

Smart IoT Home Data Analysis and Device Control Algorithm Using Deep Learning

Sang-Hyeong Lee[†] · Hae-Yeoun Lee^{**}

ABSTRACT

Services that enhance user convenience by using various IoT devices are increasing with the development of Internet of Things(IoT) technology. Also, since the price of IoT sensors has become cheaper, companies providing services by collecting and utilizing data from various sensors are increasing. The smart IoT home system is a representative use case that improves the user convenience by using IoT devices. To improve user convenience of Smart IoT home system, this paper proposes a method for the control of related devices based on data analysis. Internal environment measurement data collected from IoT sensors, device control data collected from device control actuators, and user judgment data are learned to predict the current home state and control devices. Especially, differently from previous approaches, it uses deep neural network to analyze the data to determine the inner state of the home and provide information for maintaining the optimal inner environment. In the experiment, we compared the results of the long-term measured data with the inferred data and analyzed the discrimination performance of the proposed method.

Keywords : IoT, Smart Home System, Deep Learning, Deep Neural Network

딥 러닝 기반 스마트 IoT 홈 데이터 분석 및 기기 제어 알고리즘

이 상 형[†] · 이 해 연^{**}

요 약

Internet of Things(IoT) 기술이 발전하면서 다양한 IoT 기기들을 이용하여 사용자의 편의성을 높이기 위한 서비스가 늘어나고 있다. 또한, IoT 센서가 다양해지고 가격이 낮아지고 있어서 다양한 데이터를 수집 및 활용하여 서비스를 제공하는 사업자도 증가하는 추세이다. 스마트 IoT 홈 시스템은 IoT 기기를 이용하여 사용자의 편의성을 향상하는 대표적인 활용 사례이다. 본 논문에서는 스마트 IoT 홈 시스템의 사용자 편의성을 향상하기 위하여 데이터를 분석하여 연관 기기의 제어를 위한 방법을 제안한다. 스마트 IoT 홈 시스템의 센서에서 수집한 내부 환경 측정 데이터, 기기 제어 액츄에이터에서 수집한 데이터 및 사용자의 판단 데이터를 학습하여 현재 홈 내부 상태를 분석하고 기기 제어 방법을 결정한다. 특히 기존 기술들과 다르게 최신 딥 러닝 기반의 심층 신경망을 도입하여 데이터를 분석하여 홈 내부 상태를 판단하고 최적의 홈 내부 환경 유지를 위한 정보를 제공한다. 실험에서는 실제 장기간 측정된 데이터와 추론 결과를 비교하여 제안한 방법의 판별 성능에 대한 분석을 수행하였다.

키워드 : IoT, 스마트 홈 시스템, 딥 러닝, 딥 뉴럴 네트워크

1. 서 론

IT 산업의 시작인 3차 산업혁명을 넘어 전 세계적으로 4차 산업혁명의 시대로 넘어가면서 ICT 기술의 발전과 그에 대한 연구가 진행되고 있다. 또한, ICBM 기술로 분류되는 IoT,

Cloud, Big Data, Mobile 기술을 포함하여 다양한 기술 간의 융복합 기술 연구가 진행되고 있다. 특히, 각종 사물에 센서를 부착하고 부착된 센서들이 서로 통신을 하여 데이터를 수집하고 전달하여 이를 분석하거나 학습하는 기술의 필요성이 증가하고 있고 여러 기업에서 연구하고 서비스를 개발하고 있다. IoT 기술은 전 세계적으로 관심이 증가하고 있으며, 이를 이용한 플랫폼 구축을 통해 다양한 가치를 창출하기 위한 노력이 진행되고 있다.

IoT 기술은 건물 자동화, 헬스케어, 홈 자동화, 물류 산업, 보안, 리테일 등 다양한 산업 분야에 적용되고 있다. 각 분야에서 다양한 센서를 이용해 정보를 수집하고 수집된 정보를

※ 본 연구는 과학기술정보통신부 및 정보통신기술진흥센터의 대학ICT연구센터육성지원사업의 연구결과로 수행되었음(IITP-2017-2014-0-00639).

† 준 회 원 : 하나금융티아이 사원

** 정 회 원 : 금오공과대학교 컴퓨터소프트웨어공학과 교수

Manuscript Received : September 1, 2017

First Revision : November 7, 2017

Accepted : December 5, 2017

* Corresponding Author : Hae-Yeoun Lee(haeyeoun.lee@kumoh.ac.kr)

관리하고 분석하여 사용자에게 서비스를 제공한다. IoT 기술을 활용하여 수집한 정보를 분석하기 위해 다양한 분석 방법을 활용한 연구가 진행되고 있으며 국내에서는 IoT 기술 표준 선점을 위한 스마트 홈 플랫폼을 구축하고 있다. 국내 통신 사업 3사인 SKT[1], KT[2], LG U+[3]에서는 IoT 연결이 가능한 제품들을 하나의 플랫폼으로 관리하여 사용자에게 편의성을 제공하는 사업을 진행 중이다. 사용자 행동 패턴에 맞게 디바이스를 제어하고 설정된 조건에 따라 디바이스가 동작하는 서비스를 비롯하여 사용자가 직접 디바이스를 제어할 수 있도록 모바일과 연동하여 플랫폼을 구축하고 있다.

