

Matrix Profile 기반의 가전기기 이벤트 탐지 및 특징 추출 기법

강효은*, 김호원^o

Event Detection and Feature Extraction for Home Appliances Based on Matrix Profile

Hyo-eun Kang*, Ho-won Kim^o

요약

1인당 전력 소비량이 지속해서 증가함에 따라, 에너지를 절약하는 방법으로 NILM(Non-Intrusive Load Monitoring)에 대한 관심이 높아지고 있다. NILM은 실시간 에너지 소비 모니터링을 통해 사용자의 에너지 절약을 유도하여 에너지 소비를 줄이는 기술이다. 본 연구에서는 Matrix Profile 알고리즘을 적용하여 이벤트 인식률을 높이는 방법을 제안한다. 이 알고리즘은 과도 상태(Transient state) 구간을 탐지하고 단일 가전기기의 고유 특징을 추출하는 알고리즘이다. 과도 상태의 탐지율을 높이기 위해 고주파 데이터 수집 시스템(DAQ)을 사용하여 3가지 가전기기의 전류 데이터를 수집하였다. 제안한 방법의 성능을 평가하기 위해 가전기와 유사한 전력 크기의 노이즈 데이터를 수집하였다. 그리고 CNN(Convolutional Neural Network)과 GRU(Gated Recurrent Unit) 기반의 가전기기 분류 시스템을 구현하기 위해 과도 상태의 전류 데이터, Matrix Profile 데이터에 재추출(Resampling) 기법을 적용하였다. 실험 결과, 특정 가전기와 유사한 전력 레벨을 갖는 노이즈와 가전기기를 구분할 수 있으며, 실시간 정보의 손실 없이 전류 데이터만으로 가전기기 분류가 가능함을 확인하였다.

Key Words : Energy monitoring systems, Non-Intrusive Load Monitoring, Event detection, Matrix Profile

ABSTRACT

As per capita power consumption per person continues to increase, the interest in NILM (Non-Intrusive Load Monitoring) is growing as a way of saving energy. NILM is a technology to reduce energy consumption by inducing user's energy saving through real-time energy consumption monitoring. In this study, we propose a method to increase the event recognition rate by applying the Matrix Profile algorithm. This algorithm detects transient state interval and extracts the signature of a single home appliances. To increase the detection rate of transient event, current data from the three household appliances were collected using a high frequency data acquisition system (DAQ). To evaluate the performance of the proposed method, we collected noise data with a power size similar to that of household appliances. In addition, we apply a resampling method to the current and the Matrix Profile data in the transient state to implement a home appliance classification model based on CNN and GRU. Experiments have shown that it is possible to classify between a noise data having a power level similar to the specific home appliance and a home appliance, and it can be classified only by current data without loss of real-time information.

* 이 논문은 2019년도 정부(과학기술정보통신부)의 재원으로 정보통신산업진흥원의 지원을 받아 수행된 연구임 (S0249-19-1003, 조신소 중대재해 사고 예방을 위한 통합 안전관리시스템 구축)

※ 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업의 연구결과로 수행되었음 (2014-1-00743)

• First Author : Pusan National University Department of Computer Science and Engineering, hyoeun405@pusan.ac.kr, 학생회원

◦ Corresponding Author : Pusan National University Department of Computer Science and Engineering, howonkim@pusan.ac.kr, 종신회원
논문번호 : 201810-293-C-RE, Received September 30, 2018; Revised March 26, 2019; Accepted April 25, 2019

I. 서 론

IoT 기술이 발전함에 따라 산업이 고도화된 선진국과 아직 발전 중인 개발도상국 모두에서 에너지 수요가 증가하고 있으며, 이에 따른 에너지 소비 비용 또한 꾸준히 증가하고 있다. 특히 2040년까지 세계 전력 수요는 60% 증가하여 주요 에너지원 중 가장 빠른 수요 증가를 시현할 것으로 전망된다^[1].

