

인공지능 기법으로 스마트 플러그를 이용한 제품 자동분류에 관한 연구

손창우 · 이상배*

The research of Automatic Classification of Products Using Smart Plug by Artificial Intelligence Technique

Chang-Woo Son · Sang-Bae Lee*

Department of Electronic & Communication Eng, Korea Maritime University, Busan 49112, Korea

요 약

스마트 플러그는 가정집에서 콘센트와 제품 간 중간에 연결하는 장치로써, 전원 On/Off 제어 기능과 전력 측정 기능으로 에너지 절약을 유도하고 외부에 정보를 전송할 수 있는 IoT 기기를 말한다. 여기에 사람의 사고방식을 컴퓨터에 학습 시키는 인공지능 기술의 딥러닝을 스마트 플러그에 탑재하여, 입력 교류 전류 패턴을 이용하여 제품이 동작만 하면 어떤 제품인지 자동으로 분류하고 세탁기의 동작 상태를 자동으로 판단하는 시험을 하였다. 본 연구를 통해 제품이 IoT 기능이 안 되더라도 스마트 플러그 연결만으로도 제품의 종류와 동작 상태를 분류하므로, 한 가정의 생활 패턴과 에너지 절감의 새로운 패러다임을 그릴 수 있을 것이다.

ABSTRACT

The Smart plug is a device that connects between the outlet and the product at home, and it is an IoT type device that can drive energy saving and transmit information to the outside by power on / off control function and power measurement function. In this case, a smart plug that incorporates deep learning of intelligence technology that allows people to learn how to think about a computer, automatically classifies a product as it operates, and automatically tests the operating status of the washing machine by using input AC current pattern. Through this study, even if the product does not function as IoT, it can classify product type and operation state by smart plug connection alone, so we can draw a new paradigm of life pattern and energy saving in one family.

키워드 : 스마트 플러그, 교류 전류, 인공지능, 딥러닝, 패턴 인식

Key word : Smart Plug, AC Current, Artificial Intelligence, Deep Learning, Pattern Recognition

Received 24 February 2018, Revised 28 March 2018, Accepted 24 May 2018

* Corresponding Author Sang-Bae Lee(E-mail : leesb@kmou.ac.kr, Tel:+82-51-410-4317)

Department of Electronic & Communication Eng, Korea Maritime University, Busan 49112, Korea

Open Access <http://doi.org/10.6109/jkiice.2018.22.6.842>

pISSN:2234-4772

©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

스마트 플러그란 가정집에서의 콘센트와 제품 간 중간에 연결하는 장치로써 전원 On/Off 제어, 전력 측정, 안전관리, 통신기능을 포함한 차세대 제품으로 기존의 단순한 기계식 구조를 탈피하여 전력의 이상 상태를 모니터링하고 외부에 전송 할 수 있는 IoT(Internet of Things) 기기를 의미한다[1]. 최근 스마트 플러그를 포함하고 있는 스마트 홈 시장의 동향을 보면, 큰 그림이나 트렌드는 글로벌 기업들이 주도하고 있고 스마트 홈 분야에 특화된 노하우와 능력이 부족한 것이 단점으로 지적되고 있어 차별화 되는 핵심 기술 개발이 필요한 현실이다[2].

그리고 딥러닝이란 인간 뇌의 학습 처리 과정을 모방한 머신러닝 방법의 한 종류로, 사람의 사고방식을 컴퓨터에게 가르치는 인공지능을 의미한다[3]. 또한 1980년대 등장한 인공신경망(ANN, Artificial Neural Networks)에 기반하여 설계된 개념으로써, 딥러닝이 성공적으로 발전할 수 있었던 계기는 크게 3가지를 말할 수 있다. GPU(Graphic Processing Unit)를 이용한 병렬처리 Process 발전과 빅 데이터(Big Data) 구하기가 쉬워졌고 과 적합(Overfitting) 문제 등의 한계를 극복해 발전할 수 있었다. 하지만 주요한 성과들이 영상 및 음성 인식 분야에만 국한되어 있어서, 본 논문은 전류센서 기반으로 자동 분류를 하는 사례를 만들어, 딥러닝이 보다 더 많은 영역과 분야에서 활용할 수 있도록 만들고자 한다. 이를 위해 스마트 플러그에서 가전 제품의 입력 전류(교류 전류) 파형으로 종류나 동작을 자동으로 분류하는데 목적이 있다.

