tag{7}$$

- e의 변화를 가지는 모든 전이 조합을 계산한다.

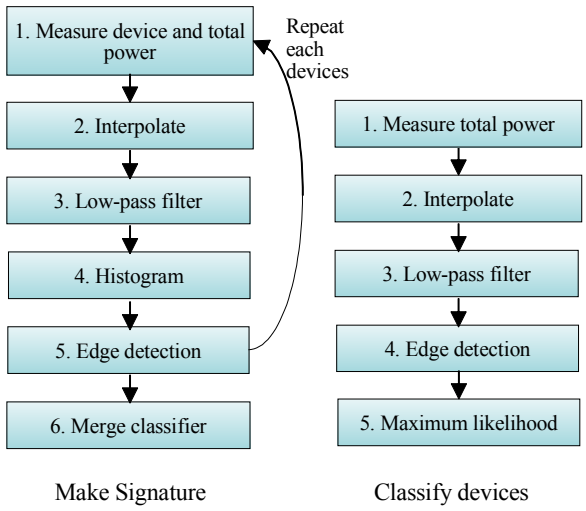

그림 5. 에지 변화에 따른 분류

Fig. 5. The classification on a edge

그림 5에서와 같이 시그너처 작성 단계에서는 단독 및 여러 기기에 대한 총 전력량을 측정하고 미측정 전력에 대해서는 보간법을 사용하여 전력량을 추정한다. 고주파 노이즈를 제거하기 위하여 Low-pass 필터를 통과시키고 각 샘플별로 기기 전력 사용에 대한 확률 밀도 함수(PDF, Probability Density Function)을 계산하여 1Watt bin 단위의 히스토그램을 생성한다. 따라서 각 가능한 상태 변화에 대해 탐지된 에지에 대한 해당 기기 전

력 레벨을 데이터베이스에 저장한다.

기기 분류 단계에서는 보합 로드에 대한 유효전력(P)을 측정하고 미측정 구간에 대해서는 예상 전력 값을 보간법을 사용하여 삽입한다. 시그너처 작성 단계와 마찬가지로 고주파 노이즈를 제거하기 위하여 Low-pass 필터를 통과 시킨 후 전력량의 상태 변화를 일으키는 에지를 탐지한다. 다음 탐지된 에지에 대해 데이터베이스에 저장된 에지 전력 레벨과 비교하여 사용된 기기의 전력 사용량을 추정한다.

Ⅲ. 실험 결과

본 실험에서는 5가지 가전기기 종류와 7가지의 다른 기기를 사용하였으며 표1에 표시하였다. 데이터 수집은 Yokokawa사의 WT210을 사용하여 초당 20번의 샘플링을 수행하였다. 실험은 학습단계에서 각 가전기기의 유/무효 전력 평면과 유효전력의 에지 상태변화를 구하여 시그너처를 작성하였다. 다음의 기기 인식 단계에서는 작성된 시그너처를 기반으로 사용되고 있는 가전기기를 식별한다.

표 1. 실험에 사용된 가전기기 종류
Table 1. Appliances types in simulations

Type	No.	Device
Set top box	0	BKO-100
	1	SMT-C5010
TV	2	32LK451
	3	UN32EH4000F
Audio	4	MM-E330D
Light	5	OSRAM 20EX-L
Heater	6	HEFW-2150

3-1 시그너처 작성 단계

각 기기별 또는 2개 이상의 복합기기 사용 시의 측정 자료를 입력으로 steady-state 상태에서의 기기 인식에 사용할 유효전력과 무효전력의 측정치를 구한다.

1) 유효 전력 측정
- 각 기기별로 측정된 자료를 노이즈 제거를 위하여 Low-pass 필터를 통과 시킨다.
- 각 기기별로 평균화된 유효 전력을 초 단위로 읽는다.
- 각 steady state에서의 평균 전력, 최소 전력, 최대 전력, 경과시간을 측정한다.
- 각 steady state에서의 변화되는 edge(최초 전력, 마지막 전력, 변화 크기)를 구한다.
- 각 steady state 에서의 각 전력량별로 빈도수 히스토그램을 구한다.

2)무효 전력 측정
- 각 기기의 무효전력의 합은 복합기기 사용 시 무효 전력의 합으로 사용할 수 없으므로 각각의 복합기기 사용 시 측정한 무효 전력에 대하여 노이즈 제거를 위해서 Low-pass 필터를 통과 시킨 후 초 단위로 평균화 된 무효전력을 구한다.

3) 유효전력(P)과 무효전력(Q) 평면상에서 분류를 실행하며 분류자를 생성하기 위하여 빈도수 히스토그램(histogram)을 사용한다.