국내 전력소비량도 꾸준히 증가하고 있다. 국내 1인당 전력소비량은 2010년 1인당 8883KWh에서 2017년 9869KWh로 연평균 1.5%씩 증가했다. 특히, 국내 가정 부문의 전력 소비량은 2000년 3,191 KTOE에서 2017년 5,720 KTOE로 연평균 3.5% 증가하며 매년 최고치를 갱신하고 있다.

세계적으로 전력 수요량이 증가함에 따라 전력의 수요와 공급을 효율적으로 관리할 수 있는 방안에 대해 많은 연구가 이루어지고 있다. 연구에 따르면 주거용 건물에서 가정용 기기 소비량의 실시간 모니터링만으로도 에너지 소비에 긍정적인 행동 변화를 유도하며 전력비용을 약 10~15% 절약할 수 있다고 보고하고 있다^[2].

가정 에너지 관리를 위한 연구 중 NILM (Non-Intrusive Load Monitoring) 분야가 있다. NILM은 가정 내 모든 기기가 연결된 스마트 미터와 같은 단일 지점에서 모니터링 되는 총 전력 데이터를 사용하여 건물에서 실행되는 개별 기기를 추론하고 전력 소비량을 추정하는 시스템이다^[3].

NILM 접근법은 각 기기의 상태 전환을 탐지하여 분류하는 이벤트 기반과 비 이벤트 기반으로 분류할 수 있다. 본 논문에서는 이벤트 기반의 NILM 시스템에 초점을 맞춘다.

NILM 시스템은 크게 네 단계로 나누어진다^[4]: 데이터 수집(Data Acquisition), 이벤트 검출(Event Detection), 특징 추출(Feature Extraction), 가전기기 분류(Classification of Load Appliances).

첫 번째, 데이터 수집 단계는 가정 내 계측기를 통해 가정 내 총 소비전력량을 수집한다. 전력 데이터 수집 방법은 LSF(Low Smpling Frequency)와 HSF(High Sampling Frequency)으로 분류할 수 있다.

두 번째, 이벤트 탐지는 가전기기의 전력 레벨의 변화를 분석하여 ON-OFF 상태 변화를 탐지한다. 가전기기 상태는 순간 정상 상태(Steady-State)와 과도 상태(Transient-State)로 나누어진다. 과도 상태 탐지를 위해 데이터 수집 단계에서 일반적으로 1kHz 이상 샘플링 레이트로 이루어진다. 이벤트 탐지의 정확성은




그림 1. 이벤트 탐지 기반의 NILM 프로세스
Fig. 1. NILM process based on Event Detection

분류 작업의 결과에 직접적인 영향을 미친다.

세 번째, 특징 추출은 이벤트 탐지를 기반으로 유효 전력과 무효 전력을 포함하여 고조파 등 전력 데이터 특징을 추출하는 것이다.

네 번째, 기기 분류는 추출된 전력 데이터 특징을 기반으로 개별 가전기기를 분류하는 것이다.

일반적으로 사용되는 이벤트 탐지 알고리즘에는 Cumulative Sum^[5], Generalized Likelihood Ratio (GLR)^[6], Goodness-of-Fit (GOF)^[7]이 있으며, 모두 고정된 크기의 윈도우에서 가전기기 이벤트를 탐지한다. 그러나 이 방법은 가전기기마다 이벤트 지속 시간, 사용 주파수 등 서로 다른 방식으로 작동하므로 효율적이지 못하다.

이벤트 탐지를 통해 특징을 추출하는 방식은 저주파수를 기반으로 유효 전력과 무효 전력을 추출하거나^[8], 고주파수를 기반으로 FFT, 고조파 등을 추출하는 기법이 있다. 이 방법은 전력 계산, 필터링 또는 FFT 변환으로 인해 시간 관련 정보의 손실을 초래할 수 있다. 이를 개선하기 위해 출력전압 왜곡^[9]이나 전류 신호^[10]을 입력으로 사용하는 연구도 진행되기 시작했다.