해외에서도 Google을 비롯하여 다양한 서비스를 개발하고 있다. Google Nest Labs에서 스마트 홈 시스템을 구축하고 있으며, 자동 온도 조절 기능, 화재 정보 등의 기능을 탑재하면서 사용자의 편의성을 높이는 스마트 홈 IoT 플랫폼 구축을 위한 연구 및 서비스를 진행하고 있다.

현재 서비스가 진행되고 있는 스마트 홈 시스템은 사용자가 어플리케이션을 통해 기기를 제어하는 플랫폼으로 이루어져 있다. 사용자의 일상생활에 맞추어 자동으로 제어하는 시스템에 대한 연구가 진행되고 있으며 사용자의 상태 판단을 위한 다양한 분석 방법을 적용하고 있다. 하지만 연구 중인 연구 기법들은 매우 복잡하고 1차 내지 2차 가공된 데이터를 활용하여 연구의 복잡성 또한 높다.

본 논문에서는 홈 내부에 설치된 스마트 IoT 시스템을 통해 쉽게 수집 가능한 데이터를 바탕으로 DNN(Deep Neural Network)을 이용해 사용자의 상태를 판단함과 동시에 구축된 플랫폼을 통해 사용자가 디바이스를 제어할 수 있도록 정보를 제공하거나 분석된 상태 판단을 통해 스스로 제어할 수 있도록 하는 기반 분석 기법에 대하여 제안한다. 스마트 IoT 홈 시스템을 통해 홈 내부 상태 정보인 온도, 조도, 습도, 먼지 농도에 관한 수치형 데이터를 수집한다. 시스템을 통해 수집된 데이터와 사용자가 느끼는 홈 내부 상태를 DNN을 통해 학습하고 현재 상태를 분석하여 홈 내부 디바이스 조작을 통해 최적의 상태를 맞출 수 있도록 기반 정보 및 디바이스 제어 정보를 제공한다.

논문의 구성은 다음과 같다. 2장에서는 IoT 기술 및 데이터 분석 기법과 관련된 연구에 대하여 설명하고, 3장에서는 스마트 IoT 홈 시스템 및 DNN을 이용한 상태 판단 분석 기술을 제안한다. 4장에서는 시스템을 이용한 실험 결과에 대하여 제시 및 분석하고 5장에서 결론을 짓도록 하겠다.

2. 관련 연구

IoT를 이용한 스마트 홈 기술은 무선 인터넷 환경이 발전하면서 시장 영역이 확대되고 있다. 스마트 홈 시장은 6가지의 구성 요소를 가진다. 1) 유무선 인터넷 인프라, 2) IoT 통신이 가능한 디바이스, 3) 스마트 디바이스 간 통신 표준, 4) 운용 및 제어가 가능한 플랫폼, 5) 사용자의 편의성에 맞는 제어 디바이스, 및 6) 사용자의 니즈를 충족하는 콘텐츠로 구성되어 있다. 국내외에서는 각 구성 요소에 맞는 스마트 홈

IoT 플랫폼을 연구 및 구축하고 있다.

Ro and Kim은 스마트 홈 네트워크를 구축하여 홈 내부 개인의 환경에 맞는 서비스를 제공하는 방법을 연구하였다[4]. 스마트 폰 중심의 개인 환경 서비스를 위해 홈 내부의 다양한 기기들을 서버에 연결하여 제어하면서 사용자의 선호도에 맞는 설정을 통해 기기들을 자동 설정하여 편의성을 제공한다. 사용자는 스마트 폰을 이용해 서버와 통신을 하면서 각종 정보들을 주고받으면서 사용자의 편의에 맞는 설정을 통해 기기들을 제어한다.

Kim et al.은 감정 분석을 통한 개인화된 홈 네트워크 서비스 시스템을 연구하였다[5]. 지능형 에이전트 시스템을 이용해 개인의 감정을 분석하고 분석된 감정을 토대로 사용자에게 서비스를 제공한다. 수집된 영상과 음성 데이터를 분석하여 사용자의 감성을 판단하고 행동 패턴을 분석하여 선호 정보를 추출한다. 이에 따라 사용자의 감성과 행동 패턴을 통해 홈 내부 기기 제어를 통한 서비스를 제공한다.

Xue et al.은 IoT 센서들로 연결된 홈 네트워크에서 데이터 학습을 위한 플랫폼 구축을 연구하였다[6]. 중앙의 센서 게이트웨이를 통해 무선 연결된 센서 노드와 통신을 하고 웹 서버와 데이터베이스와 연결하여 센서에서 발생한 데이터를 저장하고 학습한다. 사용자는 인터넷을 통해 게이트웨이에 접속하고 저장 데이터 및 학습 결과에 접근하게 된다.

Lazarescu는 IoT 데이터 수집을 위한 환경 설정 및 플랫폼, IoT 어플리케이션에 대한 연구를 수행하였다[7]. 센서 간의 배치와 숫자 등을 통해 낮은 유지 보수비용과 높은 서비스 품질을 제공하기 위한 연구를 진행하였다.

Mannini and Sabatini는 IoT 센서를 이용해 인간의 움직임에 대한 정량적 분석과 자동 분류 연구를 수행하였다[8]. 사람의 신체에 대하여 움직임을 가속도 센서를 통해 분류하는 방법을 제시하였다. 이를 위해 Hidden Markov Model을 이용하여 모델을 수립하고 시계열 데이터인 가속도 데이터를 입력 데이터로 하여 데이터 세트를 분석하였다.