4) 유효전력에 대한 탐지된 에지가 있을 때 기기가 특정 상태일 확률을 계산하기 위해 베이즈의 이론(Bayes' theorem) 식(5)을 이용하여 분류자를 생성한다.

6) 각 기기별 분류자들을 훈련시키고 훈련된 분류자들을 이용하여 전체 전력 사용량으로부터 기기들을 분해한다.

3-2 기기 인식 단계

1) 측정 자료로부터 Low-pass 필터를 이용하여 노이즈를 제거한 후 steady-state를 구한다.

2) 유/무효 전력의 미측정 구간이 발생 시 측정된 정보로부터 보간법을 이용하여 추정 값을 생성한다.

3) 각 기기의 유효 전력의 합은 해당하는 복합기기의 유효 전력의 합으로 사용할 수 있으므로 개별 측정된 유효전력 값으로부터 복합기기 사용 시의 유효전력의 합을 계산한다.
- sum-of-subset 알고리즘을 이용하여 각 측정 유효전력량에 대해 기기별 작동 확률 구한다.

4) 상태전이(state transition)를 추론한다.
- 각 전이에 대하여 상태 S가 되는 전이 확률을 찾는다.
- e의 강도를 가지는 모든 전이 조합을 계산한다.
- 위의 정보를 가지고 가장 큰 확률을 가진 $Pr(E = e|S)$을 탐색한다.

5) 조합된 유/무효전력 및 edge 분류자를 이용하여 총 측정 전력량을 각 기기의 전력 사용 추정치로 분해하여 기기를 분류하고 각 기기의 종류와 동작 상태를 식별한다.
- 동시에 2개 이상의 기기가 작동(on 또는 off)하지 않는다고 가정한다.

다음의 그림 6과 7은 각 가전기기별 시그너처를 나타낸다.

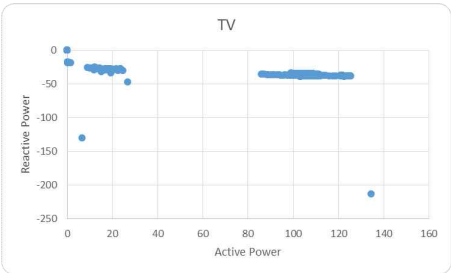

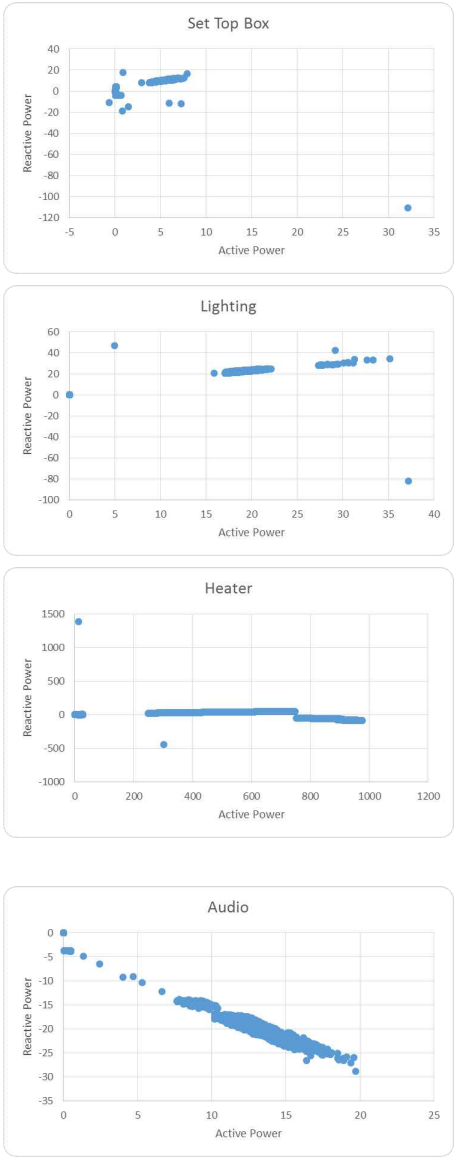

그림 6. 학습단계에서의 각 가전기기의 P-Q 평면
Fig. 6. P-Q plane of each appliances in training stage

