

## 딥러닝을 활용한 실내 사람 수 추정을 위한 WiFi CSI 데이터 전처리와 증강 기법

김연주<sup>1</sup> · 김승구<sup>2\*</sup>

### WiFi CSI Data Preprocessing and Augmentation Techniques in Indoor People Counting using Deep Learning

Yeon-Ju Kim<sup>1</sup> · Seungku Kim<sup>2\*</sup>

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

<sup>2\*</sup>Associate Professor, Department of Electronics Engineering, Chungbuk National University, Cheongju, 28644 Korea

#### 요약

사람 수 추정은 스마트 홈, 스마트 빌딩, 스마트 자동차 등과 같은 응용 서비스를 제공하기 위해 중요한 기술이다. 최근 COVID-19의 영향으로 사회적 거리두기가 시행되면서 사람 수 추정 기술은 새롭게 주목받고 있다. 사람 수 추정 시스템은 서비스 요구사항에 따라 카메라, 센서, 무선 등과 같은 다양한 방법으로 구현 가능하다. WiFi AP를 활용한 사람 수 추정 방식은 다중경로 정보를 반영하는 WiFi CSI를 활용하는 기술로 낮은 비용으로 실내에서 사용하기에 효과적이다. 기존에 제안된 WiFi CSI 기반 사람 수 추정 시스템은 정확도가 낮아 고품질 서비스를 제공하기 어렵다. 본 논문은 WiFi CSI 데이터에 기반한 딥러닝 사람 수 추정 시스템을 제안한다. 오토인코더를 활용한 데이터 전처리 방식, WiFi CSI 데이터를 변형하는 데이터 증강 기법, 그리고 딥러닝 모델링을 통해 추정 정확도를 높인다. 실험 결과 제안하는 시스템은 최대 6명에 대해 89.29%의 정확도를 보였다.

#### ABSTRACT

People counting is an important technology to provide application services such as smart home, smart building, smart car, etc. Due to the social distancing of COVID-19, the people counting technology attracted public attention. People counting system can be implemented in various ways such as camera, sensor, wireless, etc. according to service requirements. People counting system using WiFi AP uses WiFi CSI data that reflects multipath information. This technology is an effective solution implementing indoor with low cost. The conventional WiFi CSI-based people counting technologies have low accuracy that obstructs the high quality service. This paper proposes a deep learning people counting system based on WiFi CSI data. Data preprocessing using auto-encoder, data augmentation that transform WiFi CSI data, and a proposed deep learning model improve the accuracy of people counting. In the experimental result, the proposed approach shows 89.29% accuracy in 6 subjects.

**키워드**: 데이터 증강, 데이터 전처리, 딥러닝, 사람 수 추정

**Keywords**: Data augmentation, Data preprocessing, Deep learning, People counting

Received 17 September 2021, Revised 25 September 2021, Accepted 12 October 2021

\* Corresponding Author Seungku 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.2021.25.12.1890>

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/licenses/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. 서론

IoT의 발전과 스마트 기기 수의 증가로 빅데이터 분석, 수집이 용이해지면서 인공지능 기술을 결합한 스마트빌딩, 스마트홈, 스마트 자동차 등에 대한 수요가 증가하고 있다. 스마트빌딩, 스마트홈은 건물 관리 자동화, 모니터링과 데이터 분석, 에너지 관리 등의 실현을 목표로 한다. 실내 사람 수 추정은 이러한 스마트 빌딩 서비스를 지원하기 위한 필수적인 기술이다. 실내 사람 수 추정이 가능해지면 사람 수에 따른 전력 조정 등으로 에너지 낭비를 줄이고 최적의 실내조건을 유지하는 사람 중심의 서비스를 제공할 수 있다. 한편 최근 코로나 바이러스가 전 세계적으로 유행하면서 방역을 위한 사회적 거리두기가 진행됨에 따라 실내 사람 수 추정 시스템의 필요성이 주목받고 있다. 집합, 모임 등에 제약이 생기고 상가 등의 실내 수용 가능한 인원수가 제한되어, 이러한 방역수칙이 지켜지고 있는 지 감시하기 위해 실시간 실내 인원수 추정 시스템이 활용될 수 있다.

이미지[1], 센서[2], RF 기반[3-7] 방법 등 실내 사람 수 추정을 위한 다양한 기법이 제안되어 왔다. 이미지 기반 방식은 카메라를 통해 사진 또는 영상을 분석하여 사람 수를 추정하는 방식이다. 이미지 기반 방법은 조명의 영향으로 분석이 어려울 수 있으며 사생활 침해가 우려된다는 치명적인 단점이 있다. 센서 기반 방식은 센서를 통과하는 인원을 카운트하는 방식으로 주로 설계된다. 이러한 방식은 센서를 설치하는 초기비용이 발생하는 문제가 있다. RF 기반 방식은 무선신호를 이용하여 사람 수를 추정하는 방식이다. 이미지, 센서 기반 방식과 달리 RF 기반 방식은 조명의 영향, 사생활 침해의 우려가 전혀 없으며 기존에 설치되어있는 AP를 사용할 수 있어 초기 설치 비용 문제 또한 없기 때문에 효과적이다. 초기 연구에는 RF 기반 방식으로 RSSI(Received Signal Strength Indicator)가 널리 사용되었다. 그러나 RSSI는 다중경로 현상에 취약해 실내에서 신호의 지표로 사용하기 적합하지 않다.[5] 최근에는 다중경로 정보를 담고 있는 CSI(Channel State Information)를 대안으로 많은 연구가 진행되고 있다.

