

# 스마트 플러그를 이용한 전력 데이터 분석 및 위험 상황 예측에 관한 연구

정세훈<sup>†</sup>, 김준영<sup>\*\*</sup>, 박 준<sup>\*\*\*</sup>, 장승민<sup>\*\*\*\*</sup>, 심춘보<sup>\*\*\*\*\*</sup>

## A Study On Power Data Analysis And Risk Situation Prediction Using Smart Plug

Se Hoon Jung<sup>†</sup>, June Young Kim<sup>\*\*</sup>, Jun Park<sup>\*\*\*</sup>, Seung Min Jang<sup>\*\*\*\*</sup>, Chun Bo Sim<sup>\*\*\*\*\*</sup>

### ABSTRACT

It is that failure of equipment at the factory site causes personal injury and property damage. We are required a real-time monitoring and risk forecasting techniques to prevent for equipment failure. In this paper, we proposed a 3-phase smart plug and real-time monitoring system that can be used in factories, and collected environmental information and power information using a smart plug to analyze the data. In order to analyze the correlation between the risk situation and the collected data, we predicted the risk situation using Linear Regression, SVM, and ANN algorithms. As a result, the SVM and ANN algorithms obtained high predictive accuracy and developed a mobile app that could use it to check the risk forecast results.

**Key words:** Smart Plug, Smart Factory, Data Analysis, Risk Situation Prediction

### 1. 서 론

스마트 기술의 발전에 따라 스마트 기기들이 우리의 일상생활뿐만 아니라 다양한 분야에 스며들고 있다. 가정의 냉장고, TV 등 가전제품들과 사무실의 다양한 기기, 공장의 설비들이 스마트화되고 있다 [1-2]. 2011년 에너지경제연구원의 발표에 따르면 우리나라는 전체 에너지의 약 97%를 수입에 의존할 정도로 에너지 자원이 부족한 에너지 수입국이며, 이는 현재에도 지속되고 있다. 스마트 및 자동화 시스

템 보급률의 증가에 따라 전력 사용량이 증가하고 있는 추세로 전기 에너지 소비를 절감하기 위한 대책이 필요하다[3]. 최근 효율적으로 전력을 사용하기 위한 스마트 그리드 기술이 연구되고 있다[4-5]. 스마트 그리드는 통신 기술, IT 기술 등을 활용하여 전력사용 효율을 최적화하는 기술을 의미한다. 스마트 그리드의 한 분야로 스마트 플러그를 활용한 전력 소비 감소 연구가 많이 진행되고 있다. 가정에서 대기전력을 줄이기 위해서는 플러그를 뽑거나 멀티플러그의 전원을 끄는 방법이 있으나 실제로 잘 이행되

※ Corresponding Author : Chun Bo Sim, Address: (57922) 255, Jungang-ro, Suncheon-si, Jeollanam-do, Republic of Korea, TEL : +82-61-750-3830, FAX : +82-61-750-3834, E-mail : cbsim@scnu.ac.kr

Receipt date : June 15, 2020, Revision date : June 15, 2020  
Approval date : June 19, 2020

<sup>†</sup> School of Creative Convergence, Andong National University

(E-mail : jungsh@anu.ac.kr)

<sup>\*\*</sup> Dept. of Multimedia Eng., Sunchon National University  
(E-mail : kjoone3k@naver.com)

<sup>\*\*\*</sup> Dept. of Multimedia Eng., Sunchon National University (E-mail : todnehd1@naver.com)

<sup>\*\*\*\*</sup> NARAE INFO. Co., Ltd.  
(E-mail : sun@nrinfo.kr)

<sup>\*\*\*\*\*</sup> Dept. of Multimedia Eng., Sunchon National University

※ This paper has been written with the support of Jeollanam-do ('2019 R&D supporting program' operated by Jeonnam Technopark). and this research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education(2017R1D1A3B0303537914)

고 있지 않다. 기존 연구에서는 이를 위해 스마트 플러그 기술을 활용하여 대기전원을 차단하거나 전원 자동제어 등의 기능을 활용하여 절전에 대한 연구가 진행되고 있다. 스마트 플러그는 제품이 사용되지 않을 때 자동으로 전원을 차단하고 소비전력 정보, 사용자의 사용 정보에 맞추어 예약 설정을 제공하는 등의 무선통신 기능을 갖춘 기술이다. 따라서 기존 비절전 제품에 대해 스마트 전력 모니터링 기술을 제공하여 모니터링 및 분석 기능, 원격 전원 관리 등의 기능을 제공하는 기기이다.

그러나 가정에서 사용하는 기기에서 발생하는 대기전력보다 공장과 같은 대규모 시설에서 사용되는 대기 전력이 많다. 이에 비해 연구되고 있는 스마트 플러그 시스템은 가정에서 사용되는 스마트 플러그 시스템이 주로 연구되고 공장에서 사용하는 스마트 플러그 시스템의 연구가 미비한 실정이다. 그리고 규모가 크고 복잡한 시스템은 설비 고장이 발생하였을 경우 그 피해 규모가 막대하고 인명피해가 발생할 가능성이 매우 크다. 공장 현장에서의 설비 고장은 큰 인명피해 및 재산적 피해를 유발시키므로, 장비의 실시간 모니터링, 고장 및 위험 예측 기술을 위해서 데이터수집, 저장, 인공지능 기반 실시간 데이터 분석에 관한 연구가 필요한 실정이다[6-7].

본 논문에서는 IIoT센서를 활용하여 공장에서 사용할 수 있는 3상 스마트 플러그를 연구하며 스마트 플러그와 연결된 설비의 전력을 모니터링하고 분석하여 위험상황을 예측하는 시스템을 제안한다. 제안하는 시스템은 3상 스마트 플러그를 이용하여 장비의 온도, 습도, 가스, 전력, 전압, 전류와 부하 상태에 관한 데이터를 수집하여 실시간 모니터링 및 데이터 분석을 통한 위험 상황 예측에 관한 연구를 진행한다.

본 논문의 구성은 다음과 같다. 2장에서는 스마트 플러그와 전력 데이터 분석과 관련된 기존 연구 내용을 제시하며, 3장에서는 제안하는 3상 스마트 플러그 전체 시스템 구성 및 스마트 플러그 H/W 설계 및 H/W 구현을 제시하고, 4장에서는 스마트 플러그 전력 데이터 분석 및 위험 상황 예측 시스템의 알고리즘에 대해 제시한다. 마지막으로 5장에서 결론을 맺는다.