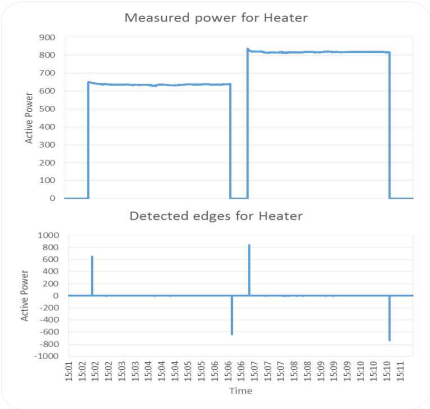

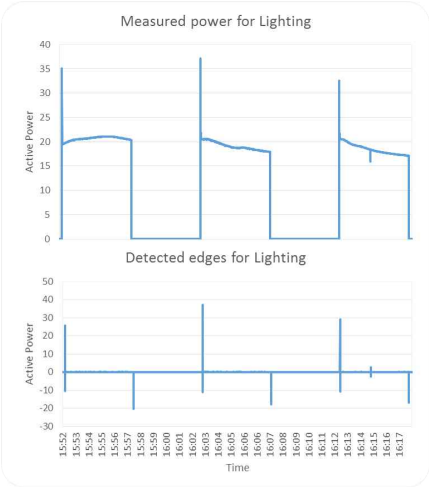

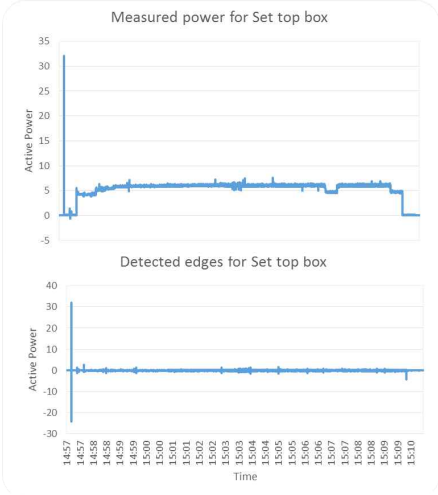

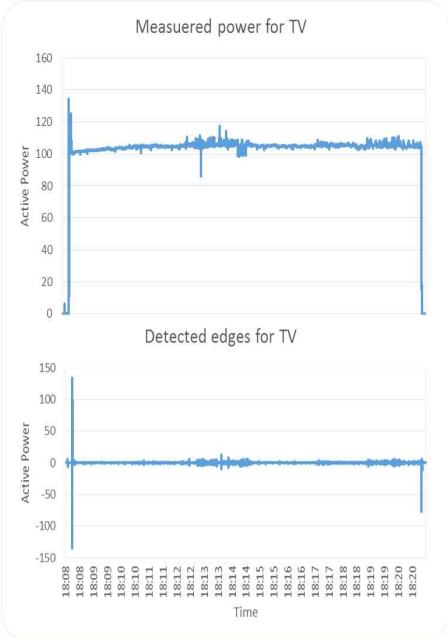

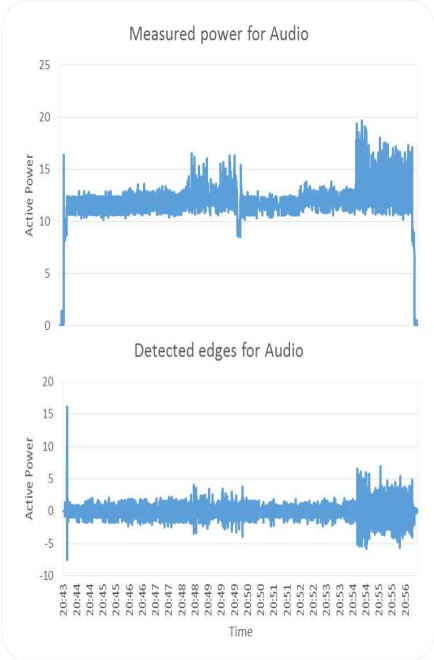

그림 7. 학습단계에서의 각 가전기기의 에지 변화
Fig. 7. The edge state transition of each appliances in training stage

7가지의 가전기기에 대한 실험 결과는 표2에 나타내었다. 평균 정확도는 95.25%로 계산되었다. 오디오의 경우 정확도가 80%로 가장 부정확하게 인식되었는데 이는 다른 가전기기와는 달리 에지의 상태변화를 올바르게 인식하지 못한 결과로 복수개의 셋탑 박스의 사용과 한 개의 오디오 사용을 잘못 인식하는 사례가 발생하였다. 따라서 시그너처 작성에 오디오의 에지 변화에 대한 연구가 더 필요할 것으로 예상된다.

또한 히터의 인식 오류는 전등을 사용하는 것으로 잘못 인식하는 사례가 가끔 발생하였으나 곧 올바르게 인식이 이루어졌다. 이는 유/무효 전력의 시그너처를 본 실험보다 잘 이용할 수 있는 방안을 모색할 필요가 있어 보인다.

