

Journal of the Korea Institute of Information and Communication Engineering

한국정보통신학회논문지 Vol. 24, No. 7: 935~941, Jul. 2020

# CSI를 활용한 딥러닝 기반의 실내 사람 수 추정 기법

안현성1·김승구2\*

# A Deep Learning Based Device-free Indoor People Counting Using CSI

# Hyun-seong An<sup>1</sup> · Seungku Kim<sup>2\*</sup>

<sup>1</sup>Graduate Student, Department of Electronic Engineering, Chungbuk National University, Chungbuk, 28644 Korea

<sup>2\*</sup>Associate professor, Department of Electronic Engineering, Chungbuk National University, Chungbuk, 28644 Korea

#### 요 약

사람 수 추정 기술은 IoT 서비스를 제공하기 위해 중요하다. 대부분의 사람 수 추정 기술은 카메라 또는 센서 데이터를 활용한다. 하지만 기존 기술들은 사생활 침해 문제가 발생 가능하며 추가로 인프라를 구축해야한다는 단점이었다. 본 논문은 Wi-Fi AP를 활용하여 사람 수를 추정하는 방법을 제안한다. 사람 수 추정을 위해서 Wi-Fi의 채널 상태 정보를 딥러닝 기술을 활용하여 분석한다. Wi-Fi AP 기반 사람 수 추정 기술은 사생활 침해 우려가 없으며, 기존 Wi-Fi AP 인프라를 활용하면 되기 때문에 추가 비용이 발생하지 않는다. 제안하는 알고리즘은 k-바인딩 데이터 전처리 과정과 ID-CNN 학습 모델을 사용한다. AP 2대를 설치하여 6명의 사람 수 추정 결과를 실험을 통해 분석하였다. 정확한 사람 수 판별에 관한 결과는 64.8%로 낮은 결과를 보였지만, 사람의 수를 클래스로 분류한 결과는 84.5%의 높은 결과를 보였다. 해당 알고리즘은 제한된 공간에 사람의 밀집도를 파악하는데 응용 가능할 것으로 기대된다.

#### **ABSTRACT**

People estimation is important to provide IoT services. Most people counting technologies use camera or sensor data. However, the conventional technologies have the disadvantages of invasion of privacy and the need to install extra infrastructure. This paper proposes a method for estimating the number of people using a Wi-Fi AP. We use channel state information of Wi-Fi and analyze that using deep learning technology. It can be achieved by pre-installed Wi-Fi infrastructure that reduce cost for people estimation and privacy infringement. The proposed algorithm uses a k-binding data for pre-processing process and a 1D-CNN learning model. Two APs were installed to analyze the estimation results of six people. The result of the accurate number estimation was 64.8%, but the result of classifying the number of people into classes showed a high result of 84.5%. This algorithm is expected to be applicable to estimate the density of people in a small space.

**키워드**: IoT, CSI, Wi-Fi, 사람 수 추정, 딥러닝

Keywords: IoT, CSI, Wi-Fi, People Counting, Deep Learning

Received 1 April 2020, Revised 10 April 2020, Accepted 15 April 2020

\* Corresponding Author Seung-Ku Kim(E-mail:kimsk@cbnu.ac.kr, Tel:+82-43-261-2479)
Associate professor, Department of Electronic Engineering, Chungbuk National University, Chungbuk, 28644 Korea

Open Access http://doi.org/10.6109/jkiice.2020.24.7.935

print ISSN: 2234-4772 online ISSN: 2288-4165

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(http://creativecommons.org/li-censes/by-nc/3.0/) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Copyright © The Korea Institute of Information and Communication Engineering.

