



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학박사 학위논문

딥러닝 기반으로 스마트 플러그를 이용한
가전제품 자동 분류에 관한 연구

The research on Automatic Classification of Home Appliances
using Smart Plug based on Deep Learning



2018년 8월

한국해양대학교 대학원

전자통신공학과

손창우

본 논문을 손창우의
공학박사 학위논문으로 인준함

위원장 양 규 식 (인)

위원 심 준 환 (인)

위원 손 경 락 (인)

위원 최 성 욱 (인)

위원 이 상 배 (인)

2018년 8월

한국해양대학교 대학원

목 차

List of Tables	iii
List of Figures	iv
Abstract	vi
제 1 장. 서 론	1
1.1 연구의 배경 및 필요성	1
1.2 연구의 목표 및 범위	4
제 2 장. 딥러닝 이론	7
2.1 딥러닝 소개	7
2.2 역전파 알고리즘	8
2.3 딥러닝 알고리즘 종류	16
제 3 장. 스마트 플러그/콘센트 관련 연구	24
3.1 스마트 플러그/콘센트 기술 동향	24
3.2 스마트 플러그 구성 요소	28
제 4 장. 지능형 스마트 플러그 시스템 설계 및 구현	36
4.1 하드웨어 구성	36
4.2 소프트웨어 설계	41
제 5 장. 실험 및 결과	53
5.1 실험 목표	53
5.2 전력변환 회로와 전류 패턴 분석	54

5.3 실험 방법	59
5.4 실험 결과 분석	66
5.5 온라인 학습에서의 정확도 검증	73
제 6 장. 결론	75
참고문헌	77
부록	82



List of Tables

Table 1 Types of Deep Learning and Application	23
Table 2 Main Spec of ESP-12E	40
Table 3 Data collection method	43
Table 4 The object of an experiment	54
Table 5 Power converter circuit and description	55
Table 6 10 Input characteristics	57
Table 7 10 Input current waveforms	58
Table 8 Internal variables for 3 purposes	65
Table 9 Confusion matrixes of 7 product categories	67
Table 10 Cross Validation results of 2 times 4-Fold at 7 categories	68
Table 11 Confusion matrixes of 10 categories	69
Table 12 Cross Validation results of 2 times 4-Fold at 10 categories	70
Table 13 Confusion matrixes of Wash and Spin	72
Table 14 Cross Validation results of 2 times 4-Fold at Wash and Spin	73
Table 15 10 types and 2 motion classification result in MCU	74

List of Figures

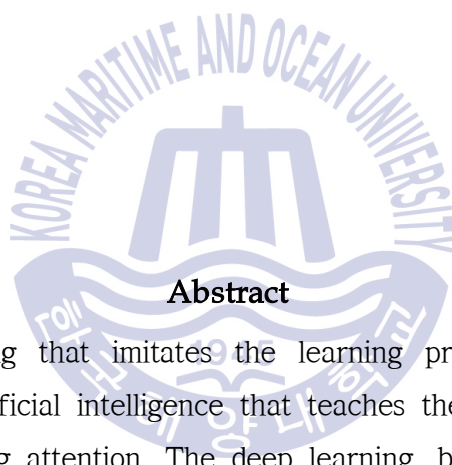
Fig. 1 How to use Smart Plug	2
Fig. 2 Smart Home World Market Size	3
Fig. 3 Smart Plug with Deep learning	5
Fig. 4 Human nerve cell	8
Fig. 5 Artificial Neural Network circuit	9
Fig. 6 Multi Layer Neural Network	10
Fig. 7 BP Algorithm block diagram of two hidden layers	14
Fig. 8 Typical Deep Learning structure	16
Fig. 9 Fully-connected layer and Convolution Neural Network Structure	21
Fig. 10 MNIST data Feature Map	22
Fig. 11 The Importance of the IoT Concept	25
Fig. 12 Products of Smart Plug	26
Fig. 13 Smart Plug system structure diagram	27
Fig. 14 Link between IoT and Smart Home	28
Fig. 15 Structure of Smart Plug	29
Fig. 16 Smart Plug to Measure Input Current	31
Fig. 17 Features of Smart Plug	32
Fig. 18 Scope of Smart Plug	33
Fig. 19 Power conversion system	34
Fig. 20 Power conversion method	34
Fig. 21 Power conversion classification	35
Fig. 22 Functional Block diagram	36
Fig. 23 Overall circuit diagram	37
Fig. 24 Power measuring circuit	38
Fig. 25 Pin arrangement of the ESP-12E module	39

List of Figures

Fig. 26	Board including power circuit and MCU/Wi-Fi (Before PCB)	40
Fig. 27	Smart Plug board(After PCB) and Usage	41
Fig. 28	Full configuration of Deep Learning	42
Fig. 29	Deep Learning Design Stage	43
Fig. 30	Deep Learning preprocessing process	45
Fig. 31	Train and Validation method	46
Fig. 32	On-line Test method	48
Fig. 33	Deep Learning Flow chart at MCU	49
Fig. 34	When ESP-12E is used as a client(a) or server(b)	51
Fig. 35	App. design at Smart phone	52
Fig. 36	Structure of Deep Learning	60
Fig. 37	Off-line learning and verification methods	61
Fig. 38	Cross Validation construction	63
Fig. 39	Bootstrap construction	64
Fig. 40	Error rate graph of first goal	66
Fig. 41	Error rate graph of the second goal	69
Fig. 42	Comparison of operation speed(Full batch vs. Mini batch)	70
Fig. 43	Error reduction rate of Mini batch	71
Fig. 44	Error rate graph of the third goal	72

The research of Automatic Classification of Home Appliances using Smart Plug based on Deep Learning

Son, Chang Woo




Abstract

Today deep learning that imitates the learning process of the human brain among the artificial intelligence that teaches the human mind to the computer is attracting attention. The deep learning, based on the Artificial Neural Networks(ANNs) that emerged in the 1980s, was successful with three developments. It is parallel processing with GPU(Graphic Processing Unit), easy acquisition of big data and overfitting problems. In this paper, we will make a case of automatic classification based on sensor rather than video or speech recognition technology by deep learning, and make it possible to utilize deep learning in more areas and fields. For this purpose, it is aimed to automatically classify the type and operation of the product by the input current waveform of household appliances in the smart plug. The smart plug is a device that connects between the outlet and the

product at home, and it is an IoT(Internet of Things) 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.

KEY WORDS : Smart Plug, AC Current, Deep learning, Pattern recognition



제 1 장 서 론

1.1 연구의 배경 및 필요성

딥러닝(Deep learning)이란 인간 뇌의 학습 처리 과정을 모방한 머신러닝 방법의 한 종류로, 사람의 사고방식을 컴퓨터에게 가르치는 인공지능을 의미하며 [1][2], 또한 1980년대 등장한 인공 신경망(ANN, Artificial Neural Networks)에 기반을 두어 설계된 개념이다. 딥러닝이 성공적으로 발전할 수 있었던 원인을 크게 3가지로 나누어보면, 첫 번째는 GPU(Graphic Processing Unit)를 이용한 병렬처리 프로세서의 발전이고, 두 번째는 빅 데이터(Big Data) 수집이 쉬워졌다는 점이며, 마지막 세 번째는 IT(Information Technology) 기술의 발전과 함께 단점으로 여겨지던 과 적합(Overfitting) 문제 등의 한계가 극복된 점이다[3]. GPU는 딥러닝에서 복잡한 행렬 연산에 소요되는 시간을 크게 단축시키는 하드웨어 발전이고, 빅 데이터는 대량으로 쏟아져 나오는 데이터들과 다량의 자료와 태그 정보들이 종합되고 분석되어 학습에 이용되고 있다[4][5]. 그리고 최근 구글 딥 마인드의 알파고와 이세돌 간 세기의 바둑 대결 등을 통해 인공지능과 딥러닝 기술에 대한 관심이 증폭되고 있다.

딥러닝 활용에서는 화상인식의 정밀도가 향상되면서 X-ray, CT 등 이미지 기반의 자동 진단이 가능해진 의료분야의 변화 가능성이 커졌고, 검색이나 소셜 네트워크 등의 인터넷 업계가 영상 인식 기술의 사업화로 식물 사진을 올리면 식물 이름을 찾아주는 서비스가 제공되고 있듯 우리는 이미 경험을 하고 있다 [6][7][8]. 또한 딥러닝 기술은 영상 인식 기술을 이용해 실시간으로 생산 모니터링과 이상 상태를 감시하는 제조 분야에 활용이 되고, 음성 인식 기술로 자연어 학습이나 번역/통역 등의 교육 분야 등에도 활용이 되고 있다.

본 논문에서는 딥러닝으로 영상이나 음성 인식 기술이 아닌 센서 기반으로 자동 분류를 하는 사례를 만들어, 딥러닝이 보다 더 넓은 영역과 분야에 활용할 수 있도록 하고자 한다. 이를 위해 스마트 플러그에서 가전제품의 AC 입력 전류 파형으로 종류를 분류하고 동작 상태의 판단이 가능한지의 실험 결과를 제시하는데 목적이 있다.

스마트 플러그란 그림 1에서와 같이 가정집에서의 콘센트와 가전제품 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 사물 인터넷(IoT, Internet of Things)형 기기를 의미한다[9][10].



Fig. 1 How to use Smart Plug

스마트 플러그의 산업에서는 상시 실시간 에너지 소비 모니터링을 통해 사용자의 에너지 절약 활성화를 유도하고 사용자 설정 기반의 알람 기능을 통해 소비전력을 절감하며, 유무선 네트워크를 통한 스마트 그리드의 적용 및 향후 신

재생 에너지 생산 및 소비 관리 기술 플랫폼으로 발전 가능성이 높아지고 있다. 하지만 경쟁 심화에 따른 가격하락으로 수익성 악화 우려가 커지고 있으며 범용 제품으로 제품 차별화가 어렵다. 세계 시장 성장 측면에서 글로벌 조사기관인 SA(Strategy Analytics)에 따르면 그림 2와 같이 글로벌 서비스 제공자가 접근 가능한 스마트 홈 시장은 2015년 240억 달러에서 연평균 24.2% 씩 성장하여 2020년에는 710억 달러 수준의 시장으로 성장할 것으로 전망하고 있어 제품의 경쟁력 확보가 필요하다.

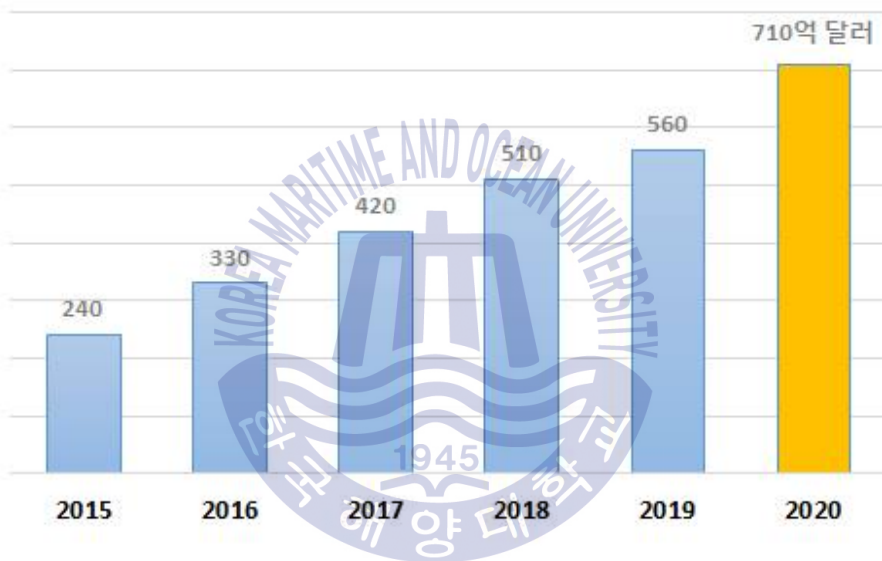


Fig. 2 Smart Home World Market Size[11]

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.

스마트 홈이란 주거 환경에 정보통신기술을 융합하여 공간과 기기의 제약 없이 폭넓고 다양한 정보와 서비스를 제공함으로써 경제적 편익, 건강과 복지 증진, 안정된 생활이 가능하도록 하여 거주자 삶의 질을 한층 더 높게 만들어주

는 주거생활 공간을 의미한다[12].

여기에 사람의 사고방식을 컴퓨터에 학습시키는 딥러닝 기술을 스마트 플러그에 탑재시키고, 각 제품의 입력 전류를 스마트 플러그에서 측정하여 제품이 동작만 하면 어떤 제품인지 자동 분류 능력과 제품의 동작 상태를 판단한다면 사용자에게 보다 많은 편리성을 부여하고 경쟁력을 강화할 수 있을 것이다 [13][14].

만일 각 제품의 종류를 인식하는 기능이 추가된다면 각 제품의 동작 상태를 스마트 폰으로 편리하게 모니터링이 가능하고, 각 제품의 누적 전력량도 측정하고, 또한 다른 특성들의 제품군들(발열체, 냉각기, 회전체, 영상기 등)의 전체 사용량도 비교가 가능하다, 또한 가전제품이 동작 중에 기존 동작 패턴과 안 맞으면 고장 알림 기능도 가능할 뿐만 아니라 전력 소모량을 최소화 할 수 있도록 유도를 하고 전력 변화 추이에 대해 알림을 할 수 있다.

또한 각 제품의 동작 상태 판단이 가능하다면 세탁기의 경우 세탁/탈수 판단으로 끝나는 시점을 사용자에게 알려 멀리 떨어져 있어도 확인이 가능하고, 냉장고의 경우 문의 여닫음을 확인하여 사용자 생활 패턴의 모니터링과 독거노인일 경우 가정집에서의 활동 내역도 확인이 가능하다. 정수기 동작과 시간 판단이 가능하다면 일일 음료 섭취량 파악 및 알림을 할 수 있고, 전자레인지의 경우 요리 사용 횟수 알림 등을 할 수 있어 사용자의 생활 패턴을 모니터링하며 건강관리에도 효과를 줄 수 있을 것이다. 이러한 시간과 공간의 제약 없이 모든 정보와 서비스가 사용자 중심으로 제공되는 주거환경이 된다면 스마트 홈 시장에 핵심 기술로 경쟁력을 가질 것이라 판단된다.

1.2 연구의 목표 및 범위

본 논문의 목표는 스마트 플러그를 이용한 센서 기반의 자동 분류하는, 딥러닝의 이론을 실험으로 검증하고자 함이다. 그림 3에서와 같이 각 가전제품에 스마트 플러그들이 연결되고 제품이 동작되면 스마트 플러그에서 AC 입력 전류를 측정하여, 딥러닝 알고리즘으로 제품의 종류와 동작 상태를 자동으로 인

식하고 와이 파이(Wi-Fi)를 통해 사용자 앱(App.)으로 전송하는 시스템을 구현하고자 한다.

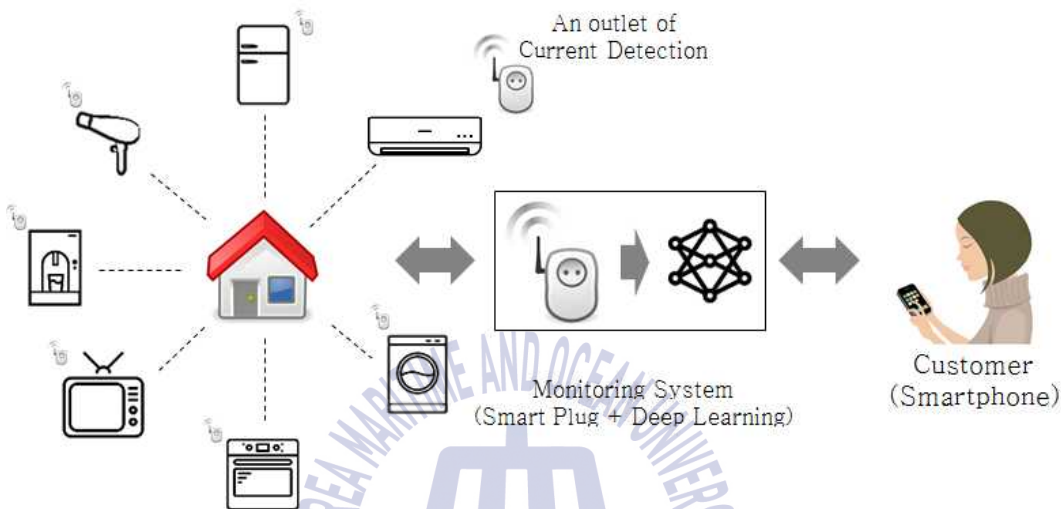


Fig. 3 Smart Plug with Deep learning[15]

가전제품의 자동인식 종류는 세 가지로, 첫 번째는 종류를 자동으로 분류하는 것과 두 번째는 한 플러그에 두 개의 제품이 연결되었고 동시 동작을 했을 때 제품의 종류를 분류하는 것이고 마지막 세 번째는 특정 제품의 동작 상태를 분류하고자 한다.

첫 번째와 두 번째는 60Hz의 한 주기인 16.67msec 동안의 AC 전류를 측정하여 전류 패턴으로 제품 종류를 분류하고, 세 번째는 1초 동안의 평균 전류를 측정하고 60초 동안(60개 데이터)의 시간영역에서 특정 제품의 동작 상태를 구분한다.

만일 제안하는 첫 번째와 두 번째 방식이 가능하다면, 사물 인터넷이 안 되는 제품이라도 제품의 종류를 파악할 수가 있고 TV 시청 시간을 누적 적산하여 사용자에게 알릴 수 있으며 회전체, 발열체, 냉각기, 영상기 등의 전류 소비 패

턴을 확인할 수 가 있다. 세 번째 방식이 가능하다면, 세탁기에서 세탁 행정과 탈수 행정을 구분해 멀리서도 스마트폰으로 탈수 동작 확인이 가능하니 종료 시점을 확인하러 세탁실에 가지 않아도 되는 번거로움을 줄일 수가 있고, 냉장고에서 냉장/냉동 문이 열리는 시점과 횟수 파악이 가능하니 독거노인이나 독신자의 가정집 생활 상황을 파악 할 수 있는 많은 장점을 가지고 있다.

또한 제안하는 시스템이 가정집의 모든 콘센트에 들어간다면 한 가정에서 동작되는 제품의 종류와 전력을 측정하여 생활 패턴과 에너지를 모니터링 하고 에너지 절감의 새로운 패러다임을 그릴 수 있을 것이다.

본 연구의 구성은 1장에서 제품의 전력 패턴으로 각 제품의 종류를 자동으로 분류하고 동작 상태를 판단하는 목표와 필요성 그리고 스마트 홈의 활성화 가능성에 대해서 정리하였다. 2장에서는 신경망과 딥러닝에 대한 역사와 발전 할 수 있었던 계기들을 설명하고 학습 알고리즘들의 개념과 종류를 정리하였다. 3장은 에너지 절감을 위한 스마트 플러그 및 콘센트의 기술 동향을 소개하고 스마트 홈 시스템인 지능형 정보 가전 기술과 연결시키는 내용을 설명하였다. 4장에서는 가전제품의 자동식별을 구현하기 위하여 스마트 플러그 시스템을 설계한 내용을 하드웨어 측면의 회로 설계와 소프트웨어 측면의 딥러닝 구성 내용에 대해 제시하였다. 5장에서는 전력 변환 회로 분석으로 AC 입력 전류의 파형이 제품마다 차이가 남을 분석하고 설계한 지능형 시스템이 실제 동작에서 각 제품의 종류를 분류 하고 동작 상태의 판단이 가능한지 실험 결과를 제시하였다. 마지막 6장에서는 연구 결과에 대한 결론과 앞으로의 향후 계획을 제시하였다.

제 2 장 딥러닝 이론

본 장에서는 신경망과 딥러닝에 대한 역사와 발전 할 수 있었던 계기들을 설명하고 신경망에서 학습에 바탕이 되는 역전파 알고리즘 적용에 대해 도식적으로 설명한다. 그리고 입력층과 출력층 사이에 복수개의 은닉층들로 이루어진 심층 신경망에서 학습의 효율과 정확도를 높일 수 있었던 기법들에 대한 설명을 하고 이미지 인식과 음성 인식 등 다양한 곳에서 사용되는 합성곱 신경망과 내부에 메모리를 통해 반복적인 학습이 가능하고 시계열 데이터 분석을 위한 신경망인 순환 신경망에 대해 설명한다.

2.1 딥러닝 소개

딥러닝은 인공지능을 구성하기 위한 인공신경망(ANN, Artificial Neural Network)에 기반으로 컴퓨터에게 사람의 사고방식을 가르치는 방법이고, 사람이 가르치지 않아도 컴퓨터가 스스로 사람처럼 학습 할 수 있는 인공지능의 기술이다[16][17].

딥러닝은 엄밀히 말하면 새로운 개념이 아닌 인공 신경망의 일종이다. 1943년 미국 일리노이 의대 정신과 부교수였던 McCulloch & Pitts의 Boolean Neural Network에 시작된 인간의 뇌 구조와 유사한 인공 신경망 알고리즘이 최초로 등장하였고 Rosenblatt의 단층 퍼셉트론으로 신경망은 각광을 받았다. 하지만 1969년 Minsky M. L에서 X-OR(Exclusive OR) 연산을 분류할 수 없다는 사실을 증명하면서 1차 암흑기가 찾아왔다.