Choi and Jo는 지능적인 IoT 서비스를 위해 수많은 미 가공 데이터를 이용하여 사람의 의도와 상황을 파악하는 연구를 진행하였다[9]. 사람의 의도와 상황을 파악하기 위해 기계 학습 방법 중 하나인 의사 결정 트리를 기반으로 하여 결정 포레스트 분류와 회귀를 포함한 실험을 통해 의도 및 상황 파악 실험을 수행하였다.

3. 제안하는 스마트 IoT 홈 시스템 분석 및 제어 방법

2장에서 살펴본 바와 같이 IoT 시스템이나 플랫폼에서 발생하는 데이터를 이용하여 다양한 연구를 진행하고 있다. 대체적으로 IoT 환경에서 발생하는 데이터를 패턴 분석이나 컨텍스트를 통한 2차 가공을 수행한 후 데이터를 분석 및 활용한다. 본 논문에서는 IoT 시스템에서 일반적으로 수집되는 간단한 수치형 데이터를 이용한다. 추가적인 가공 단계를 거치지 않고 1차적으로 수집 가능한 데이터를 학습 및 분석하여 내부 환경의 상태를 판단하고 디바이스 제어를 위한 정보를 제공하는 연구를 진행하였다.

3.1 스마트 IoT 홈 시스템

본 논문에서 대상으로 하는 스마트 IoT 홈 시스템은 모바일 메신저 기반 스마트 IoT 하드웨어 제어 시스템을 활용한다. 수집한 데이터를 홈 내부 상태 분석 및 기기 제어를 위해 활용하였다[10].

스마트 IoT 홈 시스템의 구조는 Fig. 1과 같다. 스마트 IoT 게이트웨이를 중심으로 사용자와 IoT 센서가 연결되어 있는 구조이다. 사용자는 모바일 디바이스를 이용하여 스마트 IoT 게이트웨이와 통신이 가능하고 IoT 센서들은 스마트 IoT 게이트웨이와 연결되어 데이터를 주고받는다. 시스템에서는 환경 측정 센서, 도어락 센서, IR 센서, 에어컨 On/Off 센서 등 많은 IoT 기기와 연결이 되어 있으나 상태 분석 및 기기 제어를 위하여 일부 센서의 데이터를 이용해 데이터 분석을 수행한다.

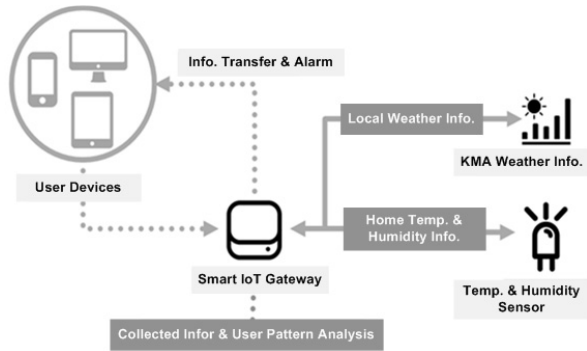


Fig. 1. Smart IoT Home System Architecture

Table 1에 스마트 IoT 게이트웨이로 전송된 데이터가 저장되는 데이터베이스를 표로 나타내었다. Time은 정보 수집 시간, State는 현재 내부에 사람이 있는지에 대한 여부, T는 온도(Temperature), H는 습도(Humidity), I는 조도(Illuminance), DD는 먼지농도(Dust density)를 나타내고 해당 정보만을 이용하여 데이터 분석 및 기기 제어에 활용한다. 데이터는 매 분마다 환경 측정 센서를 이용해 데이터가 수집되고 수집된

Table 1. Collected Environmental Data from Smart IoT Gateway

No	Time	State	T	H	I	DD
001	2015-08-12 14:22:34	inner	25.9	64.5	41	8.6
002	2015-09-08 14:13:21	inner	26.1	60.1	46	10.1
003	2015-10-05 14:15:23	inner	23.1	55.1	44	8.4
004	2015-11-11 14:08:39	inner	19.5	50.3	39	5.2
005	2015-12-02 14:10:11	inner	10.3	58.1	38	6.9
006	2016-01-03 14:23:35	inner	8.9	48.2	31	7.8
007	2016-02-07 14:38:24	inner	12.1	49.5	35	7.5
008	2016-03-05 14:21:12	inner	15.3	55.1	41	11.2
009	2016-04-01 14:25:41	inner	19.2	48.1	45	13.1
010	2016-05-09 14:15:23	inner	23.4	51.2	44	10.1
011	2016-06-10 14:18:19	inner	26.4	71.2	46	9.5
012	2016-07-13 14:21:51	inner	25.1	68.8	48	8.7

정보는 스마트 IoT 게이트웨이에 전달되어 데이터베이스에 저장된다. 환경 측정 센서로부터 전달된 데이터는 수집한 데이터 그대로 수치형 데이터로서 저장을 하고 분석에 활용한다.

환경 측정 센서와 마찬가지로 홈 내부 기기에 부착된 On/Off 제어 액추에이터의 데이터 정보 또한 스마트 IoT 게이트웨이로 전달되어 데이터베이스에 저장된다. Table 2는 기기 On/Off 제어 정보를 나타낸다.