WiFi CSI를 사용한 인원 수 추정 방식에 대한 기존 연구가 있었다.[6][7] 그러나 앞선 연구는 사람 수를 대략적으로 추정하는 것을 목표로 클래스 단위의 사람 수를 추정하기 때문에 정확한 인원수에 대한 추정 정확도

를 보장할 수 없다. 이로 인해 최근 중요한 이슈인 방역을 위한 실내 인원 제한 감시용 시스템으로 사용하기 어렵다. 본 논문은 WiFi CSI 기반 사람 수 추정 시스템을 새롭게 제안한다. 제안하는 시스템은 WiFi CSI 데이터를 활용해 딥러닝 학습을 기반으로 실내 사람 수를 추정한다. 사람 수를 정확하게 추정하기 위해 세 가지 방법을 통해 정확도를 높인다. 첫 번째로는 오토인코더를 사용한 데이터 전처리 방법을 제안한다. 딥러닝 학습으로 특징을 자동 추출하는 오토인코더의 특징을 이용하여 WiFi CSI 데이터의 잡음을 효과적으로 제거한다. 두 번째로는 WiFi CSI 데이터를 위한 데이터 증강 방법을 제안한다. 타임워핑, 지터링, 시간반전 방법으로 기존 데이터를 변형한 새로운 학습 데이터를 생성함으로써 오버피팅을 방지한다. 세 번째로는 딥러닝 모델링을 통해 학습모델을 개선하여 정확도를 높인다. 본 논문에서 제안하는 시스템으로 0~6명의 인원을 추정하여 거의 모든 라벨에서 80% 이상, 전체적으로는 최대 89%까지 높은 정확도를 달성했다.

본 논문은 다음과 같이 구성된다. 2장에서는 CSI, 데이터 전처리, 데이터 증강 등 관련 연구를 서술한다. 3장에서는 관련 연구의 문제점을 개선하는 새로운 WiFi CSI 기반 사람 수 추정 시스템을 설계한다. 시스템의 전체적인 구성과 제안하는 데이터 전처리, 증강, 모델링에 대해 상세하게 설명한다. 4장에서는 제안하는 시스템의 성능을 실험하고 평가한 후 5장에서는 결론으로 마무리 짓는다.

## II. 관련 연구

### 2.1. CSI(Channel State Information)

CSI는 다중경로 신호의 채널 주파수 응답 특성을 나타내는 정보이다. 실내에서 WiFi 신호는 반사, 산란, 회절을 거쳐 다중경로 신호로 전송된다. WiFi CSI는 각 다중경로 성분의 진폭, 위상, 지연시간을 포함한다. 실내 환경에서 수신기로 전송되는 WiFi 신호는 다음과 같이 표현된다.

$$h(t) = \sum_{i=1}^N \alpha_i(t) e^{-j\Phi_i(t)} \delta(\tau - \tau_i(t)) \quad (1)$$

$N$ 은 다중경로 신호 성분의 수,  $\alpha_i(t)$ ,  $\Phi_i(t)$ ,  $\tau_i(t)$ 는

각각  $i$ 번째 다중 경로 성분의 진폭, 위상, 지연시간이다. 수식(1)의 고속 푸리에 변환(FFT)는 OFDM 시스템의 채널 주파수 응답 또는 물리계층 CSI에 해당한다.

$$H(n) = [H_1(n), \dots, H_k(n)] \quad (2)$$

$$H_i(n) = |H_i(n)| e^{j\angle H_i(n)} \quad (3)$$

수신기에서 측정할 수 있는 채널에 대한 지표는 RSSI, CSI 등이 있다. 초기에는 RSSI를 활용한 접근법이 주로 연구되었으나 최근 많은 연구에서는 다중경로 정보를 반영하는 CSI가 널리 사용되고 있다.[8] WiFi CSI를 사용한 사람 수 추정 방법을 제안한 기존 논문은 특징 추출을 거친 CSI 데이터를 Linear discriminant classifier로 판별하여 라벨이 0명, 1명, 2명, 3~4명, 5~7명인 데이터를 구별했고 최대 74%의 정확도를 보였다.[6]

## 2.2. 데이터 전처리

데이터 수집 시 얻을 수 있는 원 데이터는 분석을 위한 데이터가 아니기 때문에 원 데이터로 머신러닝 학습을 한다면 부정확한 결과가 나올 수 있다. 따라서 결측치 처리, 이상치 처리, 잡음 제거 등의 데이터 전처리 과정이 필요하다. 전처리 결과에 따라 학습 결과가 크게 달라지기 때문에 이는 딥러닝 기반 시스템에서 매우 중요한 과정이다.

