

CNN-LSTM 기반 IoT 스마트플러그 설계 방안

오 성 현*, 김 정 곤^o

Design of CNN-LSTM Based IoT Smart Plug

Sung-Hyun Oh*, Jeong-Gon Kim^o

요 약

최근 고품질 전력망 구축을 위해 스마트 그리드에 관한 연구가 각광받고 있다. 스마트 그리드는 전기 및 정보 통신 기술을 기반으로 전력망 운용효율을 극대화시키는 방법이다. 일반적으로, 가정에서 낭비되는 전력의 대부분은 전원플러그의 지속적인 사용으로 발생하는 대기전력 문제이다. 따라서, 본 논문에서는 전자제품 사용시 발생하는 대기전력의 최소화를 위해 스마트 그리드 적용 시스템을 개발하였다. 개발된 시스템은 IoT(Internet of Things) 스마트플러그를 통해 사용중인 전자제품의 전력 데이터를 실시간으로 측정한다. 측정된 데이터는 앱이나 웹을 통해 관리하며, 이상전력이 발생했을 경우 사용자가 직접 On/Off 제어를 수행하는 시스템을 구축하였다. 이를 위해, CNN-LSTM(Convolutional Neural Network Long Short Term Memory) 모델을 구축하였고, 구축된 모델은 실시간 전력 데이터를 기반으로 학습을 수행하였다. CNN-LSTM 모델은 향후 사용될 전력의 예측치를 제공하여 현재의 상태와 비교할 수 있도록 설계하였다. 전력 데이터의 객관적인 확인을 위해 노트북, 모니터와 같은 전력 사용량이 큰 제품을 시스템 설계에 사용하였다. 또한, 제한하는 알고리즘의 성능 최적화를 위해 하이퍼 파라미터 조정을 수행하였다. 실험 결과 최적화된 인공지능 모델은 약 95%의 정확도로 전력 사용량을 예측하였다.

Key Words : Smart-grid, IoT, Monitoring Program, AI, Power Consumption Prediction

ABSTRACT

Recently, research on smart grids has been in the spotlight to build high-quality power grids. Smart grids are a way to maximize the efficiency of power grid operations based on electricity and information and communication technologies. In general, most of the power wasted in the home is a standby power problem caused by the continuous use of the power plug. Therefore, in this paper, a smart grid application system was developed to minimize standby power generated when using electronic products. The developed system measures power data of electronic products in use in real time through the Internet of Things (IoT) smart plug, manages them through apps or the web, and establishes a system that allows users to control on/off in the event of abnormal power. To this end, a CNN-LSTM(Convolutional Neural Network Long Short-Term Memory) model was constructed, and the constructed model was trained based on real-time power data. The CNN-LSTM model is designed to compare with the current state by providing a predicted value of power to be used in the future. In order to objectively verify the power data, products with high power consumption such as laptops and monitors were used in the system design. In addition, hyper-parameter tuning was performed to optimize the performance of the proposed algorithm. As a result of the experiment, the optimized artificial intelligence model predicted power consumption with about 95% accuracy.

* First Author : Tech University of Korea Department of Electronics Engineering, osh119@tukorea.ac.kr, 학생회원

^o Corresponding Author : Tech University of Korea Department of Electronics Engineering, jgkim@kpu.ac.kr, 종신회원
논문번호 : 202211-273-D-RN, Received November 7, 2022; Revised January 29, 2023; Accepted February 6, 2023

1. 서 론

스마트 그리드란 전기 및 정보통신 기술을 활용하여 전력망을 지능화 고도화함으로 고품질 전력망을 구현하는 것을 의미한다. 기술의 발전에 따라 최근에 다양한 스마트 디바이스가 많은 산업에 사용되고 있다. 이로 인해, 최근에는 스마트 디바이스를 일상에서도 쉽게 볼 수 있다¹⁾. 이러한 스마트 디바이스를 사용하기 위해서는 많은 양의 에너지 자원이 필요하다. 하지만, 우리나라는 에너지 자원을 얻기 어려운 국가이므로, 수입을 통해 대부분의 에너지 자원을 충당하고 있다. 따라서, 에너지 사용을 관리하고 효율적인 사용을 위해 스마트그리드에 대한 관심 및 연구의 필요성이 커지고 있다²⁾.

일반적으로 전원플러그의 계속된 사용으로 발생하는 대기전력은 국내 가정 소비 전력의 약 11%를 점유하고 있다. 따라서 대기전력 저감은 에너지 효율을 높이기 위해 필수적으로 고려해야 할 사항이다. 대기전력을 최소로 하기 위한 일반적인 방법은 제품을 사용하지 않을 때 코드를 분리하는 방법이다³⁾. 하지만, 실제 환경에서 하나의 플러그에 다양한 제품을 연결하므로, 코드의 분리 및 재결합 측면에서 불편한 점이 많다. 이러한 불편을 해결하기 위해 제품에 MCU(Micro Controller Unit)를 탑재하여 제품 자체가 전력을 조절하는 방법이 대안으로 제안된다⁴⁾. 그러나 이러한 방법은 기존 플러그에 추가적인 설계가 필요하므로 생산 초기 비용을 증가시킨다.

따라서 최근에는 기존 플러그에 IoT(Internet of Things) 기술을 접목하는 방식을 채택하여, 새로운 제품을 개발할 필요 없이 전력 관리서비스를 제공할 수 있는 방법들이 연구되고 있다. 먼저, [5]에서는 국내 전력산업에서 수요관리의 다양한 전략을 제안한다. 수요관리 방안은 부하관리, 수요반응, 효율향상 3가지로 구분할 수 있다. 이 중 부하관리 측면에서는 건물 냉난방 원격관리, 최대전력관리, 축열식 냉난방설비 등과 같은 방안들이 제시된다. [6]에서는 미래의 폭발적인 전력수요를 충족시키기 위해 양방향 에너지 프로슈머 전력 거래시장에 관해 논한다. 이러한 전력 거래 시장에서 에너지 효율증가와 프로슈머의 계통 연계 안정성 확보 측면에서 전력사용량 패턴 예측 기술이 필수적인 요소로 고려된다. 여기서 전력 사용량 패턴 예측기를 위한 기술로 확률모델, 머신러닝, 딥러닝 및 하이브리드 모델들에 대하여 특징을 설명하고 분석하여 제시하였다.