## 2. 관련 연구

### 2.1 전력 데이터 분석

[8]의 연구에서는 배전설비에서 발생하는 고장과 외부 환경요인간의 상관관계를 확인하기 위한 연구를 진행하였다. 두 요인 간 상관관계 분석을 위해 배전설비 데이터(COS, 가공변압기, 개폐기, 피뢰기, 애자, 가공지선 고압전선, 전주)와 기상데이터(기온, 강수량, 풍속, 습도, 적설)를 수집하여 의사결정나무, 로지스틱회귀 알고리즘을 활용하였다. 분석결과 풍속, 강수 및 적설과 관련된 기상환경요인이 배전설비 고장에 영향을 주는 것을 확인하였고, COS에 대한 로지스틱회귀 분석결과 약 94.6%의 정확도를 제시하였다. [9]는 인공지능망을 활용하여 수전설비에서 발생하는 고장과 설비의 온도와의 관계를 분석하였다. 데이터 분석을 위해 LSTM(Long Short Term Memory)기반 인공지능망을 활용하였으며, 신경망의 깊이는 3개 층으로 구성하고, 8,000개의 학습데이터와 2,000개의 테스트데이터로 연구를 진행하였다. 연구결과 97.7%의 정확도를 보여주었다. [10]은 수배전반에서 발생하는 고장을 분석하기 위한 시스템을 제안하였다. 배전반 내의 전류, 전압, 온도의 센서 데이터 분석을 통해 수배전반 시스템의 고장을 예측하는 시스템인 EPS(Error Prediction System)을 설계 및 구현하였다. 수배전반 시스템의 내부 설비의 전류, 전압, 온도 데이터를 토대로 정상범위를 넘는 이상 신호와 이러한 이상 신호가 자주 발생하는 빈도를 이용하여 이상사건을 분류하고 또한 이상사건의 빈도를 이용하여 경고로 분류하였다. [11]의 연구에서는 시간단위 전력수요 예측성능 향상을 위해 시간단위 기상정보를 활용하여 2007년 1월 1일부터 2012년 12월 31일까지 전력수요량 자료에 삼중 계절성 지수평활모형을 적합시켜 예측오차를 계산하였다. 2010년 1월 1일부터 2012년 12월 31일까지 삼중 계절성 지수평활모형의 예측값에 추정된 회귀모형을 보정하여 전력수요량 예측 향상도를 평가하였다. [12-13]의 연구는 K-means 알고리즘의 문제점을 보완하여 큰 규모의 전력 데이터를 분석하고 이상점을 추출할 수 있는 클러스터링 아키텍처를 제안하였다. 제안하는 클러스터링 프로세스는 변형된 K-means 알고리즘을 기반으로 Row Data Level, Clustering Level, User Interface Level로 총 3 Level로 구분하여 전력

데이터를 분류 및 분석을 진행하였으며, 총 4개의 전주를 기준으로 완급과 전주를 각각 구분하여 성능평가한 결과 89개 이상점 감소와 전체 데이터 대비 평균 0.5% 감소율을 확인하였다. [14]의 연구는 전력 수요 관리 방식인 NILM(Non Intrusive Load Monitoring) 시스템의 성능 고도화를 위해 시스템 최종 단의 분류기 모델을 제안하였다. 제안된 모델은 MFCML-LSTM(Multi-Feature Combination ML-LSTM) 기반의 새로운 RNN 구조로 패턴 분석을 통해 기기 분류를 진행하였으며, 기존 방식인 GRN 또는 LSTM 기반의 방법보다 3~10% 이상의 성능향상을 보이며 99~100%의 정확도와 93~100%의 F1-Score 성능을 보였다. [15]의 연구는 기하학적으로 증가하는 데이터의 빠른 분석을 위해 하둠 기반의 스마트그리드 전력 데이터 분석 시스템을 제안하였다. 해당 시스템은 하둠의 병렬처리 지원방식인 맵리듀스를 이용하여 분석을 진행하였으며, 10일간 전력 사용량을 기준으로 관계형 데이터베이스와 비교 결과 약 3~5배 더 빠른 분석 속도를 보였다.

## 2.2 스마트 플러그

[16]의 연구에서는 복수 shunt resistor를 활용한 부착형 스마트 플러그를 제안하였다. 제안된 스마트 플러그는 4개의 분리로 구성하여 각 분리가 relay에 의해 개폐되어 부하에 공급되는 전류를 측정하기 위해 분리에 연결된 shunt resistor의 저항값을 조합하여 ADC(Analog-to-Digital Converter)에서 모니터링 할 수 있도록 하였다. 제안하는 스마트 플러그를 대기전력 차단장치로 사용하기 위해서는 산업통상자원부에서 고시한 대기전력 차단 소비전력 0.5W를 초과하여 대기전력 차단장치로 부적합하였다. [17]은 전기용품안전기준 K10026 규정 기반의 스마트 플러그 시스템과 성능평가에 대한 연구를 진행하였다. 제안하는 시스템은 스마트폰 앱을 이용하여 온/오프, 예약, 실시간 전력량, 누적 전력량을 모니터링할 수 있도록 구성하였다. 스마트 플러그 기능 중 대기전력, 과전류 자동 차단에 대한 성능평가를 진행하여 100%의 성공률을 확인하였다. [18]의 연구에서는 와이파이 기능을 내장한 플러그와 전력 소비량을 모니터링하고 제어할 수 있는 웹서버로 구성하여 사용자가 쉽게 전력 소비 상태를 체크하고 콘센트의 전원 상태를 조작할 수 있는 스마트폰용 웹을 개발하였다.

와이파이와 LCD를 사용하여 대기상태에서 기준치인 0.5W보다 높은 1.18W를 소모하고 전력량 오차 기준인 3%보다 높은 최대 7.62%의 성능을 보인다. [19]의 연구는 사물 인터넷 기반의 스마트 콘센트 시스템에 대한 연구를 진행하였다. 제안하는 시스템은 WiFi AP를 기반으로 AC 전원센서(SCT-013)를 통해 콘센트의 전력량을 실시간으로 원격 모니터링 및 제어할 수 있으며, 장치의 전력 공급 및 차단 스케줄링을 위한 타이머 기능과 전력사용량의 이상 수치탐지를 통한 알람 서비스를 받을 수 있는 스마트 콘센트 시스템을 개발하였다. [20]의 연구는 스마트 플러그에 딥러닝 기술을 결합하여 스마트 플러그를 통해 연결된 60Hz 주기의 교류 입력 전류로 표현되는 10가지 종류의 가전제품(세탁기, 전자레인지, 에어컨, TV 등)들의 종류와 동작 상태(세탁, 탈수 등)를 인식하고 이를 모니터링할 수 있는 모바일 앱을 개발하였다. 해당 연구는 10개의 가전제품 종류의 분류에서 94% 이상의 정확도를 보였으며, 가전제품의 동작 상태 분류에서는 86%의 정확도 성능을 보였다. [21]의 연구는 플러그 제어에 필요한 서버 없이 블루투스 와 지그비 통신 인터페이스를 활용하여 직접 스마트 플러그와 원격장치 및 모바일 기기와 통신하여 전력 및 제어하는 시스템을 개발하였다. 제안된 스마트 플러그는 스마트폰으로 여러개의 플러그들과 블루투스로 연결을 위해 HC-06 모듈을 사용하여 다중 연결을 지원하며, 지그비 통신의 신호 세기를 기준으로 거리를 측정하여 자동으로 온/오프 스위치를 제어하도록 개발하였다. 하지만 지그비 통신을 통한 거리측정은 주변 환경의 영향으로 오차범위가 일정하지 않는다는 문제점이 존재하였다.