WiFi CSI 데이터의 잡음 제거에 대해  $k$ 개의 인접한 값을 묶어 새로운 데이터를 만드는  $k$ -binding이라는 전처리 방식이 제안되었다. WiFi CSI 데이터는 WiFi AP로부터 빠르게 전달되므로 인접한 값끼리 평균을 내는 방법을 통해 신호의 노이즈를 제거할 수 있다.[7]

WiFi CSI 기반 신원 식별 시스템에서 WiFi CSI 원 신호의 노이즈를 제거하기 위해 PCA(Principle Component Analysis)와 저역통과필터를 사용하는 방법이 제안되었다. CSI 데이터 수집 시 수집한 데이터와 전송 ICMP 패킷의 수 간의 불일치를 보간하기 위해 PCA를 사용한 특징 추출 및 데이터 재구성을 구현했고, 차단 주파수 10Hz의 저역통과필터를 사용하여 데이터에서 불필요한 고주파 노이즈를 제거했다.[9]

WiFi CSI 데이터 전처리 과정에서 DBSCAN (Density-Based Spatial Clustering of Applications with Noise) 알고리즘을 사용하는 방법이 제안되었다. DBSCAN은 밀도 기반의 클러스터링 알고리즘으로 이상값을 추출하

는 데 일반적으로 사용된다. 해당 논문은 DBSCAN을 적용하여 WiFi CSI 데이터의 이상값을 제거했다.[10]

## 2.3. 데이터 증강

딥러닝 기반 시스템이 높은 정확도를 달성하기 위해서는 많은 양의 학습 데이터가 필요하다. 그러나 실험을 통해 데이터를 얻고 라벨링 하는 과정에는 많은 시간과 비용이 들기 때문에 적합한 양의 학습 데이터 수를 확보하기 어렵다. 또한 적은 양의 데이터로 학습할 경우 오버피팅(overfitting) 문제가 발생하기 쉽다. 학습 데이터의 수를 늘리기 위한 대표적인 해결 방법은 데이터 증강이다. 데이터 증강은 정확한 라벨을 유지하면서 기존 데이터를 변형하여 새로운 데이터를 생성하는 방법이다.

AlexNet은 오버피팅을 줄이기 위해 데이터 증강을 적용했다. 이미지 변환 및 좌우반전, RGB 변환을 통한 이미지 데이터 증강 방법을 적용했다. 사이즈가  $256 \times 256$ 인 이미지로부터 무작위로  $224 \times 224$  패치를 추출하고 좌우반전 등을 적용하여 새로운 데이터 생성한 결과 2048배까지 학습 데이터 크기를 증가시켰다.[11]

Terry T. U.의 연구는 파킨슨병 환자 모니터링에 사용할 수 있는 웨어러블 센서 데이터의 여러 가지 증강 방법을 제안했다. 파킨슨병 환자는 손발이 떨리거나 움직임이 느려지는 등 이상행동장애를 보이는데, 이러한 증상을 모니터링하여 약물 투여량을 결정하기 위해 웨어러블 센서를 사용한 딥러닝 기반 모니터링 자동화 시스템이 제안되었고 이를 위한 대량의 데이터를 얻을 수 있는 데이터 증강 방법을 제안했다. 가속도 센서 데이터에 대해 Permutation, Jittering, Scaling, Rotation, MagWarp, TimeWarp, Cropping 등의 방법으로 라벨이 변하지 않는 새로운 데이터를 생성했고 만들어진 데이터를 평가했다.[12]

## III. CSI 기반 사람 수 추정 시스템

본 논문에서는 CSI 기반 사람 수 추정 시스템을 제안한다. 제안하는 시스템의 전체적인 구조는 그림 1과 같다. 먼저 데이터 수집 단계에서는 각각 송신기와 수신기의 역할을 하는 AP 두 대가 설치된 실내에서 WiFi CSI 데이터를 수집한다. 이때 수집된 데이터는 원 데이터로 바로 학습에 사용하기 어렵다. 따라서 전처리 과정으로

오토인코더를 통한 특징 추출 및 잡음 제거를 수행한다. 데이터 증강 단계에서는 학습에 사용할 데이터 수를 늘리고, 그 후 데이터를 세그먼트 단위로 나누어 딥러닝 모델에 학습한다.