1980년대 중반에 역전파(Back Propagation) 알고리즘이 고안되면서 제2의 전성기 시대를 맞이하게 되지만, 타 인공지능과 유의차가 없다는 단점이 있었고

또한 적은 수의 계층으로 구성된 얇은 네트워크에 대해서만 효과적으로 사용되었다. 계층이 많아지거나 네트워크가 복잡해지면 매우 느린 학습시간의 문제, 학습이 수렴(Convergence)이 되지 않고 발산하는 문제, 트레이닝 셋에 너무 가깝게 맞추어 학습되는 과 적합(Overfitting) 등의 치명적인 문제점들이 나타나게 되고 비현실적인 방법으로 간주되어 2차 암흑기가 찾아왔다.

그러나 2000년대 후반 들어 Geoffrey Hinton 교수 등의 지속적인 연구 노력과 함께 강력한 그래픽 병렬처리 연산을 하는 GPU(Graphics Processing Unit)의 발전과 과 적합을 개선한 알고리즘들이 개발되고 빅 데이터들을 구하기가 쉬워지면서, 계층 수가 많아지고 네트워크가 복잡한 시스템에서도 탁월한 성능이 발휘되면서 심층 신경망(DNN, Deep Neural Network)이라 불리기도 한 딥러닝은 또 다시 전성기에 서 있다[18].

딥러닝은 지속적으로 발전되고 있고 병렬처리 연산으로 충분히 많은 데이터를 가지고 반복적인 학습을 통해 올바른 결론을 도출함으로써, 기업에서 바라봤을 때 돈이 되는 문제점들(영상처리, 음성인식, 사용자 편리성)을 해결해주고 있다는 것에 각광을 받는지도 모른다.

2.2 역전파 알고리즘

생물학적 신경망은 아래의 그림 4와 같이 4가지로 구성이 된다.




Fig. 4 Human nerve cell

수상돌기(Dendrite)는 외부로부터의 신경자극을 받아들이는 역할을 하고 축색 돌기(Axon)는 가늘고 길게 뻗어 있는 섬유 모양인 전류와 비슷한 형태로 다른 뉴런으로 신호를 전달하는 기능을 담당한다. 신경 세포체(Soma)는 신경 세포의 핵을 담당하고 여러 뉴런으로부터 전달되는 외부 자극에 대한 판정을 하고 뉴런으로 신호를 전달할 것인지를 최종 결정을 담당한다. 시냅스(Synapse)는 어떤 뉴런의 축색돌기 말단과 다음 뉴런의 수상돌기의 연결부위를 말하는 즉 다른 뉴런의 축색돌기로부터 받은 신호를 어느 정도의 세기(Strength, Weight)로 전달할 것인지 결정한다.

인간의 뇌는 수많은 뉴런으로 서로 연결되어 있어서 인간의 뇌와 유사한 인공적인 신경망은 다층 구조로 표현 할 수 있다. 그리고 서로 연결된 뉴런에 의해서 더욱 더 좋은 성능으로 수행할 수 있어 일반적으로 더욱 큰 망은 큰 연산 용량을 제공한다. 그림 5에서는 다층 신경망의 기본적인 구조를 보여주고 있고, 뉴런의 함수를 수학적으로 표현하면 식 (1)과 같다. 여기서 μ_i 와 f 는 활성화 함수를 의미한다.




Fig. 5 Artificial Neural Network circuit

$$y = f\left[\sum_{i=1}^n w_i x_i - w_0\right] \tag{1}$$

패턴 인식과 분류 제어와 같은 응용에서 가장 일반적으로 사용되는 알고리즘은 가중치(Weight) 매개변수의 기울기를 효율적으로 계산하는 역전파 알고리즘

을 가지는 다층 신경망(Multi Layer Neural Network)이다. 그림 6은 전형적인 다층 신경망을 나타낸다.

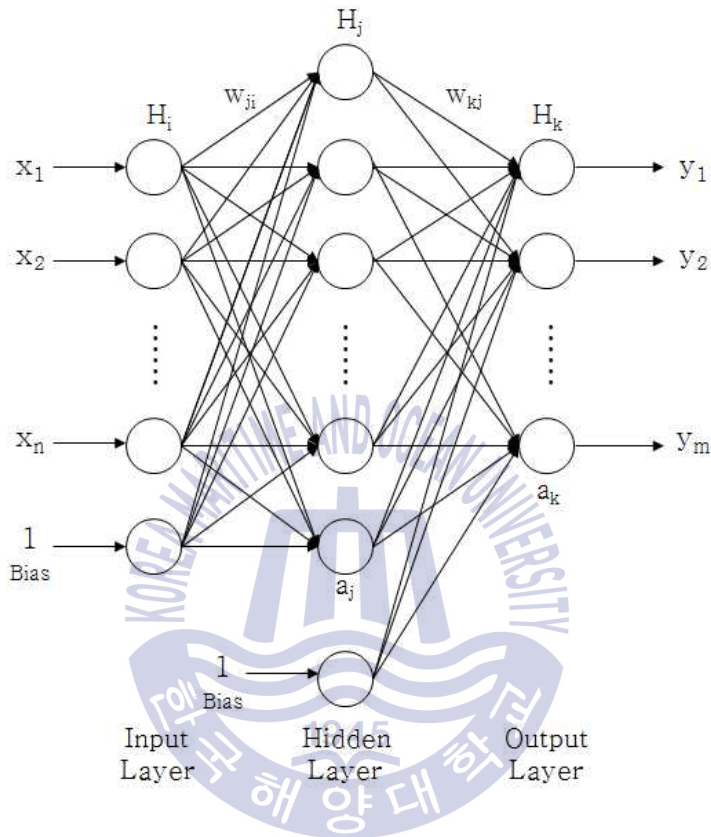


Fig. 6 Multi Layer Neural Network

각각의 원들은 그림 4에서 보여준 생물학적 뉴런들이다. 이 신경망은 x 라는 맨 왼쪽 줄에 입력 벡터를 갖는 입력층과 y 라는 맨 오른쪽 줄에 출력 벡터를 갖는 출력층으로 이루어지며 입력층과 출력층 사이의 중간층을 우리는 보통 은닉층(Hidden layer)이라 한다. H_i, H_j, H_k 는 입력층, 은닉층, 출력층 들의 각 뉴런 출력이고, 입력층과 은닉층 사이의 가중치를 w_{ji} , 은닉층과 출력층 사이의 가중치를 w_{kj} 로 표기한다. 모든 정보는 신경망의 가중치에 저장되며, 학습과정 동안 가중치 w_{ji}, w_{kj} 의 성분은 계속적으로 새로운 정보로 바뀌어 진다. 일반적으로 새로운 정보를 변경하는 신경망의 대표적인 알고리즘은 역전파 알고리즘

이다[19].

역전파 알고리즘은 하나의 지표(최종 뉴런의 출력과 바라는 출력 사이의 관계)를 기준으로 최적의 매개 변수 값을 탐색하는데, 이렇게 학습에서 사용되는 지표를 손실 함수(Cost Function)라 한다. 각 뉴런에 의해 계산된 최종 출력층 뉴런의 출력과 바라는 출력 사이의 오차를 최소화하는데, 손실 함수는 크게 2 가지로 최소-평균 자승법(Least-mean square)과 교차 엔트로피 오차(Cross entropy Error)가 있다. 여기서는 이해를 쉽게 하고자 최소-평균 자승법으로 설명한다.

역전파 알고리즘의 원리는 먼저 입력층에서는 신경망의 입력 x 를 은닉층으로 보낸다. 두번째로 은닉층의 뉴런들은 각각의 입력층으로 부터 입력된 값과 가중치들의 곱을 합산함과 동시에 활성화 함수를 통해 연산된 결과를 출력층으로 보낸다. 출력층은 은닉층과 같은 뉴런 연산을 하여 출력한다. 이때 신경망의 출력값이 바라는 목표값과의 차이를 구하며, 이 차를 오차라고 말한다.

이 오차를 최소화하기 위해 각 층에 있는 가중치의 오차 벡터 항을 편미분하여 가중치를 조정한다. 다시 말해 출력층의 출력과 바라는 목표치의 오차를 연산한 후 출력층에서 은닉층으로, 은닉층에서 입력층으로 역전파하여 오차에 따른 가중치 변화량에 의해 가중치들을 조정하며 이것을 오류 역전파(Error Back Propagation)라고도 말한다[20].

역전파 알고리즘을 수식적으로 나타내면 다음과 같다.

먼저 입력층, 은닉층, 출력층의 뉴런 출력은 식 (3), 식 (5), 식 (7)과 같다.

$$a_i \quad (i = 1, 2, 3, \dots, n) \quad (2)$$

$$H_i = \lambda f[a_i] \quad (3)$$

$$a_i = \sum_j W_{ji} H_j \quad (4)$$

$$H_j = \lambda f[a_j] \quad (5)$$

$$a_k = \sum_k W_{kj} H_j \quad (6)$$

$$H_k = \lambda f[a_k] \quad (7)$$

여기서 사용한 f 는 활성화 함수이며, a_i , a_j , a_k 는 이전의 뉴런 출력과 현재 층에 있는 가중치들과의 곱을 합산한 값이고 λ 는 활성화 함수의 기울기이다. 신경망을 학습시키기 위해 신경망의 출력값(y)이 바라는 목표값(D)과의 차인 오차를 구해야 하며 이 오차를 구하는 수식은 식 (8)에 나타내었다.

$$E = \frac{1}{2} \sum_k (D_k - H_k)^2, \quad H_k = y : \text{출력값} \quad (8)$$

학습의 목적은 가중치를 조정하여 오차 E 를 최소화하는 것이므로 가중치의 조정에 대하여 살펴보면 오차를 최소화하기 위해 가중치를 음의 경사방향 (Negative Gradient Direction)으로 변화시킨다. 따라서 가중치 변화를 음의 경사 방향으로 가중치의 방향 벡터를 편미분 함으로써 가중치 변화량을 구할 수 있다. 각 층에 있는 변화량을 구하면 식 (9)와 같다.

$$\Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}}, \quad \eta > 0 \quad (9)$$

여기서 η 는 학습 속도를 나타내는 상수이며 이것을 학습율이라 한다. 그리고 식 (9)을 연쇄 규칙(Chain Rule)을 사용하여 아래 식 (10)과 같이 쓸 수 있다.

$$\begin{aligned}\frac{\partial E}{\partial W_{kj}} &= \frac{\partial E}{\partial H_k} \frac{\partial H_k}{\partial a_k} \frac{\partial a_k}{\partial W_{kj}} \\ &= \frac{\frac{1}{2} \sum_k (D_k - H_k)^2}{\partial H_k} \frac{\partial \lambda f[a_k]}{\partial a_k} \frac{\partial \sum_k W_{kj} H_j}{\partial W_{kj}}\end{aligned}\quad (10)$$

여기서 활성화 함수 f 가 선형 함수라고 가정하면, 가중치 변화량 ΔW_{kj} 는 다음의 식 (11)과 같다.

$$\Delta W_{kj} = \eta (D_k - H_k) H_j \quad (11)$$

은닉층에 대한 가중치 변화량도 오차를 최소화하기 위해 음의 경사 방향으로 변화시키는 수식은 식 (12)와 같다.

$$\Delta W_{ji} = -\eta \frac{\partial E}{\partial W_{ji}}, \quad \eta > 0 \quad (12)$$

식 (12)을 연쇄 규칙(Chain Rule)을 사용하여 아래 식 (13)과 같이 쓸 수 있다.

$$\begin{aligned}\frac{\partial E}{\partial W_{ji}} &= \frac{\partial E}{\partial H_k} \frac{\partial H_k}{\partial a_k} \frac{\partial a_k}{\partial W_j} \frac{\partial H_j}{\partial W_{ji}} \\ &= \frac{\frac{1}{2} \sum_k (D_k - H_k)^2}{\partial H_k} \frac{\partial \lambda f[a_k]}{\partial a_k} \frac{\partial \sum_k W_{kj} H_j}{\partial H_j} \frac{\partial \lambda W_{ji} H_i}{\partial W_{ji}}\end{aligned}\quad (13)$$

식 (13)에 의해 입력층과 은닉층 사이에 있는 가중치의 변화량은 다음의 식 (14)로 나타내어진다.

$$\Delta W_{ji} = \eta (D_k - H_k) W_{ki} H_i \quad (14)$$

따라서 가중치의 변화는 다음과 같다.

$$W_{ji} = W_{ji} + \Delta W_{ji} \quad (15)$$

$$W_{kj} = W_{kj} + \Delta W_{kj} \quad (16)$$

은닉층을 2개로 구성하는 역전파 알고리즘을 블록 다이어그램으로 표현하여 설명하자면 그림 7과 같이 구성이 되고, 오른쪽에서 왼쪽 방향으로 가중치를 업데이트(학습)시키는 수식을 설명한다.

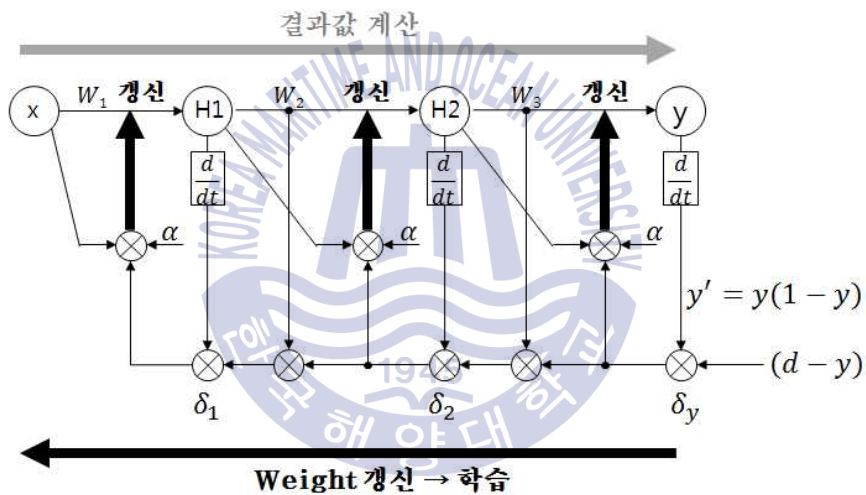


Fig. 7 BP Algorithm block diagram of two hidden layers

x 와 y 는 입력층과 출력층이고 H_1 과 H_2 는 2개의 은닉층이며 W_1 W_2 W_3 은 매개변수인 가중치이다. δ_i 는 오차 신호로써, 새로운 정보를 얻기 위해 역전파로 신호를 받는 영역이다. 그리고 활성화 함수가 단극성 시그모이드 함수를 사용한다면 출력 y 의 미분된 값은 식 (17)과 같이 나타낼 수 있다.

$$y = f(x) = \frac{1}{1 + e^{-\lambda x}} \quad (17)$$

$$y' = y(1 - y)$$

따라서, 출력층과 은닉층 1, 2로 들어오는 오차 신호는 식 (18), (19), (20)으로 표현되고, d 는 목표값이다.

$$\delta_y = (d - y)y(1 - y) \quad (18)$$

$$\delta_2 = \delta_y H_2' W_3 = \delta_y H_2 (1 - H_2) W_3 \quad (19)$$

$$\delta_1 = \delta_2 H_1' W_2 = \delta_2 H_1 (1 - H_1) W_2 \quad (20)$$

다음으로 각각의 가중치를 갱신하려면 이전의 가중치와 앞에서 계산한 오차 신호, 학습율 α 와 입력층/은닉층으로 식 (21), (22), (23)에서 역전파 알고리즘의 개념이 정리되어 진다.

$$W_3 = W_{3old} + \alpha \cdot \delta_y \cdot H_2 \quad (21)$$

$$W_2 = W_{2old} + \alpha \cdot \delta_2 \cdot H_1 \quad (22)$$

$$W_1 = W_{1old} + \alpha \cdot \delta_1 \cdot x \quad (23)$$

신경망을 학습시킬 때 초기 가중치는 작은 무작위 값으로 설정하고 이런 초기화는 최종 출력에 영향을 미치므로 보통 일반적으로 초기 가중치는 -0.5에서 0.5 사이의 값을 주로 사용한다.

2.3 딥러닝 알고리즘 종류

2.3.1 심층 신경망(DNN, Deep Neural Network)

심층 신경망은 신경망 알고리즘 중에서 여러 개의 층으로 이루어진 신경망을 의미한다. 즉, 그림 8처럼 입력층과 출력층 사이에 복수개의 은닉층들로 이뤄진 피드포워드 신경망(Feedforward Neural Network)을 의미한다. 심층 신경망은 일반적인 인공 신경망과 마찬가지로 복잡한 비선형 관계들을 모델링 할 수 있다.




Fig. 8 Typical Deep Learning structure

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[21]. 심층 신경망의 이러한 특징은 비슷하게 수행된 인공신경망에 비해 더 적은 수의 유닛(Unit, Node) 들 만으로도 복잡한 데이터를 모델링 할 수 있게 해준다[22]. 이전의 심층 신경

망들은 보통 앞 먹임 신경망으로 설계되어 왔지만, 최근의 연구들은 심층 학습 구조를 순환 신경망(RNN, Recurrent Neural Network)에 성공적으로 적용했고 일례로 언어 모델링 분야에 심층 신경망 구조를 적용한 연구 등이 있다.

심층 신경망은 역전파 알고리즘을 기반으로 분류될 수 있게 학습될 수 있다. 이때, 가중치들은 아래의 등식을 이용한 확률적 경사 하강법(Stochastic Gradient Descent)을 통하여 식 (24)와 같이 갱신한다.

$$\Delta w_{ij}(t+1) = \Delta w_{ij}(t) + \eta \frac{\partial C}{\partial w_{ij}} \quad (24)$$

η 는 학습율(Learning Rate)을 의미하며, C는 신경망의 학습 지표로써 손실 함수(Cost Function)를 의미한다. 손실 함수의 선택은 학습의 형태(지도학습, 기계 학습, 강화학습)와 활성화 함수와 같은 요인들에 의해서 결정된다. 예를 들어, 다중 클래스 분류 문제(Multiclass Classification Problem)에 지도 학습을 수행할 때 일반적으로 출력값 표현법과 손실 함수는 각각 소프트맥스 함수와 교차 엔트로피 함수(Cross Entropy Function)로 결정된다.

소프트맥스 함수는 출력값 합이 1이 되도록 변형하여 문제를 확률적으로 대응 할 수 있고, 다음의 식 (25)로 정의된다.

$$p_j = \frac{\exp(x_j)}{\sum_k \exp(x_k)} \quad (25)$$

이때 p_j 는 클래스 확률을 나타내며, x_j 와 x_k 는 각각 유닛 j 로의 전체 입력과 유닛 k 로의 전체 입력을 나타낸다.

그리고 모델을 학습시키기 위해서는 우선 모델이 좋다는 것이 어떤 것인지를 정량적인 표현으로 정의해야 하는데, 주로 교차 엔트로피 함수를 사용한다. 이것은 정보 이론 분야에서 정보를 압축하는 방법으로 고안되었지만 딥러닝에 많이 활용되고[23], 식 (26)으로 정의된다.

$$C = - \sum_j d_j \cdot \log(p_j) \quad (26)$$

이때 d_j 는 출력 유닛 j 에 대한 목표 확률을 나타내며, p_j 는 해당 활성화함수를 적용한 이후의 j 에 대한 확률 출력이다[24].

심층 신경망이 각광을 받고 있는 이유 중의 하나는 신경망에서 보다 학습의 효율과 정확도를 높일 수 있었는데 다음에서 설명하는 3가지 기법들이 나오면서 발전할 수 있었다.

첫 번째는 가중치의 최적화인데, 신경망 학습의 목적은 손실 함수의 값을 가능하면 낮추는 매개변수 즉 가중치를 찾는 것이고, 이러한 문제를 푸는 것을 최적화(Optimization)라 한다. 이 가중치를 수식을 풀어서 순식간에 낮은 값으로 구하는 방법은 없기 때문에 가중치를 갱신하는 일을 몇 번이고 반복해서 최적의 값으로 다가간다. 이렇게 찾아가는 방법 중에 기초적인 방법이 경사 하강법(GD, Gradient Descent)이고 무작정 찾는 방법에서 발전되어 4가지 대표 방법인 확률적 경사 하강법(SGD, Stochastic Gradient Descent), 모멘텀(Momentum), AdaGrad(Adaptive Gradient Descent)와 Adam(Adaptive Moment Estimation)이 있다[25]. 확률적 경사하강법의 수식은 식 (27)과 같다.

$$W = W - \eta \frac{\partial L}{\partial W} \quad (27)$$

W 는 가중치고 $\frac{\partial L}{\partial W}$ 는 W 에 대한 손실 함수의 기울기이고 η 는 학습율이다. 가중치 최적화를 위해 전체 데이터 대신에 일부 데이터의 모음(Mini batch)에 대해서만 손실 함수를 계산을 하면 다소 부정확 할 수는 있지만 훨씬 계산 속도가 빠르다는 장점이 있다. 그리고 모멘텀은 운동량을 뜻하는 단어로 식 (28)과 식 (29)로 표현이 가능하다.

$$v = \alpha v - \eta \frac{\partial L}{\partial W} \quad (28)$$

$$W = W + v \quad (29)$$

v 는 물리에서 말하는 속도(Velocity)에 해당하고 이동하는 과정에서 일종의 관성을 주어 과거에 이동했던 방식을 기억하면서 그 방향으로 일정 정도를 추가적으로 이동하는 방식이다. AdaGrad는 개별 가중치에 적응적(Adaptive)으로 학습율을 조정하면서 학습을 진행하고 식 (30)과 (31)로 표현된다.

$$h = h + \frac{\partial L}{\partial W} \odot \frac{\partial L}{\partial W} \quad (30)$$

$$W = W + \eta \frac{1}{\sqrt{h}} \frac{\partial L}{\partial W} \quad (31)$$

h 는 기존 기울기 값을 제공하여 계속 더해주고 \odot 는 행렬의 원소별 곱셈을 의미한다. 그래서 가중치를 갱신할 때 $\frac{1}{\sqrt{h}}$ 을 곱해 학습율을 조정한다. 이 방식은 지금까지 많이 변화하지 않은 변수들은 Step size를 크게 하고, 지금까지 많이 한 변수들의 경우는 세밀한 값을 조정하여 세밀한 탐색을 한다. 그리고 Adam은 2015년도에 제안된 기법으로, 이론은 다소 복잡하지만 직관적으로는 AdaGrad와 모멘텀을 융합해 만든 것 같은 방법이다.

