

채널 상태 정보를 활용한 LoS/NLoS 식별 기반 인간 행동 인식 시스템

권혁돈¹, 권정혁², 이솔비², 김의직^{3*}

¹한림대학교 소프트웨어학부 학사과정, ²한림대학교 스마트컴퓨팅연구소 연구교수, ³한림대학교 소프트웨어학부 부교수

LoS/NLoS Identification-based Human Activity Recognition System Using Channel State Information

Hyeok-Don Kwon¹, Jung-Hyok Kwon², Sol-Bee Lee², Eui-Jik Kim^{3*}

¹B.S. Course, Division of Software, Hallym University

²Research Professor, Smart Computing Laboratory, Hallym University

³Associate Professor, Division of Software, Hallym University

요약 본 논문에서는 수신환경에 따라 변화하는 인간 행동 인식 (Human Activity Recognition, HAR)의 정확도를 향상시키기 위해 채널 상태 정보 (Channel State Information, CSI)를 활용한 Line-of-Sight (LoS)/Non-Line-of-Sight (NLoS) 식별 기반 HAR 시스템을 제안한다. 제안 시스템은 수신환경을 고려한 HAR 시스템을 위해 Preprocessing phase, Classification phase, Activity recognition phase의 세 동작 단계를 포함한다. Preprocessing phase에서는 CSI 원시 데이터로부터 진폭이 추출되고, 추출된 진폭 내 노이즈가 제거된다. Classification phase에서는 데이터 수신환경이 LoS 환경 또는 NLoS 환경으로 분류되고, 수신환경 분류 결과를 기반으로 HAR 모델이 결정된다. 마지막으로, Activity recognition phase에서는 결정된 HAR 모델을 활용하여 인간의 동작을 앉기, 걷기, 서 있기, 부재중으로 분류한다. 제안 시스템의 우수성을 입증하기 위해, 실험적 구현을 수행하였으며 제안 시스템의 정확도를 기존 HAR 시스템의 정확도와 비교하였다. 실험 결과, 제안 시스템은 대조군 대비 16.25% 더 높은 정확도를 달성하였다.

주제어 : 머신러닝, 수신환경 분류, 인간 행동 인식, 채널 상태 정보, LoS/NLoS 식별

Abstract In this paper, we propose a Line-of-Sight (LoS)/Non-Line-of-Sight (NLoS) identification-based Human Activity Recognition (HAR) system using Channel State Information (CSI) to improve the accuracy of HAR, which dynamically changes depending on the reception environment. To consider the reception environment of HAR system, the proposed system includes three operational phases: Preprocessing phase, Classification phase, and Activity recognition phase. In the preprocessing phase, amplitude is extracted from CSI raw data, and noise in the extracted amplitude is removed. In the Classification phase, the reception environment is categorized into LoS and NLoS. Then, based on the categorized reception environment, the HAR model is determined based on the result of the reception environment categorization. Finally, in the activity recognition phase, human actions are classified into sitting, walking, standing, and absent using the determined HAR model. To demonstrate the superiority of the proposed system, an experimental implementation was performed and the accuracy of the proposed system was compared with that of the existing HAR system. The results showed that the proposed system achieved 16.25% higher accuracy than the existing system.

Key Words : Machine learning; Reception environment categorization; Human activity recognition; Channel state information; LoS/NLoS identification

본 연구는 2022년도 중소벤처기업부의 기술개발사업 지원에 의한 연구임 [S3278476]. 이 논문은 2020년도 정부 (교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (No. 2020R111A3052733). 이 성과는 정부 (과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2021R1C1C2095696). 본 논문은 교육부와 한국연구재단의 재원으로 지원을 받아 수행된 3단계 산학연협력 선도대학 육성사업 (LINC 3.0)의 연구결과입니다.

*교신저자 : 김의직 (ejkim32@hallym.ac.kr)