### I. 서 론

모든 사물과 센서를 인터넷을 통해 하나로 연결하는 IoT(Internet of Things) 서비스는 점차 대중화되고 있다. 실내 환경 조절을 자동으로 하는 스마트 빌딩이나 재난 상황 관리 등 다양한 IoT 서비스들이 상용화되고 있다. 이러한 서비스들을 제공하기 위해서는 인터넷과 서비 스를 받는 사람의 위치 등 다양한 요소가 필요하다. 그 중 사람 수는 중요한 요소들 중 하나이다. 사람 수를 측 정하는 방법들은 많이 연구되어왔고 사용되고 있다. 이 미지를 사용하는 방법과 그렇지 않은 방법으로 분류 할 수 있다. 이미지를 사용하는 방법은 주로 CCTV 카메라 를 사용[1]한다. 카메라에 찍힌 사진 또는 영상으로 사 람의 특징을 분석하고 높은 정확도의 인구 밀집도를 계 산한다. 그러나 빛의 영향으로 역광이 일어나 이미지에 손상이 일어나기도 한다. 또한 이미지를 제공하는 카메 라는 높은 해상도가 요구된다. 높은 해상도의 카메라는 비용이 많이 들고 카메라에 찍힌 사람들의 사생활 침해 도 문제가 된다. 이미지를 사용하지 않는 방법들은 센서 및 무선신호를 사용하는 방법들이 있다. 하중감지센서 [2] 등의 센서를 설치하여 대중교통 사용자의 수를 계산 하거나 게이트의 통과인원을 체크하는데 사용되기도 한다. 그러나 센서를 사용하는 방식은 다수의 센서를 사 전에 설치해야하는 설비문제가 있다. 무선신호를 사용 하는 방식은 주로 Wi-Fi나 블루투스를 사용한다. 스마 트폰의 대중화가 되면서 Wi-Fi나 블루투스에 연결[3]된 인원을 직접적으로 확인한다. 하지만 스마트폰을 소지 하고 있을 때만 서비스를 받을 수 있고 그렇지 않으면 서비스를 받지 못하는 문제가 있다.

이러한 제약사항들을 해결하기 위해 무선신호를 사용하는 방법 중 Wi-Fi AP만을 이용하는 방법들이 연구되어왔다. Wi-Fi AP만을 이용하면 영상으로 인한 프라이버시 침해의 문제가 없으며 스마트폰과 같은 별도의기기를 휴대할 필요가 없다. 또한 공공장소는 물론 가정에서도 Wi-Fi가 설치되어 있다. 그렇기 때문에 추가적인 설비도 요구되지 않는다. Wi-Fi AP간의 패킷 송수신만을 이용하여 사람 수를 추정한다. 멀티패스로 인한 페이딩 현상과 LOS 감쇠 특성을 이용하여 추정한다. 신호세기(RSSI)를 이용한 방식[4]은 안정적인 결과를 뽑기위해 추가적인 AP와 LOS 환경마다 설치해야하는 단점이 있다. 이러한 문제를 해결하기 위해 CSI(CHannel

State Information)를 이용한 방식이 연구되었다.

본 논문은 Cheng[5] 등이 제안한 데이터 전처리 및 DNN 모델의 제한적인 실험환경의 한계를 지적하고 해결한다. 2장에서는 기존의 Wi-Fi AP를 이용한 사람 수추정 연구와 딥러닝을 이용한 연구들에 관해서 서술하고 CSI와 기본적인 딥러닝의 배경지식을 서술한다. 3장에서는 기존 데이터 전처리 방식과 모델의 문제점에 대해 서술하며 이러한 문제점을 해결하기 위한 새로운 데이터 전처리 방식을 제안하고 ID-CNN 모델로 학습한다. 4장에서는 데이터 수집 및 제언한 전처리 방식과 모델로 실험을 진행한다. 기존의 전처리 방식 및 DNN 모델과의 성능을 비교한다. 5장에서는 결론을 맺고 논문을 끝마친다.

## Ⅱ. 관련 연구 및 배경지식

#### 2.1. 관련 연구

### 2.1.1. Wi-Fi AP만을 이용한 사람 수 추정

Domenico[6] 등은 CSI 진폭 데이터만을 이용하여 사람 수를 판별하였다. 3가지의 각자 다른 크기의 실내에서 다수의 인원이 무작위 행동을 하는 데이터를 수집한다. 유클리드 거리 기법으로 인원별 서브캐리어 특징을 추출한다. 그리고 평균과 분산을 이용한 DBI(Device-Bouldin Index)를 이용하여 인원 수 별 특징을 데이터를 만들었다. 선형 판별 분석으로 사람 수 추정을 하였다. 다수 인원에 대해서는 클래스로 묶어서 판별하였다. 하지만 52~72%로 전체적으로 낮은 결과를 보였다.