두 번째는 배치 정규화(Batch Normalization)이다. 딥러닝의 계산량이 많아 학습 시간이 길다보니 활성화 함수의 활성화 값 또는 출력값을 정규화(정규분포로 만들)하는 것이다. 특정 은닉층에 들어가기 전에 배치(Batch) 정규화 층을 더해 주어 입력을 수정해 준 뒤 새로운 값을 활성화 함수로 넣어주는 방식으로 써, 각 은닉층에서 정규화를 하면서 입력분포가 일정하게 되고 이에 따라 학습율을 크게 설정해도 가능하므로 결과적으로 학습 속도가 빨라지게 된다[26].

마지막 세 번째는 과 적합을 억제하는 기술인 가중치 감소(Weight Decay)와 드롭 아웃(Drop Out)이다[27]. 과 적합이 주로 일어나는 경우는 가중치 수가 많고 학습 데이터가 적은 경우이다. 가중치 감소는 학습 중에 가중치가 큰 것에 대해서는 일종의 패널티를 부과해 과 적합의 위험을 줄이는 방법이고 드롭 아웃은 훈련을 할 때 임의의 뉴런을 골라 삭제하여 신호를 전달하지 않게 하는 방법이다.

이러한 중요한 기술들로 인해 최적의 가중치를 찾아가는 방법들과 연산 시간을 줄이고 과 적합을 억제하는데 효과를 보면서 심층 신경망은 발전되고 있다.

2.3.2 합성곱 신경망(CNN, Convolution Neural Network)

합성곱 신경망은 1989년 LeCun 논문의 “Back-propagation applied to handwritten zip code recognition” 으로 소개되었다[28]. 그 당시에는 필기체 인식에 있어서 의미 있는 결과가 나왔지만 이를 범용화 하는 데는 미흡한 단계였다. LeCun은 추후에 LeNet이라는 네트워크를 1998년에 소개했는데, 이것이 이미지 인식과 음성 인식 등 다양한 곳에서 사용되는 최초의 합성곱 신경망이라고 할 수 있다[29].

지금까지 본 신경망은 인접하는 계층의 모든 뉴런과 결합되어 있는 완전히 연결된 계층(Fully-connected)을 Affine 계층이라 하면, 합성곱 신경망의 구조는 레고 블록처럼 계층을 조합하여 만들 수 있다. 합성곱 계층(Convolutional Layer)과 풀링 계층(Pooling Layer)이 새롭게 등장한다. 합성곱 계층은 다차원의 데이터 연산이고, 풀링 계층은 데이터의 공간 크기를 축소하는 연산이다.

그림 9에서와 같이 위의 그림은 Affine 계층으로 이루어진 네트워크를 나타내고, 아래의 그림은 합성곱 계층과 풀링 계층으로 이루어진 합성곱 신경망의 구조를 보여주고 있다[30].

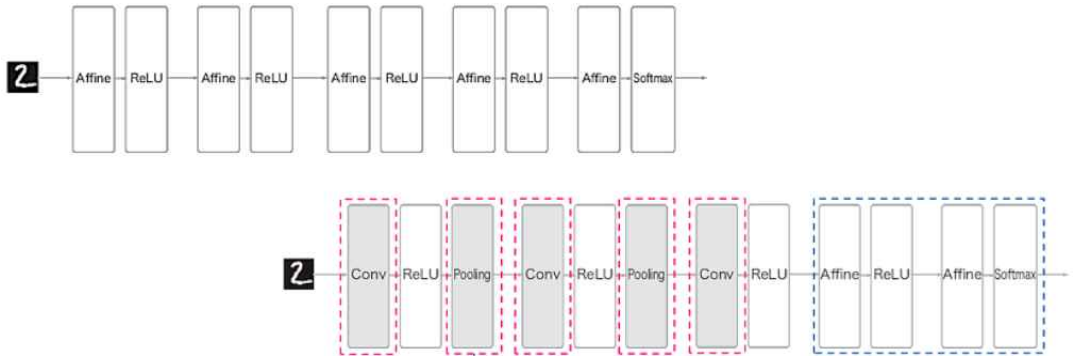


Fig. 9 Fully-connected layer and Convolution Neural Network Structure

기존의 다중 퍼셉트론의 문제점은 변수의 개수, 네트워크의 크기와 학습 시간의 세 가지 문제가 발생한다. 아래 그림 10과 같이 28×28 크기의 필기체를 인식하는 네트워크를 만든다고 하면, 은닉층이 한 층이고 100개의 뉴런을 가지고 있는 경우에 이 네트워크에 필요한 가중치와 편향(Bias)은 총 79,510($78,400 + 100 + 1000 + 10$)개가 필요하다. 이 글자를 전체적으로 2 픽셀 씩 이동하게 되면 새로운 학습 데이터로 처리해줘야 하는 문제점이 있을 뿐만 아니라, 글자의 크기, 회전, 변형이 있게 되면, 이에 대한 새로운 학습 데이터를 넣어줘야 하는 문제가 있다. 글자의 형상은 고려하지 않고, 로우 데이터를 직접 처리하기 때문에 많은 양의 학습 데이터가 필요하고, 따라서 학습 시간이 길어지게 된다 [31].

이런 문제를 해결하고자 만들어진 것이 합성곱 신경망이다. 그림 10의 필기체나 MNIST 데이터와 같은 이미지 데이터는 일반적으로 채널, 세로, 가로 이렇게 3차원으로 구성된 데이터이고 Affine 계층에서는 이 3차원 데이터를 1차원 데이터($28 \times 28 = 784$)로 바꿔 입력했지만 합성곱에서는 3차원 데이터(1, 28, 28)를 입력하고 3차원의 데이터로 출력하므로 형상을 유지할 수 있다. 합성곱 신경망에서는 이러한 입출력 데이터를 특징맵(Feature Map)이라고 한다.




Fig. 10 MNIST data Feature Map

2.3.3 순환 신경망(RNN, Recurrent Neural Network)

순환 신경망은 시계열 데이터 분석을 위한 신경망으로써 일반적인 신경망과 달리 신경망 내부에 메모리를 통해 반복적인 학습이 가능하다[32][33]. 순환 신경망은 인공 신경망을 구성하는 유닛 사이의 연결이 방향성 사이클(Directed Cycle)을 구성하는 신경망을 말하며, 임의의 입력을 처리하기 위해 신경망 내부의 메모리를 활용할 수 있다[34]. 메모리는 학습하는 단계의 이전 단계에서 얻은 정보를 저장할 수 있고 이러한 정보로 입력 데이터에 이전 단계의 정보를 고려하는 피드백 기능을 제공하기 때문에 시간 순으로 입력되는 데이터를 처리하기에 적절한 알고리즘이다[35].

다음의 표 1은 딥러닝 활용사례 및 적용되는 딥러닝 내용이다.

Table 1 Types of Deep Learning and Application

종류	개념	활용 분야
심층신경망 (DNN)	입력계층과 출력계층 사이에 복수개의 은닉계층들로 이루어진 인공신경망	자연어 처리, 음성 인식, 센서기반 분류
합성곱신경망 (CNN)	레고 블록처럼 계층을 조합하여 만들 수 있고, 합성곱 계층과 풀링 계층으로 이루어진 신경망	영상, 음성 분석
순환신경망 (RNN)	내부에 메모리를 통해 반복적인 학습이 가능하고 시계열 데이터 분석을 위한 신경망	필기체 인식

위 표 1과 같이 각각의 알고리즘들로 활용하는 분야에서의 딥러닝을 알아보았고, 본 논문에서는 심층 신경망으로 센서로 출력되는 데이터를 기반으로 패턴 분류에 활용되는 사례를 연구하고자 한다.

제 3 장 스마트 플러그/콘센트 관련 연구

본 장에서는 에너지 절감을 위한 스마트 플러그/콘센트의 기술 동향을 소개하고 경쟁 심화에 따라 가격 하락으로 수익성 악화가 우려되는 현 시점에 경쟁력 확보를 위한 새로운 패러다임을 설명한다. 더 나아가 스마트 홈 시스템에서의 지능형 정보가전의 기술과 연결시키는 내용을 설명한다.

3.1 스마트 플러그/콘센트 기술 동향

사물 인터넷이란 흔히 IoT라고 불리는데, 실제 세계에 존재하는 사물들을 네트워크로 상호 연결하여 사람과 사물, 사물과 사물 간에 언제 어디서나 서로 소통할 수 있도록 하는 미래 인터넷 기술을 말한다[36][37].

앞서 언급 했듯이 딥러닝이 발전하게 된 계기 중 한 가지가 빅 데이터를 확보할 수 있었다는 것인데, 사물 인터넷이 널리 보급됨으로써 사용자의 가전제품 사용 습관과 제품이 사용되는 주변 환경 등의 많은 정보를 얻을 수 있게 되었다. 가전제품과 사물 인터넷과의 만남은 상호작용 가능한 정보와 통신기술에 기반하고, 물리적이고 가상적인 상호접속 대상물에 의해 고도화된 서비스가 가능하고, 또한 정보사회를 위한 글로벌 인프라 구축을 할 수 있게 되었다.

시장 조사기관인 SA(Strategy Analytics)에 따르면, 그림 11에서의 표현과 같이 2012년 전 세계에 20억 명이 네트워크로 연결이 되었다면 2020년경이 되면 500억 개의 사물 인터넷 디바이스들이 보급되어 거대 네트워크가 만들어질 것이라는 예측을 한바가 있다.




Fig. 11 The Importance of the IoT Concept[38]

2015년 사물 인터넷 기기 시장 비중이 9.5%이지만, 사물 인터넷의 확산은 사회 전체 분야에 걸쳐 혁신적인 상품 및 서비스 시장을 창출할 뿐 아니라 스마트 센서 및 분석 플랫폼 등 기반 기술에 대해서도 거대한 시장을 제공할 것으로 예견되고 있다. 그리고 사물 인터넷 기술이 냉장고, 세탁기, 에어컨, TV 등 다양한 가전에 동시에 적용됨에 따라 시장 성숙이 한층 빠르게 전개되고 있으며 스마트폰이 홈 네트워크와 함께 연동되면서 통합적 스마트 홈이 실현되고 있어, 세대 내/외부의 각종 기기를 유기적으로 결합한 시스템인 홈오토메이션 분야는 최근 한 단계 더 진화되고 있다[39]. 모든 제품을 사물 인터넷 관련 기기의 시장 성장세가 크지는 않지만 지능형 가전 기기의 발전이 뒤따른다면 성장할 것으로 예상된다.

스마트 홈은 사물 인터넷을 기반으로 여러 형태의 자동화 서비스를 제공하는 새로운 주거형태를 의미하고 가스 원격제어, 냉난방 제어, 조명 제어 등이 가능하고 사용자와 집 안의 여러 가전기기들과의 소통이 가능하다. 따라서 사용자가 집 안에 있지 않아도 자동으로 작동이 가능한 다양한 서비스들이 스마트 홈에 포함이 된다.

스마트 플러그 및 콘센트란 그림 12에서의 모습으로써 전원 On/Off 제어, 전력측정, 안전관리, 통신기능을 포함한 차세대 제품으로 기존의 단순 기계식 구조를 탈피하여 전력의 이상상태를 모니터링하고 외부에 전송할 수 있는 에너지 절감 시스템의 사물 인터넷형 기기를 말한다.



Fig. 12 Products of Smart Plug

또한 유무선 네트워크를 통해 연동하여, 스마트 플러그에서 측정된 기기별 소비전력 정보를 실시간으로 사용자에게 보여주고 스마트 플러그에 연결된 가전제품의 전원 제어, 대기 전력 자동 학습, 대기전력 자동 차단, 가전 기기 자동 인식 기능, 사용자 등록 이벤트에 의한 전원제어, 실시간 그래프, 요금조회 등 다양한 어플리케이션을 제공하고 있다. 그리고 내부에 소비전력을 측정할 수 있는 하드웨어 모듈과 스마트 플러그 및 콘센트에 연결된 가전기기의 전원을 On/Off 제어 할 수 있는 모듈 및 측정한 결과를 에너지 절감 시스템 서버로 전달 할 수 있는 통신 모듈로 구성되어 있다. 또한 가정 내 에너지 소비 모니터링 및 소비 전력 절감을 위한 기기별 전력 소비량의 실시간 모니터링 기술, 전력 제어기술, 대기전력 자동학습, 대기전력 자동차단 등을 지원하고 있는 지능적인 홈 에너지 절감 시스템과 연동이 가능하다. 무엇보다도 대기전력에 대한 이슈가 증가하면서 이를 줄이기 위한 정부 및 지자체에서 다각도의 노력이 진행 중이며, 2015년부터 스마트 플러그 시범사업을 진행하고 있다.

그리고 그림 13에서와 같이 기존의 콘센트 및 플러그와 인터넷에 사물 인터넷을 기반으로 한 스마트 기능이 추가 된 스마트 플러그는 이종산업으로부터 새롭고 다양한 형태의 제품 및 서비스가 융합되는 산업 생태계로 변모하고 있다. 이전에는 플러그, 콘센트, 전기제품 사물 인터넷에 국한되었다면 지금은 스마트 플러그/콘센트, 스마트 스위치/누전차단기를 이용하여 스마트 홈/사물 인터넷, 스마트 빌딩, 스마트 그리드로 발전되고 있다.



Fig. 13 Smart Plug system structure diagram

하지만, 기존의 콘센트 및 플러그 산업은 비교적 안정적인 국내 수요가 유지되고 기존 제품의 전자기기화로 전력 수요가 늘어나면서 관련 부품 수요가 증가하고 있으나 낮은 진입장벽으로 중국 등 해외 기업의 시장 진입이 확대되고 있고, 경쟁 심화에 따른 가격 하락으로 수익성 악화 우려가 커지고 있기 때문에 경쟁우위 확보를 위해 제품의 신뢰성 외에도 가격 경쟁력 확보가 필요하다. 세계 각 나라마다 사물 인터넷을 기반으로 스마트 홈에 대한 기술력을 높이고 새로운 사업기회를 모색할 수 있는 정책적인 지원이 이루어지고 있으며 특히 미국과 중국은 사물 인터넷을 국가 성장의 핵심 성장 동력으로 보고 강력한 의지를 가지고 기술 개발을 위한 산업 육성 정책을 추진하고 있다.

최근 스마트 플러그를 포함하고 있는 스마트 홈 시장의 동향을 보면, 큰 그림이나 트렌드는 글로벌 기업들인 구글, 애플, 퀄컴, 인텔 등이 주도하고 있지만, 스마트 홈 분야에 특화된 노하우와 능력이 부족한 것이 단점으로 지적되고 핵심 기술력으로 차별화되는 분야가 필요한 현실이다.

그러므로 인공지능 기술을 스마트 플러그나 콘센트에 접목하여 가전기기의 자동 인식 기능으로 제품 종류를 분류하고 제품의 동작을 판단한다면, 전력 관리 기술 측면에서는 각 제품의 동작 상태를 모니터링하고 제품군 별(발열체, 냉각기, 회전체, 영상기 등) 누적 사용량을 확인하여 비교가 가능하고 각 제품의 고장을 진단 할 수가 있다. 가전기기의 지능화 기술 측면에서는 세탁기의 경우

탈수가 완료되는 시점을 알려주는 알람 기능이 가능하고, 냉장고의 경우 독거노인의 가정 내 생활 패턴 확인이 가능하며, 정수기의 경우 일일 간 음료 섭취량/사용량 모니터링이 가능하고, 전자레인지의 경우 요리하는 횟수나 시간을 알려 줄 수가 있다. 이는 스마트 홈 시스템에서의 지능형 정보가전의 기술이라 할 수 있고 이는 그림 14에 도식적으로 설명 할 수 있다.

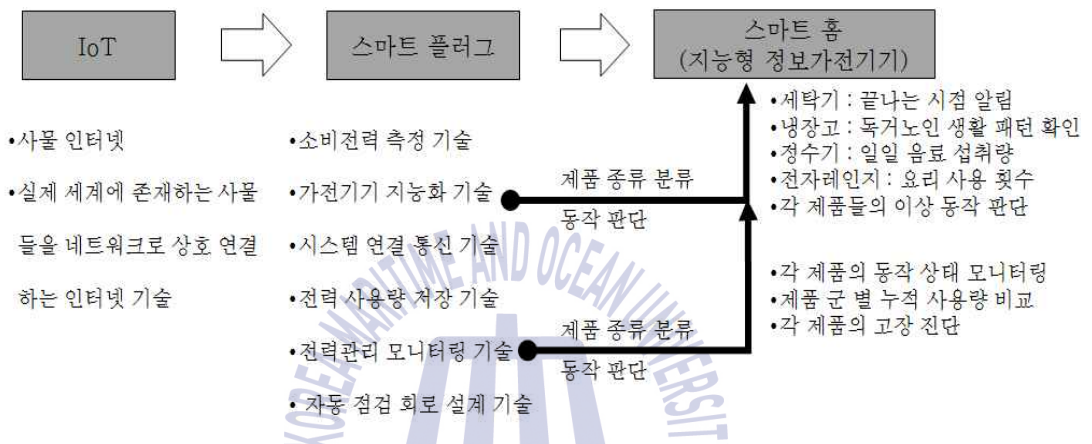


Fig. 14 Link between IoT and Smart Home

지능형 정보가전 기술이란 사람-기기-환경과 자연스러운 상호작용으로 동작하며 네트워크와 연결되어 정보를 송수신하고 서비스와 연동 할 수 있는 지능형 생활기기로 스마트 홈 환경에서 인간 중심의 생활 서비스를 제공하여 인간의 풍요로운 삶을 지원하는 모든 전자기기 기술을 의미한다. 1인 가구의 확산으로 개인 생활 스타일에 적합한 제품 구매와 자신만의 차별화된 제품을 소유하고 싶어 하는 욕구를 만족시켜 줄 수 있는 사물 인터넷 기반의 정보 가전들이 출현하고 있다. 스마트 플러그와 콘센트의 설치되는 장소는 다르지만 기능은 동일하므로, 스마트 플러그로 언급한다.

3.2 스마트 플러그 구성 요소

스마트 플러그는 다음 그림 15와 같이 AC 입력 전원을 받아 가전기기에 전

원을 연결해 소비되는 전류를 측정하여 에너지 절감이 되도록 유도를 한다. 또한 가전기기 내의 전력변환 장치와 전원으로부터 전기를 공급 받는 부하에 따라 소비되는 전류 패턴이 달라지는데 이런 구성 요소에 대해 알아보려고 한다.




Fig. 15 Structure of Smart Plug

3.2.1 AC 입력 전원

DC는 도선의 한쪽 방향으로만 전류가 흐른다. 건전지의 예를 들면 항상 같은 극을 유지하기 때문에 한쪽 방향으로만 전류가 흐른다. AC는 일정한 방향 없이 진동만 한다. 이것은 주기적으로 회로의 전압이 바뀌기 때문이고 50Hz와 60Hz의 2가지 종류가 있는데, 우리나라는 60Hz이다. 이 60Hz 의미는 전압이 두 번 바뀌어 원래 상태로 돌아오는 과정을 초당 60회 반복한다는 의미이다. AC 전원을 사용하는 전자기기들은 극성 표시가 필요 없기 때문에 플러그의 극성에 대해 신경 쓰지 않아도 된다[40].

AC는 패러데이 전자기 유도 법칙에 따라 생성되어 일정한 주기를 갖고 방향을 바꾸는 파동 에너지이다. 발전원에 따라 다양한 파형이 있을 수 있으나 안정적인 에너지원으로 쓰이기 위해 일반적으로 사용되는 전원은 사인파의 형태를 나타낸다.

AC의 전압과 전류는 아래의 식 (32), (33)과 같이 나타낼 수 있다.

$$V(t) = V_m \cos(\omega t + \theta_v) \quad (32)$$

$$I(t) = I_m \cos(\omega t + \theta_i) \quad (33)$$

$V(t)/I(t)$ 는 순간 전압/전류, V_m/I_m 는 최대 전압/전류, wt 는 위상, θ_v/θ_i 는 전압/전류의 순간 변위이다.

따라서 특정 순간의 전력은 아래 식 (34)와 같이 나타낼 수 있다.

$$P(t) = V(t) \cdot I(t) \quad (34)$$

$$= V_m \cos(wt + \theta_v) \cdot I_m \cos(wt + \theta_i)$$

$$= \frac{V_m I_m}{2} \cos(\theta_v - \theta_i) + \frac{V_m I_m}{2} \cos(2wt + \theta_v + \theta_i)$$

일반적인 공급 전원은 동상(In phase)이므로 전압과 전류의 위상과 순간 변위는 같다고 간주하여 계산할 수 있다. 위의 AC 전력 식 $P(t)$ 는 일정한 주기를 갖는 주기 함수이다. AC 전력은 일정한 주기를 갖기 때문에 주기를 단위로 하여 합하면 상쇄되어 0이 되어 버리고 만다. 그러나 매 시각의 전력은 분명 0이 아니기 때문에 실제 줄열을 발생시키는 유효 전력을 계산할 필요가 있다. 전기 회로 이론에서는 제곱 평균의 양으로 전압과 전류의 실효값을 계산하고 이를 통해 유효전력을 나타낸다[41].