여기에 사람의 사고방식을 컴퓨터에 학습 시키는 딥러닝을 스마트 플러그에 탑재 시키고, 각 제품의 입력 전류를 스마트 플러그에서 측정하여 제품이 동작만 하면 어떤 제품인지 자동으로 분류하는 능력과 동작 상태 감지를 한다면 더 고객에게 편리성을 부여하고 경쟁력을 강화할 수 있을 것이다.

II. 본 론

본 논문에서는 그림 1과 같이 스마트 플러그에 가전 제품이 연결되고 동작이 되면 전류를 측정하여, 딥러닝

알고리즘으로 제품의 종류와 동작 상태를 자동으로 인식하고 와이 파이(Wi-Fi)를 통해 소비자 App(앱)으로 전송하는 시스템을 구현하는 것이다.




Fig. 1 Home IoT block diagram[4]

가전 제품의 자동인식 목표는 두 가지로, 첫 번째는 10개 제품의 종류를 분류 하는 것이고 두 번째는 특정 제품의 동작 상태를 분류하고자 한다. 첫 번째는 60Hz의 한 주기인 16.7msec 동안의 교류 전류를 측정하여 한 주기 패턴으로 제품 종류를 분류하고, 두 번째는 1초 동안의 평균 전류를 측정하고 그 60개 시간영역 데이터로 특정 제품의 동작 상태 구분을 한다.

만일 제안하는 첫 번째 방식이 가능하다면, IoT가 안되는 제품이라도 제품의 종류를 파악할 수가 있고 TV 시청 시간을 누적 적산하여 사용자에게 알릴 수 있고 회전체, 발열체, 냉각기, 영상기 등의 전류 소비 패턴을 확인 할 수 가 있다. 두 번째 방식이 가능하다면, 세탁기에서 세탁 행정과 탈수 행정을 구분해 멀리서 스마트폰으로 탈수 동작 확인이 가능하니 종료시점을 확인 하러 세탁실에 가지 않아도 되는 번거로움을 덜 수가 있는 장점을 가지고 있다.

2.1. 전류 측정기

입력 교류 전류 데이터를 측정하기 위해 전류 센서를 전원 플러그에 직렬 연결하고, 한 주기 60Hz(16.7msec) 동안의 전류 데이터를 측정하였으며 해당하는 시스템은 그림 2에 표현된다. 전류 센서는 Hall-Effect 기반의 선형 전류 센서인 ACS712를 사용하여 AC 및 DC 신호에 대해 정교한 전류 측정이 가능하며, 측정된 전류에 선형으로 비례하게 전압을 측정한다.

그리고 +/- 20A까지 측정이 가능하고 출력 전압은 0~5V 출력이 된다. Zero Cross 회로는 교류 전압의 시

작을 알리기 위한 Flag-용으로 사용된다. Zero Cross 회로에서 신호가 Low에서 High로 트리거 되면 이때부터 교류 전류값을 측정한다. 그림 2에서의 i_i 는 교류 전류 파형이다.

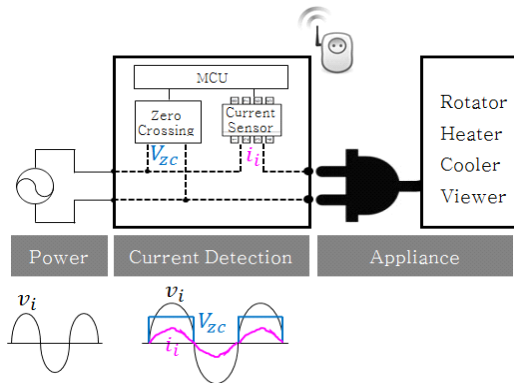


Fig. 2 Current Meter

2.2. 교류 전류 패턴 분석

그림 3에서와 같이 AC-DC 변환에서 General Rectifier는 AC전원을 DC로 변환하여 부하 동작을 하고 메인 부하는 Motor, Comp와 SMPS를 예로 들 수가 있다.