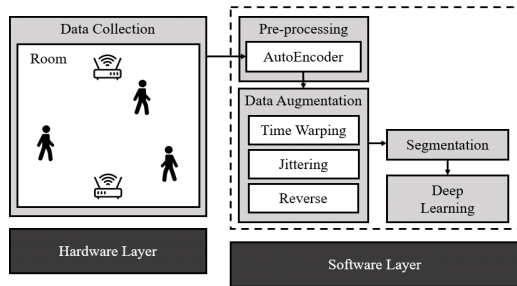


Fig. 1 The Architecture of WiFi CSI based People Counting System

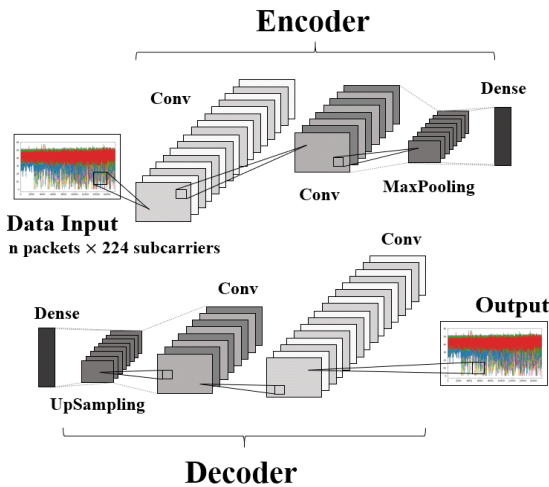


Fig. 2 The Architecture of Data Pre-processing Model

3.1. 데이터 전처리(Pre-processing)

데이터 전처리 단계에서 오토인코더를 사용해 WiFi CSI 데이터의 노이즈 제거 및 특징 추출을 효과적으로 수행하는 방법을 제안한다. 실내에서 여러 명의 사람을 수용한 WiFi CSI 데이터의 경우, 원본데이터에서 육안으로 또는 직관적으로 그 특성을 알아내기 쉽지 않다. 따라서 딥 러닝 학습을 통한 전처리 방식을 사용한다. 오토인코더는 이미지 데이터의 특징 추출 및 노이즈 제거에 널리 이용되는 딥 러닝 모델이다. 인코더와 디코더의 두 단계로 구성되어, 노드 수가 줄어든 은닉층을 통과하여 출력신호에서 초기 입력신호를 복구하도록 설

계된다. 차원 축소 과정에서 특징을 추출하고 추출한 특징으로부터 원본 신호를 복원해내는 과정에서 사람이 직접 관찰하기 어려운 특징을 자동으로 추출할 수 있다. 본 논문에서 WiFi CSI 데이터 전처리를 위해 제안하는 오토인코더 모델은 그림 2와 같다. 인코더 부분은 Convolution layer와 maxpooling layer로 차원을 줄이도록 구현했다. 디코더는 인코더의 입력 부분과 같은 모양이 되도록 재현하는 부분으로 Upsampling layer와 Convolution layer를 사용해 인코더와 대칭되는 형태를 구성했다. 데이터 수집 단계에서 수집된 WiFi CSI 데이터를 정규화(normalization)로 스케일링한 후 오토인코더의 입력으로 사용한다. 그 후 출력 부분에서 재구성된 데이터를 통해 학습을 진행한다.

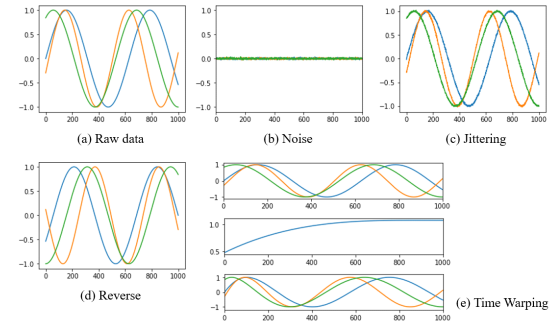


Fig. 3 The Experiments of Data Augmentation for random data

3.2. 데이터 증강(Data Augmentation)

사람 수 추정 시스템을 구현하기 위해서는 여러 사람 수에 대한 각각의 데이터가 필요하기 때문에 반복적으로 많은 실험을 해야 하는 번거로움이 있으며, 데이터에 라벨링하는 과정에도 많은 시간과 비용이 든다. 데이터 증강을 활용한다면 데이터 수를 임의로 늘려 데이터 수집의 어려움을 해결할 수 있다. 본 논문에서는 WiFi CSI 데이터 증강을 위한 방법으로 지터링, 시간반전, 타임워핑을 제안한다.