본 논문에서는 시간 도메인에서 과도 상태 이벤트 구간을 탐지하여 가전기기 고유 특징을 추출하는 기법을 제안한다. 과도 상태 이벤트 탐지의 정확성을 높이기 위한 방안으로 Matrix Profile 알고리즘^[11]을 도입하였다.

본 논문의 구성은 다음과 같다. 제2장에서 기존 가전기기 이벤트 특징 추출 기법 관련 연구를 살펴보고 제3장에서는 Matrix Profile을 활용한 가전기기 이벤트 추출 기법에 대해 다룬다. 제4장에서는 제안하는 시스템의 주요 구성과 실험 방법을 살펴보고 하겠으며, 제5장에서는 제안 시스템의 실험 결과에 대해 다룬다. 마지막으로 6장에서는 본 연구의 결론과 향후 과제에 대해 제시하도록 한다.

II. 관련 연구

2.1 가전기기 이벤트 기반 특징 추출 연구 동향

NILM 시스템에서 이벤트(Event)는 하나의 정상 상태 혹은 과도 상태에서 다른 상태로의 변화를 의미

한다. 이벤트 검출 모듈은 전력 레벨의 변화를 분석하여 상태 전환을 탐지한다.

초기 NILM 시스템에서 이벤트 기반 특징 추출은 정상 상태 동작을 기반으로 이루어졌다^[8,12,13]. Hart가 제안한 이벤트 탐지 및 특징 추출 기법은 단일기기의 각 단계 변화에 대해 정상 상태 동작에서 유효 전력만 추출하여 가전기기를 분류했다^[8]. 그러나 전력 변화가 거의 없거나 작은 가전기기에 대해서는 특징을 추출하지 못했다. Marisa B. Figueiredo은 정상 상태 영역에서 유효 및 무효 전력을 추출하여 이벤트를 검출하는 방식을 제안했다^[12]. 이 방식은 전력 소비 특성이 매우 다른 기기를 탐지하는 데 높은 정확도를 보였다. 그러나 유사한 전력 소모 수준을 갖는 기기에 대해 분류하지 못했다. ^[13]에서 제시한 연구 기법도 높은 소모 전력을 갖는 가전기기에 대한 분류 정확도는 높은 편이나, 소모 전력이 적은 가전기기가 동시에 동작할 경우 인식률이 떨어지는 경향이 있어 NILM 응용에 어려움이 있다.

가전기기 인식률을 높이기 위해 과도 상태 전력 신호에서 가전기기의 고유 특징(Signature)을 추출하여 기기 상태 변화를 탐지하는 방법이 연구되고 있다. 과도 상태 신호는 1kHz보다 높은 고주파수 계측기에서 추출할 수 있다^[14]. 최근에는 기존 기법과는 다르게 전류-전압 파형 자체의 구조 분석을 통한 이벤트 탐지 및 특징 추출에 대한 연구도 진행되고 있다^[15].

III. Matrix Profile을 이용한 가전기기 이벤트 특징 추출 기법

3.1 Matrix Profile

Matrix Profile은 시계열 시퀀스에서 모티프(Time Series Motif) 발견을 위한 알고리즘이다^[11]. 모티프란 시계열 시퀀스 상에서 빈번하게 반복되는 서브 시퀀스 패턴을 말한다^[16]. 모티프는 분류, 클러스터링, 규칙 발견 등에 사용될 수 있다. Matrix Profile은 서브 시퀀스 간 유클리디안 거리 알고리즘^[17]을 적용하여 유사도를 측정하여 반복되는 서브 시퀀스 패턴을 찾아낸다.