위와 같은 연구를 기반으로 현재 개발되고 있는 스

마트플러그의 경우 일반적인 플러그와 유사한 형태로 만들어진다. 기능적인 부분의 경우, 현재 국내에서 IoT를 통한 스마트 가전 형성에 대한 완성도가 높지 않다. 따라서, IoT 기기 회사들의 독자적인 규격으로 설계되어 호환성이 떨어지고 전송 효율이 낮음과 동시에 단일적인 동작을 수행한다^{8,9)}. 이러한 제품들의 대표적인 단일 동작은 현재 플러그에 연결된 제품들이 소비하고 있는 전력 정보를 제공하는 것이다. 그리고, 제품이 사용되지 않는 경우와 사용 중에 이상 전력이 발생하는 경우 자동으로 전원을 차단하는 기능이다¹⁰⁾. 여기서, 이상전력은 순간적으로 전압이 상승하는 상황을 의미한다. 이후, 온도 및 습도 센서와 같은 다양한 센서와 결합하여 플러그의 효율성을 높여려는 연구도 이루어지고 있다¹¹⁾.

위와 같이 플러그와 센서의 결합에 대한 연구가 진행됨에 따라 스마트플러그가 사용될 상황의 범위가 넓어졌다. 또한, 사용자의 통제 범위 밖의 제품에 대해 제어의 필요를 확인하게 되었다. 정수기처럼 인간이 사용하지 않아도 전력 에너지를 지속해서 소모하는 제품의 문제를 해결하기 위한 연구가 진행되었으¹²⁾, 이러한 연구를 통해 얻은 전력 데이터를 분석하여 위험 상황을 예측하고 방지하기 위한 연구 역시 진행되었다¹³⁾. 이처럼 스마트플러그의 역할 및 기능이 발전함에 따라 위에서 언급한 기능들의 활용을 위해 해당 제품에 종속적인 전용 앱을 필요로 한다. 현재, 소비자들의 전자제품 의존도가 크게 증가하면서, 사용되는 전력량 역시 증가했다. 단순히 전력 사용량을 확인하고 자동으로 전원을 차단하는 기능에 국한되지 않고 사용자의 의지가 제품에 반영될 수 있도록 하려는 시도가 생겨나기 시작했다¹⁴⁾.

또한, 효율적인 시스템 관리를 위해 인공지능 모델의 도입이 연구되고 있다. 최근에는 RNN(Recurrent Neural Network), LSTM(Long Short - Term Memory) 등의 순환신경망의 성능을 개선한 모델들이 적용되고 있다. [15]에서 저자들은 도시부 간선도로에서 교통상황별 속도 예측시스템을 제안하였다. 여기서, 기존 CNN(Convolutional Neural Network) 모델과 LSTM 모델 및 CNN-LSTM(Convolutional Neural Network-Long Short - Term Memory) 모델의 성능을 비교하였다. 비교결과 CNN-LSTM 모델의 예측성능이 CNN 및 LSTM 보다 정확하였으며, 평균 절대 오차율 측면에서도 가장 낮은 오차를 달성하였다. [16]의 저자들은 CNN-LSTM 기반 전력 예측 모델을 제안하였다. 제안모델의 성능 분석을 위해 FCNN(Fully Connected Neural Network), CNN, LSTM과 비교를

수행하였다. 성능은 RMSE(Root Mean Square Error)를 통해 비교되었으며 CNN-LSTM 모델이 가장 높은 예측 정확도를 달성함을 제시하였다.

본 논문에서는 기존 기술을 개선한 센서 네트워크 기반의 IoT 기술을 활용한 스마트플러그를 개발하였다. 제안하는 시스템의 핵심 기술은 추가적인 제어 환경을 개발하여 전력사용량을 확인하는 것뿐만 아니라 사용자가 현재 전력사용량 추이를 확인하고 예측값과 비교하여 원하는 시점에 전원 제어를 할 수 있도록 구현하였다. 여기서, 전력사용량 예측 모델은 기존 연구를 기반으로 시계열 데이터 예측 모델 중 예측성능이 뛰어난 CNN-LSTM 모델을 사용했다¹⁵⁻¹⁷⁾. 이를 통해, CNN-LSTM 모델이 순간적인 이상전압 발생을 예측하고 사용자가 확인할 수 있도록 설계했다. 또한, 해당 전력 제어 환경을 웹 서버와 연결하여 인터넷 사용이 가능한 환경에서 자유롭게 사용하도록 개발했다.

본 논문에서 개발한 시스템의 핵심 차별성은 다음과 같다. 먼저, 기존 스마트플러그와 다르게 AI(Artificial Intelligence)를 기반으로 미래의 전력사용량을 예측하여 제공한다는 것이다. 이때, CNN-LSTM 모델을 적용하여 높은 예측 정확도를 제공할 수 있다. 다음은 MCU의 판단에 따라 전원을 단순하게 on/off 하는 것이 아니라, 사용자가 직접 on/off 제어를 수행할 수 있도록 설계된 것이다. 이를 통해 기존 시스템과는 다르게 사용자가 실시간 제어를 수행할 수 있도록 구현되었다.