Table 2에서 Time은 정보 수집 시간, State는 현재 내부에 사람이 있는지에 대한 여부, AC는 에어컨(Air-conditioner), B는 보일러(Boilder), H는 가습기(Humidifier), DH는 제습기(De-humidifier), C는 커튼 상태(Curtain), ACL는 공기 청정기(Air conditioner)를 나타낸다. B(Boiler)의 경우, 실험 환경에 따라 히터로 대체 하였다. 해당 기기 제어 정보를 활용해 데이터 분석 및 기기 제어 분석에 활용한다. 각 기기의 제어 액추에이터를 통해 수집한 정보는 스마트 IoT 게이트웨이에 전달되어 데이터베이스에 저장된다. 각 전달된 정보는 매 분마다 정보를 저장하고 각 장치의 On/Off 유무에 대해 1(on) 또는 0(off)으로서 데이터가 저장된다.

Table 2. Device on/off Information in Smart IoT Gateway

No	Time	State	AC	B	H	DH	C	ACL
001	2015-08-12 14:23:04	inner	on	off	off	on	off	off
002	2015-09-08 14:13:51	inner	off	off	off	off	off	on
003	2015-10-05 14:15:53	inner	off	off	off	off	off	off
004	2015-11-11 14:09:09	inner	off	off	on	off	off	off
005	2015-12-02 14:10:41	inner	off	on	off	off	off	off
006	2016-01-03 14:24:05	inner	off	on	on	off	off	off
007	2016-02-07 14:38:54	inner	off	on	on	off	off	off
008	2016-03-05 14:21:42	inner	off	off	off	off	off	on
009	2016-04-01 14:26:11	inner	off	off	on	off	off	on
010	2016-05-09 14:15:53	inner	off	off	off	off	off	on
011	2016-06-10 14:18:49	inner	on	off	off	on	off	off
012	2016-07-13 14:22:21	inner	on	off	off	on	off	off

3.2 Deep Neural Network를 이용한 홈 데이터 분석

심층 신경망은 딥 러닝(Deep Learning)을 위한 인공 신경망이다. 심층 학습은 여러 비선형 변환 기법의 조합을 통해 높은 수준의 추상화를 시도하는 기계 학습 방법 중 하나이다. 인공 신경망에는 다양한 종류가 존재하며 대표적으로 심층 신경망(Deep Neural Network, DNN), 합성곱 신경망(Convolutional Neural Network, CNN), 순환 신경망(Recurrent Neural Network, RNN), 제한 볼츠만 머신(Restricted Boltzmann Machine, RBM), 심층 신뢰 신경망(Deep Belief Network, DBN) 등 다양한 형태의 신경망이 존재한다.

본 논문에서는 IoT 센서 데이터를 이용해 홈 내부 상태 분석을 위해 심층 신경망(DNN)을 활용한 방법을 연구하였다. 본 연구에서 다루는 데이터의 형태는 수치형 데이터를 기반으로 하며, 수치형 데이터의 경우 머신 러닝 기법에서 일부 다루고 있으나 복잡한 수식을 적용해야 하고 단편적인 시점

에 대해서만 판단을 내리기 때문에 본 연구에 적용하는 것에 무리가 있다. 본 연구에서는 이전의 사용자가 행동이 어떠한 시점에서 이루어졌는지는 바탕으로 하고 단순한 수치형 데이터를 처리함으로써 복잡한 연산을 줄이고 내부 환경 변화에 따라 판단 결과 또한 바뀌어야 하기 때문에 단순한 심층 신경망의 적용을 통해 수치형 데이터를 처리하여 홈 내부 상태를 판단하기 위하여 환경 측정 센서에서 수집한 환경 측정 데이터, 실제 사용자가 느끼는 정보를 이용해 심층 신경망을 구성하여 홈 내부 상태를 판단한다.

심층 신경망은 복잡한 비선형 관계를 모델링하는 방법이며 신경망에 존재하는 각 객체들은 계층적 구성을 이루고 있으며 하위 계층들은 상위 계층의 특징을 통합한다. 이러한 특징을 이용해 적은 수의 유닛을 이용해 복잡한 처리 과정을 모델링 할 수 있다. Fig. 2는 일반적인 심층 신경망의 모형을 나타낸다.




Fig. 2. General Deep Neural Network Model

심층 신경망 모형 정립을 위해 각 환경 측정 데이터간의 연관성을 가정한다. 데이터 간의 연관성을 가정한 정보는 Table 3과 같다.

Table 3. Correlation Between Environmental Measured Data

Measured data item	Related data
Temperature	Humidity, Illuminance
Humidity	Temperature
Illuminance	-
Dust density	Humidity

Table 3과 같이 연관성을 있는 환경 측정 데이터를 활용하여 심층 신경망 모델을 구성하였다. 심층 신경망 모델을 Fully-Connected Layer 형태로 구성하여 각 노드간의 가중치가 환경 측정 데이터의 연관성을 나타낸다. Fig. 3은 구성한 홈 내부 상태 분석 심층 신경망 모델이다.