그림3은 제안하는 데이터 증강 방법의 예시이다. 그림 3의 (a)는 데이터 증강을 설명하기 위한 예제 데이터이며 (b), (c), (d), (e)는 예제 데이터로부터 변형한 증강 데이터를 설명하기 위한 그림이다. 그림3의 (b)와 (c)는 지터링 방식을 보여준다. 지터링 방식은 노이즈 제너레이터를 통해 신호 세기가 작은 가우시안 노이즈를 생성하여 원래 신호에 더해주는 방식이다. 그림3의 (b)는 생성한

가우시안 노이즈, (c)는 원래 신호 (a)에 노이즈를 더하여 변형한 신호이다. (d)는 원래 신호 (a)에 시간반전을 적용한 예시이다. 시간 순서를 완전히 뒤집어 새로운 데이터를 생성한다. (e)는 타임워핑의 예시이다. 랜덤한 신호를 생성하고, 원래 신호와 생성한 랜덤 신호를 보간하는 방법으로 원래 신호보다 느려지거나 빨라지는 새로운 데이터를 생성한다. 그림4는 사람 수 추정에 사용되는 WiFi CSI 데이터에 데이터 증강 방법을 적용하여 시각화한 그래프이다. WiFi CSI 데이터는 실내에서 무작위로 움직이는 사람들에 대한 시나리오로 수집되었다. 해당 데이터에 대해 타임워핑을 적용하여 데이터의 시간이 느려지거나 빨라지도록 변한다면 사람들이 움직이는 속도가 느려지거나 빨라지는 효과와 같으며 라벨에는 영향을 주지 않는다고 가정했다. 그림 4의 (c)는 그러한 타임워핑 방식을 적용하여 만든 WiFi CSI 데이터의 예시이다. 지터링 방식을 통해 증강한 데이터는 그림 4의 (a)에 나타내었다. 지터링은 신호에 가우시안노이즈를 추가하여 구현했다. 생성한 노이즈는 원래 신호보다 작은 값을 가지므로 사람 수 추정을 위한 데이터를 손상시키지 않을 것이다. 시간반전 방식은 원래 데이터의 시간 순서를 완전히 반대로 뒤집는 방식으로, WiFi CSI 데이터에 적용하여 그림4의 (b)에 나타냈다. 무작위로 움직이는 사람들에 대해 수집된 데이터는 그 순서가 반대로 뒤집힌다면 원래 신호와 반대방향으로 움직이는 사람들에 대해 수집된 데이터와 유사할 것이다.

### 3.3. 딥러닝 모델

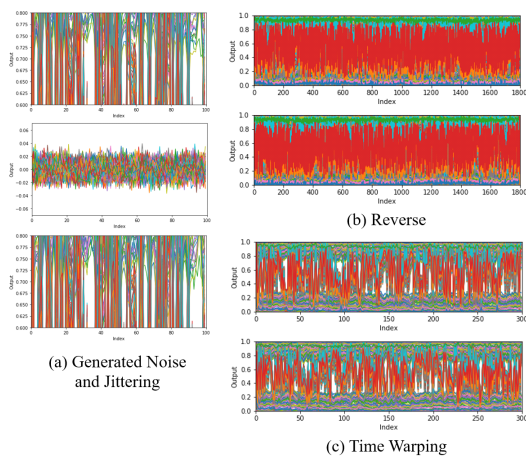


Fig. 4 The Experiments of Data Augmentation for WiFi CSI Data

학습을 위한 딥러닝 모델은 LSTM 레이어로 구성했다. 입력 부분에서는  $(n \times 60 \times 224)$ 와 같은 형태로 데이터를 입력받는다. 논문에서 사용하는 CSI 데이터는 한 패킷 당 224개의 서브캐리어를 가지며, 초당 20개의 패킷이 수집되었다. 224개의 서브캐리어로 구성된 패킷들을 3초 단위, 즉 60개의 패킷 단위로 묶어 n개의 데이터에 대하여 입력받도록 한다. 출력은 0~6명의 사람 수를 추정하도록 softmax로 구현했다. 손실 함수는 다중분류 손실함수를 사용했으며, 옵티마이저는 adam으로 구현했다.

## IV. 실험 및 평가

본 논문에서 제안하는 CSI 기반 사람 수 추정 시스템을 평가하기 위해 TP-LINK TL-WDR4300으로 수집한 WiFi CSI 데이터를 사용했다. 사용한 WiFi CSI 데이터는 주파수 채널은 2.4GHz, 송신전력 20dB, 224개의 서브캐리어로 초당 20개의 패킷을 송수신하여 수집되었다. 시스템은 다음과 같이 평가한다. 1)전처리 성능 평가. 제안하는 전처리 방식과 데이터 정규화 외의 전처리를 하지 않은 데이터, 저역통과필터로 잡음 제거한 데이터를 시각화하여 비교하고 각각의 데이터를 학습할 시 정확도를 비교 및 평가한다. 2)데이터 증강 평가. 제안한 세 가지 데이터 증강 방식이 원본 데이터와 비슷한 데이터를 만들어내는지 평가한다. 데이터 증강으로 학습 데이터가 늘어남에 따라 평가 정확도가 얼마나 상승하는지 그래프로 비교하여 평가한다. 3)모델 평가. 다른 모델과 성능을 비교 및 평가한다. 전처리 유무와 증강 전후 결과까지 포함하여 모델에 따른 정확도 상승을 객관적으로 평가한다.