AC 전력을 사용하는 전기 회로에서 부하를 통과하는 전류는 제곱 부하의 특성인 저항 계수(Resistance), 유도 계수(Inductance)와 용량 계수(Capacitance)에 따라 전압과 전류의 위상에 차이가 생기게 된다.

AC 회로 내에 유도 계수가 있으면 다음 식 (35)와 같이 전류가 전압보다 위상이 $\frac{\pi}{2}$ 만큼 느리다.

$$v = \sqrt{2} V \cdot \sin(wt + \frac{\pi}{2}) = \sqrt{2} \omega LI \cdot \sin(wt + \frac{\pi}{2}) [V] \quad (35)$$

용량 계수가 있으면 다음 식 (36)과 같이 전압이 전류보다 위상이 $\frac{\pi}{2}$ 만큼 느리다.

$$i = \sqrt{2} I \cdot \sin(\omega t + \frac{\pi}{2}) = \sqrt{2} \omega C V \cdot \sin(\omega t + \frac{\pi}{2}) [A] \quad (36)$$

이와 같이 제품의 특성과 종류 따라 입력되는 AC의 위상이 차이가 남을 알 수 있고, 그림 16에서와 같이 입력 전원 앞단에 스마트 플러그를 연결해 제품의 입력전류(i_i)를 판단 한다.

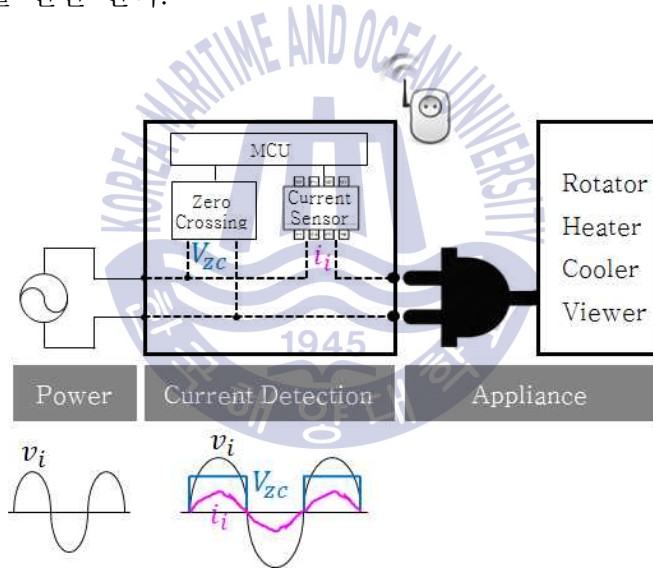


Fig. 16 Smart Plug to Measure Input Current

3.2.2 스마트 플러그 개념 및 적용 범위

스마트 플러그는 가정집에서의 콘센트와 가전제품 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 사물 인터넷형 기기를 의미한다. 또한 스마트 플러그의 산업 특징으로는 상시 실시간 에너지 소비 모니터링을 통해 사용자의 에너지 절약 활성화를 유도하고 사용자 설정 기반의 알람 기능을 통해 소비전력을 절감하며, 유무선 네트워크를 통한 스마트 그리드의 적용 및 향후 신재생 에너지 생산 및 소비 관리 기술 플랫폼으로의 응용 가능성이 높아지고 있다[42].

그림 17은 스마트 플러그의 기능으로써 가전기기가 연결되어 동작 할 때 소비전력을 측정할 수 있는 하드웨어 모듈과 스마트 플러그에 연결된 가전기기의 전원을 On/Off 제어 할 수 있는 모듈 및 측정된 결과를 에너지 절감 시스템 서버로 전달할 수 있는 통신모듈로 구성되어 있다.

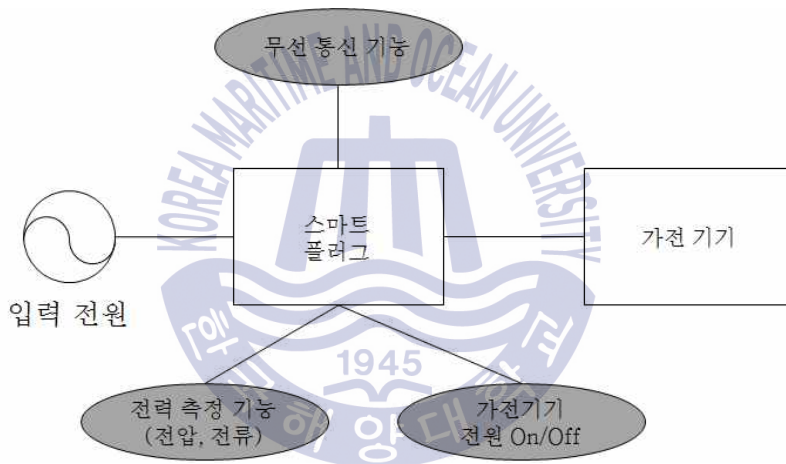


Fig. 17 Features of Smart Plug

스마트 플러그의 적용 범위는 그림 18에서와 같이 기존에 단순한 플러그의 기계적인 제품을 기반으로 사물 인터넷 기능을 탑재하여 제어 연동, 에너지 절약, 어플리케이션과 정보 관리의 4가지 기능을 제공하는 제품을 포함하고 있다.

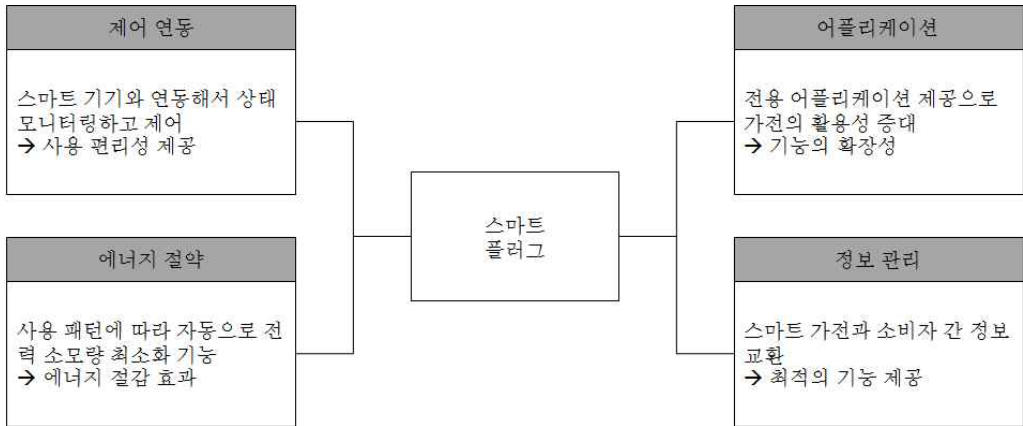


Fig. 18 Scope of Smart Plug

제어 연동은 스마트 폰이나 태블릿 PC 등 스마트 기기와 연동해 원격으로 스마트 플러그를 모니터링하고 제어함으로써 사용상 편리성을 제공하는 기능이고, 에너지 절약은 전기 요금 체계 및 소비자의 사용 패턴에 따라 자동으로 전력 소모량을 최소화하여 사회 전체적인 에너지 절감 효과 기능을 제공한다. 어플리케이션은 스마트 가전의 특징에 적합한 전용 어플리케이션이 제공됨으로써 가전의 활용성을 증대시키고 기능의 확장성을 개선하는 기능이고, 정보 관리는 통신 인프라를 통한 스마트 가전과 소비자 간 정보 교환이 용이하며 지속적인 업그레이드를 통해 최적의 기능을 제공한다.

3.2.3 전력 변환

가전제품에서 전력변환 시스템의 기능은 단지 전력의 흐름을 제어하고 전압이나 전류의 형태를 변환시키는데 있다.

가정집에서의 입력은 AC 전원으로 들어가서 전력변환 시스템을 통해 출력은 DC로도 만들고 AC로도 만들어지는데, 마지막 단 부하의 특성에 따라 전력변환 시스템이 달라지고 입력단의 AC 전류도 차이가 발생한다.

이때 그림 19와 같이 스마트 플러그는 제품의 입력 단에 연결되어 있고 내부에는 입력되는 전압과 전류를 측정 할 수 있는 기능을 가지고 있으며, 플러그

의 위치는 어떠한 제품이 연결되더라도 항상 조건 없이 신호를 받을 수 있다는 장점을 가지고 있다. 이러한 스마트 플러그로 측정되는 전류의 패턴으로 제품 분류 능력과 동작 상태를 파악하는 데이터로 사용되므로, 전력 변환되는 방식이 어떠한지 알아보려고 한다.



Fig. 19 Power conversion system

전력 변환 방식에서는 그림 20에서와 같이 전력반도체 스위치(예 정류기, 인버터, 초퍼 등)를 사용하여 전력의 형태를 변환하고 그 흐름을 제어한다.

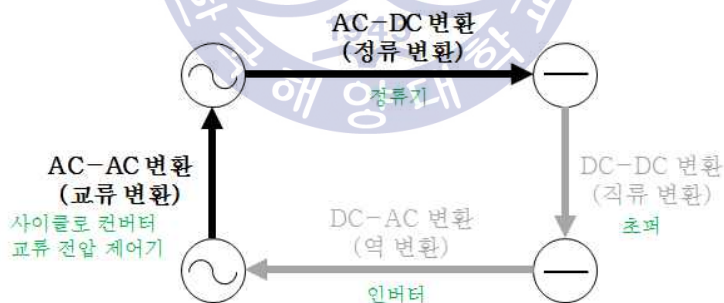


Fig. 20 Power conversion method[43]

그러므로 전력변환기는 변환하는 전력의 형태에 따라서, 또 전력의 전달방향에 따라서 기능적으로 AC-DC 변환, AC-AC 변환, DC-DC 변환, DC-AC 변환으로 나뉘어진다. 전력의 형태는 크게 DC 전력과 AC 전력으로 나눌 수 있다.

가정에서의 전력변환은 AC 전력에서 DC 전력이나 AC 전력으로 변경 할 수

있다. 이러한 일반 가정집에서의 전력변환에서 정류되는 방식에 대해 아래의 그림 21과 같이 정의된다.

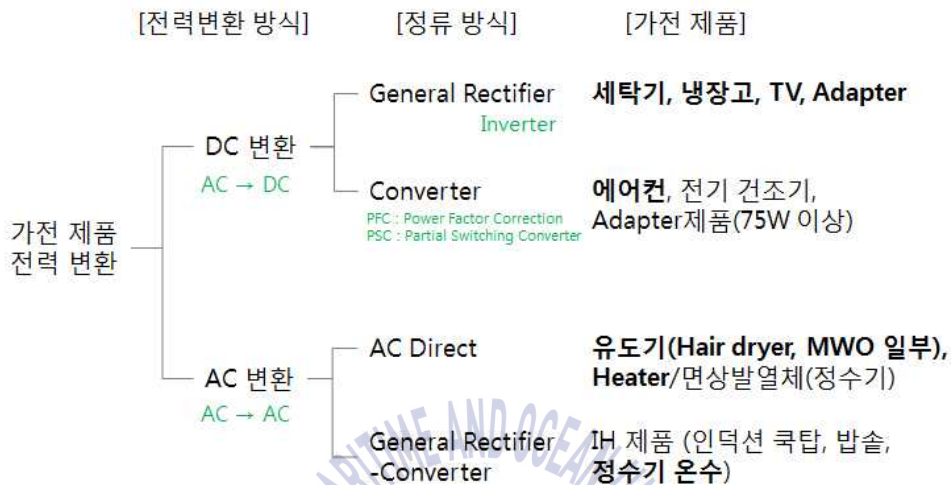


Fig. 21 Power conversion classification

먼저 AC에서 DC로 변환 할 때 2가지 정류방식이 있는데, 일반 정류기 (General Rectifier)와 컨버터(Converter) 방식이 있다. 일반 정류기는 일반적인 DC 정류 방식이고 컨버터 방식은 일반적 정류기에서 부하로 가는 전류의 형태를 완만하게 유지하는 방식이다. 이는 하모닉(Harmonics) 규제 대응으로 사용이 된다. 일반 정류기는 AC 전원을 DC로 변환하여 DC 부하를 사용하는 TV, 아답터(Adapter) 제품 등이 있고, AC 전원을 DC로 변환하여 다시 DC를 AC로 변환하는 인버터(Inverter) 방식의 세탁기, 냉장고 등의 제품이 있다.

AC에서 AC로의 변환 할 때는 직접 AC(AC Direct) 방식과 일반 정류 변환기 (General Rectifier - Converter) 2가지 정류 방식이 있는데, 직접 AC는 최종 부하가 AC 전원을 직접 사용하는 부하로써 변환 방식 없이 저가로 사용되는 방식이다. 적용되는 제품은 유도기나 히터 제품들이다. 일반 정류 변환기는 출력 전류의 진폭이나 위상, 주파수를 변환하기 위해 변환을 한다. 제품으로는 유도 가열(IH, Induction Heating) 제품이라 할 수 있다.

제 4 장 지능형 스마트 플러그 시스템 설계 및 구현

본 장에서는 데이터 획득이 용이한 사물 인터넷형 스마트 플러그로, 부류의 분류를 명확히 하는 딥러닝 이론의 실험 구성을 설명한다.

가전제품의 자동 분류를 구현하기 위하여 스마트 플러그 시스템을 설계한 내용을 하드웨어 측면의 회로설계와 소프트웨어 측면의 딥러닝 구성 내용에 대해서 제시하고, 그림 22에서와 같이 하드웨어 측면에서는 전류 및 전압 측정을 위한 전력 측정 회로와 신호를 얻기 위한 MCU 회로, 사용자와의 통신을 위한 와이 파이 회로가 있다. 소프트웨어 측면에서는 입력 데이터를 받아서 패턴 분류하고 평가를 할 수 있는 딥러닝 구조에 대해 설명한다.

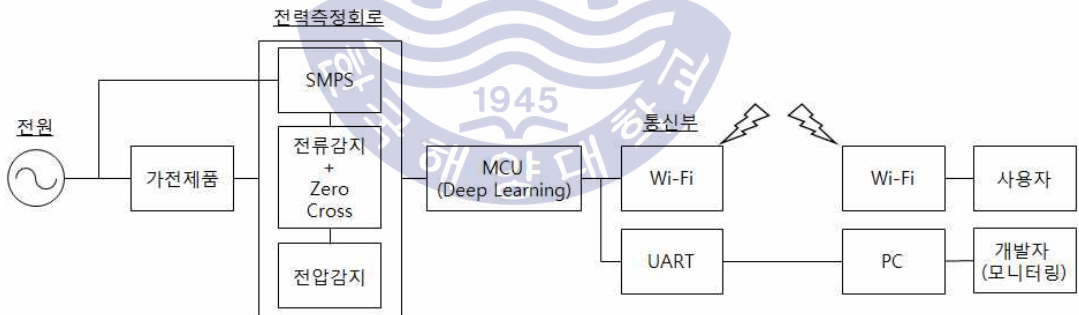


Fig. 22 Functional Block diagram

4.1 하드웨어 구성

4.1.1 전력 측정 회로 설계

하드웨어 구성은 아래의 그림 23과 같이 묘사되고 2가지로 구분하여, 전력 측정회로와 MCU 및 와이 파이 회로가 있다. 전력 측정 회로는 전류 감지, 전압 감지, 제로 크로싱 신호와 MCU 동작을 위한 5V 정전압용 SMPS 회로가 적용된다.

그림 23에서의 전력 측정 회로는 스마트 플러그에 전류와 전압의 입력 신호를 인가하여 제품의 전력 측정과 제품을 자동으로 식별하는 등의 다양한 성능을 내하고자 하는데 목적이 있다.




Fig. 23 Overall circuit diagram

본 논문에서 적용한 전력 측정 회로는 그림 24와 같이 전류 측정, 제로 크로싱 측정, 전압 측정, 정전압용 SMPS로 구성되어 있다.

전류감지는 홀 효과(Hall-Effect) 기반의 선형 전류 센서인 ACS712를 사용하여 AC 및 DC 신호에 대해 정교한 전류 측정이 가능하며, 측정된 전류에 선형으로 비례하여 아날로그 전압을 출력한다. +/- 20A까지 측정이 가능하고 출력 전압은 0.5 ~ 4.5V 출력이 된다. 제로 크로싱 회로는 AC 전압의 시작을 알리기 위한 플래그(Flag)용으로 사용된다. 제로 크로싱 회로에서 신호가 Low 레벨에서 High 레벨로 트리거 되면 이때부터 AC 전류값을 측정한다.

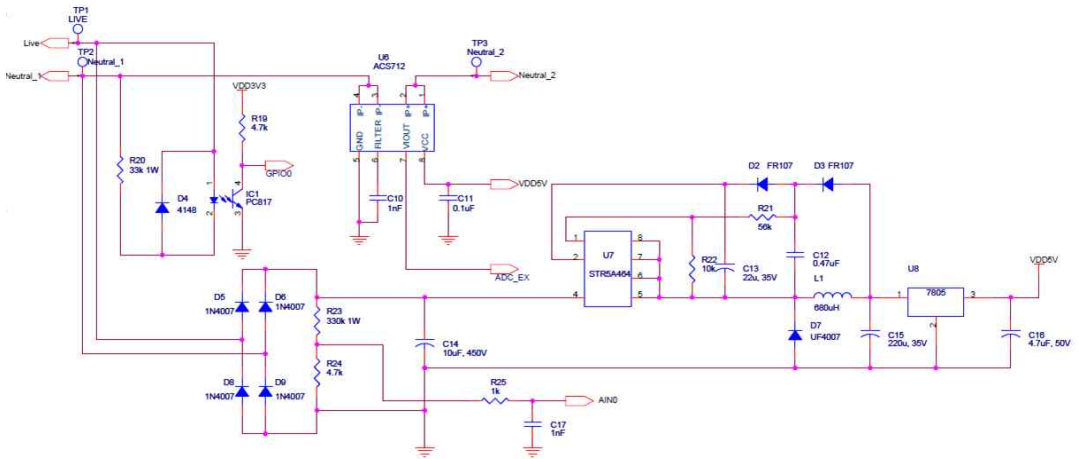


Fig. 24 Power measuring circuit

전압 측정 방식은 AC 전압에서 브릿지 다이오드로 통과되고 평활 콘덴서를 통해 DC로 바뀌는 단계에서의 DC 전압을 측정하여 AC 전압을 유추하여 측정한다. DC 전압은 310V 정도로 높기 때문에 전압분배 회로를 이용하여 310V 일 때 3.5V 수준이 되도록 저항 파라미터를 맞추고, 이렇게 측정된 전압은 전류와 합산하여 전력량 계산에 사용된다.

정전압 SMPS는 STR5A60 Series 반도체 소자를 이용하여 구현하였다. 이것은 MOSFET과 비 절연 벅 컨버터(Buck Converter)와 인버터 컨버터 토폴로지(Inverting Converter Topology)가 적용된 스위칭 파워 서플라이이고, 구성이 단순하고 전력 효율이 높은 방식이다.

4.1.2 MCU 및 와이 파이 회로 설계

본 논문에서는 MCU와 와이 파이를 동시에 사용이 가능한 ESP-12E 모듈을 사용한다. 그림 25의 ESP-12E는 아두이노 기반의 개발이 가능한 마이크로 프로세서와 와이 파이 모듈이 결합된 ESP8266 칩과 RAM, GPIO(General Purpose Input Output), 안테나가 내장된 모듈이다. 이러한 모듈 하나만으로도 MCU와 와이 파이가 통합되어 간단한 사물 인터넷 개발을 가능하게 해준다.

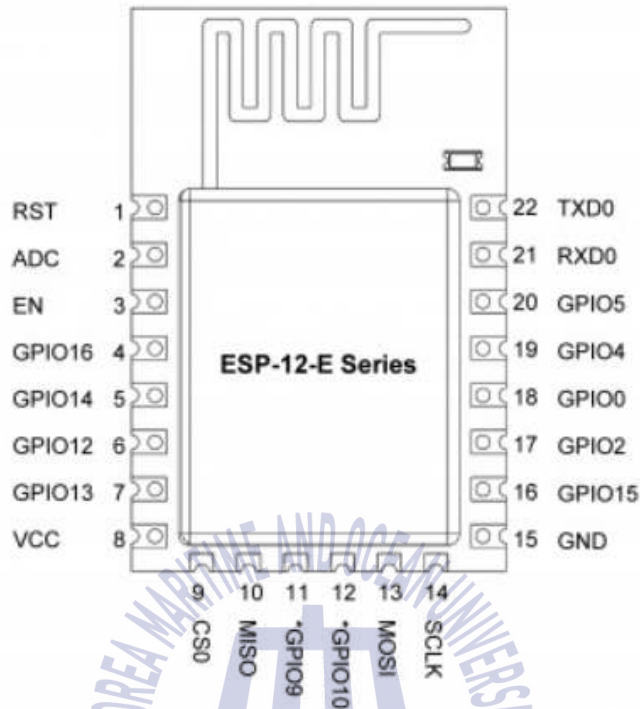


Fig. 25 Pin arrangement of the ESP-12E module

무선으로 인터넷에 연결되는 장치를 구현하기 위해서는 쉽고 간단하며 저렴한 수단이 필요한데, ESP8266이 이에 해당한다. ESP8266은 와이 파이라는 특별한 기능이 추가된 마이크로 컨트롤러를 하나의 칩으로 구현해 놓은 것으로, SoC(System on Chip)라 한다. SoC란 특별한 용도의 시스템을 하나의 칩으로 구현한 반도체를 가리키는 말이다.