## 3. 제안하는 스마트 플러그 시스템

### 3.1 스마트 플러그 시스템 전체 구성도

Fig. 1은 스마트 플러그 시스템의 전체 구성도이다. 스마트 플러그 하드웨어는 소비 전력 패턴을 위한 전력 측정부, 사고 위험 방지 및 처리 알고리즘에 의한 전원, 전력 제어 프로세스 구축을 위한 부하전원 제어부, 데이터 전송을 위한 무선 송수신부, 온도, 습도 및 GAS, VOC 등 소형 MEMS 기반의 환경센서 데이터 수집을 위한 환경 센서부 4가지로 구성하였다. 3상 스마트 플러그 하드웨어를 통해 온도,

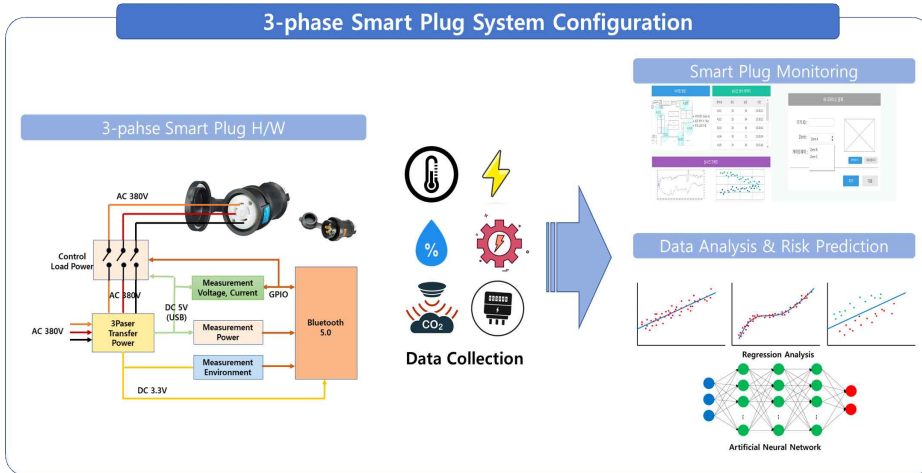


Fig. 1. 3-phase Smart Plug System Configuration.

습도, 가스, 전류, 전압, 전력 데이터를 수집한다. 수집한 데이터는 스마트 플러그 모니터링 시스템을 이용하여 값들을 모니터링 할 수 있으며 스마트 플러그의 개별부하제어, 개별전력사용량 등의 기능으로 구성하였다. 데이터 분석을 통한 위험상황 예측을 위해 스마트 플러그를 통해 수집된 데이터를 활용하여 위험상황과의 상관관계를 파악하고 Linear Regression, SVM, ANN 알고리즘을 활용하여 예측 모델을 생성한 후 비교분석을 통해 최적의 예측 모델을 선정하였다.

3.2 스마트 플러그 H/W 설계

Fig. 2의 스마트 플러그의 하드웨어 구성요소이다. 스마트플러그는 Main 제어기, 센서부, 제어회로, 주변부, 릴레이 및 스위치로 구성하였다. 스마트플러그는 AC 380V가 들어오며 Voltage, current와 pow-



Fig. 2. Smart Plug Hardware Configuration.

er 측정에는 USB를 활용하여 DC 5V로 변환 및 사용하고 Bluetooth 5.0 module에는 DC 3.3V로 변환하여 사용한다. Voltage, Current는 GPIO로 인해 조절이 되며 Control Load Power에서 GPIO에서 받은 Voltage, Current의 출력을 참고해 출력할 Voltage, Current를 조절한다.

Fig. 3의 (a)는 스마트 플러그의 Power 설계 회로도이며 AC POWER, Voltage Regulator(5V to 3V3, 3V3 to 1V2), External USB Power Source로 구성하였다. (b)는 일반 상용 전압 16A 대응/플렌트용 전력 제어 안정성을 위한 50A 대응 설계 회로도이다.


Fig. 4의 (a)의 MCU는 VDDIO\_decoupling, VDDCORE\_decoupling, MCU reset, Erase Jumper, X-TAL로 구성하였으며, (b)는 MCU 주변기기는 LED, User Button, GLCD, JTAG, I2C pull up and LED로 구성하였다.

Fig. 5는 스마트 플러그 Sensor의 설계 회로도이다. PCB Current sensor, 출력 전력 측정 센서인 EXT Current sensor, 온도와 습도 센서, gam sensor connector로 구성되어 있다. Fig. 6은 Bluetooth 5.0 module 하드웨어 설계도이다.


3.3 스마트 플러그 통신 프로토콜 설계

Fig. 7은 스마트 플러그의 데이터 전송 프로토콜이다. 전압, 전류, 전력, 부하 상태, 온도, 습도, 가스 등의 데이터를 전송하기 위해 전송 프로토콜을 구성하였다. HEAD는 스마트 플러그 장치 모듈의 HEAD


AC POWER IN




External USB Power Source



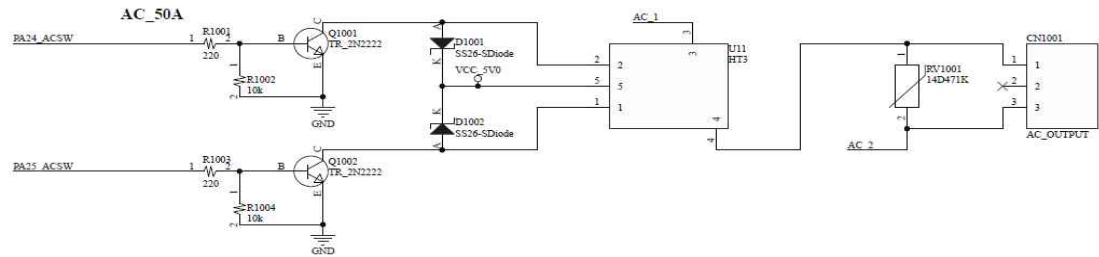
Voltage Regulator 5V to 3V3



Voltage Regulator 3V3 to 1V2



(a) Power circuit design



(b) AC Connection circuit design

Fig. 3. Power PCB Design.