# 2.1.2. 딥러닝과 Wi-Fi AP를 이용한 사람 수 추정

Cheng[5] 등은 CSI 진폭 데이터를 DNN에 적용하여 사람 수를 추정하는 것을 제안하였다. 패킷 하나의 진폭 데이터 평균을 각 서브캐리어에 빼는 것으로 전처리 (average subtract)를 한다. 0명부터 9명까지 각 케이스 별 1000개의 데이터를 수집한다. 전처리하기 전과 후 두 개의 진폭데이터를 하나로 합친다. 3개의 은닉층으로 이루어진 DNN모델을 만들고 학습시킨다. 88%의 결과가 나오지만 특정 위치에 고정된 상황에서만의 데이터로 학습 및 테스트를 진행한 한계점이 있다. 또한 잘못된 데이터 입력으로 모델이 학습을 진행할수록 정확도가 낮아지는 문제가 있다.

#### 2.2. 배경 지식

#### 2.2.1. CSI

CSI(Channel State Information)란 OFDM(Orthogonal Frequency Division Multiplexing) Wi-Fi의 PHY 계층 정보이다. MIMO(Multiple-Input Multiple-Output) AP 의 수신 측에서 계산된 각 안테나 별 서브캐리어들의 산란 및 페이딩, 그리고 진폭과 위상의 정보가 출력된다. RSSI(Received Signal Strength Indicator)에 비해 한 번의 송수신으로 서브캐리어의 수만큼의 많은 정보를 수집할 수 있다. 또한 환경변화에 민감하여 멀티패스 특징이 잘 나타난다.

본 논문에서 사용하는 네트워크 펌웨어는 Atheros CSI tool[7]로 그림 1과 같이 복소수의 형태로 출력된다. Atheros CSI tool은 802.11n 기반의 다양한 리눅스 환경에서 손쉽게 이용 가능한 오픈소스 펌웨어이다

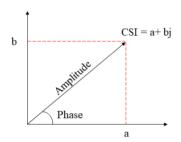


Fig. 1 Channel State Information

#### 2.2.2. DNN

DNN(Deep Neural Network)은 입력층과 출력층, 그리고 중간의 은닉층들로 구성된 인공 신경만이다. 각층은 사람의 신경망과 유사한 형태를 지니고 있어 인공 신경망이라 불린다. 각층마다 노드들이 있으며 인접한층의 모든 노드들은 서로 연결되어 있다. 각각의 노드들은 주어진 입력에 따라서 가장 적합한 가중치를 찾는 것이목표라 할수 있다.

#### 2.2.3. CNN

DNN의 한계를 극복하고 영상 처리 분야에 특화된 신경망이 CNN(Convolutional Neural Network)이다. CNN은 합성곱 신경망으로 불리며 사람의 시신경을 모 방한 구조이다. 영상 또는 사진의 특징을 추출하여 학습 한다. 전체적인 구조는 합성곱 계층과 풀링 계층으로 나 뉜다.

#### Ⅲ. 문제 정의 및 기법 제안

#### 3.1. 문제 정의

#### 3.1.1. 새로운 모델의 필요성

딥러닝을 이용한 사람 수 추정은 별도의 알고리즘 없이 판별이 가능하다. Cheng[5] 등이 제안한 DNN 모델을 사용한 사람 수 추정은 고정된 자리의 인원수 판별에서는 높은 성능을 보인다. 하지만 학습한 데이터와 다른 위치에 사람이 있거나 행동하고 있는 상황이라면 판별하지 못하는 문제가 있다. 인원별로 무작위의 향동을 하는 상황의 데이터로 학습한 결과는 전체적으로 낮은 정확도를 보인다. 또한 CSI 진폭 데이터와 같은 복잡한 데이터를 학습시키기 위해서는 모델을 깊게 만들 필요가 있다. 그러나 DNN의 은닉층과 노드들을 늘리면 성능이 떨어지는 문제도 있다. 모델이 학습을 진행하면서 입력층과 가까운 은닉층의 가중치들이 출력층에 끼치는 영향이 줄어들기 때문이다.