본 논문의 구성은 다음과 같다. 2절에서는 IoT 스마트플러그 개발개요에 대해 설명한다. 먼저, 센서 네트워크를 위해 사용한 I2C(Inter-Integrated Circuit) 통신 및 모니터링 프로그램으로 사용한 Flask를 이용한 웹 서버에 대해 살펴본다. 다음으로 미래에 소비될 전력량을 예측하기 위해 사용된 CNN-LSTM 알고리즘에 대해 살펴본다. 3절에서는 본 논문에서 구현한 CNN-LSTM 기반 스마트플러그 시스템의 구성 및 동작 절차를 설명한다. 4절에서는 CNN-LSTM 모델 설계를 위해 설정된 파라미터들에 대해 소개한다. 이후, CNN-LSTM 모델의 학습을 위한 실험 시나리오 및 실제 전력 사용량 예측 결과를 제시한다. 끝으로 5절에서는 본 논문의 결론 및 추후 연구 방향을 제시한다.

II. IoT 스마트플러그 개발 개요

2.1 개발 시스템 구성개요

본 절에서는 개발 시스템의 구성개요에 대해 자세히 설명한다. 먼저, 그림 1은 본 논문에서 제안하는 스




그림 1. CNN-LSTM 기반 IoT 스마트플러그 구성도
Fig. 1. Configuration diagram of IoT smart plug based on CNN-LSTM

마트플러그의 구성도를 나타낸 것이다.

그림 1에서 볼 수 있듯이, 개발된 스마트플러그의 경우 크게 신호 처리부, 연산부, 제어부의 3가지 부분으로 구분된다. 먼저, 신호 처리부는 연속된 아날로그 입력을 받아들여 원하는 정보만을 얻어내는 작업이 이루어진다. 이후, 연산부에서는 받아들인 신호를 물리량으로 변환해준다. 변환된 값은 추후 연산 및 예측을 위한 인공지능 입력 데이터로 사용된다. 해당 결과는 메인보드 상의 임시 DB(Mongo DB)에 저장되며 Flask를 이용해 구성된 모니터링 웹 서버에 전달된다. 전달된 결과는 최종적으로 사용자에게 웹 및 앱 환경으로 제공된다. 끝으로, 사용자가 직접 스마트플러그를 제어할 수 있도록 하는 제어부는 가장 마지막에 위치한다.

2.2 Flask Web Server

Flask Web Server는 파이썬(Python)의 마이크로 웹 프레임워크이다. Werkzeug 툴킷과 Jinja2 템플릿 엔진에 기반을 두고 운영되며 서버의 확장성 및 가벼움 덕분에 파이썬을 통해 구성되는 시스템에 주로 사용된다. Flask는 특별한 도구나 라이브러리가 필요하지 않기에 마이크로 프레임워크라고 불린다. 또한, 데이터베이스 추상화 계층, 양식 유효성 확인, 기타 기존의 서드파티 라이브러리가 기능을 제공하는 구성요소를 가지지 않는다. Flask Web Server에서, 마이크로 웹상의 서비스 구현을 위한 핵심 기능을 포함하며 확장성을 유지하는 것을 목표로 함을 의미한다¹⁸⁾. 위에서 언급한 확장성은 Flask의 특성에서 비롯된다. Flask에는 폼(Form), 데이터베이스(Database)를 처리하는 기능이 존재하지 않는다. 따라서, 확장 모듈을 통해 해당 기능을 보완하며, 개발자는 해당 기능이 필요한 경우 직접 추가할 수 있도록 한다. 하지만 Flask는 공개된 HTTP(Hyper Text Transfer Protocol) 환경을 사용하기에 연동 작업을 진행할 경우 보안에 취약하다는 단점을 가진다. 따라서, 최근에는 Flask의 장점을 활용하기 위해 보안 문제를 분석하여 해결하고

자 하는 연구가 진행되고 있다¹⁹⁾.

2.3 I2C 통신

I2C(Inter-Integrated Circuit) 통신은 필립스에서 개발한 통신 방식으로 초기에는 DAC(Digital to Analog Converter)등의 칩셋과 제어칩셋 간 소리 데이터를 전송하기 위한 통신규격으로 사용되었다. 현재는 IC(Integrated Circuit)간 통신으로 많이 쓰이며 여러 장비를 함께 연결할 수 있다는 장점 덕분에 센서 네트워크에서 주로 사용된다. I2C 통신은 SDA(Serial Data)와 SCL(Serial Clock) 두 가닥의 선만으로 데이터 송수신이 가능하다는 점에서 효율적이다. 또한, 동기식 통신이므로 비동기식 UART(Universal Asynchronous Receiver/Transmitter) 등에 비해 안정적인 통신 특징을 가진다. 여기서, SCL은 마스터와 슬레이브 간의 클럭을 맞춰 데이터를 송수신할 수 있게 해준다.

그림 2는 I2C 통신의 프레임 포맷을 보인다. 그림 2에서 볼 수 있듯이, 시작 신호 뒤에 나오는 7bit는 슬레이브의 주소값이다. 프레임 포맷에서 8번째 bit는 통신의 Read/Write를 결정해준다. 기본값은 HIGH일 때 SDA가 HIGH에서 LOW로 가면 시작, LOW에서 HIGH로 가면 끝을 의미한다. SDA는 통신하고자 하는 데이터를 의미하며, 위의 설명처럼 SCL이 LOW일 때 데이터를 주고받을 수 있다. 각각의 전송에는 ACK가 포함되어 데이터를 읽는 방식에 따라 규격을 달리 한다. 또한, BUS 형태로 한 개의 I2C 마스터에 다수의 I2C 슬레이브 장치 연결이 가능하다. I2C는 기본적으로 반이중 통신 방식을 사용하므로 통신 시 송신 또는 수신 중 한 가지 작업만을 수행한다. 통신 속도는 100kHz, 400kHz, 3.4MHz를 사용하며 표준속도는 100kHz로 정해져 있고, Fast Mode나 High Speed Mode를 정의할 때 나머지가 사용된다. 기존의 네트워크 기반의 센서들은 UART 통신을 주로 사용한다. 이로 인해, 클럭 드리프트 및 오프셋에 의하여 데이터 손실 우려가 있다.