Matrix Profile 알고리즘은 n 길이를 갖는 시계열 시퀀스 T에서 하위 시퀀스 간 유사도 측정을 위해 서브 시퀀스 Q에 대한 길이 $m(4 \leq m \leq n/20)$ 을 선택한다. 그리고 $(n-m+1)$ 개의 서브 시퀀스로 분할하여 각 서브 시퀀스 간의 유클리디안 거리를 계산한다. 각 서브 시퀀스에 대한 유클리디안 거리는 그림 2와 같이 Distance Profile에 기록되며, 기록된 값보다 낮은 값




그림 2. 시계열 T로부터 추출된 서브 시퀀스 Q를 이용하여 Distance Profile을 형성하는 과정^[8]
 Fig. 2. A subsequence Q extracted from a time series T is used as a query to every subsequence in T. The vector of all distances is a distance profile. from^[8]

으로 갱신된다. 최종적으로 가장 작은 값을 갖는 유클리디안 거리를 추출하여 Matrix Profile을 형성한다. 시계열 시퀀스에서 빈번히 나타나는 패턴일수록 거릿 값은 0에 가까워진다. 상대적으로 Matrix Profile 값이 낮은 구간은 시계열 데이터를 대표하는 모티프 구간에 해당하며, 가장 높은 구간은 시계열 불일치(Discord)^[18]에 해당한다.

IV. 제안 시스템

제안하는 시스템의 특성평가를 위해 미니 선풍기, 헤어드라이어, 24인치 LED 모니터를 대상으로 하였다. 본 논문에서는 전압 및 전류 파형을 얻기 위해 Red Pitaya에서 개발한 데이터 수집 모듈 STEMlab10 보드와 데이터 저장, 가공, 처리를 위한 PC로 구성하였으며, 관련 데이터 처리 프로그램을 구현하기 위해 MATLAB을 이용하였다.

표 1은 본 논문에서 선별한 3가지 가전기기에 대한 정격 전압, 정격 전류, 소비 전력을 나타낸다. 가전기기별 5번의 OFF-ON을 진행하였다.

데이터 처리 구성의 상세도는 그림 3과 같다. 전류 측정기를 통해 나온 출력은 1개의 DAQ (Red Pitaya STEMlab10) 채널로 공급되어 10bit 분해능으로 디지털로 변환된다. DAQ 채널은 16k samples 버퍼의 크기를 가지며, 122kHz의 샘플링 레이트와 $\pm 500mV$ 의 Scale로 구성하였다. 이 구성을 사용하여 단일 가전기기의 OFF-ON 상태 전환에 대한 전력 데이터를 수집하였다.

표 1. 가전기기 특성
 Table 1. Characteristics of Home Appliances

Appliance	Watt	Character
Monitor	23	220V, 60Hz
Fan	40	220V, 60Hz
Hair dryer	1300	220V, 60Hz




그림 3. 데이터 처리 구성
Fig. 3. Data Processing Structure

V. 실험결과 및 분석

5.1 실험 환경

본 연구에서는 가전기기 OFF-ON 상태 전환 시 Matrix Profile을 이용하여 과도 상태 시작점부터 과도 응답이 소멸한 후 정상 상태에 들어서는 순간까지 전류 신호를 추출하였다. Matrix Profile의 서브 시퀀스 길이는 800으로 설정하였다. 수집한 전류 데이터에서 잡음 성분을 제거하기 위해 가우시안 스무딩 (Gaussian smoothing)을 윈도우 크기 50으로 지정하여 적용하였다. 딥러닝 학습에 소요되는 시간과 메모리 점유율을 줄이기 위해 1kHz으로 리샘플링 (Resampling) 기법을 적용하였다.

성능 검증을 위해 과도 상태 구간에서 전류 신호와 Matrix Profile 값을 기반으로 특징 패턴을 인식^{19, 20}하는 CNN(Convolutional Neural Network)과 GRU(Gated Recurrent Unit)을 사용하여 시스템을 구현하였다. 그림 4는 전류 데이터와 Matrix Profile을 입력으로 받아 가전기기에 대해 학습을 수행하는 과정을 나타낸다. 실험 데이터에 임의로 발생시킨 노이즈 데이터를 추가하였으며, 실험 데이터는 Train, Validation, Test로 나누어졌으며 각 60%, 20%, 20%에 해당한다.