하지만 ESP8266은 펌웨어를 저장하기 위한 플래쉬 메모리를 포함하고 있지 않아 단독으로 사용이 불가하여, SPI(Serial Peripheral Interface) 방식의 플래쉬 메모리와 몇 가지 부가 기능을 위한 회로가 추가된 모듈 형태로 사용해야 한다. 이것이 ESP-12E 모듈이고 대부분의 ESP8266 핀을 사용하는 것이 가능하여 컨트롤러로 사용하기 적합하고 다양한 응용이 가능하다[44]. 표 2는 ESP-12E의 주요 스펙이다.

Table 2 Main Spec of ESP-12E

특징	내용
프로세서	Tensillica 사의 L106 저전력 32bit MCU
동작 전압/전류	3.3V(3.0 ~ 3.6V) / 순간 전류 300mA
와이 파이	802.11 b/g/n
범용 입출력	17개
플래시 메모리	512KB ~ 16MB 연결 가능
동작 클럭	80 ~ 160MHz
ADC	10bit 1개 ADC

그림 26은 전력 측정 회로와 MCU/와이 파이 회로로 구성된 보드(PCB 전)의 그림이고, 그림 27은 상기의 내용들을 모두 포함한 보드(PCB 후)와 실제 벽 콘센트에 설치한 상태를 나타내는 그림이다.



Fig. 26 Board including power circuit and MCU/Wi-Fi (Before PCB)



Fig. 27 Smart Plug board(After PCB) and Usage

지능형 스마트 플러그 시스템에서 MCU 및 와이 파이 회로도와 PCB에 관한 사항은 본 논문 마지막 <부록 A>에서 <부록 H>를 참조하기 바란다.

4.2 소프트웨어 설계

4.2.1 딥러닝 설계

소프트웨어 구성은 딥러닝을 어떻게 설계하는지의 순서를 나열하면서 그 안에 오프라인 학습 방법과 온라인 학습 방법 등을 설명한다. 오프라인 학습에서는 Tensorflow Tool로 딥러닝 알고리즘 설계와 과 적합인지 검증하고, 온라인 상인 실제 사용자 입장에서 스마트 플러그가 동작하기 위해서는 MCU에 딥러닝의 소프트웨어를 올려 설계한 내용을 설명하고자 한다. 그림 28은 딥러닝 전체 구성을 보여주고 있다.

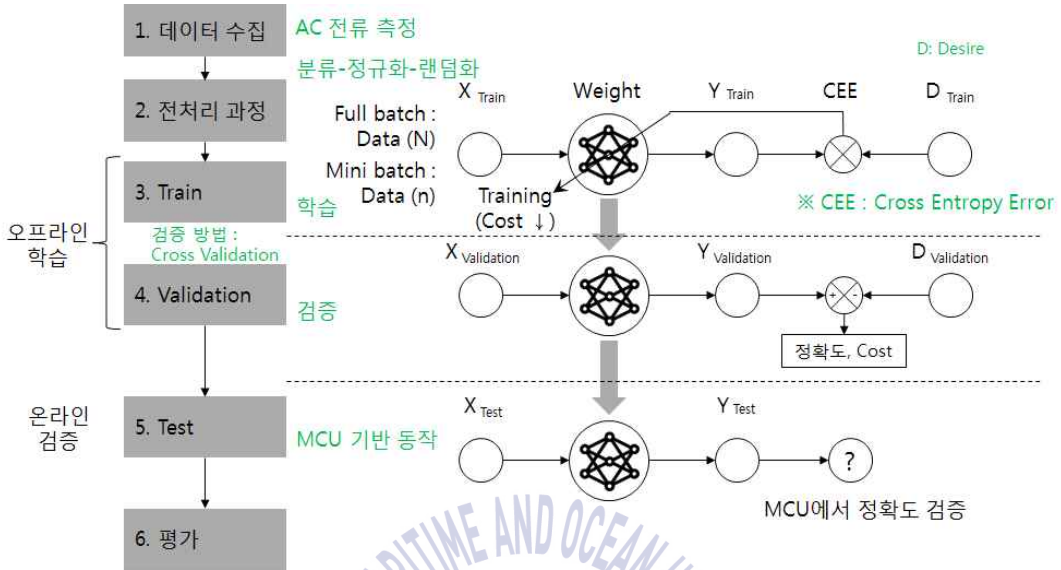


Fig. 28 Full configuration of Deep Learning

딥러닝 설계 과정은 그림 29처럼 나타난다. 첫 번째 AC 전류의 데이터 수집에서는 제품의 종류를 자동 분류하는 데이터와 세탁기의 동작 상태를 분류하는 데이터인데, 16.67msec(60Hz) 동안의 데이터는 제품의 종류를 자동 분류에 사용되고 1초간 데이터 60개로 세탁기의 동작 상태를 분류하는데 사용한다. 두 번째는 분류, 정규화와 랜덤화로 진행되는 전처리 과정인데, 전처리를 통해 식별 능력을 개선하고 학습 속도를 높이는 용도로 사용된다. 이러한 기술들로 인해 최적의 가중치를 찾아가는 방법들과 연산 시간을 줄이고 과 적합을 억제하는데 효과를 보고 있다. 그래서 이러한 변환된 데이터로 오프라인 상태에서 손실 함수가 줄어들도록 가중치를 학습시키고 검증을 한다. 오프라인에서의 학습과 검증은 학습 데이터(Train Data)로 역전파 알고리즘에 의해 가중치를 학습시킨 후 남은 데이터인 검증 데이터(Validation Data)로 과 적합을 검증한다. 마지막으로 온라인 상에서 MCU에서 실시간으로 측정된 테스트 데이터(Test Data)로, 딥러닝 알고리즘을 설계하여 정확도를 최종적으로 확인하는 설계 과정이다.




Fig. 29 Deep Learning Design Stage

(1) 데이터 수집

데이터 수집은 표 3과 같이 2 종류로써, 제품의 종류를 자동 분류하는 데이터와 세탁기의 동작 상태를 분류하는 데이터로 분류한다.

Table 3 Data collection method

	제품 종류 자동 분류	세탁기 동작 상태 분류
Signal		
입력값	60Hz 전류 패턴	세탁기 동작의 60초 평균 전류 패턴
Sampling	0.5msec	1sec
측정 주기	16.67msec (60Hz)	60sec (Next 1초간 Moving AVG)
입력층	30개	60개
은닉층	10개, 10개	10개, 10개
출력층	7개, 10개 (동시 동작 포함)	2개 (세탁모드, 탈수모드)

제품 종류의 자동 분류는 AC 전류 60Hz 동안의 전류 패턴으로써 0.5msec 마다 30개의 측정된 데이터로 판단하고, 제품의 종류는 총 10가지인데 플러그에 한 가지 제품만 꼽았을 때의 7가지(세탁기, 냉장고, 에어컨, 전자레인지, 정수기, TV, 헤어드라이기) 제품과 2개의 제품을 동시에 꼽아 동시동작 했을 때의 3가지(냉장고+전자레인지, 냉장고+헤어드라이기, 전자레인지+헤어드라이기)를 더해 총 10가지에 대해 분류한다. 동시 동작 시 냉장고, 전자레인지와 헤어드라이기를 선택한 사유는 총 전류가 16A를 넘으면 가정집의 누전차단기가 떨어지므로 동시에 2개를 돌렸을 때 16A 이상 되지 않는 조건이라 판단하여 선정하게 되었다.

세탁기 동작 상태 분류는 만일 세탁기 제품의 동작 상태를 전류 1초간의 60개 데이터를 이용하여, 세탁을 하는지 탈수를 하는지 판단 할 수 있다면 사용자는 세탁기에 직접 다가가지 않아도 원격으로 탈수 동작을 확인 하고 옷감을 꺼내러 갈 수도 있고 초기 세탁이면 남아 있는 빨랫감을 더 넣을 수 있으므로 동작 상태만 분류가 가능하다면 보다 편리할 것이다. 이를 위한 데이터는 1초 동안의 전류 값 60개의 측정된 데이터로 판단하고, 1초가 지나면 이전의 1초는 버리고 새로 들어온 1초를 넣은 60개의 데이터로 판단하는 이동 평균(Moving Average) 방식으로 입력 데이터를 만든다.

(2) 전처리 과정

입력 데이터에 특정 변환을 가하는 것을 전처리 과정이라 하는데, 전처리를 통해 식별 능력을 개선하고 학습 속도를 높이는 등의 사례가 많이 제시되고 있다. 여기서는 분류와 정규화와 랜덤화로 변환하고자 한다.

정규화는 데이터를 특정 범위로 변환함을 말하는데 입력 데이터의 범위(Scale)를 변환 시켜서 0.2 ~ 0.8로 옮긴다. 이는 사용되는 활성화 함수가 시그모이드 함수인데 0 ~ 1 사이 결과가 나오므로 비슷한 영역의 값으로 변환하여 연산을 하면 월등히 큰 값이 나올 확률이 줄어들어 학습율이 높아 학습 속도가

높아지고 식별 능력도 높아진다. 따라서 0.2 ~ 0.8 사이로 정규화 시키는 수식은 다음 식 (37), (38)과 같다

$$\frac{(x - x_{min})}{(x_{max} - x_{min})} = Val_1 \tag{37}$$

$$Val_1 \times 0.6 + 0.2 = Val_2 \tag{38}$$

x_{max} 는 0.8이고 x_{min} 는 0.2로 주어졌을 때 식 (37)로 Val_1 값을 먼저 계산하고, 식 (38)로 Val_2 를 계산하여 정규화 시킨다.

마지막으로 랜덤화는 정규화된 데이터들을 섞는다. 이는 비슷한 유형의 데이터들이 한 곳에 뭉쳐 있다면 학습 시 과 적합이 되는 경우가 생기므로 랜덤하게 섞어 주어야 한다. 이런 과정들을 도식한 내용을 그림 30으로 표현한다.

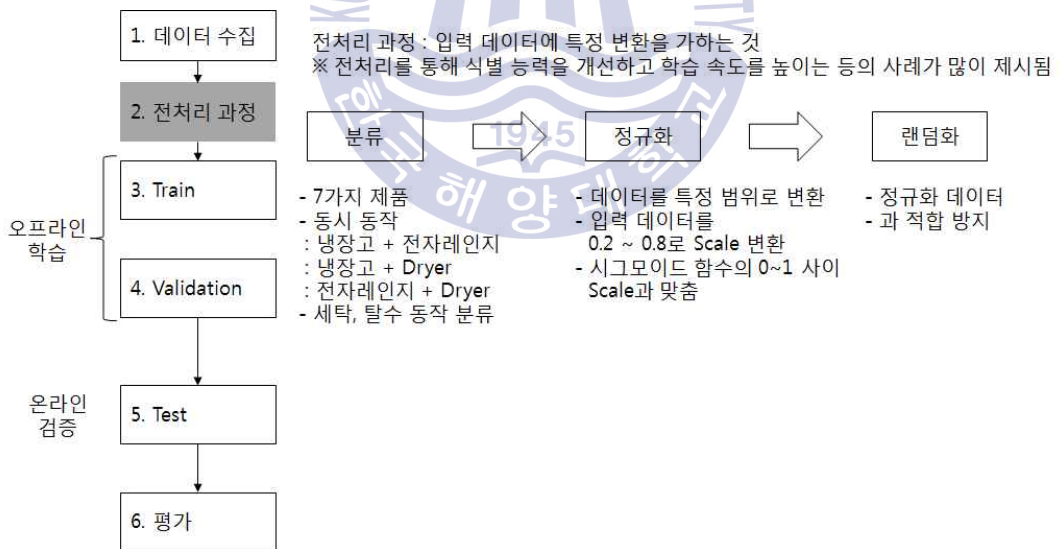


Fig. 30 Deep Learning preprocessing process

(3) 학습 및 검증

학습과 검증은 그림 31에서와 같이 앞서 만들어진 데이터들로 PC상(GPU 기반)에서 학습을 하는 단계이다.

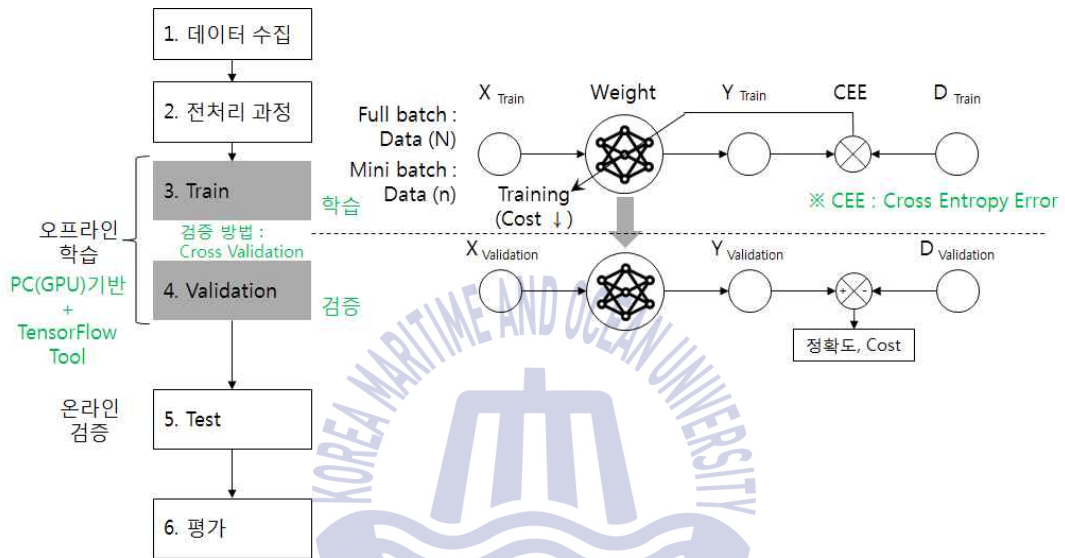


Fig. 31 Train and Validation method

학습과 검증의 데이터 비율은 3:1로써, 학습 데이터로 역전과 알고리즘에 의해 가중치를 학습시킨 후 남은 데이터인 검증 데이터로 앞에서 학습된 가중치를 다시 갱신하든지 아님 계속 사용하든지 결정을 하여 좀 더 손실 함수를 줄이는 작업을 한다. 이러한 검증 작업을 교차 검증(Cross Validation) 방식이라 하는데, 과 적합을 방지하기 위한 도구 중 하나이다. 모델을 평가하기 위해 전체 데이터를 학습 데이터와 검증 데이터로 분리하고, 학습 데이터에 학습시킨 후에 학습 데이터엔 모델이 매우 잘 적합 되었지만 검증 데이터에 대해서는 적합하지 않을 수 있으므로 과 적합이 일어나지 않도록 검증을 한다. 본 논문은 k-Fold 교차 검증 방식을 사용하여 검증하는데, 이는 k개의 그룹으로 나누고 (k-1)개의 학습 폴더와 1개의 검증 폴더로 지정한 후 총 k회 검증을 하여 과

적합이 되는지 확인을 하고, 여기서는 4-Fold로 설정한 후 검증을 한다. 그리고 신경망은 하나의 지표를 기준으로 최적의 매개 변수값을 탐색하는데 이렇게 학습에서 사용되는 지표를 손실 함수라 하고, 각 뉴런에 의해 계산된 최종 출력층 뉴런과 바라는 출력 사이의 오차를 최소화 하는게 목표이다. 손실 함수는 크게 2가지를 방법을 사용하는데, 식 (39)에서와 같이 평균제곱 오차(MSE, Mean Squared Error)와 식 (40)에서의 교차 엔트로피 오차(CEE, Cross Entropy Error) 이고 여기서는 교차 엔트로피 오차의 손실 함수를 사용한다[45].

$$E = \frac{1}{2} \sum_k (y_k - d_k)^2 \quad (39)$$

$$E = - \sum_k (d_k \times \ln(y_k) + (1 - d_k) \ln(1 - y_k)) \quad (40)$$

입력층의 입력 방법에 있어서 풀 배치(Full batch)와 미니 배치(Mini batch)의 2가지 방법을 사용한다. 풀 배치는 모든 학습 데이터를 사용하여 한 번에 가중치를 갱신하므로 기울기의 변화가 커서 수렴이 어렵고 학습 시간이 많이 걸리는 단점이 있다. 미니 배치는 소량의 학습 데이터를 랜덤하게 사용하다보니 지역 최소점(Local minimum)에 빠질 확률이 적고 학습 시간이 짧게 되는 장점이 있어, 이 2 가지를 비교하고자 한다.

(4) 테스트

본 논문에서 사용된 모델이 잘되었는지를 최종적으로 확인 하는 작업으로써, 그림 32에서와 같이 온라인 상에서 검증을 한다. 이를 위해 MCU에 딥러닝 알고리즘을 설계해서 정확도를 확인한다.

(5) 평가

마지막으로 MCU에서 모델을 동작시켜 정확도 확인을 했다면, 이것이 과 적합인지 학습력이 좋은지 판단한다.

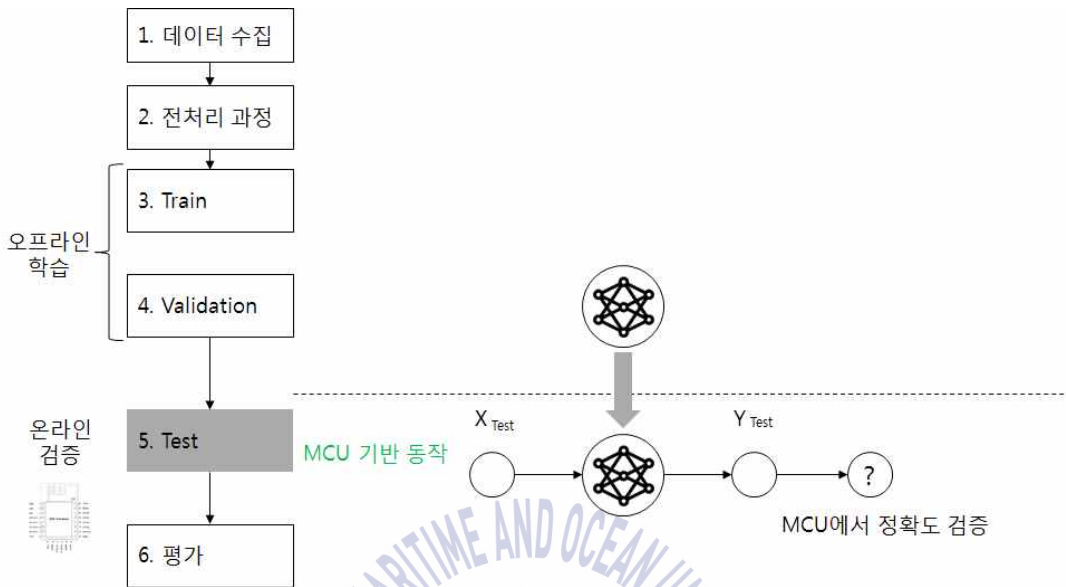


Fig. 32 On-line Test method

4.2.2 Tensorflow Tool 설계

각 제품의 입력 전류를 스마트 플러그에서 측정하여 제품이 동작만 하면 어떤 제품인지 자동으로 분류를 하고 제품의 동작 상태를 판단하고자 하는 딥러닝 알고리즘의 프로그램은 Tensorflow Tool로 오프라인 상에서의 학습과 검증을 한다.

Tensorflow는 기계학습과 딥러닝을 위해 구글에서 만든 오픈 소스 소프트웨어 라이브러리이며, 데이터 플로우 그래프 방식을 사용하여 수치 연산이 가능하고 파이선과 C++을 통해 프로그램 구현이 가능하다[46][47]. 유연한 시스템으로 구성되어 있기 때문에 약간의 코드 수정으로도 다양한 기기에서 CPU 또는 GPU를 사용하여 연산이 가능하다. Tensorflow에서 데이터는 Tensor로 표현하고 Tensor는 다차원의 동적 배열이며, Tensor가 Flow 그래프에서 흐르는 것처럼 작동한다[48].

4.2.3 MCU 프로그램 설계

오프라인에서 측정된 데이터를 이용하여 Tensorflow로 손실 함수의 최솟값이 될 때의 매개 변수(가중치)를 찾고 정확도와 에러율을 개선을 했다면, 온라인 상에서는 스마트 플러그에서 실시간으로 측정되는 데이터를 측정하여 이 딥러닝 모델의 정확도가 어느 수준인지를 판단하기 위해 마이크로 프로세서 기반의 시스템을 설계하여 그림 33과 같이 구현하였다. 이때 제로 크로싱 감지, AC 전류 측정, 0.5msec 타이머 인터럽트, 실시간 입력 데이터와 고정된 가중치 간의 연산 등 코딩 방식을 메인 프로그램 루틴과 인터럽트 서비스 루틴(ISR, Interrupt Service Routine)으로 구현하였다.