따라서, 본 논문의 제안기술은 1:N의 통신에 적합한 I2C 통신을 이용하여 시스템을 설계하였다. 이론



그림 2. I2C 통신 프레임 포맷
Fig. 2. I2C communication frame format

상으로 UART 통신은 Baud Rate에 따라 에러가 발생한다. 이에 반해, I2C의 경우 SCL 클럭의 동기화를 수행하므로 에러를 최소화하는 것이 가능하다.

2.4 CNN-LSTM(Convolutional Neural Networks-Long Short Term Memory)

본 논문에서 구현하는 시스템의 경우 시계열 데이터를 사용하기에 시퀀스를 이용한 모델이 사용된다. 시퀀스를 이용한 대표적인 모델은 RNN이 사용된다. 기존 신경망들에서 데이터는 은닉층에서 활성화 함수를 지난 후 모두 출력층 방향으로 향한다. 하지만, RNN의 경우 활성화 함수를 통해 출력된 결과를 출력층 방향과 은닉층의 다음입력 2개의 방향으로 보낸다. 이처럼 RNN 모델은 이전의 값을 기억하려고 하는 메모리 역할을 수행할 수 있다. 따라서, 실시간으로 변하는 시계열 데이터 처리에 유리하다. 하지만 본 논문에서 구현하는 시스템은 긴시간동안 데이터가 축적되어 시간이 지날수록 초반의 정보량이 손실되는 문제가 있다. 이러한 문제가 지속되면 초기 정보가 전체 정보에 영향을 미치지 못하는데 이를 장기 의존성 문제라고 한다. 본 논문에서는 은닉층에 입력 게이트, 망각 게이트, 출력 게이트를 추가하여 장기 의존성 문제를 해결 가능한 LSTM 모델을 사용한다.

그림 3은 LSTM 모델의 구성을 보인다. LSTM 모델은 기존 RNN 모델과 다르게 셀 상태라는 값이 추가되었다. 이를 기반으로 LSTM 모델은 RNN에 비해 긴 시퀀스의 입력을 처리하는데 탁월한 성능을 달성한다.

위와 같은 이유로 제안하는 시스템은 LSTM 모델을 기반으로 구현하였다. 해당 시스템에서 얻고자 하




그림 3. 인공지능 LSTM 모델 구성도
Fig. 3. AI-LSTM model block diagram

는 결과는 시간의 정보가 제외된 예측된 전력량만을 필요로 한다. 따라서, 원천 데이터로부터 주어진 문제 해결에 유용한 속성을 추출할 때 사용하는 알고리즘인 CNN 층을 추가하였다. CNN이란 Neural Network의 한 종류로서 기계학습과 인지과학에서 생물학의 신경망을 기반으로 한 통계학적 학습 알고리즘이다. 가중치 조정기반 결합의 변화를 통해 문제를 해결하는 모델 전반을 의미하기도 한다. 또한, 입력된 데이터의 특징을 추출할 수 있는 장점이 있기에 주로 이미지 처리와 같은 분야에서 사용된다. 추가적으로, CNN 층은 다른 모델에 적용되어 데이터의 범위를 제한하는 역할을 수행할 수 있다. CNN 층은 합성곱 연산을 기반으로 시간 정보 파악을 담당하는 LSTM 모델에 들어가기 위한 데이터의 전처리를 맡게 된다. 전력 사용량을 시간과 함께 CNN 층의 입력값으로 사용하고, 출력된 데이터를 LSTM 모델의 입력으로 사용하여 학습이 진행되도록 하였다.

그림 4는 본 논문에서 고려한 CNN-LSTM의 구조를 나타낸다. 해당 모델은 인코더 역할을 하는 CNN 층과 디코더 역할을 하는 LSTM 모델이 하나의 쌍으로 구성된다. 모든 입력을 1차원의 벡터로 인코딩하며 CNN 모델에서 출력된 결과는 디코더의 역할을 하는 LSTM으로 입력된다. 이를 통해, 1차원 시퀀스가 출력되고, 결과를 도출하여 정확도를 개선할 수 있다.

마지막 결과의 경우 Fully Connected layer에서 오차가 가장 작은 값을 선택하도록 설계했다. 제안된 CNN-LSTM 모델에서 전력량 예측을 위해 필요한 입력 데이터의 구성은 그림 5와 같다. 그림 5에서 시계열 데이터의 경우 기존 DNN(Deep Neural Network)의 데이터와 다르게 Time step이라는 하이퍼 파라미터가 추가된다. 이는 LSTM 모델이 Time step이라는

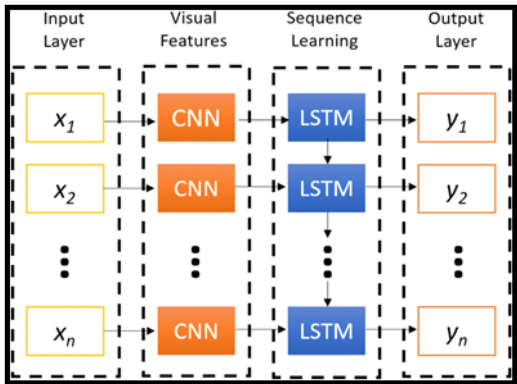


그림 4. 인공지능 CNN-LSTM 모델 구성도
Fig. 4. AI CNN-LSTM model block diagram




그림 5. 시계열 데이터 처리를 위한 입력 데이터 형태
Fig. 5. Configuration of input data for processing time series data

하이퍼 파라미터를 기반으로 현재 시점에서 과거의 데이터를 어느 시점까지 참조할지 설정하도록 한다. 다음 절에서는 본 절에서 기재된 기술을 적용하여 개발된 IoT 스마트플러그의 구성방안에 대해 자세히 기술한다.