#### 3.1.2. 학습에 적합한 데이터

모델을 원활하게 학습시키기 위해 적합한 데이터가 필요하다. 데이터 전처리는 기존 데이터의 잡음 및 표준 화를 통해 모델의 경사하강법을 원활하게 해준다. 올바 르게 전처리 된 데이터로 학습을 하면 비용함수의 최솟 값을 찾기 쉬워진다. 사람 수 추정에서 CSI 진폭 데이터 를 그대로 학습에 이용하면 모델의 학습이 제대로 이루 어지지 않는다. 또한 잘못된 데이터는 모델이 전혀 학습 하지 못하는 원인이 되기도 한다. Cheng[5] 등은 입력 데이터 노드가 많으면 정확도가 올라가는 것에 착안하 여 전처리 전후의 데이터를 합쳐서 학습을 진행하였다. 전처리 전의 Raw 진폭 데이터와 전처리 후의 진폭 데이 터를 하나로 합친 모델은 학습 반복 횟수(epochs)가 늘 어나도 정확도가 올라가지 않는다. 반대로 전처리 데이 터만을 넣은 것은 학습이 잘 되는 것을 알 수 있다. 그러 나 학습이 원활하게 진행되더라도 낮은 정확도를 보인 다. 성능 향상을 위해서 사람 수 추정에 적합한 모델을 찾고 사용해야한다.

#### 3.2. 기법 제안

저자는 잡음을 제거하는 데이터 전처리 방식인 k-binding을 제안한다. 또한 1차원 데이터에 CNN을 적 용하는 1d-convolution을 이용하여 만든 1D-CNN 모델 을 사용한다. k-binding 데이터 전처리 및 전처리 데이터를 학습한 모델은 기존 DNN을 사용한 결과와 비교하여 성능이 향상되었고 무작위 행동에 대해서도 인원수를 판별한다.

#### 3.2.1. k-binding

k-binding은 average subtract를 진행한 인접한 데이터들을 k개 묶는다. 그 후 같은 인덱스의 서브캐리어들의 평균을 도출한다. 도출한 평균으로 새로운 데이터를만든다. Wi-Fi AP의 송수신은 매우 빠르게 이루어진다. 빠르게 송수신되는 패킷에는 사람 수 추정에 불필요한잡음이 기록되기도 한다. k-binding 전처리는 다수의 패킷 정보를 집약하고 각 패킷마다 기록된 불필요한 잡음을 제거한다.

#### 3.2.2. 1D-CNN

1D-CNN 모델은 그림 2와 같다. 일반적인 CNN은 2 차원의 사진데이터를 처리하기 위해 만들어졌다. 이것을 1차원 데이터에 적용하기 위해 1d-convolution을 사용하여 1D-CNN 모델을 만들었다. 입력층 224개의 노드 중 7개의 노드를 묶어 합성곱을 진행한다. 노드를 한 칸씩 옮겨가며 합성곱을 진행한다(stride = 1). 각각의다른 가중치를 가지는 6개의 필터로 합성곱을 진행 (Convolutional layer)하면 노드가 218개인 각기 다른 6

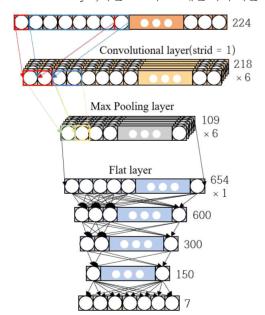


Fig. 2 1D-CNN Model

개의 데이터가 만들어진다. 그렇게 만들어진 데이터로 2개씩 묶어 최댓값만을 추출(Max Pooling)한다. 추출한 데이터들을 하나로 묶는다(Flat layer). 하나로 만들어진데이터를 3개의 은닉층에 넣어 학습시킨다. 각 은닉층은 600, 300, 150개의 노드로 구성된다. 활성화 함수가 필요 없는 Flat layer를 제외하고 모든 연산의 활성화 함수는 Relu를 사용하였다.