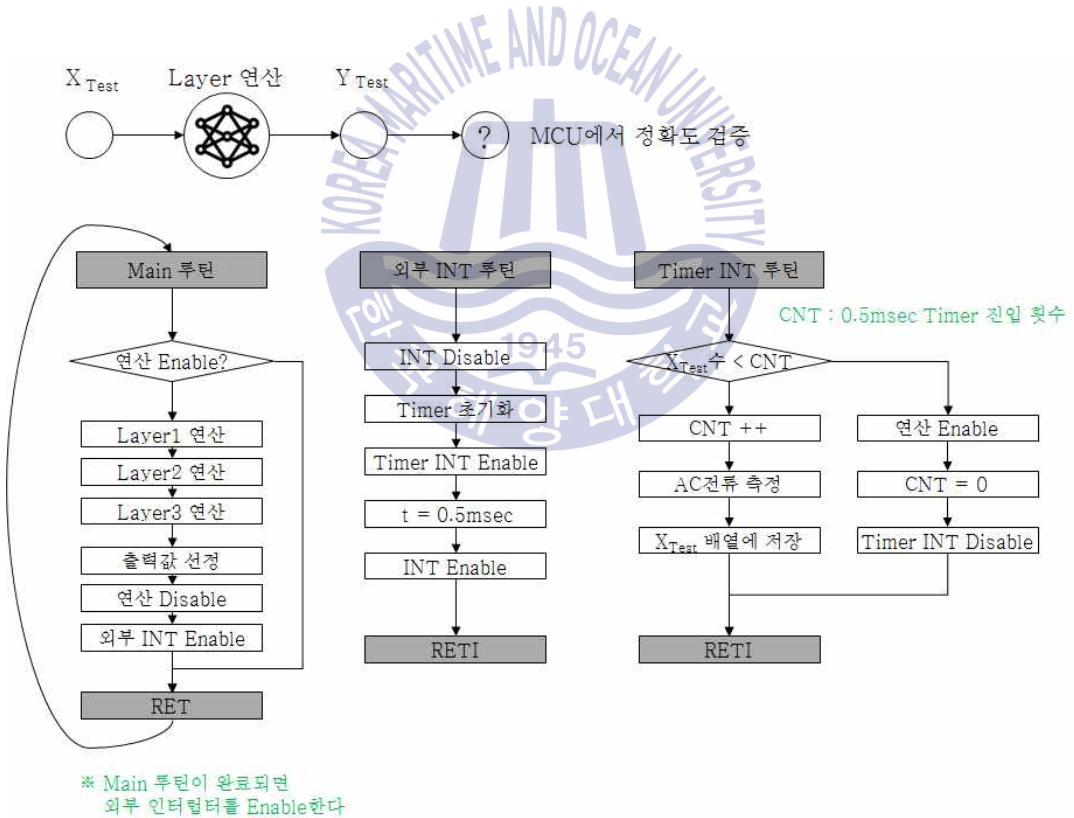


Fig. 33 Deep Learning Flow chart at MCU

측정된 AC 입력 전류의 데이터인 X_{Test} 를 딥러닝 연산 함수(Layer 연산)에 통과 시켜 출력 값(제품 종류, 제품 동작) Y_{Test} 를 연산하여, 와이 파이로 전송한다.

이때의 마이크로 프로세서 내부에서의 루틴은 메인 루틴, 외부 인터럽트 루틴, 타이머 인터럽트 루틴의 3가지로 이루어진다. 메인 루틴은 계층(Layer) 1, 2, 3 연산 수행과 외부 인터럽트 루틴을 수행 할지 여부를 판단하고 은닉층이 2개이고 출력층이 1개라 계층 연산이 3번 필요하다. 외부 인터럽트 루틴은 제로 크로싱 신호가 상승 에지로 변경되면 발생하게 되는데, 이 때 0.5msec 타이머 인터럽트 루틴을 동작 시키고 빠져 나온다. 마지막의 타이머 인터럽트 루틴이 수행되면 0.5msec 마다 ADC(Analog - Digital Converter) 동작으로 AC 입력 전류를 측정하고, 30번 측정이 되면 타이머 인터럽트 루틴을 마치고 다음에 변경될 제로 크로싱 신호를 기다린다. 30번 측정 이유는 한번에 0.5msec 마다 측정하고 30번을 곱하면 15msec인데 측정하려는 AC 입력 전류의 주기가 16.67msec(60Hz)라서 이 범위를 벗어나지 않기 위해 15msec까지 측정하고자 한다. 이러한 16.67msec 주기를 1회라 하면, 60회 데이터에 대해 평균을 한다면 1초에 대한 평균 데이터라 할 수 있다. 이 1초에 대한 평균 데이터를 이용하여 제품의 동작 상태를 분류하는데 사용한다.

4.2.4 와이 파이 설계

그림 34의 (a)와 같이 서버 PC를 두고 클라이언트를 스마트 플러그로 설정한 후 TCP/IP 소켓 통신으로 연동되는게 기본 구성이지만, 이를 위해서는 서버 구성과 데이터 베이스, 웹 스크립트 구성에 제약이 많아 ESP-12로 단순하게 그림 34 (b)와 같이 사물 인터넷 기능을 구현하였다.

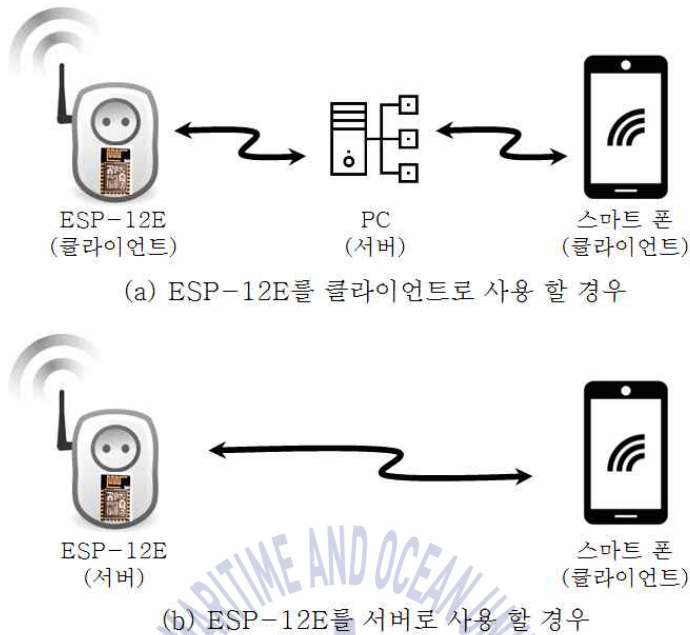


Fig. 34 When ESP-12E is used as a client(a) or server(b)

ESP-12E를 웹 서버로 사용하면 컴퓨터나 스마트 폰의 웹 브라우저를 통해 ESP-12E로 접속하는 게 가능하며, ESP-12E에 연결된 전류 센서 데이터를 접속한 클라이언트로 보내는 것도 가능하다. 클라이언트인 스마트폰이 서버인 ESP-12E에 데이터를 요청하면 서버인 ESP-12E는 HTML(Hyper Text Markup Language)로 데이터를 전송하는 방식도 가능하여 쉽게 사물 인터넷 기능을 꾸밀 수 있다.

그림 35는 ESP-12E을 HTML로 스마트 폰에 데이터를 전송하여 꾸민 앱 화면이다. (a) 화면은 최초 접속 시 나타나는 화면이고, 시작 버튼을 누르면 (b) 화면으로 앱이 전환된다. 이 앱에는 표가 2개 있는데, 위의 표는 10가지 조건의 가전기기에서 자동으로 종류를 분류하고 종류가 판단된 제품에 1로 표시를 한다. 그 밑의 표는 세탁기 동작 시 세탁/탈수 동작 중을 자동으로 판단하여 1로 표시한다.



(a) 최초 앱 화면 (b) Start 버튼 후의 앱 화면

Fig. 35 App. design at Smart phone

제 5 장 실험 및 결과

본 장은 전력 변환 회로 분석으로 AC 입력 전류의 파형이 제품 마다 차이가 남을 확인하고, 설계한 지능형 시스템이 실제 동작에서 각 제품의 종류를 분류할 수 있고 동작 상태의 판단이 가능한지의 실험 결과를 제시한다.

5.1 실험 목표

스마트 플러그 사업의 경쟁 심화에 따른 가격하락으로 수익성 악화 우려가 커지고 범용 제품으로 제품 차별화 확보가 시급함에 따라, 기본적인 기능 이외에 차별화되는 기술 추가를 위하여 제품의 종류와 동작 상태를 자동으로 분류하는 것에 표 4와 같이 4 가지 실험 목표로 수행하였다.

구체적인 목표로 첫 번째는 7 가지 제품을 60Hz AC 전류의 패턴으로 자동 분류하는 것이다. 두 번째는 2 종류의 제품이 한 개 스마트 플러그에 꼽혀서 동작 할 때도 분류 될 수 있는지의 동시 동작에 대해 확인 하는데, 앞서 언급한 7 가지 제품과 동시 동작에서 3가지를 더해 10 가지에서의 종류를 자동 분류를 한다. 세 번째는 1초짜리 전류 데이터로 60초 동안의 데이터를 이용하여 세탁기에서 세탁 동작과 탈수 동작을 자동으로 판단이 가능한지 자동 분류를 한다. 마지막으로 네 번째 목표는 온라인에서 MCU 동작으로 제품 종류와 세탁기 동작을 자동으로 판단하는 게 목표이다. 이때 오프라인 검증은 사전에 만들어진 데이터로 검증을 하고, 온라인 검증은 MCU에서 직접 측정된 데이터로 검증을 한다.

Table 4 The object of an experiment

목표	1	2	3	4
설명	7가지 제품의 종류 분류	10가지 종류 분류 (7 + 3가지 동시동작)	세탁기의 동작 상태 분류	MCU로 온라인 동작 확인
종류	·세탁기 ·냉장고 ·에어컨 ·전자레인지(MWO) ·정수기 ·TV ·Hair Dry	·7가지 제품 ·3가지 동시동작 포함 :냉장고, 전자레인지, Hair Dry :15A 이내	·세탁 동작 ·탈수 동작	·10가지 종류 (2번 목표) ·세탁기 세탁/탈수 (3번 목표)
평가	가전제품 종류 정확도	동시 동작 패턴 추가 시 정확도	세탁기의 동작 정확도	사용자 환경에서의 정확도
입력 값	AC 입력 전류 (60Hz)	AC 입력 전류 (60Hz)	1초간 60개의 평균 전류	AC 입력 전류(60Hz) 1초간 60개의 평균 전류
검증	오프라인 검증 (GPU를 이용하여 컴퓨팅 파워가 높음)			온라인 검증(MCU)

5.2 전력 변환 회로와 전류 패턴 분석

3장에서 언급한 가전기기에서 분류된 전력 변환 회로(AC - DC 변환, AC - AC 변환)에 대해 자세히 분석하였고, 본 절에서는 제안한 스마트 플러그 시스템으로 각 가전기기들을 어떻게 분류 할 수 있을지에 대해 설명한다. 아래의 표 5는 전력 변환기 회로와 그에 대해 분석한 표인데, 변환 방식과 제품 부하에 따라 달라진다.

AC - DC 변환의 첫 번째에서 일반 정류기는 AC 전원을 DC로 변환하여 부하 동작을 하는 가장 일반적인 변환 방식으로, 메인 부하는 모터, 컴프레셔와 파워 서플라이를 예로 들 수가 있다.

Table 5 Power converter circuit and description

가전제품 전력변환	AC - DC 변환		AC - AC 변환	
	General Rectifier	Converter	AC Direct	General Rectifier-Converter
회로				
입출력 전압/전류				
설명	- 입력전압이 출력전압보다 높을 때 입력 전류 흐름	- 출력이 높거나 Harmonic 규제 대응에 사용	- AC 전원을 직접 사용	- 출력 전압/전류의 크기, 주파수, 위상 변경
제품 분류	회전기(Inverter), 영상기	냉각기(Harmonic 규제 포함), 건조기, Adapter	유도기, Heater 제품	Induction Heater(쿡탑)
대표 제품	세탁기, 냉장고, TV	에어컨	MWO, Hair dryer, 정수기 온수	-

이 변환의 특징은 평활 콘덴서 전압(V_o)보다 입력 전압(V_{in})이 커지는 구간만큼 콘덴서의 방전 에너지를 보충하는 형태로 충전시키도록 입력 전류가 흐르며, 이것이 AC 입력전류로 되므로 이 구간만큼 충전전류가 흐르고 이 때문에 정현파가 되지 않는다. 따라서 왜곡이 심한 사인파 형태로 나타나고 평활 콘덴서(C_o)의 용량이 높을수록 입력전류의 진폭은 올라가게 되는데, 평활 콘덴서의 용량은 우물에서 양동이로 물을 끌어 올릴 때의 양동이 크기와도 흡사하다. 이러한 변환기로 사용되는 제품은 회전기, 영상기 등이 있다.

AC - DC 변환의 두 번째에서 컨버터는 앞서 언급한 일반 정류기에서 PFC(Power Factor Correction)와 PSC(Partial Switching Converter) 회로를 추가하여 사용한다. 이는 출력 피크가 높거나 하모닉 규제 대응을 위해 사용되고, 스위칭 제어로 입력전류의 형태를 완만하게 유지하며 입력 전류를 넓게 하여 피크를 억제하는 효과를 가지고 있다. PFC 회로에서 입력 전류는 매끄러운 사인파 형태로 나타나고, PSC의 입력 전류는 한 주기의 구형파 제어로 물결 모양의 형태로 나타난다. 사용되는 제품은 전류를 많이 쓰는 냉각기, 전기 건조기와 아답터가 속한다.

AC - AC 변환의 첫 번째에서 직접 AC(AC Direct)는 가격적 장점을 얻기 위해 AC단을 직접 연결하는 회로로써 부하의 특성에 따라 입력 전류의 형태가 달라지는데, 내부 저항성, 용량성, 유도성 특성에 의해 입력 전류의 파형은 차이가 난다. 여기에 속한 제품은 유도기와 발열 히터 등의 제품이 있다.

AC - AC 변환의 두 번째에서 일반 정류 변환기는 공진형 회로라 불리는데, 출력변화를 위해 진폭과 위상 변화가 가능하고 입력 전류는 제어적 스위칭 동작에 따라 사인파에 가깝게 나타난다. ZVS(Zero Voltage Switching) 방식으로 스위칭 하므로 소자의 발열 개선에 효과적이고 IGBT의 V_{cer} 값이 낮아 EMI에 안정적이라 할 수 있다. 이러한 변환기로 사용되는 제품으로는 유도 가열(IH, Induction Heater) 기능의 쿡탑이 있다.

Table 6 10 Input characteristics

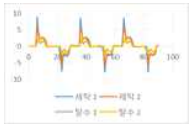
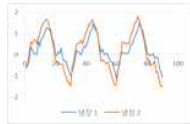
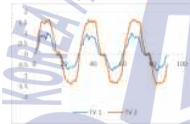
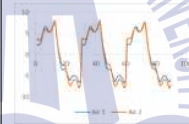
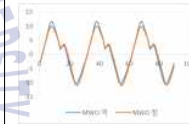
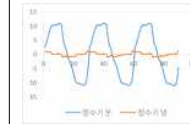
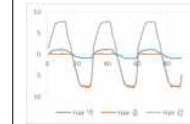
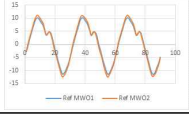
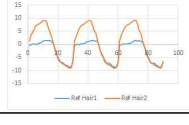
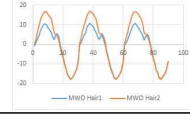
제품	세탁기	냉장고	LED TV	에어컨	전자레인지	정수기	Hair dryer
전력변환 (부하)	Rectifier (3상 Inverter Motor)	Rectifier (3상 Comp, 냉각 Fan)	Rectifier (SMPS)	Converter (PSC + 3상 Motor)	AC Direct (마그네트론)	AC Direct (Heater, 소형 Comp)	AC Direct (Heater, Fan)
동작	세탁, 탈수 : 소,중,대 옷감	냉장, 냉동	Display	강/약 냉방 실내기, 실외기	요리 동작	정수, 온수, 냉 수	약, 중, 강풍
60Hz 전류파형							
동시 동작	냉장고 + 전자레인지	냉장고 + Hair dryer	전자레인지 + Hair dryer				
동작	냉장, 냉동 + 요리 동작	냉장, 냉동 + 약, 중, 강풍	요리 동작 + 약, 중, 강풍				
60Hz 전류파형							

Table 7 10 Input current waveforms

조건	세탁기	냉장고	LED TV	에어컨
60Hz 전류파형				
조건	전자레인지	정수기	Hair dryer	냉장고+전자레인지
60Hz 전류파형				
조건	냉장고+Hair dryer	전자레인지+Hair dryer		
60Hz 전류파형				

본 논문에서 사용될 대표 제품은 7가지이고 입력조건은 7가지 / 10가지로써 표 6과 표 7에서는 특징과 AC 입력전류의 파형을 표현하였다. 제품별 동작특성과 AC 입력전류 파형으로 우리 일상생활에서 흔히 볼 수 있는 제품으로 선정하였으며 여기에 2개의 제품을 동시에 연결해 동작했을 때의 조건 3가지를 추가하였다. 냉장고, 전자레인지와 헤어드라이기의 3개 제품에서 냉장고-전자레인지, 냉장고-헤어드라이기와 전자레인지-헤어드라이기의 동시 동작 조건을 추가하였는데 동시 동작 했을 때 전체 전류가 16A 이하가 되는 제품으로 선정하였다. 그 이유는 가정집의 누전차단기가 떨어질 수 있으므로 이를 고려하여 동시 동작에서의 제품을 선정하였다.

따라서 10가지 조건의 입력 전류 파형을 선정하였고, 스마트 플러그로 입력 전류를 측정하고 자동 분류 될 수 있는지 연구하는 게 목적이다.

5.3 실험 방법

딤러닝의 구조는 다음의 그림 36과 같고 두 번째 목표인 동시 동작을 포함한 10가지 제품 종류를 분류하는 구조의 그림을 예로 들었다. 입력층 개수는 30개이고 출력층은 10개, 은닉층 2개에 개수는 10개씩 구성하였다.

그리고 자동 분류를 위해 원하는 AC 입력전류 데이터를 수집하고 정규화/랜덤화로 전처리 과정을 거친 데이터들을 학습 데이터와 검증 데이터로 나눈다. 이런 과정들은 학습 능력과 정확도를 향상시키고, 과 적합의 문제가 있는지 검증하여 가중치를 선정하게 된다. 이 후 온라인 상에서 스마트 플러그에 입력 데이터와 선정된 가중치로 실제 동작에서의 정확도를 확인한다.

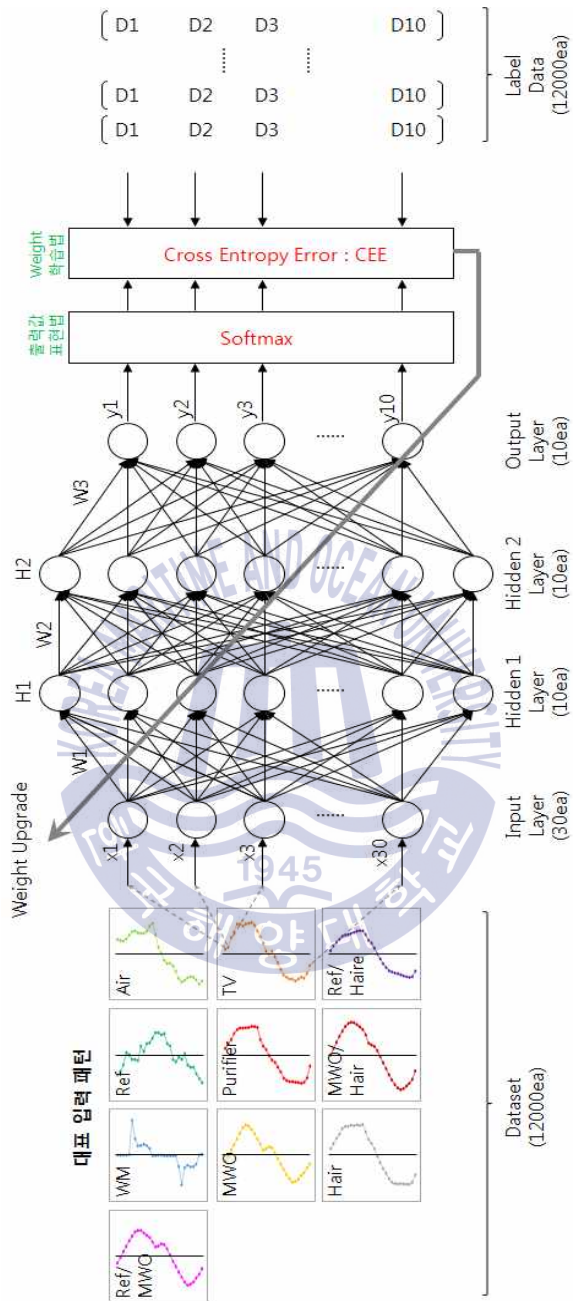



Fig. 36 Structure of Deep Learning

그림 37은 본 논문 오프라인에서 학습과 검증 확인 방법에 대해 설명한다.



	Train Data	Validation Data
목적	<ul style="list-style-type: none"> • 웨이트 선정 • 학습 능력 확인 	<ul style="list-style-type: none"> • 정확도 검증 (성공률) • 과 적합 확인
검증 방식	<ul style="list-style-type: none"> • 그래프 • Full batch vs. Mini batch → 학습 속도 및 Local Minimum 개선 	<ul style="list-style-type: none"> • Confusion Matrix • Cross Validation 검증
비고	※ Mini batch : Train 데이터에서 일부만 골라 학습을 수행하는 방식	※ Confusion Matrix (혼돈 행렬) : 알고리즘의 성능을 시각화 할 수 있는 특정 테이블의 레이아웃

Fig. 37 Off-line learning and verification methods

오프라인에서 학습 데이터와 검증 데이터로 3:1 비율로 구분한다. 학습 데이터로는 손실 함수의 에러율이 줄어드는 방향으로 학습시켜 학습 능력 확인과 가중치를 선정한다. 이러한 검증 방식으로는 학습 횟수가 늘어나면서 손실 함수의 에러율이 줄어드는지 그래프로 검증을 하고, 두 번째 목표인 동시동작 10 가지에서는 풀 배치와 미니 배치 학습 비교로 학습 속도의 차이를 확인한다. 검증 데이터로는 혼돈 행렬(Confusion Matrix)로 정확도를 검증하고 과 적합의 문제점이 있는지를 확인한다. 이러한 검증이 끝나면 온라인 상에서 최종 테스트를 실시한다.