III. IoT 스마트플러그 구성방안

본 논문에서 구현하는 IoT 스마트플러그는 전류 센서와 전압 센서를 통해 수집한 전력 데이터와 딥러닝 모델을 사용하였다. 제안하는 기술은 기존 스마트플러그와는 다르게 전용 앱의 의존도를 줄이고 웹 서버를 통해 실시간으로 사용되는 전력량과 전력 소모 예측 값을 제공한다. 사용자는 인터넷을 통해 스마트플러그에서 측정된 전력 사용량과 예측값을 확인하고 필요한 경우 스마트플러그의 제어도 가능하다.

본 논문에서 구현하는 시스템의 경우 편리성과 접근성을 위해 메인보드인 라즈베리파이에 DB(Data Base)를 설치하여 웹 서버를 작동한다. 따라서, 인터넷 사용이 가능한 환경이라면 원하는 장소 및 시점에 스마트플러그 조작이 가능하다. 해당 시스템을 통해 측정할 전력의 경우 220V의 교류 전기를 기준으로 진행되기에 전압과 전류로 나누어서 측정하는 과정을 포함한다.

3.1 개발 하드웨어 구조

그림 6은 개발된 스마트플러그의 하드웨어 외관을 나타낸 것이며 해당 시스템의 입력은 기존의 멀티탭과 같은 형태로 구성했다. 6-①은 시스템에서 측정될 제품들의 코드가 직접적으로 연결되는 부분을 나타낸




그림 6. 개발 스마트플러그 하드웨어 외관
Fig. 6. Development smart plug hardware and outside

것이고, 6-②는 플러그가 환전의 메인 플러그와 연결될 부분을 나타낸다.

본 시스템에서 데이터를 저장 및 전달을 수행할 메인 보드는 앞서 언급했듯이 접근성과 호환성을 고려해 라즈베리파이 4B로 결정하였다. 전류값을 측정하기 위해 Allegro MicroSystems사의 ACS712 모듈을 사용했고, 전압값 측정을 위해 Qingxian Zeming Langxi Electronic사의 ZMPT101B 모듈을 사용했다. 이후, 측정된 전류 및 전압 값을 기반으로 소비 전력량을 얻기 위해 Texas Instruments사의 ADS1115 모듈에 두 모듈을 연결하였다. 이후, 해당 센서값들은 I2C 통신을 통하여 실시간으로 라즈베리파이 내부에 데이터 세트를 구축한다.

그림 7은 개발된 스마트플러그 하드웨어의 내부를 나타낸 것이다. 7-①의 전류 센서와 7-②의 전압 센서로 전류 및 전압 데이터수집 부분이 먼저 구성된다. 7-③을 지나며 수집된 아날로그 데이터를 디지털 데이터로 변환해준다. 7-④의 메인보드를 통해 연산의 동작과 서버가 동작하게 되며, 마지막으로 모바일 앱 및




그림 7. 개발 스마트 플러그 하드웨어 내부
Fig. 7. Development smart plug hardware and inside

웹 서버 이용을 통해 7-⑤의 릴레이 제어로 시스템 실행 부분이 구성된다.

3.2 개발 소프트웨어 구조

본 논문에서 구현하는 시스템의 경우 데이터의 calibration 및 전처리 작업 등 시스템의 동작 대부분을 소프트웨어를 통해 이루어지도록 설계하였다. 먼저, 센서 수집부에서 감지한 흐름을 수치로 나타내주는 작업이 수행된다. 전류 센서의 경우 1A에 66mV의 민감도를 가지는 제품을 사용했다. 해당 부품의 경우 영점 전압이 2.5V이므로, offset을 2.5V로 설정하였다. 따라서, offset을 기준으로 값이 변화하는 상황을 감지하도록 했다. 전압 센서의 경우, 220V인 교류 전기를 받아들이므로 측정되는 전압 신호를 50배 감소하여 표시해주는 제품을 사용했다. 전류 및 전압 센서 모두 아날로그 신호를 결과로 출력하므로 ADC(Analog to Digital Converter)를 사용했다. ADC의 경우 표본화를 필요로 하며, 신호의 올바른 복원을 위해 나이퀴스트율을 만족해야하므로 최소 2배 크기의 주파수를 필요로 한다.

위의 3가지 연산을 모두 진행하게 되면 처리 부분에서 전력량에 대한 데이터 군집이 만들어진다. 해당 데이터와 인공지능 모델의 결과는 모두 라즈베리파이에서 MongoDB를 통해 구성된 임시 서버에 저장된 후 정렬 작업이 수행된다. 연산 이후 생성된 데이터 군집은 인공지능 모델의 입력으로 사용되기 위해 시간 정보와 함께 저장되며 3차원의 형태로 전처리가 수행된다. 앞서 언급했듯이 인공지능 모델의 경우 CNN-LSTM 모델을 사용했다. 해당 모델을 사용하기 위해서는 학습이 수행되어야 하며, 이를 위해 학습 데이터를 필요로 한다. 그림 8은 인공지능 모델을 학습시키기 위해 수집한 데이터를 나타낸 것이다. 학습 데이터의 경우 흐름을 파악할 수 있도록 전력 소모가 큰 노트북, 라즈베리파이 여러 개, 보조배터리, 모니터를 연결해 5만 개 정도의 데이터를 직접 수집했다. 이때, 각 기기의 전력 소모량은 다음과 같다. 노트북은 230W, 라즈베리파이는 5.1W이며 총 3개를 사용하였고, 보조배터리는 4W, 모니터는 60W이다. 이처럼 인공지능 모델과 관련된 데이터는 모두 정규화 및 구조화를 통해 Windowed dataset으로 변환되어 사용된다. 이후 변환된 데이터는 사용자가 접근하여 확인가능한 모니터링 웹 서버로 전달된다.