	AC - DC Transform	
	General Rectifier	Converter
Circuit		
Input, Output		
Appliance	Wash Machine, Refrigerator, TV	Air condition

Fig. 3 AC current pattern analysis

이 변환의 특징은 콘덴서 전압(V_{out})보다 입력 전압(V_{in})이 커지는 구간 만큼 콘덴서의 방전에너지를 보충하는 형태로 충전시키도록 입력 전류가 흐르며, 이것이 AC 입력전류로 되므로 이 구간 만큼 충전전류가 흐르고 이 때문에 정현파가 되지 않는다. 따라서 왜곡이 심한 사인파 형태로 나타나고, 평할 캐패시터의 용량이 높을수록 입력전류의 진폭은 올라가게 되는데 이는 우

물에서 양동으로 물을 끌어 올릴 때 용량과도 흡사하다. 이러한 변환기로 사용되는 제품은 회전기(Inverter), 영상기 등이 있다.

Converter는 정류기에서 PFC(Power Factor Correction)와 PSC(Partial Switching Converter) 회로를 사용한다. 이는 출력 Peak가 높거나 Harmonic 규제 대응을 위해 사용되고, 스위칭 제어로 입력전류의 형태를 완만하게 유지하고 입력 전류를 넓게 하여 피크를 억제한다. PFC 회로에서 입력 전류는 매끄러운 사인파 형태 나타나고, PSC의 입력 전류는 한 주기의 구형파 제어로 물결 모양의 형태로 나타난다. 사용되는 제품은 전류를 많이 쓰는 냉각기, 전기 건조기와 Adaptor가 이에 속한다. 이렇게 가전 제품에서의 입력 전압은 교류(AC)로 들어가서 전력변환 시스템을 통해 출력은 직류(DC)로도 만들어지고 교류(AC)로도 만들어지는데, 마지막 단 부하의 특성에 따라 전력변환 시스템이 달라지며 입력단의 교류 전류도 차이가 발생한다. 이러한 교류 전류 특성을 분석하여 제품의 종류를 자동 분류하는데 사용하고자 한다.

2.3. 딥러닝 (Deep Learning)

인간의 뇌는 수많은 뉴런으로 서로 연결되어 있다. 인간의 뇌와 유사한 인공적인 신경망은 다층구조라 할 수 있고, 이러한 다층구조를 딥러닝이라 부른다. 딥러닝에 대한 개념은 1986년 Rina Dechter에 의해 처음 소개 되었으며, 2000년 Igor Aizenberg가 신경망을 활용하여 딥러닝을 소개하였다[5]. Igor는 딥러닝의 입출력 층을 제외하고 2개층 이상의 구조를 갖는 신경망 구조를 딥러닝이라 표현하고 있으며, 따라서 딥러닝은 비선형 데이터의 조합을 통해 높은 수준의 추상화가 가능한 기계 학습 방법으로, 다층의 은닉층을 가진 인공신경망을 지칭한다. 인공신경망이 층의 증가와 함께 비선형 문제의 학습 성능이 월등히 증가하였지만, 학습 연산이 매우 많고, 과 적합 문제로 인해 점차 활용이 줄어들었다. 하지만 병렬 연산의 개발과 함께 2005년 G. Hinton 이 과 적합 문제를 해결하며 보다 다양한 분야에 활용되기 시작하였고[6], 본 연구는 심층 신경망(Deep Neural Network, DNN)에 대해 논의해 본다.