값을 저장, 날짜 및 시간은 MCU 내부의 타이머를 기준으로 값을 전송한다. 그리고 장치 ID에 대한 값들과 장치에 의해 측정된 전압, 전류, 전력, 부하상태, 온도, 습도, 가스값들을 전송하고 CS 16bit check sum을 사용한다. 데이터는 8bit 단위로 저장되며 온도, 습도 등 소수점이 있는 경우 모두 정수로 저장한다. 온도, 습도, 전력, 가스 데이터는 2byte를 사용하고 복호로 저장하고 전송하도록 설계한다. 부하 상태의 경우 ON 상태는 1, OFF 상태는 2로 전송한다.


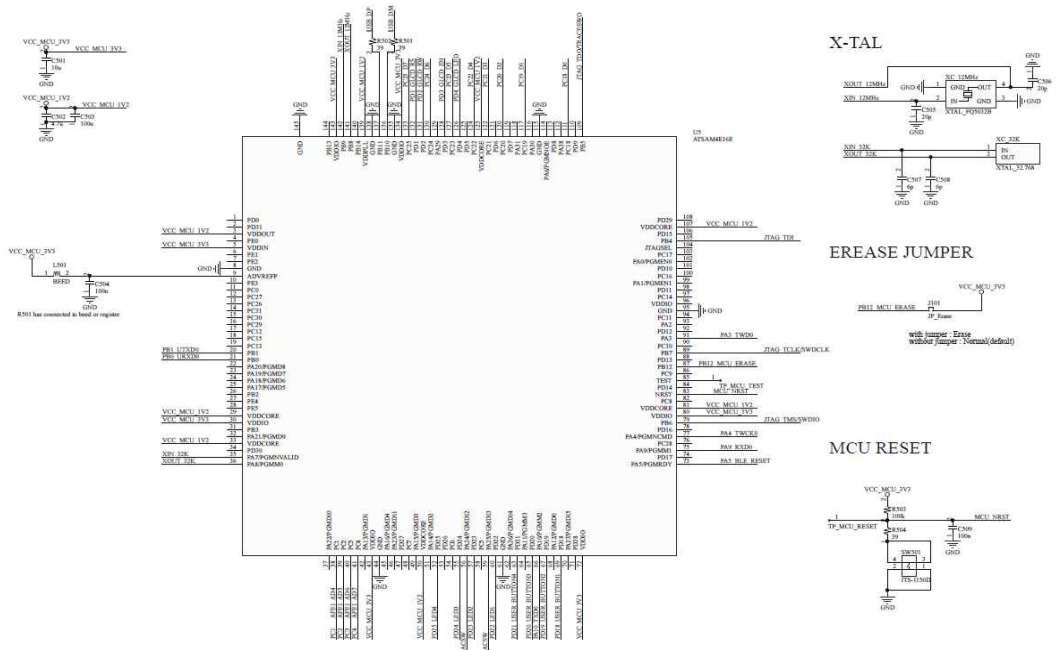
3.4 스마트 플러그 H/W 개발

Fig. 8은 스마트 플러그의 프로토타입이다. 스마트 플러그 전면부 구성은 전원 버튼, 리셋 버튼, 상태 표시창, 플러그 단자로 구성된다. 스마트 플러그의

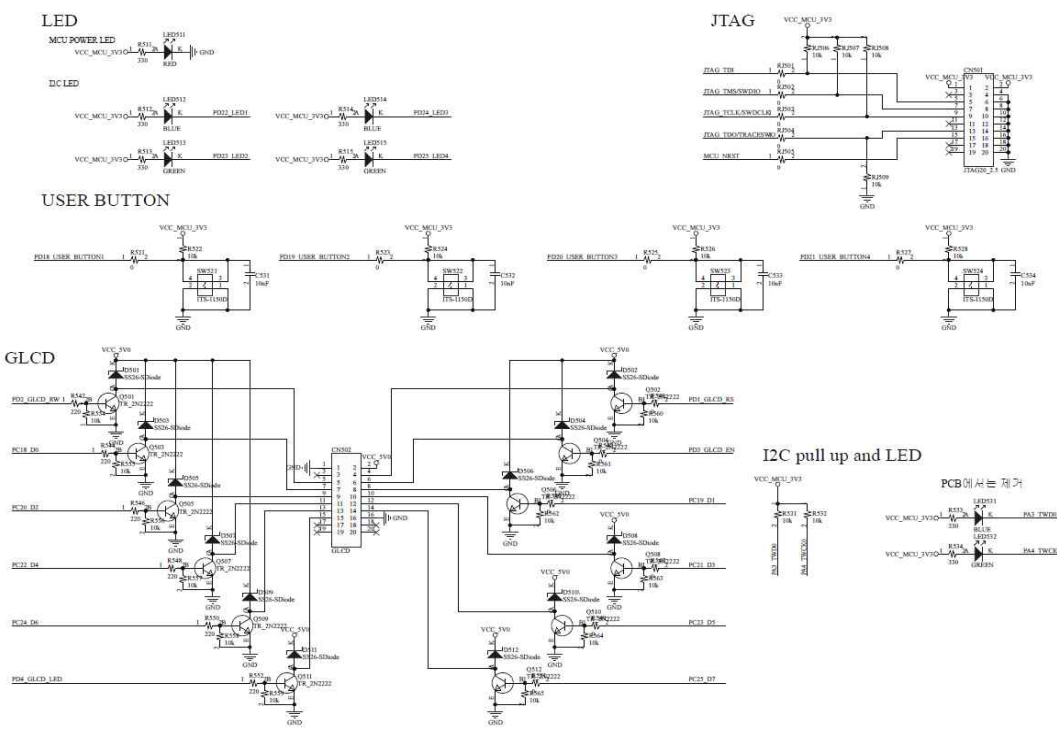
각 파트별 세부 설계 및 홀 가공, 방수형 커넥터 및 GLCD부 세부 설계 등을 이용하여 도면을 설계하고 내부 기관 및 버튼 실측 설계를 통한 단차 검증을 진행 후 프로토타입을 개발하였다.

3.5 스마트 플러그 모니터링 시스템

Fig. 9는 스마트 플러그 모니터링 시스템이다. 스마트 플러그 모니터링 시스템은 공장 내에 설치된 스마트 플러그 전체를 모니터링한다. 특정 스마트 플러그 선택 시 해당 스마트 플러그에서 측정되는 실시간 온도, 습도, 가스, 전압, 전류와 전력량을 확인할 수 있고 누적 소비량을 그래프 형태로 확인할 수 있다. 데이터 분석을 통한 플러그 진단 및 예측에 대한 정보를 확인할 수 있도록 구현하였다.