그림 9는 실제 사용자가 보고 있는 스마트플러그의 모니터링 웹 서버를 보여준다. 웹 서버는 본 논문에서 구현한 스마트플러그의 메인보드인 라즈베리파이와의

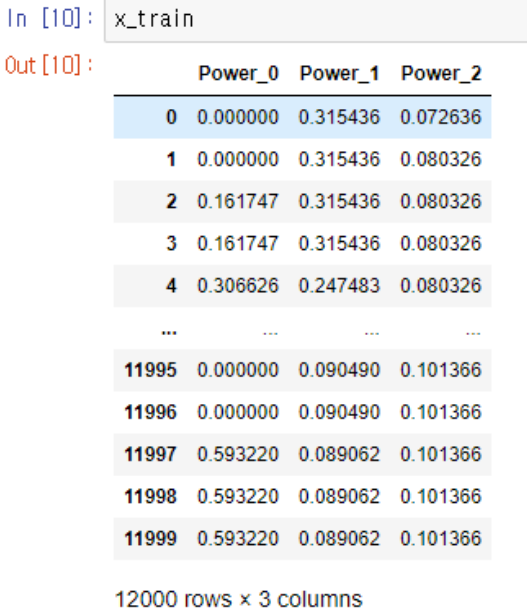


그림 8. 인공지능 모델 학습을 위한 전처리 된 데이터
Fig. 8. Preprocessed data for AI model learning

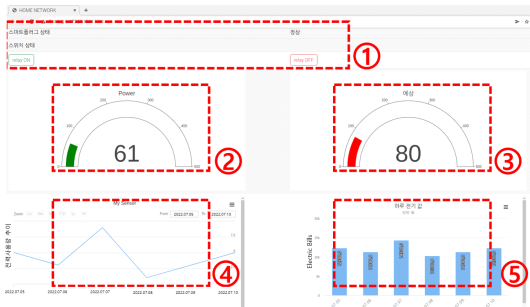


그림 9. 실시간 스마트 플러그 모니터링 화면(앱 & 웹)
Fig. 9. Real-time smart plug monitoring page(App & Web)

연동을 위해 Flask를 사용하여 설계하였다. 설계된 웹 서버는 그래프, 이미지 및 차트를 이용하여 사용자가 전력 사용량 및 부가 정보들을 쉽게 확인할 수 있도록 설계했다. 웹 서버에서 사용자가 확인 가능한 모든 부분은 각각의 객체로 구성하였다. 따라서, 본체인 라즈베리파이가 작동하여 시스템을 활성화한 경우 호출을 통해 각 객체에 해당하는 정보가 가시화되도록 설계했다. 또한, 해당 서버는 앱과 연동되어 사용자의 선택에 따라 자율적인 접속이 가능하다.

그림 9를 다음과 같이 구체적으로 구분하여 설명한다. 9-①은 본 논문에서 구현한 시스템의 대표적인 기능이며 플러그의 전원 제어 기능을 나타낸 것이다. 편

의성을 고려하여 버튼의 형태로 했다. 9-②는 스마트 플러그에 현재 연결되어 사용되는 제품들의 전력 소모 상황을 보인다. 9-③은 현재 제품들을 계속해서 사용할 경우의 예측 전력 소모량을 나타낸다. 여기서 사용자가 ②와 ③의 비교를 통해 스마트플러그를 직접 제어할 수 있도록 했다. 추가적인 기능으로는 9-④를 통해 전력 사용량 추이를 제공하였으며, 해당 그림에서 가로축은 날짜, 세로축은 전력사용량 추이를 의미한다. 9-⑤를 통해 사용된 전력에 대한 가격을 계산해서 표시했다. 여기서, 세로축은 전기요금이고 가로축은 날짜를 의미한다. 이때, 하루 전기요금은 기본료 9,800원에 kWh당 500원을 가정하여 계산하였다. 추후, 한국전력의 전기요금에 맞춰 변경할 계획이다.

본 논문에서 구현한 스마트플러그의 중요 기능 중 하나는 전력 측정치와 예측치 비교를 통한 전원제어 기능이다. 따라서 사용자가 해당 기능을 사용할 수 있도록 릴레이를 GPIO(General Purpose Input Output)에 연결하여 구성했고, 전원 제어에 대한 동작 명령은 웹과 앱을 통해 수행되도록 설계했다.

IV. 실험 및 결과

4.1 실험 파라미터 설정

본 실험에서 사용한 파라미터는 다음과 같다. 데이터의 총 개수는 5만 개이며 3차원 데이터를 입력으로 사용했다. 실험에서 사용된 주요 파라미터는 표 1에 나타났다. 여기서, Batch size의 경우 데이터의 크기를 의미하며 32로 설정했다. 다음으로 Time step의 경우 데이터의 한 묶음에서 확인할 개수를 의미하며 20으로 설정했다. 이는 [20]의 문헌을 참고하여 Time step을 10, 15, 20, 30으로 변경하며 확인해본 결과, 본 시스템에서는 20일 때 예측성능이 가장 높았다. 본 논문에서는 1초마다 데이터를 수집하였다. 따라서, 총 20초 동안 취득한 데이터를 통해, 향후 전력사용량을 예측하고자 하였다. 마지막으로 Input dimension의 경우

표 1. 실험 파라미터
Table 1. Experiment parameter

Parameter	Value
Batch size	32
Time step	20
Input dimension	1
Loss function	MSE
Optimizer	Adam
Number of data	50,000

데이터의 분류를 나타내며 본 논문의 구현 시스템에서는 전력만을 사용하기에 1로 설정했다.