### 4.1. 전처리 성능 평가

그림 5는 실내 인원 수가 0명인 데이터의 전처리 전후 각각의 그래프이다. (a)는 원본 데이터에 정규화만을 적용한 그래프이며, (b)와 (c)는 각각 차단 주파수를 10Hz와 20Hz로 설정하여 저역통과필터를 적용하여 전처리한 그래프이다. (d)는 본 논문에서 제안하는 오토인코더를 사용하여 전처리했다. 저역통과필터는 신호처리에 널리 사용되는 필터로, 고주파 영역을 잡음으로 처리하여 제거하는 역할을 한다. 실험에서는 제안하는 오토



인코더와 성능 비교를 위해 사용한다. (b)와 (c)의 그래프는 필터에 통과시키기 전인 (a)와 비교하여 고주파 영역이 삭제된 것을 확인할 수 있다. 오토인코더는 데이터에서 특징을 학습하여 데이터를 재구성한다. 이러한 과정을 통해 신호 데이터에서 사람이 직관적으로 파악하기 어려운 특징을 자동으로 추출해주는 역할을 할 수 있다. (d)는 그러한 자동 추출 및 잡음 제거 결과이다.

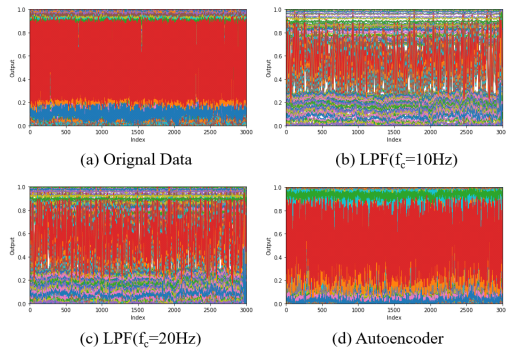


Fig. 5 The Experiments of Data Pre-processing for WiFi CSI Data

각 전처리 방법으로 잡음 제거한 데이터로 딥러닝 학습 후 정확도를 비교하여 표 1에 나타냈다. 저역통과필터는 차단주파수가 20Hz인 경우는 정확도가 61.9%로 잡음 제거 전 62.86%였던 것과 비교하여 정확도가 낮아졌다. 차단주파수가 10Hz인 저역통과필터의 경우 필터 통과 전과 비교하여 62.86%에서 67.62%로 정확도가 상승했다. 오토인코더를 사용한 전처리 방식은 73.57%로 잡음 제거 전과 비교하여 정확도가 상승했다. 비교 결과 WiFi CSI 데이터의 잡음제거 시 저역통과필터의 경우 차단주파수 10Hz를 사용할 경우 유용했으며 오토인코더 또한 효과적임을 알 수 있다. 차단주파수 10Hz의 저역통과필터와 오토인코더를 비교할 때 오토인코더를 사용한 전처리 방식이 정확도 개선 성능이 뛰어났다. 이는 고주파를 제거함에 따라 사람 수 추정에 유용한 정보

Table. 1 The accuracy Based on Data Pre-processing for WiFi CSI

pre-processing	accuracy (%)
W/O noise-removal	62.86
W/ LPF (fc=10)	67.62
W/ LPF (fc=20)	61.90
W/ autoencoder	73.57

를 잃게 할 수 있으며 오토인코더를 사용한 자동 특징 추출 방법은 그보다 효과적으로 잡음을 제거할 수 있다고 해석 가능하다.

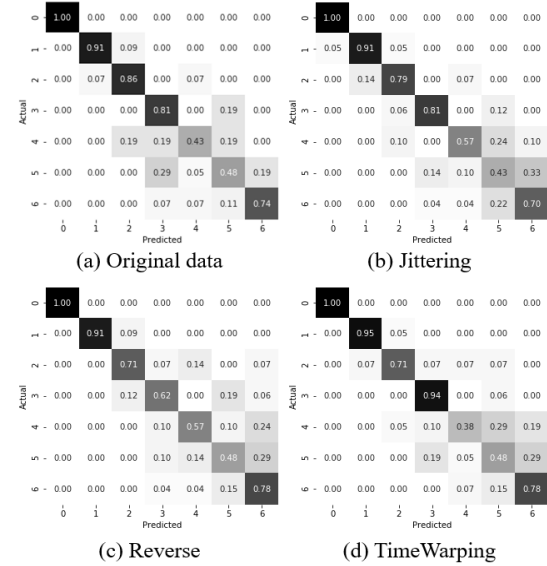


Fig. 6 Confusion Matrix According to Data Augmentation Methods

#### 4.2. 데이터 증강 성능 평가

본 논문에서 제안하는 데이터 증강 방식을 평가하기 위해 각 방식의 데이터 변형 과정이 데이터의 라벨(즉, 사람 수)에 대해 끼치는 영향에 대해 고찰했다. 또한 증강에 쓰인 데이터와 증강이 적용된 데이터를 각각 딥러닝 모델에 학습하고 정확도를 비교하여 데이터가 유사하다는 사실을 입증했다. 데이터 증강으로 학습 데이터 수를 많이 늘릴수록 정확도가 어떻게 변하는지를 비교하여 데이터 증강의 성능을 평가했다.