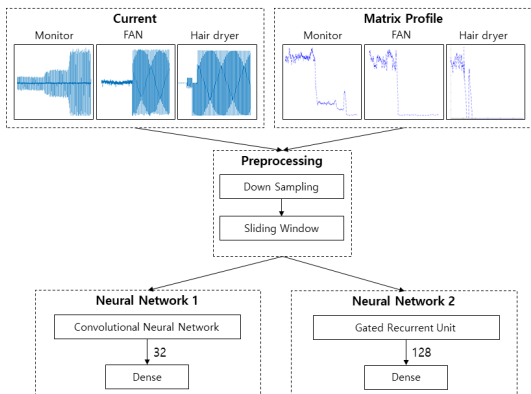


그림 4. 데이터 처리 구성
Fig. 4. Data Processing Structure

5.2 시간 도메인에서 전류 데이터 분석

본 연구에서는 가전기기 동작 시, 과도 상태에서 출력 레벨을 갖는 가전기기를 확인할 수 있었다. 그림 5에서 모니터와 헤어드라이어는 인버터에 의해 구동시 2단계 레벨을 형태를 보인다. 반면, 인버터가 없는 선풍기는 사인함수 형태로 선형 부하 특성을 보인다. 이는 소비 전력이 작거나 비슷한 가전기기들에 대해 정상 상태 성분만을 고려한 NILM에서 제한한 방법들이 다소 효과적이지 못함을 보여주는 결과를 나타낸다.




그림 5. 전류 추출 결과
Fig. 5. Current Extraction Result

5.3 Matrix Profile 데이터 분석

본 연구에서는 Matrix Profile 알고리즘을 사용하여 가전기기가 켜진 순간으로부터 과도현상이 소멸하는 구간에서 각 가전기기의 과도 상태 특성을 검출할 수 있었다.

그림 6의 결과를 분석하면, 각 가전기기가 켜지는 순간 전원 구동 방법에 따라 고유한 부하 특성을 지니고 있는 것을 확인할 수 있다. 그림 5의 전류 변화량과 과도 상태 특성을 이용하면 시간 관련 정보의 손실 없이 가전기기 종류를 인식할 수 있다는 것을 나타낸다.




그림 6. Matrix Profile 추출 결과
Fig. 6. Matrix Profile Extraction Result

5.4 실험 결과

본 장에서는 Matrix Profile을 적용하지 않고 단일 가전기기를 분류한 결과와 Matrix Profile을 적용하여 테스트한 결과를 비교함으로써 제안하는 논문의 적정성 및 신뢰성을 검증할 수 있었다.

표 2는 Matrix Profile 적용 여부에 따른 가전기기 분류 결과이다. Matrix Profile을 적용하지 않고 전류 데이터만으로 가전기기를 분류하였을 경우보다

Matrix Profile을 적용하였을 경우 검출률이 높음을 확인할 수 있다. 특히, 선형 패턴을 보이는 선풍기의 경우 임의로 발생시킨 노이즈 데이터와 유사한 패턴을 보여 전류 데이터만으론 약 60%의 정확도를 보였다. Matrix Profile을 적용한 경우, 선풍기 인식률은 86%로 증가하였다.

따라서 Matrix Profile 알고리즘을 이용하여 가전기 기 과도응답 구간에 대해 탐지가 가능하며, 해당 구간의 전류 데이터와 결합하여 유사 소비전력에 대한 가전기 기 분류가 가능한 것을 확인하였다. 또한, 시간 정보에 대한 손실 없이 가전기기를 분류할 수 있는 것을 확인할 수 있었다.