그림 10은 본 논문에서 사용된 모델에 대한 요약을 나타낸다. 앞서 언급했듯이 시계열 데이터를 처리하기 위해선택한 모델로 다양한 feature를 가지고 있는 데이터를 사용하기 위해서는 CNN 층을 통한 추출이 필요하다. 따라서 첫 번째 레이어인 conv1d의 경우 입력 층의 변수를 그대로 입력하여 convolution 연산을 통해 편향이 생기도록 했다. 해당 편향을 통해 데이터의 feature 추출 및 최적화가 가능하다. 여기서, 모델의 은닉층은 LSTM 층을 사용했다. 해당 층 안에 이미 추가적인 은닉층을 보유하고 있으므로, 메인보드의 부담을 최소화하기 위해 1개의 LSTM 층만 사용했다. 이후, dense 층을 통해 초기 conv1d 층에서 변경된 시퀀스를 다시 원래의 형태로 변환하는 작업을 진행하였다. 이후, 마지막 dense_1층을 통해 단일 출력을 가지도록 설계했다. 인공지능 모델의 활성화함수는 tanh 및 Relu를 사용하였다.

Model: "sequential"

Layer (type)	Output Shape	Param #
conv1d (Conv1D)	(None, 20, 32)	192
lstm (LSTM)	(None, 16)	3136
dense (Dense)	(None, 16)	272
dense_1 (Dense)	(None, 1)	17

Total params: 3,617
 Trainable params: 3,617
 Non-trainable params: 0

그림 10. CNN-LSTM 모델 요약
 Fig. 10. CNN-LSTM model summary

4.2 CNN-LSTM 기반 전력량 예측 결과

그림 11은 학습에 따른 모델의 성능을 보여준다. 그림에서 파란 그래프는 실제 데이터의 추이, 주황 그래프는 모델을 통한 예측 추이를 보인다. 여기서, y축은 전력사용량을 min-max 정규화한 값이며, 최대 사용가능량 대비 현재 사용량을 의미한다. 그림에서 볼 수 있듯이 총 3,000개의 time step에 대해 예측 추이가 실제 추이를 추종함을 확인할 수 있다. 이는 학습된 모델을 통해 약 3,000초 후의 전력 사용량까지 예측한 결과이며 높은 정확도를 달성함을 확인할 수 있다. 본 논문에서는 순간적인 이상전압을 측정하는 것이 목표이므로 현재 시점부터 3,000초 후까지의 짧은 결과만 예측하였다. 그러나, 개발된 모델을 기반으로 입력 데이터 발생 주기 및 time step 등의 하이퍼 파라




그림 11. CNN-LSTM 모델 학습 성능
 Fig. 11. CNN-LSTM model learning performance

미터 조정을 수행하면 월간, 연간 사용량 예측까지도 가능하다. CNN-LSTM 모델의 손실함수인 MSE(Mean Square Error)를 통해 검증한 오차는 0.009의 값을 달성하였으며, 이는 예측된 값이 실제 값과 매우 유사함을 보인다. 결과적으로 모델의 테스트 정확도 성능은 95%의 정확도를 달성하였다.

V. 결론 및 추후 연구 방향

본 논문에서 제안하는 시스템은 현재 사용 중인 전력에 대해 사용량을 실시간으로 확인함으로 제품의 역할을 확인했다. 웹 서버를 통해 관리 환경을 구축했고 모니터링을 진행했다. 이를 통해 손쉬운 사용자의 접근 그리고 이후의 업데이트도 원활함을 확인했다. 기존의 제품 대비 제어하는 과정에서 이상 발생 시 자동 전력 제어가 아닌 사용자의 의견을 반영하게 되어 문제가 발생하더라도 사용자의 개입이 이루어질 수 있게 했다. 이를 통해 시스템의 특성 역시 확인하였다. 추후, 예측 모델의 최적화를 통해 예측 정확도를 개선할 계획이다. 또한, 전력 사용량에 따른 전원 제어의 한계를 넘어, 전기료 예측 결과에 기반한 지능형 부하 제어 시스템을 고려하고자 한다. 이를 통해, 제안하는 스마트플러그의 효율적인 부하 관리 및 전기료 절약 성능을 달성하고자 한다. 추가적으로, 멀티링크를 적용하여 실시간 여러 장소에서 사용되는 전력에 대해 상태를 확인하며 데이터를 실시간으로 받아들이고 동시에 학습된 모델을 이용한 예측이 아닌 실시간 비교 모델을 사용하는 방안을 연구하고자 한다.