그림 6은 기존 데이터 또는 증강한 데이터로 학습 후 평가한 confusion matrix이다. (a)는 증강 방법을 적용하지 않은 데이터, (b), (c), (d)는 제안한 증강 방식을 통해 변형한 데이터를 사용해 학습한 후 같은 평가 데이터로 사람 수를 예측한 결과이다. 모두 420개의 데이터로 학습하고 140개의 데이터로 평가했다. 원본 데이터인 (a)에 대한 평가 정확도는 73.57%였으며 타임워핑으로 데이터를 변형한 (b)는 74.29%, 지터링으로 변형한 (c)는 73.57%, 시간반전으로 변형한 (d)는 72.86%의 평가 결과를 얻었다. 증강한 데이터로 학습할 때 원본 신호로

학습한 경우와 비슷한 정확도로 결과가 나타났으며 이 결과는 제안하는 데이터 증강 방법을 사용하여 라벨을 훼손시키지 않고 새로운 데이터를 생성할 수 있다는 것을 증명한다.

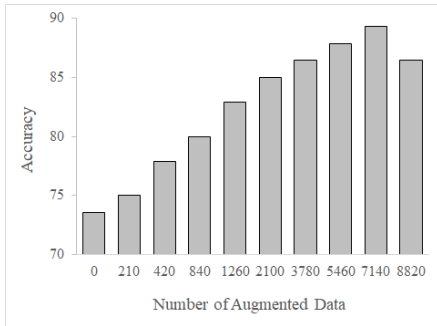


Fig. 7 Accuracy per Number of Augmented Data

그림 7은 420개의 기존 데이터에 데이터 증강을 통해 학습 데이터를 늘렸을 때 학습이 끝난 후 평가 정확도 결과이다. 0인 경우는 증강 데이터가 0개, 즉 증강 데이터를 포함하지 않은 경우로 평가 결과 정확도는 73.57%로 나타났다. 증강 데이터가 원본데이터의 17배로 늘어날 때까지 평가 정확도는 점점 증가하며, 420개의 기존 데이터에 7140개의 증강 데이터를 더하여 총 7560개의 데이터로 학습하는 경우에서 89.29%로 가장 높은 정확도를 달성한다. 증강 데이터 8820개를 학습 데이터에 포함한 경우에는 7140개의 증강 데이터를 사용했을 때보다 평가 정확도가 떨어졌다. 기존 데이터만을 사용하여 학습할 때보다는 여전히 성능이 개선됐으나, 7140개의 증강 데이터를 사용하는 경우에 가장 좋은 성능을 달성한다. 2100, 3780, 5460, 7140, 8820개의 증강 데이터를 학습 데이터에 포함시키는 경우 평가 정확도가 85% 이상으로 나타났고, 원하는 성능을 얻기 위해 학습 데이터의 9배~21배 만큼의 증강 데이터를 활용할 수 있을 것이다.

### 4.3. 모델 비교 및 최종 평가

전처리 방법, 증강 유무까지 포함하여 다양한 모델의 평가 결과를 표 2에 제시했다. 같은 전처리, 데이터 증강을 적용하는 모든 경우에서 LSTM 모델이 가장 뛰어난 성능을 보였다. 저역통과필터로 잡음 제거한 데이터는 다른 데이터와 비교할 때 데이터 증강에 인한 정확도 상승 폭이 작았다. 잡음 제거를 하지 않은 데이터에 대해 DNN 모델로 학습하는 경우, 증강 유무에 따라 정확도

상승 폭이 가장 컸다. 오토인코더로 전처리한 데이터에 대해 데이터 증강을 적용하고 LSTM 모델로 학습하는 경우 목표했던 높은 정확도를 달성했다. 그림 8에 제안하는 시스템의 평가 정확도를 confusion matrix로 나타내었다. 라벨이 4명인 경우를 제외한 모든 경우에서 80% 이상의 예측 정확도를 보였고, 전체 89.29%로 높은 정확도를 달성했다.

Table. 2 Accuracy of Final Result

model	preprocessing	accuracy(%)	
		augmentation	
		W/O	W/
DNN	W/O noise removal	51.43	76.43
	W/ LPF	65	68.57
	W/ Autoencoder	69.29	83.57
CNN	W/O noise removal	54.29	65
	W/ LPF	63.57	68.57
	W/ Autoencoder	67.14	78.57
LSTM	W/O noise removal	62.86	75
	W/ LPF	67.62	70.71
	W/ Autoencoder	73.57	89.29




Fig. 8 Confusion Matrix of Final Result

## V. 결론

본 논문은 WiFi CSI 데이터 기반 사람 수 추정 시스템을 위한 데이터 전처리 기법과 증강 기법, 효과적인 학습 모델을 제안했다. 제안하는 기법을 적용한 최종 결과 약 89%의 높은 정확도를 달성했다. 제안하는 전처리, 증강 기법을 상세히 평가하여 다양한 모델에서 효과적임을 증명했다. 제안하는 방법은 CSI 데이터뿐만 아니라

라 다양한 시계열 데이터 처리에 활용될 수 있을 것이다.