학습 데이터를 사용하는 목적은 학습을 하기 위함인데, 학습이란 학습 데이터에 대한 손실 함수의 값을 구하고 그 값을 최대한 줄여주는 가중치를 찾아내는 것을 말한다. 학습에 대한 검증 방식은 두 가지로 첫 번째는 그래프로 학습의 반복횟수(Epoch)에 대해 학습 에러율이 어떻게 내려가는지의 특성을 확인하는 것과 두 번째는 풀 배치와 미니 배치를 이용해 학습 속도 향상과 지역 최소점에 빠지지 않는지 확인하는 방식이 있다.

미니 배치에 대해 설명을 하면, 모든 학습 데이터로 손실 함수의 값을 계산하게 되는데 만일 학습 데이터가 다량 일 때는 연산의 시간이 많이 걸린다. 이를 극복하고자 모든 학습 데이터를 계산하지 않고 학습 데이터를 랜덤하게 원하는 개수 만큼 선별하여 손실 함수를 계산하는 방식을 미니 배치 방식이라 한다. 또한 미니 배치는 지역 최소점에 빠지는 현상을 덜어주는 효과도 있다. 그 이유는 랜덤하게 선별된 데이터로 학습할 때 지역 최소점에 빠졌으면 탈출 할 확률이 높은 게 미니 배치 방식이라 할 수 있다.

지역 최소점의 문제는 에러를 최소화시키는 최적의 파라미터를 찾는 문제에 있어서 파라미터의 공간에 수많은 지역적인 홀(Local Hole)들이 존재하여 전역적인 해(Global Minimum)를 찾기 힘들게 되는 문제를 말한다.

검증 데이터를 사용하는 목적은 정확도 검증(성공률)과 과 적합 확인을 위함이다[49]. 검증 방식으로는 혼돈 행렬과 교차 검증 방식이 있는데, 검증 데이터를 검증하는 방식으로 알고리즘의 성능을 시각화 할 수 있는 특정 테이블의 레이아웃 방식으로 한 눈으로 정확도를 확인 할 수 있다. 교차 검증 방식은 학습 데이터와 검증 데이터를 일정한 비율로 나누어 검증하는 방식인데, 붓스트랩(Bootstrap) 검증 방식과 비슷한데 두 가지를 같이 예를 들어 설명을 한다.

교차 검증 방식의 예로써 10가지 종류 분류에서의 전체 샘플 데이터는 12,000개이며 3:1 비율로 학습 데이터와 검증 데이터를 나누면 9,000개와 3,000개로 구분되고, 학습 능력 확인을 위해 4-Fold 교차 검증으로 구분하였다. 데이터를 다수의 조각으로 나누어 학습과 검증을 반복하는 방법을 그림 38에 표현하였고, 식 (41)은 k 개의 균등 샘플로 분할 할 경우 각 검증 시 신뢰성을 Q 라고 했을 때 교차 검증의 전체 성능은 Q_{cross} 로 표현된다.

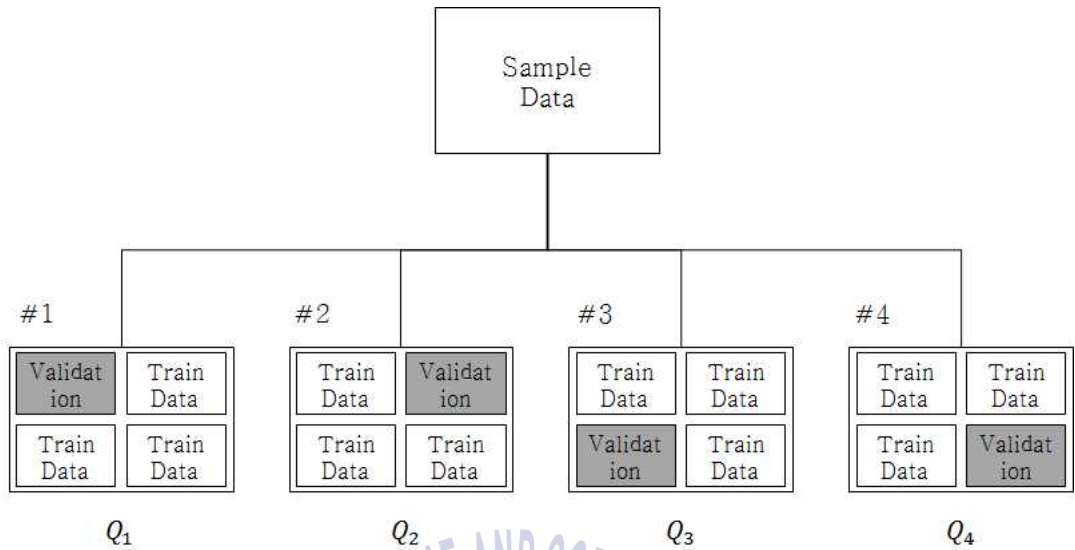


Fig. 38 Cross Validation construction

$$Q_{cross} = \frac{1}{k} \sum_{i=1}^k Q_i \quad (41)$$

붓스트랩 검증은 그림 39에서와 같이 학습 데이터에서 검증 데이터를 무작위로 뽑아 부분 집합을 생성한다. 부분 집합은 중복을 허용하여 한번 뽑힌 샘플이 다시 뽑힐 수도 있다. 생성된 부분 집합을 검증에 사용하며, 검증을 독립적으로 여러 번 수행이 가능하다. 식 (42)는 붓스트랩의 검증 결과를 보여주고 있다[50]. 붓스트랩은 한 번의 학습으로 여러 번의 검증을 진행 할 수 있기 때문에 학습 시간이 긴 알고리즘에 주로 적용하는 방법이라, 본 논문에서는 교차 검증으로 학습력을 판단한다.

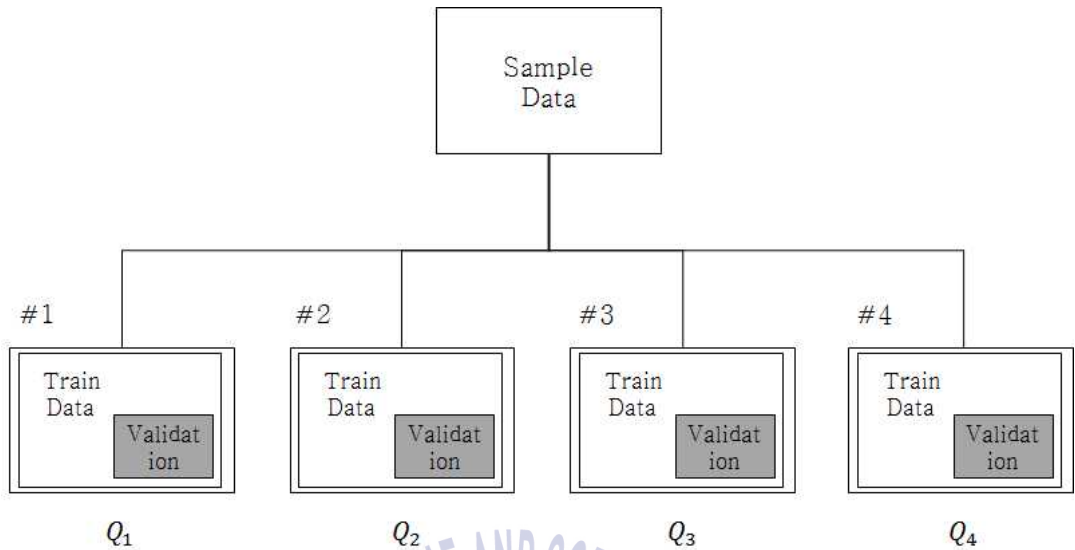


Fig. 39 Bootstrap construction

$$Q_{bootstrap} = \frac{1}{T} \sum_{i=1}^T Q_i \quad (42)$$

본 논문의 학습에 이용되는 방식과 변수를 정리하면, 입력 선택 방식으로는 2 가지인 풀 배치와 미니 배치 방식에서 2 가지 모두 구현하여 연산 속도와 지역 최소점 특성을 비교하고자 하였다. 출력값 표현법으로는 출력의 합이 1이 되도록 변형시켜 사용하는 소프트맥스 함수로 비교를 하였다. 활성화 함수는 시그모이드 함수와 ReLU 함수에서 가중치 학습에서 은닉층으로 깊게 전파 도달하지 않아도 되므로 시그모이드 함수를 사용하였다. 신경망 학습율의 지표는 교차 엔트로피 에러를 사용하며 최적의 매개변수를 갱신하는 방법으로는 Adam Optimizer로 에러를 줄이도록 설정한 내용이 표 8과 같이 표현하였다.

Table 8 Internal variables for 3 purposes

NO	변수	기호	목표 1	목표 2	목표 3
1	입력층	X	30	30	60
2	은닉층1	H1	10	10	10
3	은닉층2	H2	10	10	10
4	출력층	Y	7	10	2
5	출력값 표현	-	Softmax		
6	총 입력 데이터	N	$1200 \times 7 = 8400$	$1200 \times 10 = 12000$	$4000 \times 2 = 8000$
7	Train	-	$900 \times 7 = 6300$	$900 \times 10 = 9000$	$3000 \times 2 = 6000$
8	Validation	-	$300 \times 7 = 2100$	$300 \times 10 = 3000$	$1000 \times 2 = 2000$
9	학습능력검증	-	Cross Validation		
10	k-Fold	-	4-Fold		
11	Test(온라인)	-	MCU에서 온라인 검증		
12	Batch	-	Full batch	Full / Mini (300)	Full batch
13	Drop Out	-	1	1	1
14	활성화 함수	-	Sigmoid	Sigmoid	Sigmoid
15	손실 함수	CEE	Cross Entropy Error		
16	에러 기울기	-	Adam Optimizer		
17	학습율	η	0.005		

여기서 왜 딥러닝을 해야만 하는지 설명하면, 우선 일반 분류 알고리즘에서는 데이터와 부류 사이에 특징 추출과 판단 수행을 위한 단계가 있다. 특징 추출은 실제 세계에서 데이터 수학을 세계로 추상화(핵심적인 개념이나 기능을 간추려 내는 것) 시키는 단계이고 판단 수행은 분류를 하는 단계인데, 각각의 알고리즘으로 수행을 하고 그 조합을 경험과 직관이 있는 사람이 찾아내고 튜닝을 해야 하기에 개인의 오차가 크다[51]. 또한 제품의 전류 데이터에서 다른 제품의 전류 데이터가 추가(예. 7가지 이외의 제품이 추가)되는, 입력 정보가 업데이트되면 특징 추출과 판단 수행을 변경해야 한다면 새로운 알고리즘 구조를 다시 적용해야 될 경우가 발생할 수 있다.

반면 딥러닝은 학습 데이터로 자가 특징 생성과 오류 역전과 학습을 동시 동

작하고 테스트 데이터로 부류를 분류하는 구조이며 특징 추출과 판단 수행을 주어진 데이터를 온전히 학습하고 패턴을 발견하는 종단간 기계학습(End-to-end 학습)을 수행하므로 특성 추출 작업이 불필요하다. 또한 데이터에 포함된 중요한 특징까지 학습하므로 사람의 개입을 배제시켜 오차를 줄일 수 있다. 또한 만일 다른 제품의 전류 데이터가 추가되는 상황인 입력 정보가 업데이트가 되더라도 행렬 업데이트와 매개 변수 조절만으로 튜닝이 간단해져서 새로운 제품이 추가되어도 큰 구조 변화 없이도 가능하여 딥러닝이 본 논문에서 사용해야만 하는 이유라 할 수 있다.

5.4 실험 결과 분석

5.4.1 7가지 제품의 종류 분류 실험 결과

아래의 그림 40은 7가지 제품의 종류 분석을 위해 딥러닝으로 구현했을 때 손실 함수 에러율이 줄어드는 모습을 보여주고 있다. 6,300개(900×7)의 학습 데이터로 학습하고 반복 횟수가 늘어나면서 에러율이 줄어드는 모습을 보여주고 있고, 1,500번의 반복수(Epoch) 부터 에러율이 변화 없음을 알 수 있었다.




Fig. 40 Error rate graph of first goal

학습이 완료되어 가중치 매개변수가 정해진 후 2,100개(300×7)의 검증 데이터로 검증했을 때 성공률이 99.95%(2099/2100)임을 아래의 표 9와 같이 혼돈 행렬(Confusion Matrix)로 확인이 가능하다. 가로줄은 실험 결과인 출력의 정보이고, 세로줄은 실제 정답인 목표의 정보를 보여준다. 가로의 한 Line 전체 숫자가 제품 1개에 대한 검증 데이터(300개)로, 1~6번 제품(1~6줄)은 정확도가 100%로 나왔고 7번 제품(헤어드라이기)에서 300개 중에 1개만 TV로 판단했고 나머지는 헤어드라이기로 판단하여 정확도가 높음을 알 수 있었다.

Table 9 Confusion matrixes of 7 product categories

목표 결과 \	1	2	3	4	5	6	7
1	300	0	0	0	0	0	0
2	0	300	0	0	0	0	0
3	0	0	300	0	0	0	0
4	0	0	0	300	0	0	0
5	0	0	0	0	300	0	0
6	0	0	0	0	0	300	0
7	0	0	0	0	0	1	299

학습 검증 방법은 앞서 설명했던 교차 검증의 4-Fold 검증과 2번 반복으로 했을 때 아래의 2회 반복 교차 검증은 표 10에서와 같은 결과로 나왔다. 세로 줄의 2-1은 교차 검증의 2-fold 데이터에서 1회 했을 때의 시점이다. 정확도가 99% 이상 높게 분류되어 학습 데이터와 검증 데이터에서 동일한 정확도이므로, 과 적합 현상이 없음을 확인 할 수 있었다.

Table 10 Cross Validation results of 2 times 4-Fold at 7 categories

	에러값	정확도(%)
1-1	0.031	100
1-2	0.164	100
2-1	0.121	99.95
2-2	0.015	99.95
3-1	0.083	99.90
3-2	0.152	100
4-1	0.062	99.85
4-2	0.077	99.90

5.4.2 10가지 제품의 종류 분류 실험 결과

다음은 동시동작을 포함한 10가지 제품의 종류 분석을 위해 딥러닝으로 구현했을 때 손실 함수 에러율이 줄어드는 모습을 그림 41에서 보여주고 있다. 9,000개(900×10)의 학습 데이터로 학습하면서 반복 횟수가 늘어나면서 손실 함수 에러율이 줄어드는 모습을 보여주고 있고 2,000번의 반복에서 부터 에러율이 변화 없이 고정되어짐을 알 수 있다. 학습이 완료되어 가중치 매개변수가 정해진 후 3,000개(300×10)의 테스트 데이터로 검증했을 때 성공률이 99.97%(2999/3000)임을 아래의 표 11과 같이 혼돈 행렬로 확인이 가능하다. 수평으로의 한 줄 전체 숫자가 제품 1개에 대한 검증 데이터(300개)로, 7번 이외의 제품 정확도가 100%로 나왔고 7번 제품(헤어드라이기)에서도 300개 중에 1개만 TV로 판단했고 나머지는 헤어드라이기로 판단하여 정확도가 높음을 알 수 있다. 그리고 아래 그림 41에서와 같이 7가지 자동 분류보다 10가지 자동 분류에서의 에러 감소되는 현상이 느리지만 모두 유사하게 에러가 0에 가깝게 줄어듬을 알 수 있었다.

Table 11 Confusion matrixes of 10 categories

목표 결과	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

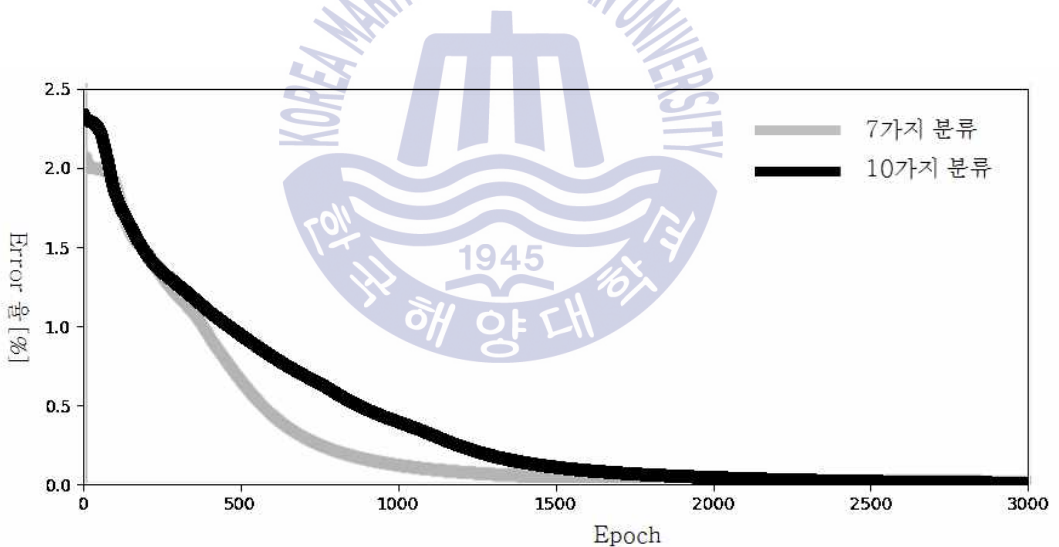


Fig. 41 Error rate graph of the second goal

학습 검증 방법은 앞서 설명했던 교차 검증의 4-Fold 검증과 2번 반복으로 했을 때 아래의 2회 반복 교차 검증 결과에서와 같이 정확도가 98% 이상 높게 분류되고 과 적합 현상이 없음을 표 12로 확인 할 수 있었다. 그리고 이전까지는 입력값 처리 방식을 풀 배치로 했던 것을 연산속도와 지역 최소점 해결에

효과가 있는 미니 배치로 변경하여 두 가지를 비교했을 때, 지금까지 지역 최소점 현상이 발생하지 않아 개선 효과를 확인할 수는 없지만 연산속도가 빨라짐을 확인할 수 있었다. 그림 42는 연산 시간에 대한 에러율이 줄어드는 현상을 그래프로 나타내었고 같은 시간에 에러율이 빨리 떨어짐은 연산 속도가 빠르다고 볼 수 있다.

Table 12 Cross Validation results of 2 times 4-Fold at 7 categories

	에러값	정확도(%)
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

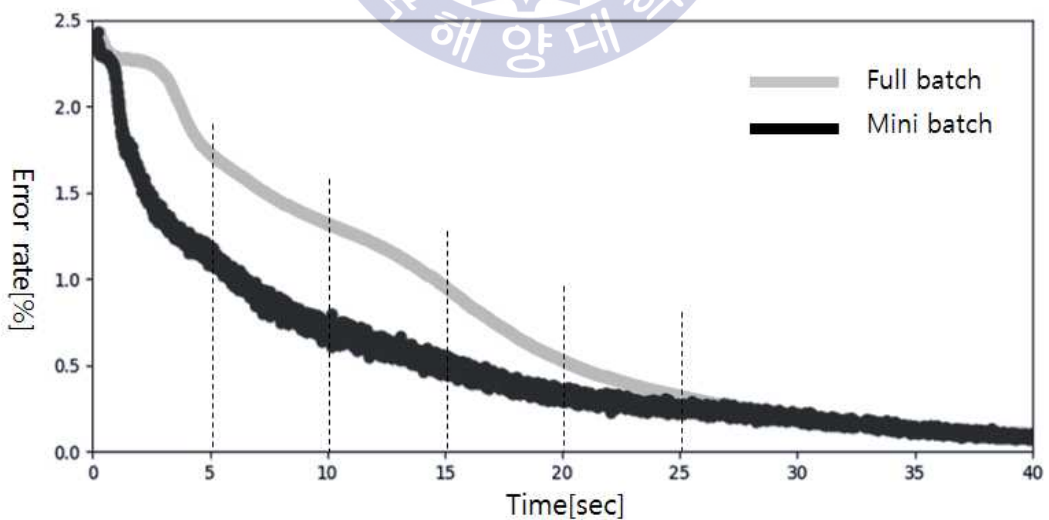


Fig. 42 Comparison of operation speed(Full batch vs. Mini batch)

이때 도달 되는 시간에 따라 풀 배치 대비 미니 배치 에러율이 몇 퍼센트 줄어 들었는지 그림 43으로 나타낼 수 있고 감소율은 20~45% 수준으로 나타난다.

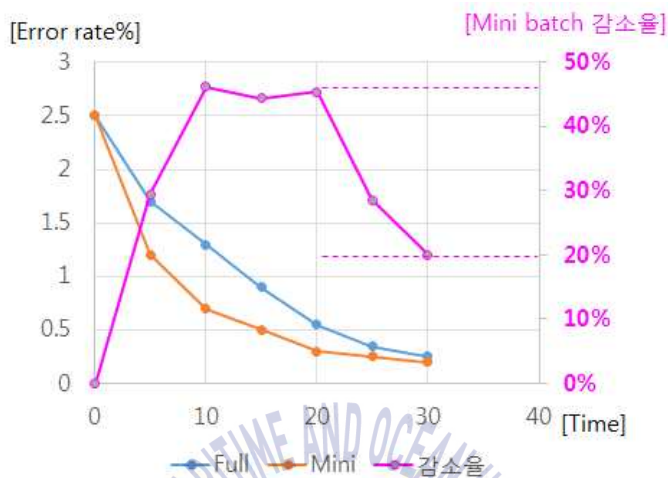


Fig. 43 Error reduction rate of Mini batch

5.4.3 세탁기 동작 상태 분류 실험 결과

여기서는 세탁기에서 세탁과 탈수 동작에 있어서 1초짜리 AC 전류 60개인 입력 데이터로 자동 동작 분류를 하여 사용자에게 스마트폰으로 전송을 하면 멀리서도 가정에서의 동작 상태를 판단함으로 사용자의 편리성을 줄 수 있는 연구이다.