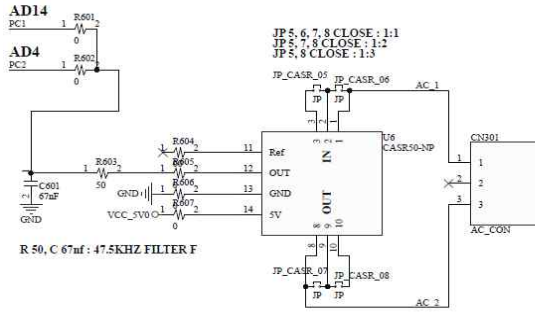
(a) MCU circuit design




(b) MCU Peripherals circuit design

Fig. 4. MCU PCB Design.

PCB CURRENT SENSOR CASR50-NP1em leaflet cas casr clskr




TEMP AND HUMIDITY



GAM SENSOR CONNECTOR

온도 습도 센서도 쪽보드에 위치  
**GAM SENSOR 3mm x 3mm**  
 쪽보드는 35mm X 20mm 제작  
 커넥터 간격 25mm



EXT CURRENT SENSOR 100A 전류센서 TFC30P100A




Fig. 5. Smart Plug Sensor circuit design.

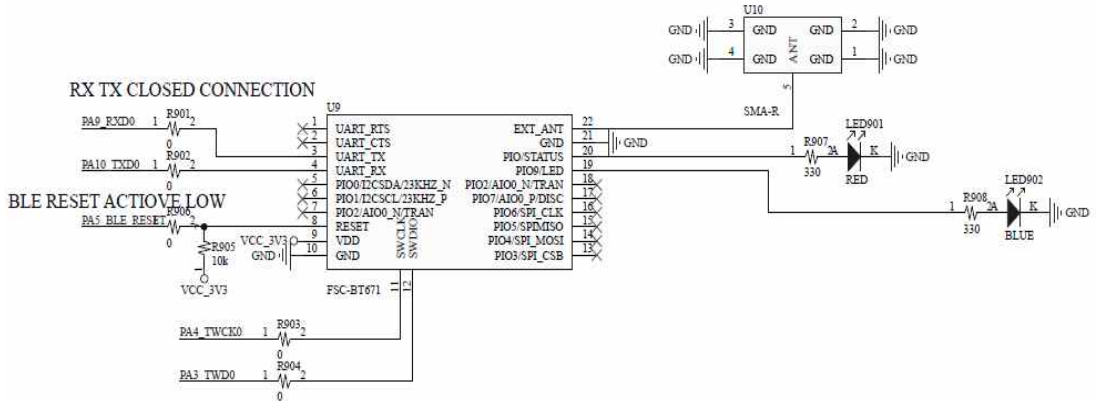


Fig. 6. Bluetooth 5.0 module hardware design.

HEAD	HEAD	HEAD	HEAD	D00	D01	D02	D03
0x53	0x46	0x50	0x4D	Date (Year)	Date (Month)	Date (day)	Time (Hour)
D04	D05	D06	D07	D08	D09	D10	D11
Time (Minute)	Time (Second)	Device ID1 0x00	Device ID2 0x01	Voltage 220	electric current 50	electric power (Up) 0x40	electric power (Down) 0x1F
D12	D13	D14	D15	D16	D17	D18	CS1 CS2
Load 1 or 2	temperature Sensor (Up)	temperature Sensor (Down)	Humidity sensor (Up)	Humidity sensor (Down)	Gas(Up)	Gas(Down)	0xFF 0xFF

Fig. 7. Smart Plug data transfer protocol.





Fig. 8. Smart Plug Prototype.

#### 4. 스마트 플러그 데이터 분석 및 위험 상황 예측 모델

본 연구에서는 공장의 설비에 과전류가 흘러 화재 위험이 있을 때 온도, 전류, 전압, 전력이 증가하는 등 공장의 설비 및 환경 요소들이 화재위험에 영향을 미친다는 가정으로 온도, 습도, 가스, 전류, 전압, 전력 총 6개의 파라미터를 활용하여 Linear Regression, SVM(Support Vector Machine), ANN(Artificial Neural Network) 3개의 알고리즘으로 위험상황 예측 모델을 평가하였다. 이를 위해 하이퍼 파라미터 또는 히든레이어 등의 구성을 비교함으로써 최적 모

델 형태를 검증 및 정확도를 비교 분석하여 예측 모델을 선택한다.

##### 4.1 데이터 형태

데이터는 스마트 플러그를 이용하여 11kW급 컴퓨터 서버를 연결하여 1분 간격으로 10주간 데이터를 수집하였다. Table 1과 같이 온도, 습도, 가스, 전류, 전압, 전력, 부하상태를 구성요소로 갖고 있으며, 데이터는 장비의 부하상태(정지 상태, 정상 작동 상태, 초기 기동 상태, 과전류 상태)를 기준으로 수집하였다. 학습데이터와 테스트데이터의 분류는 전체 데이터 100,800개에서 무작위로 학습데이터와 테스트데이터를 각각 75%, 25%로 분류하여 학습을 진행하였다.

##### 4.2 Linear Regression 모델

주변 환경 요소 및 전류, 전압, 전력 데이터가 설비에 영향을 미친다는 가정으로 해당 요인들이 부하상태와 선형적인 관계를 이루는지 파악하기 위해 예측 모델 중 하나로 Linear Regression을 선택한다. 입력 변수들의 유의미한 의미를 판단하고 선별하기 위해



Fig. 9. Smart Plug Monitoring System.

Table 1. Components of the dataset

Name	Variable name	Explanation
Temperature(°C)	temp.	average temperature for 1 minute
Humidity(%)	humi.	average humidity for 1 minute
Gas	gas	average gas for 1 minute
Electric Current	ec	average current for 1 minute
Voltage	v	average voltage for 1 minute
Electrical Energy	energy	average electrical energy for 1 minute
Load Condition	condition	equipment load condition



OLS(Ordinary Least Squares) 작업을 진행한다. OLS는 전차제곱합을 최소화하는 가중치 벡터를 행렬 미분으로 구하는 방식으로 데이터에 회귀분석을 적용하여 변수별 계수와 유의확률을 확인할 수 있다.