심층 신경망(Deep Neural Network, DNN)은 신경망 알고리즘 중에서 그림 4와 같이 여러 개의 층으로 이루어진 신경망을 의미한다.




Fig. 4 Deep running Internal structure diagram

심층 신경망은 입력계층(Input Layer)과 출력계층(Output Layer) 사이에 복수개의 은닉계층(Hidden Layer)들로 이뤄진 앞먹임 신경망(Feedforward Neural Network)을 의미한다. 심층 신경망은 일반적인 인공신경망과 마찬가지로 복잡한 비선형 관계(Non-Linear Relationship)들을 모델링 할 수 있다. 예를 들어 사물 식별 모델을 위한 심층 신경망 구조에서는 각 객체가 이미지 기본 요소들의 계층적 구성으로 표현할 수 있다. 이때 추가 계층들은 점진적으로 모여진 하위 계층들의 특징들을 규합시킬 수 있다. 심층 신경망의 이러한 특징은 비슷하게 수행된 인공신경망에 비해 더 적은 수의 유닛(Unit, Node)들 만으로도 복잡한 데이터를 모델링 할 수 있게 해준다. 이전의 심층 신경망들은 보통 앞 먹임 신경망으로 설계되어 왔지만, 최근의 연구들은 심층 학습구조를 순환 신경망(Recurrent Neural Network, RNN)에 성공적으로 적용했다. 일례로 언어모델링(Language Modeling)에 심층 신경망 구조를 적용한 연구 등이 있다[7].

심층 신경망은 표준 오류역전파 알고리즘으로 학습한다. 이때, 가중치(Weight)들은 아래의 수식 (1)을 이용한 확률적 경사하강법 (Stochastic Gradient Descent)을 통하여 갱신될 수 있다.

$$\Delta w_{ij}(t+1) = \Delta w_{ij}(t) + \eta \frac{\partial C}{\partial w_{ij}} \quad (1)$$

η 는 학습률(Learning Rate)을 의미하며, C는 비용함수(Cost Function)를 의미한다. 비용함수의 선택은 학습의 형태(지도학습, 기계학습, 강화학습)와 활성화 함수(Activation Function)와 같은 요인들에 의해서 결정된다. 예를 들어, 다중 클래스 분류 문제(Multiclass

Classification Problem)에 지도학습을 수행할 때 일반적으로 활성화 함수와 비용함수는 각각 소프트맥스(Softmax)함수와 교차 엔트로피 함수(Cross Entropy Function)로 결정된다.

$$p_j = \frac{\exp(x_j)}{\sum_k \exp(x_k)} \quad (2)$$

$$C = - \sum_j d_j \cdot \log(p_j) \quad (3)$$

소프트맥스(Softmax)함수는 수식 (2)로 정의된다. 이때 p_j 는 클래스 확률(Class Problem)을 나타내며, x_j 와 x_k 는 각각 유닛 j 로의 전체 입력(Total Input)과 유닛 k 로의 전체 입력을 나타낸다. 교차 엔트로피는 수식 (3)으로 정의되고 이때 d_j 는 출력 유닛 j 에 대한 목표 확률(Target Probability)을 나타내며, p_j 는 해당 활성화 함수를 적용한 이후의 j 에 대한 확률 출력(Probability Output)이다[8].

2.4. 하드웨어 구성

아래의 그림 5는 전류와 전압 측정을 위한 전력 측정 회로와 딥러닝이 탑재된 MCU와 통신부를 나타낸다.




Fig. 5 Block Diagram of Smart plug

그림 6은 본 논문을 위해 제작한 PCB와 PCB를 포함한 스마트 플러그의 사진이다.