표 2. Matrix Profile 적용 여부에 따른 식별 성능
Table 2. Identification performance with or without Matrix Profile

Method \ Performance	without using Matrix Profile		with using Matrix Profile	
	CNN	GRU	CNN	GRU
Precision	72%	87%	91%	93%
Recall	82%	86%	91%	91%
F1-score	75%	86%	91%	91%

VI. 결 론

기존 NILM 시스템은 정상 상태에서 유효 및 무효 전력 특징을 추출하거나, 과도 상태에서 고조파, FFT 등을 추출한다. 정상 상태에서 추출한 특징을 이용하면 전력 소모 차이가 큰 가전기기에 대한 인식률은 높으나, 전력 소모가 적거나 유사한 가전기 기 간에 대한 인식률이 낮다. 과도 상태 구간에서 고조파나 FFT를 추출하는 경우 신호를 주파수 영역으로 변환할 때 시간 정보가 고려되지 않았으며, 유사 가전기기에 대해 식별이 어려운 실정이다.

본 논문에서는 Matrix Profile 기반의 가전기 기 과도 이벤트를 탐지하여 시간 정보를 고려한 가전기 기를 인식하는 방법을 제안한다. 정확한 Matrix Profile을 추출하기 위해서는 HSF(High Sampling Frequency)가 바탕이 되어야 한다. 딥러닝 모델의 입력 데이터로 전류 신호와 Matrix Profile을 사용하였으며, 시스템의 성능 검증을 위해 Noise를 발생시켜 분류 테스트를 수행하였다.

Matrix Profile이 고려되지 않은 상태에서 전류 신호에 대한 가전기 기 인식률은 CNN 약 77%, GRU 약

86%를 보였고, 동일한 기기에 대해 Matrix Profile을 고려한 2가지 모델은 각 90% 이상의 인식률을 확인하였다. 또한, NILM 시스템의 정확도와 신뢰도를 향상하기 위해 반드시 비가전기 기 신호임을 식별할 수 있는 노이즈 데이터도 수집해야 한다는 결론을 내렸다.

향후, 본 논문에서 제안하는 NILM 시스템의 발전을 위해서는 더 많은 가전기기에 대한 데이터 집합을 비롯하여 다양한 측면에서 기능을 확장해야 할 것이다.

References

- [1] Korea Energy Economics Institute, *Yearbook of Energy Statistics*(2018), Retrieved Jan., 18, 2019, from <http://www.keei.re.kr/keei/download/YES2018.pdf>.
- [2] M. Zeifman and K. Roth, "Non intrusive appliance load monitoring: Review and outlook," *IEEE Trans. Consumer Electron.*, vol. 57, no. 1, pp. 76-84, Feb. 2011.
- [3] S.-W. Park and B.-H. Wang, "Algorithm of analysing electric power signal for home electric power monitoring in non-intrusive way," *JKIIS*, vol. 21, no. 6, pp. 679-685, Dec. 2011.
- [4] 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 Rev.*, vol. 67, pp. 235-245, Jan. 2017.
- [5] S. R. Mohanty, A. K. Pradhan, and A. Routray, "A cumulative sum-based fault detector for power system relaying application," *IEEE Trans. Power Delivery*, vol. 23, no. 1, pp. 79-86, Jan. 2008.
- [6] K. D. Anderson, M. E. Berges, A. Ocneanu, D. Benitez, and J. M. F. Moura, "Event detection for non intrusive load monitoring," *IECON 2012 - 38th Annu. Conf. IEEE Ind. Electron. Soc.*, pp. 3312-3317, Montreal, QC, Canada, Dec. 2012.
- [7] Y. Jin, E. Tebekaemi, M. Berges, and L.