Table 3은 전체 데이터의 OLS 진행 결과로 습도와 전력을 제외한 나머지는 유의확률이 모두 0.05이하로 유의미한 의미가 있는 것으로 판단되었다. 그리고 온도와 전류의 경우 양의 상관관계를 보이며 가스 와 전압의 경우 약한 양의 상관관계를 보이는 것을 확인할 수 있으며 단순 선형 회귀가 아닌 다중 선형 회귀가 예측 모델에 타당한 것을 확인할 수 있어 다중 회귀분석으로 분석을 진행하였다. 다중 회귀분석 모델의 예측 정확도는 MAE(Mean Absolute Error), RMSE(Root Mean Squared Error),  $R^2$ 을 사용하여 결과를 표현하였다. MAE는 실제 값과 예측값의 차이를 절댓값으로 계산한 평균값이며 RMSE는 실제 값과 예측값의 차이를 제곱하여 평균한 것에 루트를 취한 값이다.  $R^2$ 은 실제 값의 분산 대비 예측값의 분산 비율을 기준으로 하여 비교한 것으로  $R^2$  값이 1에 가까울수록 정확도가 높은 것으로 평가된다. Table 4는 다중 선형회귀의 결과이다. 실제 환경에서 관찰되는 예측 결과로 실제 값과 예측값의 절댓값 오차 평균은 약 0.183의 차이를 보이고 실제 환경에서 관찰되는 값의 차이는 0.322로 예측 정확도는 0.794를

Table 2. Components of the dataset

Classification of Load Condition	Volume	Explanation
0	40,447	Down State
1	54,799	Normal Working State
2	1,096	Initial Start State
3	4,458	Overcurrent Condition

Table 3. Result of OLS

Variable	coef.	P >  t
intercept	-1.83041	0.000
temp	0.01815	0.000
hum	4.788e-05	0.860
gas	0.0003	0.000
ec	0.0239	0.000
v	0.0002	0.000
energy	-0.0002	0.085

나타낸다.

### 4.3 SVM 모델

SVM 모델은 회귀분석 모델로써 고차원에서 뛰어난 효율성을 보이는 모델이다. SVM은 Scikit-learn을 사용하여 구현하였으며, 스마트 플러그의 6개의 파라미터를 사용하는 고차원으로 진행하기 때문에, SVM 커널 중에서 고차원에서 효율적은 RBF(Radial Basis Function) 커널을 사용하여 최적 모델 탐색을 진행한다. RBF 커널의 모델 최적화는 감마 값을 조절하여 데이터 샘플이 영향력을 행사하는 거리를 설정하여 결정 경계의 곡률을 조절한다. 그리고 cost 값을 설정하여 데이터의 이상치 존재 가능성을 조절한다. Table 5는 SVM의 하이퍼 파라미터별 정확도이다. C값이 0.01일 경우에는 많은 이상치를 허용하여 과소적합이 발생하였으며, Gamma 값이 커지는 경우 영향력이 줄어들어 과적합이 발생하여 학습데이터만을 최적으로 분류하는 문제가 발생하였다..

SVM 모델의 최적 하이퍼파라미터는 Gamma는 0.01, C는 1로 측정되었으며, 최적 모델의 예측 정확도는 Precision, Recall, Accuracy로 표현하였으며 Precision은 수식 1과 같이 True Positive 값을 True Positive와 False Positive를 더한 값을 나눈 값으로 예측값 중 정답의 비율을 나타내고, Recall은 수식 2와 같이 True Positive 값을 True Positive와 False Negative를 더한 값으로 나눈 값으로 실제값 중 정답의 비율을 나타내고, Accuracy는 수식 3과 같이 True Positive와 True Negative를 더한 값을 전체로 나눈 값으로 전체 데이터에 대한 정확도를 나타낸다.

$$Precision = \frac{TP}{TP+FP} \tag{1}$$

Table 4. Result of Multiple Linear Regression

Part	MAE	RMSE	Variance Score( $R^2$ )
Result	0.183	0.322	0.794

Table 5. Prediction accuracy per SVM hyperparameter

	C=0.01	C=0.1	C=1	C=10
Gamma = 0.01	0.936	0.825	0.981	0.975
Gamma = 0.1	0.825	0.935	0.943	0.943
Gamma = 1	0.614	0.943	0.914	0.919
Gamma = 10	0.594	0.941	0.779	0.795

$$Recall = \frac{TP}{TP+FN} \tag{2}$$

$$Accuracy = \frac{TP+TN}{ALL\ Prediction} \tag{3}$$

Table 6은 SVM 최적 모델의 예측 정확도이다. 정지 상태에 대한 결과는 precision과 recall 모두 1.0으로 높은 수치를 가졌고 정상 작동 상태에 대한 결과로 precision 값은 0.91, recall 값으로는 1.0으로 높은 수치를 가졌다. 초기 기동 상태에 대한 결과값은 precision 값은 0.99, recall 값은 0.59를 가졌고 과전류 상태에 대한 결과값은 precision 값은 0.96, recall 값으로는 0.7 값을 가졌다.

### 5.5 ANN 모델

ANN은 학습에 사용되는 데이터로부터 근사 함수를 만들어 위험 상황 예측 모델을 만들 수 있다. ANN은 Tensorflow를 활용하여 구현하였으며, 크로스 엔트로피 함수를 사용하여 오차를 최소화하고, 활성화 함수로 ReLu 함수를 사용, 학습률을 0.001로 설정하여 학습을 진행하였다. 모델의 최적화를 위해 Table 7과 같이 중간층 구성을 다층 신경망, 심층 신경망으로 구분하고, 각 층의 노드 수에 차이를 두어 진행하였다.

Table 8은 모델들의 학습 횟수에 따른 예측 정확도로 500회, 1000회, 5000회, 10000회의 학습으로 구

Table 6. Prediction accuracy of SVM optimal model

Load Condition	precision	recall	support
0	1.00	1.00	10124
1	0.97	1.00	13666
2	0.99	0.59	273
3	0.96	0.70	1137

Table 7. ANN Model Configuration

layer	model		
	A	B	C
1	6	10	20
2	-	13	26
3	-	14	28
4	-	8	18
5	-	6	15

분하여 정확도를 확인하였다. 모델들은 학습 횟수가 증가할수록 더욱 높은 정확도가 확인되었지만, 학습량과 모델의 복잡도가 증가함에 따라 과적합을 보이기 시작했다. 특히 모델 B와 C는 10,000회 학습에서 최고의 정확도를 보이기도 하였지만, 세 차례에 걸친 학습 모델 재검증과정에서 정확도가 큰 폭으로 감소하는 불안정한 모습을 보였다.

ANN의 최적 모델은 A모델의 10,000회 학습으로 선정하였다. B와 C 모델의 경우 A 모델에 비해 높은 정확도를 보이기도 하였지만, 모델검증 중에 정확도가 큰 폭으로 떨어지는 불안정성이 보여 안정적인 A모델을 최적의 모델로 선정하였다. Table 9는 최적 모델의 예측 정확도로 정지 상태에 대한 결과는 precision과 recall 모두 1.0으로 높은 수치를 가졌고 정상 작동 상태에 대한 결과로 precision 값은 0.97, recall 값으로는 1.0으로 높은 수치를 가졌다. 그리고 초기 기동 상태에 대한 결과값은 precision 값은 0.92, recall 값은 0.82를 가졌다. 과전류 상태에 대한 결과값은 precision 값은 0.91, recall 값으로는 0.69로 비교적 많은 에러를 가졌다.