Fig. 6 Suggested PCB and Smart plug photo

III. 실험 및 결과

본 연구의 목표로 첫 번째는 10가지 종류 분류인데, 7가지 제품과 2 종류의 제품이 한 개 스마트 플러그에 꼽혀서 동작 할 때도 분류 될 수 있는지를 확인 하는데 앞에서 7가지 제품과 동시 동작 3가지(냉장고+전자레인지, 냉장고+드라이어, 전자레인지+드라이어)를 더해 10가지에서의 종류를 자동 분류를 한다. 두 번째는 1초 짜리 전류 데이터로 60초 동안의 데이터를 이용하여 세탁기에서의 세탁 동작과 탈수 동작을 자동으로 판단이 가능한지 자동 분류를 한다. 첫 번째와 두 번째는 오프라인 조건의 PC(GPU 기반) 동작으로 분류를 하였고, 세 번째 목표는 온라인 조건인 MCU 동작에서 정확도를 검증하였다.

이러한 두 가지 목표에서 어려움이 어떻게 줄어드는지를 확인하고 교차 검증(Cross Validation)을 이용하여 분류에 대한 정확도와 과 적합(Overfitting)이 없음을 확인하고, Full batch와 Mini batch인 입력데이터 적용 방법을 변경하여 학습 속도가 어떻게 변하는지 확인한다.

그림 7은 첫 번째 목표인 동시동작을 포함한 10가지 제품 종류를 분류하기 위한 대표 전류 파형이다.

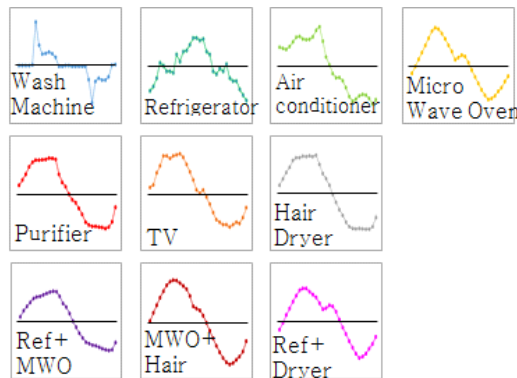


Fig. 7 10 categories of representative current waveform

입력단은 60Hz동안의 30개의 AC 전류값이고, 전체 샘플 data는 12000개이며 3:1 비율로 Train 데이터와 Test 데이터를 나누어 9000개와 3000개로 학습 능력 검증을 위한 4-Fold 교차 학습(Cross Validation)을 위해 구분하였으며 데이터를 다수의 조각으로 나누어 Train과 Test를 반복하는 방법이다. 은닉층(Hidden Layer)은 2개로 각각 10개 Layer로 구성하였고 출력층은 희망하

는 자동 분류 개수이다.

입력 선택 방법으로는 크게 2 가지인 Full batch와 Mini batch 방식에서 2 가지 모두 구현하여 연산 속도와 Local Minima 특성을 비교하고자 하며, 출력값 표현법으로는 출력의 합이 1이 되도록 변형시켜 사용하는 Softmax Function으로 비교를 한다. 활성화 함수는 Sigmoid와 ReLU 함수에서 Weight 학습에서 히든층으로 깊게 전파 도달하지 않아도 되므로 Sigmoid 함수를 사용하고, 신경망 학습율의 지표는 Cross Entropy Error를 사용하며 최적의 매개변수를 갱신하는 방법으로는 Adam Optimizer로 에러를 줄이도록 설정하였다.

3.1. 동시동작을 포함한 10가지 제품 종류 분류

그림 8은 첫 번째 목표인 동시동작을 포함한 10가지 제품의 종류 분석을 위해 딥러닝으로 구현했을 때 Cost Function Error율이 줄어드는 모습을 보여주고 있다.




Fig. 8 Error rate reduction graph of 10 categories

9000개(900×10)의 Train 데이터로 학습하면서 반복 횟수가 늘어나면서 Cost error율이 줄어드는 모습을 보여주고 있고 2000번의 Epoch에서 부터 Error율이 변화 없이 고정되어짐을 알 수 있다. 학습이 완료되어 가중치(Weight) 매개변수가 정해진 후 3000개(300×10)의 Test 데이터로 검증했을 때 성공률이 99.97%임을 아래의 표 1과 같이 혼돈 행렬(Confusion Matrix)로 확인이 가능하다.