본 논문에서는 단일모델만으로 평가했으나 앙상블 학습 등 다수의 모델을 활용하여 모델링을 통한 성능 개선이 이루어질 수 있으므로 향후 연구할 가치가 있다. 또한 표 2에서 데이터 증강에 따른 성능 향상이 조건에 따라 편차가 나타났다. 잡음 제거 과정을 적용하지 않은 데이터의 경우 데이터 증강을 통해 학습 데이터를 늘렸을 때 정확도 상승이 컸다. 이런 경우 증강 데이터를 포함하기 전 정확도가 매우 낮았기 때문에 전 후 비교 시 극적인 효과를 보일 수 있다. 다른 전처리 방식을 적용하는 경우와 비교하여 지역통과필터로 전처리한 데이터의 경우에는 학습 시 증강 데이터를 포함할 때의 정확도 상승이 모든 모델에서 현저히 적었다. 이에 대한 성능을 더 개선하기 위해서는 향후 연구가 필요할 수 있다.

최근 코로나 19의 유행이 끝나지 않으면서 사회적 거리두기 또한 지속되고 있다. 실내 인원 제한 준수를 위해 제안하는 시스템이 활용될 수 있을 것이다.

### ACKNOWLEDGEMENT

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIP) (No. 2019R1F1A1061970).

### 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 ] S. Depratla, A. Muralidharan, and Y. Mostofi, "Occupancy estimation using only wifi power measurements," *IEEE Journal on Selected Areas in Communications*, vol. 33, no. 7, pp. 1381-1393, July. 2015.

[ 4 ] Y. Yuan, J. Zhao, C. Qiu, and W. Xi, "Estimating crowd density in an rf-based dynamic environment," *IEEE Sensors Journal*, vol. 13, no. 10, pp. 3837-3845, Oct. 2013.

[ 5 ] Z. Yang, Z. Zhou, and Y. Liu, "From RSSI to CSI: Indoor

localization via channel response," *ACM Computing Surveys*, vol. 46, no. 2, pp. 1-32, Nov. 2013.

[ 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*, pp. 37-42, June. 2016.

[ 7 ] H. An and S. Kim, "A Deep Learning Based Device-free Indoor People Counting Using CSI," *The Korea Institute of Information and Communication Engineering*, vol. 24, no. 7, pp. 935-941, Jul. 2020.

[ 8 ] H. Mo and S. Kim, "A Deep Learning-Based Human Identification System With Wi-Fi CSI Data Augmentation," in *IEEE Access*, vol. 9, pp. 91913-91920, 2021.

[ 9 ] J. Lv, W. Yang, and D. Man, "Device-free passive identity identification via WiFi signals," *Sensors*, vol. 17, no. 11, pp. 2520-2536, 2017.

[ 10 ] Y. Yoo, J. Suh, Y. Lee, S. Kang, B. Kim, and S. Bahk, "Privacy-preserving People Counting with Channel State Information," in *2020 International Conference on Information and Communication Technology Convergence (ICTC), IEEE*, pp. 753-755, 2020.

[ 11 ] A. Krizhevsky, I. Sutskever, and G. E. Hinton. "Imagenet classification with deep convolutional neural networks," in *Advances in neural information processing systems*, pp. 1097-1105, 2012.

[ 12 ] T. T. Um, F. M. J. Pfister, D. Pichler, S. Endo, M. Lang, S. Hirche, U. Fietzek, and D. Kulić, "Data Augmentation of Wearable Sensor Data for Parkinson's Disease Monitoring using Convolutional Neural Network," in *Proceedings of the 19th ACM International Conference on Multimodal Interaction*, pp. 216-200, 2017.

#### 김연주(Yeon-Ju Kim)



2020년 충북대학교 전자공학부 공학사  
2020년~ 현재 충북대학교 전자공학 석사과정  
※관심분야: 인공지능, IoT

#### 김승구(Seungku Kim)



2007년 2월: 고려대학교 전기전자전파공학부 공학사  
2010년 2월: 고려대학교 전자컴퓨터공학과 공학석사  
2013년 8월: 고려대학교 전자컴퓨터공학과 공학박사  
2013년 9월~2015년 8월: 삼성전자 소프트웨어센터 책임연구원  
2015년 9월~현재: 충북대학교 전자공학부 부교수  
※관심분야: 모바일 컴퓨팅, IoT, Wireless Networks