### 4.4 알고리즘들의 최적 모델 비교

본 연구에서 사용한 Multiple Linear Regression, SVM, ANN 알고리즘들의 최적 형태 모델 중 사용할

Table 8. Prediction accuracy of model according to the number of training

Count	Model		
	A	B	C
500	0.8501	0.9442	0.9515
1,000	0.9052	0.9426	0.9681
5,000	0.9806	0.9729	0.9775
10,000	0.9821	0.9842	0.9775
10,000	0.9804	0.9439	0.9264
10,000	0.9818	0.9833	0.9856

Table 9. Prediction accuracy of ANN optimal model

Load Condition	precision	recall	support
0	1.00	1.00	10124
1	0.97	1.00	13666
2	0.92	0.82	273
3	0.91	0.69	1137

Table 10. Algorithm model performance comparison

Algorithm	Linear Regression	SVM	ANN
Learning time	00:00:01	00:02:32	00:01:34
Forecast time	00:00:00	00:00:10	00:00:00
Accuracy	0.743	0.981	0.981

모델을 선정하기 위해 학습 시간, 예측 시간, 정확도로 나누어 비교를 진행하였다. 학습 시간은 모델이 데이터를 학습하는데 소요된 시간을, 예측 시간은 모델이 예측하는데 소요된 시간으로 사용자가 예측 결과를 확인할 때, 해당 결과를 사용자에게 반영하기까지의 시간을 고려하기 위해 선정하였다. 정확도는 모델이 측정한 예측값과 실제값이 얼마나 일치하는지에 대한 것으로 평가 기준으로 선정하였다. Table 10은 최적 형태 모델들의 학습 시간, 예측 시간, 정확도를 나타낸다. Linear Regression, SVM, ANN 모델이 75,600개의 데이터를 학습하는데 걸린 시간은 각각 1초, 2분 32초, 1분 34초의 시간이 소요되었다. Linear Regression은 파라미터들의 가중치를 계산하여 식을 도출을 진행하기 때문에 가장 짧은 학습 시간이 소요되었으며, SVM은 특성 공간으로 매핑을 통해 Support Vector를 선정하여 판별경계를 선정하기 때문에 가장 오랜 학습 시간이 소요되었다. ANN의 경우 학습 횟수가 증가함에 따라 정확도가 증가하기 때문에 긴 학습 시간이 소요되었다. 각각의 모델이 25,200개의 테스트데이터를 예측하는데 Linear Regression과 ANN 모델은 학습을 통해 결정된 가중치를 이용하여 연산을 통해 결과를 출력하기 때문에 1초 미만의 짧은 시간의 예측 시간이 소요되었다. 하지만 SVM의 경우 판별경계를 통해 테스트데이터를 판별하고 결과를 출력하기 때문에 특성 공간으로 매핑을 진행하기 때문에 비교 알고리즘들 중 가장 긴 예측 시간을 갖는다. 모델들의 예측 정확도는 SVM과 ANN에서 높은 정확도가 출력되었다. Linear Regression은 다른 비교 알고리즘들과의 비교를 위해 예측 결과를 실수형에서 정수형으로, 음수 제거 등의 작업을 통해 정확도를 측정하였고, 그 결과 0.743으로 낮은 정확도 수치를 보였다. Linear Regression, SVM, ANN 알고리즘들의 학습 시간, 예측 시간, 정확도별 비교를 진행하였다. Linear Regression은 학습 시간과 예측 시간이 짧지만 낮은 정확도

를 보여주어 예측 모델로 사용하기에 적합하지 않았다. SVM은 ANN과 함께 높은 정확도를 갖지만, 학습 시간과 예측 시간에서 느린 속도를 보인다. 예측 시간에서 느린 속도를 보여주어 실시간으로 결과를 활용하기에 부적절할 것으로 판단되었다. ANN은 앞선 비교 모델 중 높은 정확도와 안정적인 예측 형태를 보였으며 학습 시간이 비교적 많이 소모되었으나 GPU 등의 개선을 통해 해결할 수 있을 것으로 판단되며, 짧은 예측 시간과 높은 정확도로 예측 모델로 활용하기에 부합한 모델로 판단되었다.

## 5. 결 론

스마트 및 자동화 시스템 보급률의 증가에 따라 사용되는 전력 사용량이 증가하고 있으며, 이에 따라 전력 에너지를 절감하기 위한 대책이 필요하다. 일반 가정에서 스마트 플러그 기술을 사용하여 전원을 차단하고 소비전력 정보를 얻을 수 있다. 하지만 공장과 같은 대규모 시설에서 사용할 수 있는 스마트 플러그 시스템이 부족하다. 그리고 대규모 공장에서 복잡한 시스템에서 전력 문제로 인해 고장이 발생할 경우, 큰 인명피해 및 재산적 피해를 발생시킬 수 있다. 이에 본 연구에서는 3상 스마트 플러그를 제작하고 이를 통해 수집되는 온도, 습도, 가스, 전류, 전압, 전력들을 분석하여 얻은 위험 상황 예측 모델을 관리자가 실시간으로 확인할 수 있는 모바일 앱을 개발하였다. 위험 상황을 예측하기 위해 Linear Regression, SVM, ANN 알고리즘을 활용하여 위험 상황 예측 모델의 설계를 진행하였으며, 3가지 알고리즘들의 학습 시간, 예측 시간, 정확도를 비교분석을 진행하였다. 비교 결과 Linear Regression의 경우 학습 시간과 예측 시간이 가장 짧았지만, 정확도 측면에서 성능이 부족하였고, SVM의 경우 정확도는 높았으나 학습 시간과 예측 시간이 비교적 높게 측정되어 실시간 시스템에 사용하기에 부적절하였다. 하지만 ANN의 경우 예측 시간과 정확도 측면에서 좋은 성능을 보였다. 학습 시간은 비교적 높았으나 이는 GPU 등의 개선을 통해 해결할 수 있어 ANN 모델을 최적의 예측 모델로 선정하였다.

향후 해당 연구결과를 바탕으로 추가적인 데이터 수집을 진행하여 데이터의 불균형 현상을 해결하여 명확한 상관관계를 파악하고 다양한 예측 알고리즘을 연구하여 비교 및 평가하고자 한다.