수평으로의 한 Line 전체 숫자가 제품 1개에 대한 Test 데이터(300개)로, 7번 이외의 제품 정확도가 100%로 나왔고 7번 제품(Hair Dryer)에서도 300개 중에 1개만 TV로 판단했고 나머지는 Hair Dryer로 판단하여 정확도가 높음을 알 수 있다. 이는 1개의 Hair Dryer 전류 파형이 TV와 유사하게 나와 판별이 안 되는 것으로 확인 할 수 있다.

Table. 1 Confusion matrix of 10 categories

	1	2	3	4	5	6	7	8	9	10
1	300	0	0	0	0	0	0	0	0	0
2	0	300	0	0	0	0	0	0	0	0
3	0	0	300	0	0	0	0	0	0	0
4	0	0	0	300	0	0	0	0	0	0
5	0	0	0	0	300	0	0	0	0	0
6	0	0	0	0	0	300	0	0	0	0
7	0	0	0	0	0	1	299	0	0	0
8	0	0	0	0	0	0	0	300	0	0
9	0	0	0	0	0	0	0	0	300	0
10	0	0	0	0	0	0	0	0	0	300

Averaged recognition rage : 99.97 (2999/3000)

학습 검증 방법은 앞서 설명했던 교차 검증(Cross Validation)의 4-Fold 검증과 2번 반복으로 했을 때 아래 표 2와 같이 정확도가 98% 이상 높게 분류되고 과 적합(Overfitting) 현상이 없음을 확인 할 수 있다.

Table. 2 Results of 2 repeated 4-fold cross validation

	Cost	Acc
1-1	0.0038	100
1-2	0.0041	100
2-1	0.0032	98.36
2-2	0.0037	98.36
3-1	0.0043	99.96
3-2	0.0042	99.96
4-1	0.0029	99.96
4-2	0.0035	99.96

그리고 그림 9와 같이 Full batch size로 학습 했던 것을 Mini batch size 300으로 학습 했을 때 연산 속도가 빨라짐을 확인 할 수 있었다.




Fig. 9 Full batch vs. Mini batch size

Error율이 0.1% 도달 했을 때 Full batch는 34초 소요되지만 Min batch 사용 시 25초 만에 도달되어 연산 속도가 빠름을 확인 할 수 있다.

3.2. 세탁기의 동작상태 분류 (세탁, 탈수 동작)

세탁기에서 세탁과 탈수 동작에 있어서 1초짜리 교류 전류 60개인 입력 데이터로 자동 동작 분류를 하여 사용자에게 스마트 폰으로 전송을 하면 멀리서도 가정에서의 동작 상태를 판단함으로써 고객의 편리성을 줄 수 있는 연구이다.

Table. 3 Confusion matrix of motion classification

	1 (Wash)	2 (Spin)
1 (Wash)	983	17
2 (Spin)	0	1000

Averaged recognition rage : 99.15 (1983/2000)

학습이 완료되어 가중치(Weight) 매개변수가 정해진 후 2000개(1000×2)의 Test 데이터로 검증했을 때 성공률이 99.15%임을 표 3과 같이 혼돈 행렬(Confusion Matrix)로 확인이 가능하다. 수평으로의 한 Line 전체 숫자가 동작 1개에 대한 Test 데이터(1000개)로, 1번(세탁동작)에서 983번은 세탁동작을 판단했지만 17번에서 1번(탈수 동작)으로 판단하였고 2번에서는 100% 2번으로 판단하였다. 그래서 전체 정확도 평균은 99.15%를 나타남을 알 수 있다.

3.3. 온라인 MCU 동작에서의 정확도 검증

오프라인에서 학습하여 정확도가 검증된 Weight를, MCU에 적용하고 연산 프로그램을 설계하여 실 시간에서의 제품 종류 분류와 동작 분류가 잘 되었는지 실험하였다. 이때 결과는 표 4와 같은 정확도를 확인하였다.