모델링한 심층 신경망 모형을 이용하여 입력 데이터와 출력 데이터를 설정하여 홈 내부 상태 분석을 위한 심층 신경망 모델을 학습시킬 수 있다. 심층 신경망의 각 노드들은 가중치로 연결되어 있다. 입력된 객체는 Hidden Layer 1~3을 거치는 동안 가중치를 통해 값이 업데이트 된다. 각각의 가중

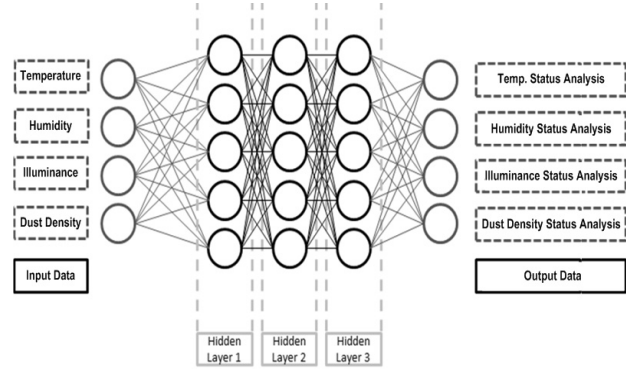


Fig. 3. DNN Model to Analyze Internal Home State

치는 오류 역전파 알고리즘을 통해 학습한다. 최종적으로 심층 신경망의 모형은 가중치 학습을 통해 입력 데이터로부터 출력 데이터의 결과를 확인하는 모형이다. 가중치는 다음 Equation (1)을 통해 계산할 수 있다.

$$y = wx + \beta \tag{1}$$

w 는 가중치이고 β 는 편향 값이다. 여기서 계산되는 가중치는 오류 역전파 알고리즘을 통해 갱신하여 최적의 신경망 모델을 찾아간다. 가중치의 갱신은 경사 하강법을 통해 이루어진다. 경사 하강법은 다음 Equation (2)와 같이 표현된다.

$$\Delta w_{ij}(t+1) = \Delta w_{ij}(t) + \alpha \frac{\partial C}{\partial w_{ij}} \tag{2}$$

C 는 비용함수를 뜻하고 α 는 학습률을 의미한다. 비용 함수는 학습 형태와 활성화 함수에 영향 받는다. 일반적으로 활성화 함수와 비용 함수는 각각 Softmax 함수와 교차 엔트로피 함수로 결정되며 Softmax 함수는 다음 Equation (3)과 같다.

$$p_j = \frac{\exp(x_j)}{\sum_k \exp(x_k)} \tag{3}$$

p_j 는 클래스 확률을 나타내며, x_j 와 x_k 는 각각 유닛 j 로의 전체 입력과 유닛 k 로의 전체 입력을 의미한다. 교차 엔트로피 함수는 다음 Equation (4)와 같다.

$$C = - \sum_j d_j \log(p_j) \tag{4}$$

d_j 는 출력 유닛 j 에 대한 목표 확률을 나타내며, p_j 는 해당 활성화 함수를 적용한 이후의 k 에 대한 확률 출력 값이다. 오류 역전파 알고리즘을 이용하여 학습을 하게 되면, 가중치의 과적합 문제가 발생할 수 있다. 과적합 문제는 훈련 데이터에 매우 근사하게 맞추어 학습이 되어 데이터 분류에 문제가 발생한다. 이러한 과적합 문제를 해결하기 위하여 Drop-Out 방식을 이용

하여 문제를 해결할 수 있다. Drop-Out 방식은 신경망의 유닛 중 일부분만 확률적으로 선택하여 학습하는 방법이다.

이와 같이 심층 신경망 모델을 구성하여 학습 절차와 판별 절차를 구성하였다. Fig. 4는 심층 신경망을 이용해 홈 내부 상태 분석을 위한 학습과 판별 절차를 나타낸다.




Fig. 4. Training & testing step to analyze smart home state

이와 같은 절차를 통해 심층 신경망을 이용한 홈 내부 상태를 분석한 결과 예시는 Table 4와 같다. 수집된 딥 러닝 모델을 통해 5일간 판단한 데이터 중 일부로서 각 검사 데이터의 시간에 따라 해당 요소(온도, 습도, 조도, 먼지 농도)에 대하여 이전의 학습 데이터를 기반으로 판단한 결과를 나타낸다. No.002가 No.004의 온도가 높은 것으로 판단하고 있고 No.001의 조도가 높은 것으로 판단하기 때문에 해당 시점에서 홈 내부 상태가 사용자에게 적절하지 않다는 것을 알 수 있다. 판단된 홈 내부 상태를 토대로 상태 판단 클래스에 따른 기기 제어 정보를 통해 홈 내부에 설치된 기기를 제어 할 수 있다. Table 5는 심층 신경망을 이용해 홈 내부 상태를 판단하여 추론한 결과를 바탕으로 사전에 지정된 판단 클래스에 따른 기기 제어 정보를 나타낸다.

Table 5에서 State 값은 현재 내부에 사람이 있으면 inner 없으면 outer 로 표시하고 inner일 경우 사용자를 위해 홈 내부 상태를 최적으로 만들기 위하여 어떤 기기를 어떻게 제어 할지에 대한 정보를 제공한다. 이 때, 각 기기의 제어 정보는 실제 현재 동작이 아닌 해당 환경에 따라 기기의 제어를 하라고 제시하는 정보이다. 실제로 No.002의 시점에서는 AC(Air Conditioner: 에어컨)이 켜져있는 상태이지만 해당 시점에서의 온도가 사용자에게 적당한 온도이기 때문에 기기를 off 하는 것으로 정보를 제공한다. 이처럼 추론된 판단 결과에 따른 기기 제어 정보를 IoT 게이트웨이에 전달한다. 정보를 전달 받은 IoT 게이트웨이는 연결된 기기 On/Off 액츄에이터에 정보를 전달하여 기기를 제어한다. 기기 제어와 함께 데이터 베이스에 홈 내부 상태 판단 결과 및 기기 제어 정보를 전달하여 데이터를 저장하고 관리한다.