References

- [1] C. H. Lee, "Trends in smart grid technology and future prospects," *Inf. Commun. Mag.*, vol. 38, no. 9, pp. 71-77, Aug. 2021.
- [2] D. W. Kim, S. W. An, J. W. Kim, and H. J. Lee, "IoT smart home care system utilizing deep learning," in *Proc. KIIT Conf.*, pp. 458-460, Jun. 2022.
- [3] Y. H. Jang and S. S. Lee, "Design and implementation of user pattern based standby power reduction system applying Zigbee-MQTT in a smart building environment," *J. KIICE*, vol. 24 no. 9, pp. 1158-1164, Sep. 2020. (<https://doi.org/10.6109/jkiice.2020.24.9.1158>)
- [4] Y. H. Jang and S. S. Lee, "Design and implementation of Zigbee-CoAP-based standby power saving system," *J. KIICE*, vol. 24, no. 5, pp. 616-622, May 2020. (<https://doi.org/10.6109/jkiice.2020.24.5.616>)
- [5] D. Hur, "Trends and implications in demand-side management of Korea," *The KIEE*, vol. 70, no. 4, pp. 30-35, Apr. 2021.
- [6] J. S. Kim and K. I. Kim, "A study on the pattern prediction of electrical usage for power demand control," in *Proc. KICS Conf.*, pp. 664-665, Nov. 2019.
- [7] J. Runge and Z. Radu, "A review of deep learning techniques for forecasting energy use in buildings," *Energies*, vol. 14, no. 3, Jan. 2021. (<https://doi.org/10.3390/en14030608>)
- [8] H. B. Nam, J. H. Jung, D. K. Choi, and S. J. Koh, "Design of container based smart farm service in IoT," in *Proc. Symp. KICS*, pp. 933-934, Jeju Island, Korea, Nov. 2021.
- [9] Y. H. Jang, S. C. Park, and S. H. Yoon, "Design and implementation of MQTT-based standby power reduction system in Z-Wave network environment," *J. Korea Multimedia Soc.*, vol. 23, no. 3, pp. 421-429, Mar. 2020. (<https://doi.org/10.9717/KMMS.2020.23.3.421>)
- [10] S. C. Lee, S. W. Kang, N. Y. Kim, and P. Chung, "Automatically shut off standby power using ultrasonic sensor," in *Proc. Korean Inf. Sci. Soc. Conf.*, pp. 1708-1710, Jun. 2019.
- [11] J. H. Kim, G. M. Lee, T. S. Kang, and J. K. Park, "Development of a small smart plug for remote monitoring and control of temperature and humidity," *J. Inst. Contr., Robotics and Syst.*, vol. 27, no. 11, pp. 878-882, Nov. 2021. (<https://doi.org/10.5302/J.ICROS.2021.21.0118>)
- [12] H. M. Cho, C. K. Lee, and S. Y. Chin, "Research on the energy efficiency of cold and hot water dispensers utilizing IoT smart plug," in *Proc. Korean Soc. Electr. Conf.*, pp. 1643-1644, Jul. 2021.
- [13] S. H. Jung, J. Y. Kim, J. Park, S. M. Jang, and C. B. Sim, "A study on power data analysis and risk situation prediction using smart plug," *J. Korea Multimedia Soc.*, vol. 23, no. 7, pp. 870-882, Jul. 2020. (<https://doi.org/10.9717/kmms.2020.23.7.870>)
- [14] T. S. Kim, B. J. Park, J. H. Park, and W. H. Jung, "Smart multi-plug system with remote control," in *Proc. Korean Soc. Comput. Inf. Conf.*, vol. 30, no. 1, pp. 307-308, Jan. 2022.
- [15] B. G. Park, S. H. Bae, and B. K. Jung, "Speed prediction of urban freeway using LSTM and CNN-LSTM neural network," *J. Korea Inst. Intell. Transp. Syst.*, vol. 20, no. 1, pp. 86-99, Feb. 2021. (<https://doi.org/10.12815/kits.2021.20.1.86>)
- [16] Y. I. Kim, S. E. Lee, and Y. S. Kwon, "Proposal of a step-by-step optimized campus power forecast model using CNN-LSTM deep learning," *J. Korea Academia-Ind. Cooper. Soc.*, vol. 21, no. 10, pp. 8-15, Oct. 2020. (<https://doi.org/10.5762/KAIS.2020.21.10.8>)
- [17] R. J. Park, S. W. Kang, J. H. Lee, and S. M. Jung, "CNN-LSTM based wind power prediction system to improve accuracy," *New & Renewable Energy*, vol. 18, no. 2, pp. 18-25, Jun. 2022. (<https://doi.org/10.7849/ksnre.2022.0001>)
- [18] J. Y. Shin, A. H. Kum, and J. H. Park, "Design and development of small open data api using flask," in *Proc. Korean Inf. Sci. Soc. Conf.*, pp. 1873-1875, Jun. 2022.

- [19] M. S. Kang, H. J. Kim, D. D. Im, and H. J. Choi, "A study on weaknesses that can be introduced and secure coding for them in Flask web application framework," in *Proc. Korean Inf. Sci. Soc. Conf.*, pp. 1685-1687, Jul. 2020.
- [20] M. Ma, C. Liu, R. Wei, B. Liang, and J. Dai, "Predicting machine's performance record using the stacked long short-term memory (LSTM) neural networks," *J. Appli. Clinical Medic. Phys.*, vol. 23, no. 3, p. e13558, Feb. 2022.
(<https://doi.org/10.1002/acm2.13558>)

오 성 현 (Sung-Hyun Oh)



2019년 2월: 남서울대학교 전자공학과 졸업 (학사)
2021년 2월: 한국공학대학교 전자공학과 졸업 (석사)
2021년 3월~현재: 한국공학대학교 정보통신학과 박사과정
<관심분야> 실내위치추위, 인공지능, 5G 이동통신

[ORCID:0000-0002-1974-8612]

김 정 곤 (Jeong-Gon Kim)



1991년 2월: KAIST 전기 및 전자공학과 졸업 (학사)
1993년 2월: KAIST 전기 및 전자공학과 졸업 (석사)
1998년 2월: KAIST 전기 및 전자공학과 졸업 (박사)
1998년 6월~1999년 5월: 하와이주립대학교 전기공학과 Post Doc.

1999년 7월~2001년 3월: LG텔레콤 선임연구원
2001년 4월~2003년 2월: 삼성전자 통신연구소 표준연구팀 책임연구원
2010년 3월~2011년 2월: 미국 USC 전기공학과 Visiting Scholar
2018년 3월~2019년 2월: 미국 산호세 주립대학교 글로벌 책임교수
2003년 3월~현재: 한국공학대학교 전자공학부 교수
<관심분야> 5G이동통신, 간섭제거, 무선자원할당 VLC, 위치추위, 기지국 협력통신, UDN AI, 협업로봇, WPAN, WBAN 설계 및 응용분야
[ORCID:0000-0002-9349-2846]