Table. 4 Classification types and 2 motion classification result in MCU

	Product	Measuring time(sec)	Accuracy (% Kinds)	Accuracy (% Action)
1-1	Washer-Wash	418	97	86
1-2	Washer-Spin	639	100	98
2	Refrigerator	910	97	-
3	Air Conditioner	429	99	-
4	Micro Waveoven	150	99	-
5	Purifier	150	100	-
6	TV	160	98	-
7	Hair Dryer	126	99	-
8	MWO +Hair Dry	151	94	-
9	Refrigerator +Hair Dry	161	97	-
10	Refrigerator +MWO	236	96	-

종류 분류에서는 94% 이상의 정확도가 나왔고, 동작 분류에서는 세탁동작에서 86%의 정확도로 낮게 나왔다. 이는 세탁과 탈수 동작에서 중복되는 동작이 존재하여 정확도가 낮게 나왔는데, 중복되는 동작은 물 빼기 동작인 배수에서 통(Tub)을 돌리는 속도가 20rpm으로 천천히 회전하는 동작이다.

IV. 고 찰

본 논문에서는 60Hz 주기의 교류 입력 전류로 표현되는 각 가전 제품의 정보를 계측하여 가전 제품마다의 표현되는 전류패턴을 분류하였으며, 제품이 동작했을 때 교류 입력 전류의 패턴으로 딥러닝을 통해 제품의 종류를 자동으로 분류가 가능함을 확인했고 또한 세탁기의 세탁, 탈수 동작을 자동으로 분류가 가능함을 확인하였다.

앞으로 여러 가전업체에서 만든 제품군에서도 동일한 학습 분류가 되도록 연구가 필요할 것이고, 모든 제품의 종류를 알고 전력을 안다면 한 가정집의 상태와 예측이 가능한 차별화 되는 스마트 홈 시스템 구성이 될 것이라 기대해 본다.

REFERENCES

- [1] D. H. Ryu, "Networked Smart Plug System for Power Management of PC & Peripherals," *Journal of the Korea Institute of Information and Communication Engineering*, vol.16, no. 10, pp.2171-2176, Oct. 2012.
- [2] Y. S. Kim, "Smart plug/home appliances spread User Experience(UX) Development Study" Sungkyunkwan University Industry Academia Collaboration Foundation, Technical Report, Sep. 2014.
- [3] Google DeepMind Research Center AlphaGo, Mastering the ancient game of Go with Machine Learning.[Internet]. Available: <https://reserch.googleblog.com/2016/01/alphago-mastering-ancient-game-of-go.html>.
- [4] C. J. Seo "Smart electricity management system in homes using pattern analytically," M.S. thesis, Kwangwoon University, Korea 2013.
- [5] W. S. Lee, S. H. Kim, J. Y. Ryu and T. W. Ban, "Fast Detection of Diseases in Livestock based on Deep Learning," *Journal of the Korea Institute of Information and Communication Engineering*. vol. 21, no. 4, pp. 1009-1015, Oct. 2017.
- [6] G. Hinton, S. Osindero, "A Fast Learning Algorithm for Deep Belief Nets," *Neural Computation*, vol.18, no.7, pp. 1527-1554, May. 2006.
- [7] Y. J. Kim, "Analysis of Image Big Data Using Deep Learning" Ph. D. dissertation, Chung Ang University, Korea 2017.
- [8] S. David, H. Aja, M. Chris and G. Arthur, "Mastering the game of Go with deep neural network and tree search," *Nature*, vol. 529, pp. 484-489, Jan. 2016.



손창우(Chang-Woo Son)

한국해양대학교 전자통신공학과 박사과정
※ 관심분야 : 인공지능, 딥러닝, 센서 응용



이상배(Sang-Bae Lee)

한국해양대학교 전자통신공학과 교수, 공학박사
※ 관심분야 : 퍼지이론, 신경회로망, 유전알고리즘