Table 4. Analysis Example of Internal Home State using DNN

No	Time	Type	Data	Result
001	2016-08-03 14:23:37	Temperature	23	Mid(온도 적당)
		Humidity	32.7	Mid(습도 적당)
		Illumination	82	High(조도 높음)
		DustDensity	10.4	Low(먼지 농도 낮음)
002	2016-08-04 19:35:12	Temperature	28	High(온도 높음)
		Humidity	32.5	Mid(습도 적당)
		Illumination	60	Mid(조도 적당)
		DustDensity	9.6	Low(먼지 농도 낮음)
003	2016-08-05 09:42:23	Temperature	23	Mid(온도 적당)
		Humidity	32.5	Mid(습도 적당)
		Illumination	62	Mid(조도 적당)
		DustDensity	8.4	Low(먼지 농도 낮음)
004	2016-08-06 11:27:34	Temperature	26	High(온도 높음)
		Humidity	34.5	Mid(습도 적당)
		Illumination	78	Mid(조도 적당)
		DustDensity	9.5	Low(먼지 농도 낮음)
005	2016-08-07 00:03:34	Temperature	20.1	Mid(온도 적당)
		Humidity	33.1	Mid(습도 적당)
		Illumination	12	Low(조도 낮음)
		DustDensity	9.5	Low(먼지 농도 낮음)

Table 5. Device Control Information from Home State Analysis

No	Time	State	AC	B	H	DH	C	ACL
001	2016-08-03 14:23:37	inner	off	off	off	off	on	off
002	2016-08-04 19:35:12	inner	on	off	off	off	off	off
003	2016-08-05 09:42:23	outer	off	off	off	off	off	off
004	2016-08-06 11:27:34	inner	on	off	off	off	off	off
005	2016-08-07 00:03:34	outer	off	off	off	off	off	off

4. 실험 결과

본 절에서는 제안한 홈 내부 상태 분석 및 기기 제어 판단을 위한 실험 환경과 실험 결과, 성능 분석에 대해 기술한다. 실험을 위한 환경으로 라즈베리파이를 이용해 IoT 홈 게이트웨이를 구성하고 홈 내부에 설치된 다양한 IoT 센서들을 라즈베리파이에 연결을 하여 데이터를 수집하고 기기에 명령을 보내는 환경을 구축하여 데이터베이스에 데이터를 저장한다. IoT 게이트웨이에 IoT 기기들이 WiFi 통신 모듈을 탑재한 액츄에이터와 연결이 되어 있다. 하지만 해당 기기 제어 등에 대하여는 실제 제어 테스트 시간 동안만 작동한다. 판단된 결과를 통해 해당 액츄에이터를 움직이도록 하는 명령어로 변환하여 테스트를 진행하였고, 실험 이외의 시간에는 외부 환경으로 인해 문제가 발생하기 때문에 실험 환경 내부에 실험자가 있는지 여부에 따라 시스템을 제어하였다. 약 9개월간 매 분마다 수집된 데이터 약 38만 건의 데이터를 이용해 데이터 분석을 수행하였다. 실험을 위해 각 시간대별 수집되는

60개의 데이터 중 40개를 학습 데이터로 사용하고 나머지 20개의 데이터를 성능 평가를 위해 활용하였다. 데이터 분석을 위한 하드웨어 환경은 Table 6과 같다.

Table 6. Hardware Environment to Analyze IoT Data

Hardware	Specification
OS	Linux
CPU	Intel Core i5-4590
GPU	nVIDIA GeForce GTX 1080TI
RAM	16GB

이와 같은 환경을 통해 각 분석 방법에 대해 실험을 진행하였다. 심층 신경망을 이용한 홈 내부 상태 분석은 Google TensorFlow 및 Python 환경에서 분석을 수행하였다.

4.1 실험 결과

홈 내부 상태 판단 및 기기 제어 판단을 위해 수립한 심층 신경망에 대하여 전체 100,000건의 데이터를 학습하고, 심층 신경망을 이용한 요소 간 상관관계를 고려한 분석을 위해 시간마다 임의로 선택한 40,000건의 데이터를 활용하였고, 데이터 분석의 성능 검증을 위해, 임의의 시간마다 선택한 40,000건의 데이터를 활용하여 성능을 분석하였다.

학습 모델을 통해 추론된 결과에 사전에 판단되어진 결과 값과의 비교를 통해 Out-of-bag (OOB) error 성능 평가를 수행하였다. 출력 데이터의 구분을 위해 각 경우에 따른 Class를 설정하여 해당 결과와 비교하여 실험을 진행하였다. 각 상태 요소인 온도, 습도, 조도의 경우 (Low, Mid, High) 3가지의 Class로 구분하였고, 먼지 농도의 경우 (Low, High)로 분류하여 실험을 진행하였다.

Table 7~10은 심층 신경망을 이용하여 홈 내부 상태를 판별한 결과의 OOB Error 이다. 전체 입력한 데이터 40,000건에 대하여 각 요소들의 상관관계를 고려하기 때문에 동일한 40,000건의 데이터에 대하여 각 판단 요소 별로 실험 결과를 정리하였다.