## REFERENCE

- [ 1 ] W.H. Kim, "Design of Wireless Smart Plug for Energy Sensor Network," *Journal of the Korea Society of Communication and Space Technology*, Vol. 6, No. 2, pp. 131-135, 2011.
- [ 2 ] S.H. Lee, H.C. Won, and S.Y. Kim, "Design and Implementation a Remote Control Smart Multi-plug Based on Wireless Network," *Journal of the Korea Industrial Information Systems Research*, Vol. 20, No. 4, pp. 47-54, 2015.
- [ 3 ] M.G. Lee and S.H. Kim, "Analysis of Smart Grid Technologies and Domestic and Foreign Policy Trends," *Journal of Korea Information Technology Society*, Vol. 11, No. 8, pp. 181-187, 2013.
- [ 4 ] 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, 2012.
- [ 5 ] S.J. Kim, J.C. Kim, J.S. Kim, S.M. Jung, and D.W. Kim, "The Direction of Smart Home-grid Evolution Based on Smart Grid," *Journal of Korea Information Science Society*, Vol. 30, No. 8, pp. 9-18, 2012.
- [ 6 ] K.M. Cheon and J.G. Yang, "An Ensemble Model for Machine Failure Prediction," *Journal of Industrial Management Systems*, Vol. 43, No. 1, pp. 123-131, 2020.
- [ 7 ] J.H. Lee, S.Y. Yoo, S.C. Shin, D.H. Kang, S.S. Lee, and J.C. Lee, "Fault Diagnosis of Bearings Using Machine Learning Algorithm," *Journal of the Korean Marine Engineering Society*, Vol. 43, No. 6, pp. 455-462, 2019.
- [ 8 ] C.W. Lim and S.K. Han, "A Study on the Effect of Weather Factors Leading to the Failure of Power Distribution Facilities and on the Development of Power Grid Fault Prediction System Based on Big Data," *Journal of the Korean Data And Information Science Society*, Vol. 29, No. 6, pp. 1615-1627, 2018.
- [ 9 ] T.S. Ki and S.H. Lee, "A Prediction Scheme for Power Apparatus Using Artificial Neural Networks," *Convergence Information Journal*, Vol. 7, No. 6, pp. 201-207, 2017.
- [ 10 ] S.Y. Cho, "An Error Prediction System for Reliability Improvement of Power Distribution System," *Journal of Security Engineering*, Vol. 8, No. 6, pp. 705-713, 2011.
- [ 11 ] J.Y. Ryu, J.M. Cha, and B.R. Lee, "Evaluation of Weather Information in Forecasting Daily Peak Load of Electricity Demand," *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers*, Vol. 32, No. 12, pp. 73-81, 2018.
- [ 12 ] S.H. Jung, C.S. Shin, Y.Y. Cho, J.W. Park, M.H. Park, C.B. Sim, et al., "A Novel of Data Clustering Architecture for Outlier Detection to Electric Power Data Analysis," *Korea Information Processing Society Transactions on Software and Data Engineering*, Vol. 6, No. 10, pp. 465-472, 2017.
- [ 13 ] S.H. Jung, C.S. Shin, Y.Y. Cho, J.W. Park, M.H. Park, C.B. Sim, et al., "Analysis Process Based on Modify K-means for Efficiency Improvement of Electric Power Data Pattern Detection," *Journal of Korea Multimedia Society*, Vol. 20, No. 12, pp. 1960-1969, 2017.
- [ 14 ] J.G. Kim, "Appliance Classification by Power Data Analysis Based on Multi Feature Input and Multi Layer LSTM," Master's Thesis of Inha University, 2019.
- [ 15 ] B.W. On, Y.T. Cho, W.J. Lee, I.G. Lee, and J.I. Choi, "Analyzing Smart Grid Energy Data Using Hadoop Based Big Data System," *The Transactions of the Korean Institute of Electrical Engineers*, Vol. 64, No. 2, pp. 85-91, 2015.
- [ 16 ] H.S. Cho, J.S. Moon, Y.S. Sun, and H.S. Chang, "Implementation of a Smart Plug for Monitoring Wide Power Consumption Range and Saving Standby Power," *Proceeding of the Fall Conference on Communications in Computer and Information Science 2014 Information and Control Systems*, pp. 93-96,

2014.

- [17] H.S. Chung, H.B. Lee, and T.Y. Chung, "Development and Performance Analysis of an Effective Smart Plug System Based on K10026 Regulation," *Journal of Embedded Systems and Applications*, Vol. 11, No. 5, pp. 287-298, 2016.
- [18] H.S. Kim, J.H. Na, S.H. Park, and S.Y. Kweak, "A Wifi Smart Power Outlet of Remote Monitoring and Control of Power Consumption," *Journal of Korea Multimedia Society*, Vol. 17, No. 2, pp. 160-169, 2014.
- [19] H.S. Kim, B.J. Park, and Y.J. Cho, "Smart Outlet System for Single-person Household Based on IoT(Internet of Things)," *Journal of Digital Contents Society*, Vol. 18, No. 5, pp. 895-904, 2017.
- [20] C.J. Lee and H.S. Chung, "An Implementation of the Smart Plug System with Distance-Based Automatic Power Controller," *The Journal of Korean Institute of Information Technology*, Vol. 15, No. 5, pp. 87-95, 2017.
- [21] C.W. Son and S.B. Lee, "The Research of Automatic Classification of Products Using Smart Plug by Artificial Intelligence Technique," *Journal of the Korea Institute of Information and Communication Engineering*, Vol. 22, No. 6, pp. 842-848, 2018.



**정 세 훈**

2010년 2월 순천대학교 멀티미디어공학과 공학사  
 2012년 2월 순천대학교 멀티미디어공학과 공학석사  
 2017년 2월 순천대학교 멀티미디어공학과 공학박사

2018년 9월~2020년 2월 영산대학교 빅데이터융합전공 조교수

2020년 3월~현재 안동대학교 창의융합학부 조교수  
 관심분야 : 빅데이터 처리 및 확률 분석, 데이터마이닝, 강화학습, 블록체인



**김 준 영**

2019년 2월 순천대학교 멀티미디어공학과 졸업(공학사)  
 2019년 3월~현재 순천대학교 대학원 멀티미디어공학과 석사과정  
 관심분야 : IoT 상황인식, 빅데이터 처리 및 분석, 딥러닝



**박 준**

2019년 2월 순천대학교 멀티미디어공학과 졸업(공학사)  
 2019년 3월~현재 순천대학교 대학원 멀티미디어공학과 석사과정  
 관심분야 : IoT 상황인식, 빅데이터 처리 및 분석, 딥러닝



**장 승 민**

1997년 2월 순천제일대학교 전자계산학과 졸업(전문학사)  
 2011년 4월~현재 나래정보(주) 이사  
 관심분야 : IoT 상황인식, 빅데이터 처리 및 분석, 인공지능



**심 춘 보**

1996년 2월 전북대학교 컴퓨터공학과 공학사  
 1998년 2월 전북대학교 컴퓨터공학과 공학석사  
 2003년 2월 전북대학교 컴퓨터공학과 공학박사

2005년 3월~현재 순천대학교 정보통신·멀티미디어공학부 교수

관심분야 : 빅데이터 시스템, 머신러닝, IoT/IoE 플랫폼, 멀티미디어