# Ⅳ. 성능 평가

#### 4.1. 실험 환경

#### 4.1.1. 사용 AP 설정

실험에 사용하는 AP는 TP-LINK 사의 TR-WDR4300[8] 이다. 리눅스 환경의 오픈소스 Atheros CSI tool[9]을 이용하여 내장되어 있는 네트워크 칩 AR9340의 CSI 정보를 수집하였다. AP의 설정 및 패킷 송수신 정보는 표 1과 같다. 주파수 채널(Frequency Channel)은 2.4GHz를 사용하였고 송신파워(Tx power)는 20db로 고정하였다. 각각의 AP에는 2개의 송수신 안테나가 내장(MIMO)되어있다. 20비트당 1심볼을 송수신하며 심볼들의 CSI 평균으로 한 패킷에 대한 CSI 데이터를 출력[10]한다. 한번의 송수신으로 총 224개의 서브캐리어(Total Subcarrier)를 출력한다. 초당 20개의 패킷을 송수신하였으며 총 3000개의 패킷의 진폭 데이터를 상황별로 기록하였다.

Table. 1 Parameter Set for the Experiment

Parameters	Configuration		
AP	TR-WDR4300		
Frequency Channel	2.4GHz		
Bandwidth	20MHz		
Tx Power	20db		
MIMO	2x2		
Total Subcarrier	224		
Packets Per sec	20		
Total Packets	3000		

#### 4.1.2. 시나리오

충북대학교 교육관 406호 강의실 양 끝에 AP를 배치하였다. 균일한 크기의 직사각형으로 강의실을  $5\times 5$  격자화 하였다. 그 배치는 그림 3과 같다. 사전 실험을 통해 인원 수 판별이 가능한 구간을 검색하였다. 빨간 구

역 외의 지역은 멀티패스의 영향이 적어 데이터에 인원 별 특징이 나타나지 않는 구간이다. 또한 AP와 사람은 일정거리 이상 떨어져야한다. AP와 가까우면 과도한 신호의 감쇠로 인원 별 특징이 나타나지 않는다. 그렇기 때문에 크기 3×5인 빨간 구역 내에서 지정된 인원이 일정한 속도로 무작위의 행동을 하며 걸어 다녔다. 초당 20개의 패킷을 송수신하였으며 인원수별 3000개의 패킷을 송수신하였다. 0명부터 6명까지 총 7가지 케이스를 상황별로 데이터를 수집하였다. 각 상황별로 3개의데이터를 수집하였다. 그림 4는 실제로 실행한 실험의 사진이다.

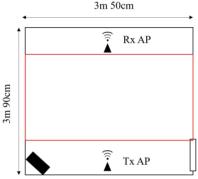


Fig. 3 Experiment Environment



Fig. 4 Data Collection

#### Table. 2 Experimental Results

	DNN	1D-CNN	k = 3	k = 5	k = 10	k = 15	k = 20
Epochs	150	20	20	20	20	20	20
Recall average	0.563	0.638	0.643	0.65	0.65	0.656	0.65
Recall Max	0.58	0.7	0.67	0.67	0.68	0.68	0.68
Recall Min	0.55	0.58	0.61	0.62	0.63	0.63	0.64
Max - Min	0.03	0.12	0.06	0.05	0.05	0.05	0.04
Class Recall	0.8	0.83	0.837	0.835	0.852	0.855	0.85

#### 4.1.3. 학습 반복횟수(epochs) 결정

최종 성능 평가전에 두 개의 데이터로 각 모델별 학습 반복 횟수를 정한다. 학습(train)과 평가(test) 정확도 (accuracy)의 수렴을 기준으로 학습 반복 횟수를 정한다. 수렴지점을 확인하기 위해 DNN 모델은 300까지 1D-CNN은 150까지 진행시켰다. 그 결과 DNN 모델은 150, 1D-CNN 모델은 20번 이후 정확도가 증가하지 않았다. 그 이상으로 학습을 진행하면 비용이 증가하여 모델이 다른 데이터에 대해 잘못된 판별을 할 수 있다. 최종 평가 반복횟수를 각각 150과 20번으로 지정하였다.