Table 7. Temperature Analysis of Internal Home using DNN

	Low	Mid	High	OOB error
Low	35987/40000	3103/40000	10/40000	0.1003
Mid	1101/40000	36481/40000	2418/40000	0.0879
High	851/40000	3026/40000	36123/40000	0.0969
accuracy	90.49%		OOB average	0.0950

Table 8. Humidity Analysis of Internal Home using DNN

	Low	Mid	High	OOB error
Low	36512/40000	2103/40000	1385/40000	0.0872
Mid	851/40000	37512/40000	1637/40000	0.0622
High	351/40000	813/40000	38836/40000	0.0291
accuracy	94.05%		OOB average	0.0595

Table 9. Illumination Analysis of Internal Home using DNN

	Low	Mid	High	OOB error
Low	37223/40000	2099/40000	678/40000	0.0694
Mid	1615/40000	36915/40000	1470/40000	0.0771
High	516/40000	1333/40000	38151/40000	0.0462
accuracy	93.57%		OOB average	0.0642

Table 10. Dust Density Analysis of Internal Home using DNN

	Low	Mid	High	OOB error
Low	38915/40000	-	1085/40000	0.0271
Mid	-	-	-	
High	476/40000	-	39524/40000	0.0119
accuracy	98.04%		OOB average	0.0195

Table 11. Overall Data Analysis Result

OOB error		Average	Accuracy
Temperature	0.0950	0.0596	94.04%
Humidity	0.0595		
Illumination	0.0642		
Dust density	0.0195		

각 홈 내부 상태 판단 Class에 대하여 OOB error의 각 평균은 0.0950, 0.0595, 0.0642, 0.0195의 결과를 가진다. 판별 정확도는 90.49%, 94.05%, 93.57%, 98.04%를 가진다. 심층 신경망을 이용한 홈 내부 상태 분석 결과를 종합하면 Table 11과 같다.

심층 신경망을 이용한 모델의 경우, 전체 판단 요소들 간의 상관관계를 고려하여 입력 데이터에 대하여 학습된 모델을 기준으로 결과를 판단하기 때문에 전체 구간에서 오판단 데이터가 발생할 수 있다. 오판단 결과는 분석을 위한 학습 데이터의 수집 및 연산 결과가 영향을 미친다. 오판단 경우를 줄이기 위해서는 학습 데이터를 선택할 때, 표본의 개수를 줄이거나 중첩 구간에서의 학습 데이터 개수를 전체 데이터 대비 동일 퍼센트로 설정하여 데이터를 학습하면 오판단 결과를 줄일 수 있다. 이와 반대로 확률 추론 기법이나 Threshold 기법, Fuzzy 등과 같은 기법에서는 각 판단 분류 Label 간의 경계선이나 임계점을 구하여 판단한다. 입력된 값이 어느 분류에 속하는지를 판단하기 때문에 분류 간 경계점에서 실제 사용자가 느끼는 판단과 다른 결과가 발생할 수 있다. 사용자가 느끼는 내부 상태에 대한 학습이기 때문에 같은 온도라 하더라도 다른 요소로 인해 사용자가 다르게 판단할 수 있기 때문에 상태 분류 Label 간 경계점에서 발생하는 오류를 줄이는 것이 더욱 중요하다.

Table 12와 Table 13은 온도의 Mid 결과와 High 결과의 경계 부분의 동일한 데이터를 확률 추론 기법과 심층 신경망 기법의 결과를 나타낸다. 각 판단 분류 Label의 경계 부분에서 확률 추론한 결과 보다 심층 신경망을 활용하여 분석했을 때의 결과가 더욱 정확한 것을 알 수 있다. 확률 추론은

단순히 수집된 데이터의 확률을 사용하기 때문에 사용자가 느끼는 상태나 외부 요인에 대하여 고려하지 않기 때문에 오히려 성능이 떨어진다.

Table 12. Analysis of Boundary Section Data through Probability Inference

User Decision Results		Probability Inference		OOB Error
		Mid	High	
Mid	894	678	216	0.241
High	1106	341	765	0.308

Table 13. Analysis of Boundary Section Data through DNN

User Decision Results		Deep Neural Network		OOB Error
		Mid	High	
Mid	894	759	135	0.151
High	1106	125	981	0.113

IoT 홈 시스템에서는 사용자의 상태가 가장 중요한 요소이고 홈 외부 또는 내부에서 발생하는 다른 요인이 있을 수 있고, 서로 다른 요소가 영향을 미칠 수도 있기 때문에 전체적인 상황을 고려하는 심층 신경망이 더욱 적합하다.

5. 결 론

본 논문에서는 스마트 IoT 홈 시스템에서 발생하는 데이터를 이용하여 사용자에게 편의성을 제공하기 위하여 홈 내부 상태를 판단하고 판단된 결과에 따라 사용자에게 맞는 환경을 제공하기 위하여 기기 제어 판단을 위한 분석 기술 및 시스템을 제안하였다. 가장 기본적인 홈 내부 데이터를 활용하여 쉽게 수집 가능한 수치형 데이터를 활용하여 홈 내부 상태를 최적화 할 수 있는 방안을 연구하였다. 특히, 홈 내부 상태 판단 및 기기 제어 정보 제공을 위하여 심층 신경망을 이용하였다.