- Soibelman, "Robust adaptive event detection in non-intrusive load monitoring for energy aware smart facilities," in *Proc. Conf. Acoustics Speech and Sign. Process.*, pp. 4340-4343, Prague, Czech Republic, May 2011.
- [8] G. W. Hart, "Nonintrusive appliance load monitoring," *IEEE Proc.*, vol. 80, no. 12, pp. 1870-1891, Dec. 1992.
- [9] R. Cox, S. B. Leeb, S. R. Shaw, and L. K. Norford, "Transient event detection for nonintrusive load monitoring and demand side management using voltage distortion," in *APEC '06. Twenty-First Annual IEEE*, Dallas, TX, USA, Mar. 2006.
- [10] B. Wild, K. S. Barsim, and B. Yang, "A new unsupervised event detector for non-intrusive load monitoring," in *2015 IEEE GlobalSIP*, pp. 73-77, Orlando, FL, USA, Dec. 2015.
- [11] C. C.-C. M. Yeh, et al., "Matrix profile I: All pairs similarity joins for time series: A unifying view that includes motifs, discords and shapelets," *IEEE ICDM*, Barcelona, Spain, Dec. 2016.
- [12] A. D. Almeida, M. B. Figueiredo, and B. Ribeiro, "An experimental study on electrical signature identification of non-intrusive load monitoring system," in *Proc. 10th Int. Conf. Adap. Nat. Comput. Algorithm ICANNGA*, pp. 31-40, Ljubljana, Slovenia, Apr. 2011.
- [13] A. Giusti, et al., "Restricted neighborhood communication improves decentralized demand-side load management," *IEEE Trans. Smart Grid*, vol. 5, no. 1, pp. 92-101, Jan. 2014.
- [14] D. Srinivasan, W. S. Ng, and A. C. Liew, "Neural-network-based signature recognition for harmonic source identification," *IEEE Trans. Power De*, vol. 21, no. 1, pp. 398-405, Dec. 2005.
- [15] N. Amirach, B. Xerri, B. Borloz, and C. Jauffret, "A new approach for event detection and feature extraction for NILM," *2014 21st IEEE ICECS*, pp. 287-290, Marseille, France, Dec. 2014.
- [16] N. Begum and E. Keogh, "Rare time series motif discovery from unbounded streams," in *Proc. VLDB Endowment*, vol. 8, no. 2, pp. 149-160, Oct. 2014.
- [17] H. Ding, G. Trajcevski, P. Scheuermann, X. Wang, and E. J. Keogh, "Querying and mining of time series data: experimental comparison of representations and distance measures," in *Proc. VLDB Endowment*, vol. 1, no. 2, pp. 1542-1552, Aug. 2008.
- [18] V. Chandola, D. Cheboli, and V. Kumar, "Detecting anomalies in a time series database," Department of Computer Science and Engineering University of Minnesota, *UMN TR09-004*, Feb. 2009.
- [19] D. H. Kim, J. B. Park, and J. D. Kim, "Machine learning-based object detection system using PIR Sensor," *ACCSE*, pp. 11-14, Barcelona, Spain, Jul. 2018.
- [20] J. B. Park, D. H. Kim, and J. D. Kim, "PIR sensor data augmentation technique using fractional frequency transformation," in *Proc. Symp. KICS*, pp. 126-127, Jeju Island, Korea, Jun. 2018.

강 효 은 (Hyo-eun Kang)



2017년 2월 : 부산대학교 IT응용공학과 졸업
 2018년 3월~현재 : 부산대학교 전기전자컴퓨터공학과 석사과정
 <관심분야> 머신러닝, 딥러닝, 디지털 트윈

[ORCID:0000-0002-9651-7439]

김 호 원 (Ho-won Kim)



1993년 2월: 경북대학교 공학
사

1995년 2월: 포항공과대학교
공학석사

1999년 2월: 포항공과대학교
공학박사

2004년: Ruhr University
Bochum, Post Doctorial

1998년~2008년: 한국전자통신연구원 팀장

2008년~현재: 부산대학교 전기컴퓨터공학부 교수

<관심분야> 정보보호, 지능형IoT, FPGA/ASIC, 디
지털 트윈

[ORCID:0000-0001-8475-7294]