#### 4.2. 최종 성능 평가

3개의 데이터를 모두 사용하여 학습과 결과도출을 6 번 진행하였다. 각 모델별 최종 성능 비교는 딥러닝의 평가 지수중 하나인 Recall로 한다. Recall은 입력받은 데이터의 정답 중 모델이 선택한 정답 비율이다.

#### 4.2.1. DNN vs 1D-CNN

average subtract 데이터로 학습시킨 DNN과 1D-CNN의 결과는 표 2와 같다. DNN 모델은 인원수별 서브캐리어데이터 전체를 한번에 입력받아 학습한다. 학습한 데이터와 판별하는 데이터가 부분적으로 공통점을 가져도 전체적으로 다르면 판별을 원활히 하지 못한다. 그렇기때문에 평균 Recall값이 0.563의 낮은 결과를 보인다. 1D-CNN 모델은 1d-convolution과 max pooling으로 만들어진 모델이다. 7개의 서브캐리어데이터를 구역별로묶어서 특징을 학습한다. 인원수별 CSI 특징이 조금 변하더라도 학습한 구역별 특징으로 판별한다. 그렇기때문에 1D-CNN 모델의 평균 Recall 값이 0.638로 DNN모델보다 높다. 그러나 6번의 결과 중 최대와 최소의 편차가 DNN은 0.03으로 작은 차이를 보였으나 1D-CNN은 0.12로 매우 크다. 이것은 학습데이터의 잡음과 관련되어있다. 실험은 초당 20개의 패킷을 송수신 하였다.

빠른 송수신으로 인해 데이터에 잡음이 기록되기도 한다. 한 개의 패킷에 기록된 잡음으로 인해 인원수별 판별이 잘이루어지지 않는다. 이러한 문제를 해결하기 위한 데이터 전처리 방법이 k-binding이다.

#### 4.2.2. k-binding

표 2는 1D-CNN 모델에 k-binding 전처리를 한 데이터를 넣은 결과이다. k-binding을 이용한 모든 결과가 평균적인 Recall값이 약 0.01에서 0.02까지 증가하였다. 또한 모든 k-binding 결과들은 최대와 최소 편차가 절반이상으로 감소하였다. k-binding 데이터 전처리는 데이터의 잡음을 제거하고 모델의 학습을 원활하게 한다. 잡음 제거를 통해 성능을 향상시킨다. 가장 성능이 뛰어난 k=15는 15개의 패킷을 묶는다. 이는 750밀리 초 동안의 패킷을 하나로 묶은 결과이다.

#### 4.2.3. 최종 성능 비교

모든 결과의 Recall값은 매우 낮은 결과를 보인다. 성능 향상을 위해 confusion matrix를 이용해 인접한 인원수별로 묶어 Class Recall을 새롭게 도출하였다. confusion matrix란 입력한 실험 데이터를 모델이 어떻게 판별하였는지 표로 출력한 것이다. 0명, 1명, 2~3명, 4~6명 총 4가지 class로 묶어서 Class Recall을 새로이 도출한 결과는 표 2와 같다.

모든 결과에 대해서 Class Recall이 0.8이상으로 올라 갔다. 모델이 판별하는 출력과 데이터의 정답이 다르더 라도 같은 class에 포함된다면 정답이 되어 Recall의 값 이 증가한다. 1D-CNN의 Class Recall은 DNN보다 0.03 높은 성능을 보인다. k-binding 데이터를 학습한 1D-CNN 은 k = 15가 0.855로 Class Recall이 가장 많이 향상되었다.