심층 신경망을 이용한 방법의 성능을 분석하기 위하여 실제 IoT 센서 데이터로부터 수집한 380,000건의 데이터 중 약 100,000건의 데이터를 학습 및 분석에 활용하였다. 해당 실험에 대하여 실제 사용자가 판단한 결과와 분석을 통해 판단된 결과를 비교하여 OOB Error를 통한 성능 분석을 수행하였다. 즉, 입력 데이터를 통해 분석을 수행하고 최종적으로 출력된 결과 값과 실제 실험 데이터를 분류한 Label과 비교하여 해당 결과 값이 기대한 Label과 동일한지에 대한 판별 성능을 확인하였으며 심층 신경망을 이용한 분석의 판별 정확도는 94.04%를 달성하였고, 홈 내부 상태 판단 결과에 따라 사전에 지정한 기기 제어 목록에 따라 기기를 제어하였다.

차후 연구에서는 실험에 사용한 데이터뿐만 아니라 다양한 IoT 센서 데이터를 이용하여 추가적인 실험을 통해 분석의 정확성을 높이거나 새로운 결과를 도출할 필요성이 있다. 또한 플랫폼의 안정성을 위해 클라우드 및 빅 데이터 시스템과 연

동하여 안정적인 데이터 보존과 다양한 분석 기법을 적용하여 스마트 홈 인공지능 시스템을 위한 연구로 발전이 가능하다.

IoT 센서의 경우, 일반적으로 수집하는 데이터는 수치형 데이터로 구성되어있다. 수치형 데이터를 분석하기 위해서는 분석을 위한 적절한 분석 기법을 찾는 것이 중요하다. 그리고 여러 센서의 데이터를 분석할 때에는 센서 데이터 간의 상호 연관성 또한 차후 연구의 고려 대상이다. 데이터 간의 연관성이 다양한 변수를 발생시켜서 분석 결과에 영향을 미치기 때문이다.

IoT를 이용한 스마트 홈 시스템은 국내외적으로 많은 연구가 이루어지고 있다. 연구를 수행하는 기업에서는 IoT를 이용한 플랫폼 구축을 통해 시장 선점을 목표로 하고 있다. 이와 같은 연구 환경에서 어느 플랫폼을 이용하더라도 사용자의 편의성을 증대시키는 것이 최종 목표가 될 것이다. 그렇기 때문에 플랫폼을 통해 수집된 데이터를 이용하여 사용자 맞춤형 분석이 필수적이며 다양한 결과를 도출하여 사용자에게 편의성을 제공하는 서비스를 구축해야 한다.

References

- [1] SKT Smart [Internet], <https://www.sktsmarthome.com/html/services.html>, 2017.
- [2] KT GIGA IoT Home Manager [Internet], <https://product.olleh.com/wDic/productDetail.do?ItemCode=1072>.
- [3] LG IoT@Home [Internet], <https://www.uplus.co.kr/ent/iot/IotProdList.hpi?mid=10427>.
- [4] K. Ro and S. Kim, "A Research on Personal Environment Services for a Smart Home Network," *Journal of the Institute of Electronics Engineers of Korea - CI*, Vol.49, No.3, pp.46-55, 2012.
- [5] J.-S. Kim, D.-Y. Kim, S.-H. Bin, D.-Y. Kim, M.-W. Ryu, and K.-H. Cho, "Design and Implementation of A Personalized Home Network Service System based on Emotion Analysis", *Journal of the Institute of Electronics Engineers of Korea - CI*, Vol.47, No.6, pp.131-138, 2010.
- [6] R. Xue, L. Wang, and J. Chen, "Using the IOT to construct ubiquitous learning environment," *MACE*, pp.7878-7880, 2011.
- [7] M. T. Lazarescu, "Design of a WSN Platform for Long-Term Environmental Monitoring for IoT Applications," *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, Vol.3, No.1, pp.45-54, 2013.
- [8] A. Mannini and A. M. Sabatini, "Machine learning methods for classifying human physical activity from on-body accelerometers," *Sensors*, Vol.10, No.2, pp.1154-1175, 2010.
- [9] D. Choi and H. Jo, "Machine learning based motion recognition technology for intelligent IoT service," *Journal of Electromagnetic Engineering And Science*, Vol.27, No.4, pp.19-28, 2016.
- [10] S.-H. Lee, D.-H. Kim, and H.-Y. Lee, "Smart IoT Hardware Control System using secure Mobile Messenger," *Journal of the Korean Institute of Electrical Engineers*, Vol.65, No.12, pp.2232-2239, 2016.



이 상 형

<https://orcid.org/0000-0003-4430-1983>

e-mail : riscap@nate.com

2015년 금오공과대학교

컴퓨터소프트웨어공학과(공학사)

2017년 금오공과대학교 소프트웨어공학과
(공학석사)

2018년~현 재 하나금융티아이 사원

관심분야: IoT, Image Processing, Digital Forensics



이 해 연

<https://orcid.org/0000-0002-6081-1492>

e-mail : haeyeoun.lee@kumoh.ac.kr

1997년 성균관대학교 정보공학과(학사)

1999년 한국과학기술원 전산학과(공학석사)

2006년 한국과학기술원 전자전산학과
(공학박사)

2008년~현 재 금오공과대학교 컴퓨터소프트웨어공학과 교수

관심분야: IoT, Image Processing, Digital Forensics