표 2. 실험에 사용된 가전기기의 정확도
Table 2. Accuracy rate of appliances in simulations

No.	Type	Device	Accuracy
0	Settop	BKO-100	98.5
1		SMT-C5010	97.2
2	TV	32LK451	99.5
3		UN32EH4000F	99.7
4	Audio	MM-E330D	80.0
5	Light	OSRAM 20EX-L	98.2
6	Heater	HEFW-2150	93.6

Ⅴ. 결 론

본 논문에서는 비접촉식으로 사용되는 총 전력량에 대한 자료를 실시간으로 수집한 후 수집된 전력 변화량으로부터 유효 및 무효 전력 변화량을 추출하여 사용되고 있는 가전기기를 식별하는 알고리즘을 개발하였다. 각 가전기기마다 가지고 있는 유효/무효 전력 평면상의 분포와 가전기기의 상태 변화 시 발생하는 유효 전력의 변화량 등 가전기기마다 특유의 시그너처 특성으로부터 분할 측정(Power Disaggregation)이 가능하다. 특히 유효 전력 변화량을 나타내는 에지의 상태변화를 베이지안 기법을 이용하여 정확도를 95.3%로 높이었다.

현재 기존의 대부분 논문들에서 나타나는 정확도가 90% 내외인 것을 감안하고 셋탑 박스 및 오디오와 같은 저전력 가전기기에 대한 인식을 진행하였다는 측면에서 본 연구에서 제시한 알고리즘의 우수성을 증명하였다고 볼 수 있다[7].

향후 연구로는 유/무효 전력 외에 일시적인 on/off 상태변화 및 고차식의 하모닉 값 등을 이용하여 보다 정확도를 향상 시킬 수 있을 것으로 보이며 현재 많은 연구가 진행 중인 딥러닝을 이용하여 인식을 진행하는 방법도 정확도 향상에 도움이 될 것으로 보인다[8].

참고문헌

[1] S. Giri, and M. Berges, “An energy estimation framework for event-based methods in Non-Intrusive Load Monitoring,” *Energy Conversion and Management*, Vol. 90, pp. 488-498, 2015.

[2] S. Chae, and J. Park, “A Study of Non-Intrusive Appliance Load Identification Algorithm using Complex Sensor Data Processing Algorithm,” *The Journal of The Institute of Internet, Broadcasting and Communication*, Vol. 17, No. 2, pp. 199-204, April 2017.

[3] I. Abubakar, S. N. Khalid, M. W. Mustafa, H. Shareef, and M. Mustapha, “Application of load monitoring in appliances’ energy management – A review,” *Renewable and Sustainable Energy Reviews*, Vol. 67, pp. 235-245, 2017.

[4] R. Bonfigli, E. Principi, M. Fagiani, M. Severini, and F.Piazza, “Non-intrusive load monitoring by using active and reactive power in additive Factorial Hidden Markov Models,” *Applied Energy*, Vol. 208, pp. 1590-1607, 2017.

[5] S. Son, “Hybrid Approach for Home Electricity Consumption Monitoring,” *International Conference On Future Information & Communication Engineering*, Vol. 7, No. 1, pp. 279-282, 2015.

[6] C. Hong, “A Distributed Hybrid Algorithm for Glass Cutting,” *Journal of DCS*, Vol. 19, No. 2, pp. 343-349, February. 2018.

[7] S. Hosseini, K. Agbossou, S. Kelouwani, and A. Cardenas, “Non-intrusive load monitoring through home energy management systems: A comprehensive review,”

Renewable and Sustainable Energy Reviews, Vol. 79, pp. 1266-1274, 2017.
[8] M. Figueiredo, A. Almeida, and B. Ribeiro, “Home electrical signal disaggregation for non-intrusive load monitoring (NILM) systems,” *Neurocomputing* , Vol. 96, pp. 66-73, 2012.

홍철의(Chuleui Hong)

1989년 미국 뉴저지공과대학교 전산학(석사)
1992년 미국 미주리대학교 전산학(박사)

1992년~1997년 한국전자통신연구원(ETRI) 선임연구원
1997년~현재 상명대학교 컴퓨터과학과 교수
※관심분야 : 분산시스템, 인공지능, 최적화기법, 멀티미디어 응용 등

박경모(Kyeongmo Park)

1980년 중앙대학교 전산학(학사)
1983년 서울대학교 전산과학(석사)
1990년 미국 New Jersey Institute of Technology 컴퓨터학(석사)
1994년 미국 George Mason University IT공학(박사)

1983년～1985년: 삼성전자(주) 컴퓨터연구개발(R&D) 연구원
1994년～1995년: 조지메이슨대학교(GMU) CS Dept. 연구원
1995년～1996년: 한국전자통신연구원(ETRI)컴퓨터시스템 연구원
1996년～현 재: 가톨릭대학교 컴퓨터정보공학부 교수
※관심분야 : 컴퓨터시스템, 시스템 소프트웨어, 클라우드 컴퓨팅, 사물인터넷, IT융합 교육, 등