#### Ⅴ. 결 론

본 논문에서는 딥러닝을 이용한 사람 수 추정에 필요한 데이터 전처리 방식인 k-binding을 제안하고 학습 모델인 1D-CNN을 사용하였다. Cheng[5]등이 제안한 데이터 전처리 및 DNN 모델은 무작위로 행동하는 인원수 추정에 대해서 약 0.56의 낮은 수치를 보였다. 이러한 제약사항을 해결하기 위해 1D-CNN 모델을 사용하였다. 1D-CNN은 학습 데이터를 서브캐리어 인덱스별 특징을 학습하여 인원수를 판별한다. average subtract 데

이터를 학습한 1D-CNN 모델은 평균 0.638까지 성능이 향상 되었다. 하지만 6번의 실험 결과 중 최소와 최대의 오차가 0.12로 컸다.

이러한 오차 문제를 해결하기 위해 데이터 전처리 방식인 k-binding을 사용하였다. 1D-CNN에 k-binding데이터를 학습시킨 결과, 최소와 최대의 오차가 0.06으로 절반 감소하였다. 또한 평균 Recall이 0.649로 성능이 향상되었다. 하지만 이는 실제로 사용하기에는 낮은 성능이다. 다수의 인원을 하나의 class로 묶어서 Recall값을 내는 새로운 지표인 Class Recall을 추가한다. Class Recall은 평균 0.845까지 성능이 향상되었다. 이러한 결과는 IoT서비스에 실제로 사용 가능할 만한 수치이다.

#### **ACKNOWLEDGEMENT**

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIP) (No. 2019R1F1A 1061970).

#### **REFERENCES**

- [1] C. Kim, and S. Choi, "A Camera-Based System for Counting People in Real Time", Korea Institute Of Communication Sciences, vol. 2002, no. 66, pp. 503-506, 2002
- [2] S. Jang, and D. Jung, "Design of a People Counting System using Piezoelectric Sensors", The Korea Institute of Information and Communication Engineering, vol. 9, no. 1, pp. 149-152, 2017.
- [3] H. Li, E. C. L. Chan, X. Guo, "Wi-Counter: Smartphone-Based People Counter Using Crowdsourced Wi-Fi Signal Data", *IEEE Transactions on Human-Machine Systems*, vol. 45, no. 4, pp. 442-452, 2015.
- [4] T. Yoshida, and Y. Taniguchi, "Estimating the number of people using existing WiFi access point in indoor environment", in Proceedings of the 6th European Conference of Computer Science, Italy pp. 46-53, 2015.
- [5] Y. Cheng, and R. Y. Chang, "Device-Free Indoor People Counting Using Wi-Fi Channel State Information for Internet of Things", in Proceedings IEEE Global Communications Conference, Singapore, pp. 1-6, 2017.

- [6] S. D. Domenicon, M. D. Sanctis, and E. Cianca, "A trained-once crowd counting method using differential wifi channel state information", in Proceedings of the 3rd International on Workshop on Physical Analytics, Singapore, pp. 37-42, 2016.
- [7] Atheros CSI Tool[Internet]. Available: https://wands.sg/research/wifi/AtherosCSI/
- [8] TL-WDR4300[Internet]. Available: https://www.tp-link.com/kr/home-networking/wifi-router/tl-wdr4300/.
- [9] keras Documentation[Internet]. Available: https://keras.io/.
- [10] R. Crepaldi, J. Lee, R. Etkin, S. Lee, and R. Kravets, "CSI-SF: Estimating wireless channel state using CSI sampling & fusion" in Proceedings IEEE International Conference on Computer Communications. USA, pp. 154-162, 2012.



안현성(Hyun-seong An) 충북대학교 전자공학부 졸업 충북대학교 전자공학전공 석사 ※관심분야: IoT, 딥러닝, 센서네트워크



김승구(Seung-ku Kim) 고려대학교 전기전자전파공학부 공학사 고려대학교 전자컴퓨터공학과 공학석사

고려대학교 전자컴퓨터공학과 공학석사 고려대학교 전자컴퓨터공학과 공학박사 삼성전자 소프트웨어센터 책임연구원 충북대학교 전자공학부 부교수 ※관심분야: 위치인식, IoT, LPWA