2가지 제품의 동작 분석을 위해 딥러닝으로 구현했을 때 손실 함수 에러율이 줄어드는 모습을 그림 44에서 보여주고 있다. 6,000개(3000×2)의 학습 데이터로 학습하면서 반복 횟수가 늘어나면서 손실 함수 에러율이 줄어드는 모습을 보여주고 있고 1,500번의 반복에서 부터 에러율이 변화 없이 고정되어짐을 알 수 있었다.




Fig. 44 Error rate graph of the third goal

학습이 완료되어 가중치 매개변수가 정해진 후 2,000개(1000×2)의 검증 데이터로 검증했을 때 성공률이 99.15%(1983/2000)임을 아래의 표 13과 같이 혼돈 행렬로 확인이 가능하였다.

Table 13 Confusion matrixes of Wash and Spin

목표 \ 결과	1(세탁)	2(탈수)
1(세탁)	983	17
2(탈수)	0	1000

수평으로의 한 줄 전체 숫자가 동작 1개에 대한 검증 데이터(1,000개)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. 학습 검증 방법은 교차 검증의 4-Fold 검증과 2번 반복으로 했을 때 아래의 표 14의 2회 반복 교차 검증 결과에서와 같이 정확도가 99% 이상 높게 분류되고 과 적합 현상이 없음을 확인 할 수 있었다.

Table 14 Cross Validation results of 2 times 4-Fold at Wash and Spin

	에러값	정확도(%)
1-1	0.011	99.70
1-2	0.013	99.80
2-1	0	99.60
2-2	0.008	99.40
3-1	0	99.10
3-2	0	99.00
4-1	0	99.20
4-2	0.01	99.20

5.5 온라인 학습에서의 정확도 검증

여기서는 딥러닝으로 오프라인에서 학습하여 최적의 매개변수 가중치를 갱신한 후 검증 데이터로 검증된 가중치를 이용해, 실 시간에서 제품의 종류 분류와 동작 분류가 잘 되었는지 검증했다. 그러기 위해서는 AC 전류값을 측정하는 회로와 딥러닝 연산을 할 수 있는 MCU 프로그램을 설계하여 학습의 정확도를 판단하였고 표 15의 결과로 나타남을 알 수 있었다.

제품 종류에 대한 성공률에서 제품의 종류마다 측정 시간은 다르지만 판단 성공률에서 94% 이상이 나왔고, 2가지 제품을 동시에 동작 시키는 8, 9, 10번에서 94%, 97%, 96%로 한 가지 제품만 돌리는 것과 비교했을 때 성공률이 낮게 나옴을 표 14로 알 수 있었다. 세탁기의 동작 분류에서는 오프라인 학습에서와 같이 세탁동작에서 86%의 성공률로 낮게 나와 세탁 동작의 자동 판단 학습이 어려움을 알 수 있었다. 이는 세탁 동작에서 물을 받는 급수와 물을 빼는 배수 동작을 한다. 이 때 세탁기 통(Tub)의 속도를 20rpm(저속)으로 동작을 하는데, 탈수 동작을 시작 할 때도 물을 빼려고 동일하게 통(Tub)의 속도를 20rpm(저속)으로 회전하기에 중복되는 동작으로써 정확도가 하락함을 확인하였다.

Table 15 10 types and 2 motion classification result in MCU

	제품	측정 시간(초)	종류 성공률(%)	동작 성공률(%)
1-1	세탁기-세탁	418	97	86
1-2	세탁기-탈수	639	100	98
2	냉장고	910	97	-
3	에어컨	429	99	-
4	전자레인지	150	99	-
5	정수기	150	100	-
6	TV	160	98	-
7	헤어드라이기	126	99	-
8	전자레인지+ 헤어드라이기	151	94	-
9	냉장고+ 헤어드라이기	161	97	-
10	냉장고+ 전자레인지	236	96	-

제 6 장 결론

본 논문에서는 딥러닝 기반으로 영상이나 음성 인식 기술이 아닌 센서를 이용하여 분류하는 사례로, 스마트 플러그에서 가전제품의 입력 전류 파형을 측정해 제품의 종류나 동작을 자동으로 인식하고 분류하는 딥러닝의 이론을 실험으로 검증하였다.

자동 분류는 AC 입력 전류의 패턴으로 분류가 가능한데, 입력 전류의 특성 차이는 제품들의 종류마다 최종단에 연결되는 부하(회전체, 발열체, 영상체, 냉각체 등)들에 따라 전류 패턴이 다르고 전력 변환(AC-DC와 AC-AC 변환)에 따라 구분되어 가능하다. AC-DC 변환에서는 전력을 평활시키는 콘덴서의 용량과 제어 방식에 따라 입력 전류의 패턴이 달라지고, AC-AC 변환은 최종단의 부하 종류와 제어 방식에 따라 패턴이 달라짐을 확인하였다.

이러한 AC 입력 전류의 패턴으로 제품의 종류를 딥러닝을 통해 자동으로 분류가 가능하였으며, 특징 들 간의 복잡한 비선형적 상호작용을 탐지하여 미 분류되는 데이터를 다루는 능력을 가졌음을 실험으로 검증하였다.

딥러닝의 설계 단계는 데이터 수집, 전처리 과정, 오프라인 학습, 온라인 평가로 이루어졌고, 데이터 수집은 AC 입력전류를 사용자 입장에서 분석해 측정하였으며, 전처리 과정은 정규화와 랜덤화로 데이터를 분류했고, 오프라인 학습에서는 수집된 데이터로 가중치를 학습하여 교차 검증 기법으로 검증하였다. 마지막으로 오프라인에서 학습된 가중치를 MCU 기반 시스템에 적용된 온라인에서 학습력을 평가하였다. 그리고 본 논문에서 사용되는 4개의 계층 구조에서 시그모이드 함수만으로도 충분히 학습이 가능했고, 풀 배치와 미니 배치에서는 동일한 학습 에러율 수렴으로 학습 했을 때의 연산 시간이 미니 배치 일 때 연

산 시간이 짧음을 확인하였다.

결과로는 오프라인 상에서 첫 번째 7가지 제품의 조건으로 종류를 99.75%의 정확도로 분류하였고, 두 번째는 7가지 제품에 동시 동작하는 3가지 조건을 포함하여 10가지 종류를 99.97%의 정확도로 분류하였으며, 세 번째는 세탁기가 동작되는 60초 동안의 전류 데이터로 세탁/탈수 동작을 99.15%의 정확도로 판단할 수 있었다. 그리고 마지막 네 번째에서는 온라인 상에서의 MCU 기반에서 제품 종류를 94% 정확도와 세탁기 동작을 85% 정확도로 분류할 수 있음을 확인하였다.

향후 연구 과제로는 다양한 가전업체의 제품에서도 제품 종류의 분류와 동작의 분류가 되도록 연구가 필요한데 유용한 빅 데이터를 어떻게 수집할지가 관건이며, 가전제품의 AC 입력 전류와 전력값의 빅 데이터로 사용자 패턴의 의미 있는 정보를 추출하는 연구를 하고자 한다. 그리하여 모든 제품의 종류를 자동으로 인식하고 전력을 측정한다면 가정집의 에너지 절약 유도과 가전제품과 소비자 간 정보 교환이 가능한 지능형 정보가전기기의 스마트 홈 시스템이 가능하리라 판단한다.



참고 문헌

- [1] G. Marcus., 2012. *Is Deep Learning a Revolution in Artificial Intelligence?* The New Yorker, 25 November.
- [2] Deng, L., Platt, J. 2014. *Ensemble Deep Learning for Speech Recognition*, Proc. Interspeech.
- [3] Y. Bengio et al., 2013. *Advances in optimizing recurrent networks*, ICASSP.
- [4] 위키백과, 딥러닝, 2017 <https://ko.wikipedia.org> [Online] Available at : https://ko.wikipedia.org/wiki/딥_러닝 [Accessed 13 October 2017].
- [5] James Manyika and Michael Chui, 2011. *Big data: The next frontier for innovation, competition, and productivity*, McKinsey Global Institute.
- [6] D. Ciresan, U. Meier, J. Schmidhuber., 2012. *Multi-column Deep Neural Networks for Image Classification*, Technical Report.
- [7] Vinyals et al. 2014. *Show and Tell: A Neural Image Caption Generator*, arXiv:1411.4555.
- [8] Nvidia, 2015. *Demos a Car Computer Trained with Deep Learning* , David Talbot, MIT Technology Review.
- [9] 네이버 백과사전 Smart Plug, 2018. <http://www.naver.com> [Online]Available at:terms.naver.com/search.nhn?query=smart+plug&searchType=&dicType=&subject= [Accessed 15 April 2018].

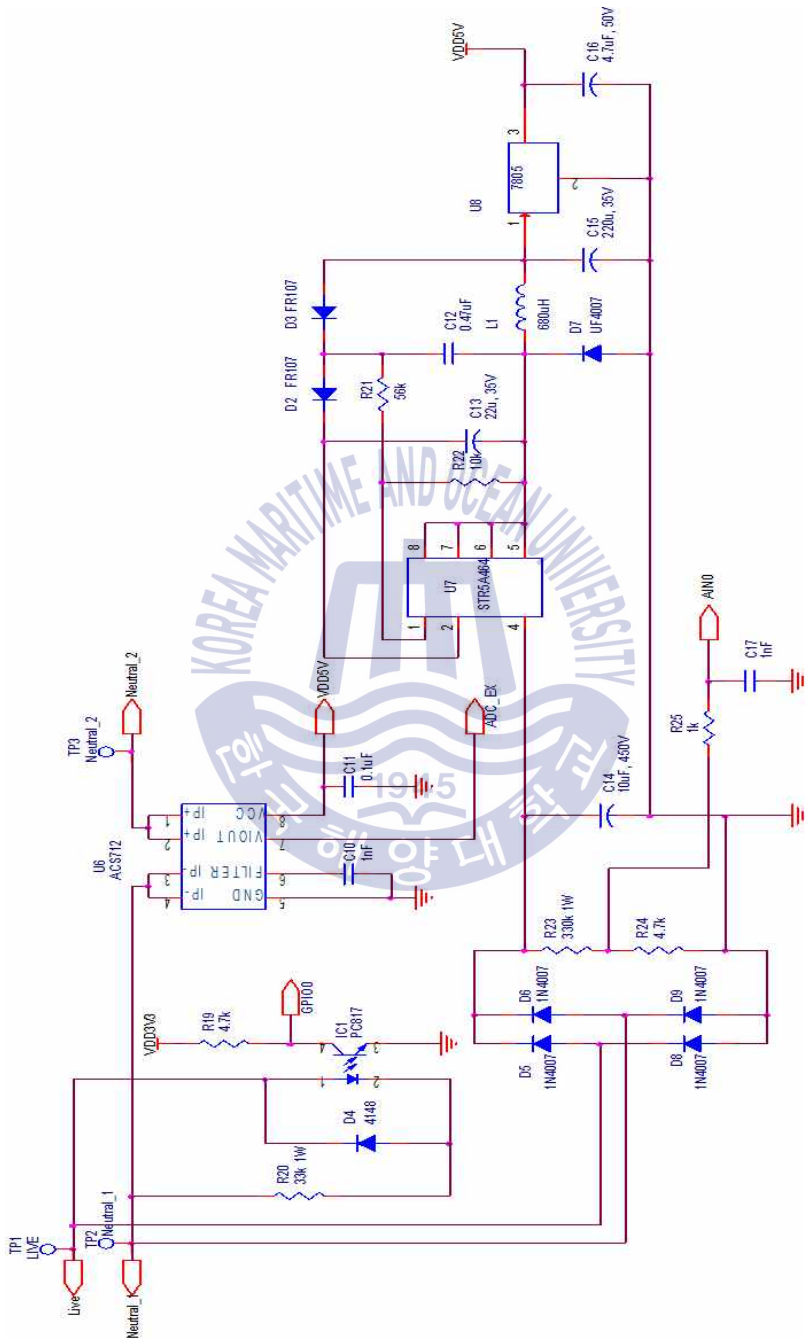
- [10] E. Bufill, J. Agusti, R. Blesa., 2011. Human neoteny revisited: The case of synaptic plasticity, *American Journal of Human Biology*, 23 (6), pp. 729 - 739.
- [11] 한국통상자원부, 2016. *스마트홈 산업 환경 및 관련 기술 동향*, 한국통상자원부.
- [12] 중소기업기술정보진흥원, 2018. *중소, 중견기업 기술로드맵 2018 - 2020 스마트홈*, 중소기업기술정보진흥원.
- [13] 중소기업기술정보진흥원, 2017. *중소, 중견기업 기술로드맵 2017 - 2019 가전*, 중소기업기술정보진흥원.
- [14] 이성준, 2015. *SEP 표준 기반의 확장된 스마트 플러그 시스템*. 박사학위논문, 제주:제주대학교.
- [15] 서창준, 2013. *패턴 분석으로 관리하는 가정용 스마트 전기관리 시스템*. 석사학위논문. 서울:광운대학교.
- [16] D. C. Ciregan, U. Meier, J. Masci, 2012. *Multi-Column Deep Neural Network for Traffic Sign Classification*, Neural Networks.
- [17] D. Ciregan, A. Giusti, L. Gambardella, J. Schmidhuber. 2012. *Deep Neural Networks Segment Neuronal Membranes in Electron Microscopy Images*, In Advances in Neural Information Processing Systems.
- [18] J. Schmidhuber, 2014 *Deep Learning in Neural Networks: An Overview*. <http://arxiv.org/abs/1404.7828>.
- [19] G. E. Hinton., 2007. Learning multiple layers of representation, *Trends in Cognitive Sciences*, Vol. 11 No. 10, 2007, pp. 428 - 434.
- [20] D. C. Ciregan, U. Meier, J. Schmidhuber. 2012. *Multi-column Deep Neural Networks for Image Classification*, IEEE Conf. on Computer Vision and Pattern Recognition CVPR.

- [21] Christian Szegedy, Alexander Toshev and Dumitru Erhan., 2013. *Deep neural networks for object detection*. Advances in Neural Information Processing Systems.
- [22] Y. Bengio, A. Courville and P. Vincent, 2013. *Representation Learning: A Review and New Perspectives*. IEEE Trans. PAMI, special issue Learning Deep Architectures.
- [23] 텐서플로우 문서 한글번역, MIST 초급, 2018.
<https://legacy.gitbook.com/book/tensorflowkorea/tensorflow-kr/details>
 [Online] Available at : <https://tensorflowkorea.gitbooks.io/tensorflow-kr/content/g3doc/tutorials/mnist/beginners/> [Accessed 15 April 2018].
- [24] G. E. Hinton et al., 2012. Deep Neural Networks for Acoustic Modeling in Speech Recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, pp. 82 - 97.
- [25] Liu, Yuan, 2015. *Incremental Learning in Deep Neural Networks*. Naster of Science Thesis.
- [26] Y. Bengio, and X. Glorot, 2010. Understanding the difficulty of training deep feedforward neural networks. *In Proceedings of AISTATS 2010*, volume 9, pp. 249 - 256.
- [27] G. Dahl et al., 2013. *Improving DNNs for LVCSR using rectified linear units and dropout"* ICASSP.
- [28] T. Sainath et al., 2013. *Convolutional neural networks for LVCSR*, ICASSP.
- [29] H. Lee, R. Grosse, R. Ranganath and A. Y. Ng, 2009. *Convolutional deep belief networks for scalable unsupervised learning of hierarchical representation*, Proceedings of the Twentieth-Sixth International Conference on Machine Learning (ICML).

- [30] 사이트 코키, 2017. *밑바닥부터 시작하는 딥러닝*. 한빛미디어.
- [31] Abdel-Hamid, O. et al., 2014. Convolutional Neural Networks for Speech Recognition. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, Vol. 22 No. 10. pp. 1533 - 1545.
- [32] T. Mikolov et al., 2010. *Recurrent neural network based language model*. Interspeech.
- [33] Y. Bengio et al., 2013. *Advances in optimizing recurrent networks*, ICASSP.
- [34] A. Graves, M. Liwicki, S. Fernandez, R. Bertolami, H. Bunke and J. Schmidhuber. 2009. A Novel Connectionist System for Improved Unconstrained Handwriting Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 31, No. 5.
- [35] 김윤진, 2017. *딥러닝을 활용한 이미지 빅 데이터 분석 연구*. 박사학위 논문. 서울:중앙대학교.
- [36] 이상엽, 2017. *스마트홈 기술 현황 및 트렌드*, 정보통신기술진흥센터.
- [37] 한국산업기술평가관리원, 2015. *IoT 기술개발 동향*, 한국산업기술평가관리원.
- [38] 강만수, 2012. *개발형 IoT 플랫폼 기술 동향*, 한국산업기술평가관리원.
- [39] 중소기업기술정보진흥원, 2017. *중소, 중견기업 기술로드맵 2017-2019 스마트홈/비즈니스*, 중소기업기술정보진흥원.
- [40] 네이버 백과사전 교류전류, 2018. <http://www.naver.com>
 [Online]Available at : terms.naver.com/search.nhn?query=교류전류
 [Accessed 15 April 2018].
- [41] 네이버 백과사전 교류전류작용, 2018. <http://www.naver.com>
 [Online]Available at : terms.naver.com/entry.nhn?docId=2117669&cid=47338&categoryId=47338 [Accessed 15 April 2018].


- [42] 한국산업기술평가관리원, 2012. *스마트 가전 현황 및 발전 방향*, 한국산업기술평가관리원.
- [43] 노의철, 정규범, 최남섭, 2000. *전력전자공학*, 문운당.
- [44] 허경용, 2017. *사물인터넷을 위한 ESP8266 프로그래밍*, 제이펍.
- [45] 손창우, 2017. *딥러닝을 이용한 가전제품 분류 시스템 구현*, 한국정보통신학회논문지, 21(9), pp.1718-1724.
- [46] 최정우, 2017. *DNN의 분산 처리 시 유동적인 지역 반복을 통한 학습 가속화*, 석사학위논문. 서울:중앙대학교.
- [47] 홍택은, 2017. *CNN을 이용한 SNS 사용자 관심사 카테고리 분류 및 팔로잉 추천 방법*, 석사학위논문. 광주:조선대학교
- [48] M. Abadi, A. Agarwal, P. Barham and et al., 2016. *Tensorflow: Large-Scale Machine Learning on Heterogeneous Distributed System*, Distributed, Parrel, and Cluster Computing.
- [49] G. E. Hinton., 2010. *A Practical Guide to Training Restricted Boltzmann Machines*, Tech. Rep. UTML TR 2010-003, Dept. CS., Univ. of Toronto.
- [50] 권배근, 2015. *기계학습 기반의 표면결합 검사에 대한 연구*, 박사학위논문. 부산:부산대학교.
- [51] 오일석, 2017. *패턴 인식*, 교보문고.

부록 A 전력 측정 회로




부록 B MCU 및 와이 파이 회로

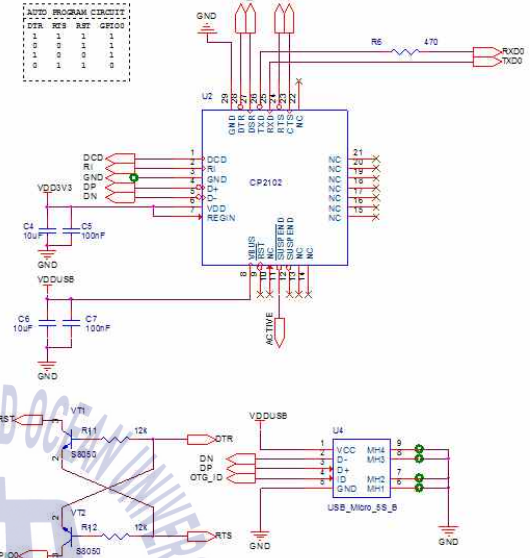
ESP-12 CORE



WATERS WELDING ATTENTION
 On every boot/reset/wakeup, CP2102 MUST keep HIGH, GPIO0 HIGH > HIGH MODE, LOW PFLASH MODE.
 When you need to use challenge mode, CP2102 and RST should be disconnected, and GPIO0 will output LOW to reset the system at the time of wakeup.




USB TO UART



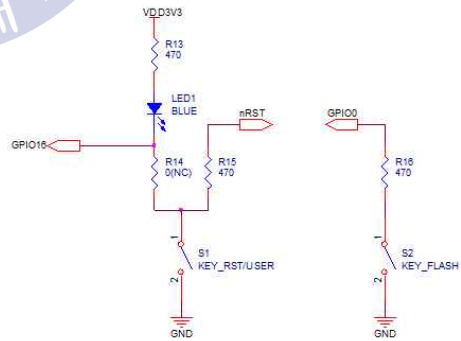

부록 C 주변 회로

POWER




Working Output: 3.3V 800mA
 Working Current Limit: 1000mA
 Max Current: 1000mA
 Max Supply Voltage: 20V
 Voltage Dropout: 1.2V@800mA


ADC




부록 D 부품 배치도(Top 및 Bottom)



부록 E PCB Gerber(Top 및 Bottom)



부록 F PCB Gerber(Solder Mask Top 및 Bottom)



부록 G Bare PCB 및 실장된 PCB



부록 H 스마트 플러그 실제 사용 모습