접수일 2024년 05월 15일 수정일 2024년 05월 30일 심사완료일 2024년 06월 10일

1. 서론

인간 행동 인식 (Human Activity Recognition, HAR)은 다양한 방법으로 수집된 데이터를 분석하여 사람의 행동을 인식하는 기술로, 스마트 홈, 안전관리, 헬스케어와 같은 다양한 산업 분야에서 침입자 탐지, 낙상감지, 환자 모니터링 등의 서비스를 지원하기 위한 핵심 기술로 고려되고 있다 [1]. 대부분의 HAR 관련 연구에서는 행동 인식을 위한 데이터 수집을 위해, 센서와 컴퓨터 비전이 주로 활용된다. 센서 기반 HAR은 웨어러블 디바이스에 내장된 이기종 센서를 통해 데이터를 수집하고 해당 데이터를 분석한다 [2]. 따라서, HAR을 위한 전용 디바이스 구매와 정기적인 유지보수가 필수적으로 요구된다. 컴퓨터 비전 기반 HAR은 카메라를 활용하여 이미지 데이터를 수집하고 이를 분석한다 [3]. 그러나, 조도가 낮은 환경에서 활용이 어려울 수 있으며, 수집 장소에 따라 사생활 침해 문제가 발생 될 수 있다. 센서 및 컴퓨터 비전 기반 HAR의 문제점을 해결하기 위해, 최근에는 무선 신호 기반 HAR에 대한 연구가 활발히 진행되고 있다.

무선 신호 기반 HAR은 Wi-Fi Access Point (AP)와 같은 상용 디바이스에서 주기적으로 발생하는 무선 신호를 활용하여 행동을 인식하기 때문에 앞서 언급한 전용 디바이스 구매 및 유지보수, 데이터 수신환경, 사생활 침해 문제를 해결할 수 있다. 구체적으로 무선 신호 기반 HAR은 행동에 따라 변화하는 무선 신호의 왜곡 패턴을 분석하여 사람의 행동을 인식한다. 대표적으로 사용되는 무선 신호로 Received Signal Strength Indicator (RSSI)와 채널 상태 정보 (Channel State Information, CSI)가 주로 고려된다. RSSI 기반 HAR은 사람의 행동으로 인해 변화된 RSSI 값을 이용해 행동을 인식한다 [4]. 그러나, RSSI는 단일 반송파의 수신 강도에 대한 정보만 제공하기 때문에 고려할 수 있는 정보가 제한적이다. 이에 무선 신호의 다양한 특성을 활용하기 위해 CSI 기반 HAR이 최근 주목받고 있다. CSI는 단일 반송파를 다수의 부반송파로 분할하여 세분화된 정보를 제공하기 때문에 RSSI 대비 행동 인식 측면에서 높은 정확도 성능을 갖는다 [5]. 그러나, 무선 신호 기반 HAR은 주변 환경이나 장애물에 의해 다중 경로 페이딩 및 신호 세기 감쇄로 신호 왜곡이 발생된다. 이러한 문제점을 해결하기 위해 데이터 수신환경을 고려한 행동 인식 연구가 활발히 수행되고 있다 [6].

일반적으로, 데이터 수신환경은 Line-of-Sight (LoS) 환경과 Non-Line-of-Sight (NLoS) 환경으로 구분된

다. LoS 환경은 디바이스와 수신기 사이에 가시선이 확보된 상황을 의미하고, NLoS 환경은 디바이스와 수신기 사이에 가시선이 확보되지 않은 상황을 의미한다. 대부분의 기존 연구에서는 데이터 수신환경이 LoS 환경과 NLoS 환경으로 구분되었으며, 각 환경에서 HAR을 수행하는 실험을 진행하였다. 이후, LoS 환경과 NLoS 환경 각각에서 수신된 데이터를 기반으로 HAR 모델을 제안하였다. 그러나, 이러한 HAR 모델은 데이터 수신환경이 달라지면 학습 데이터와 다른 수신 신호 세기의 변화로 인해 행동 인식 정확도가 감소할 수 있다.

본 논문에서는 CSI 기반 HAR 시스템을 제안한다. 제안하는 시스템은 수신환경에 따라 변화하는 HAR 시스템의 성능 저하 문제를 해결하기 위해 LoS/NLoS 식별 (Identification) 모델을 사용하여 수신환경에 관계없이 행동 인식 정확도를 향상시키는 것을 목표로 한다. 제안 시스템은 Preprocessing phase, Classification phase, Activity recognition phase로 구성된다. Preprocessing phase는 CSI 데이터에서 HAR에 적합한 특징을 추출한다. 이후, 데이터에 포함된 노이즈를 제거하는 과정을 거친다. Classification phase는 데이터 수신환경을 LoS 환경 또는 NLoS 환경으로 구분하고, 데이터 수신환경에 따라 HAR 모델을 선택한다. 이를 위해 LoS/NLoS identification 모델과 Model decision 모듈이 사용된다. LoS/NLoS identification 모델은 데이터 수신환경을 고려하기 위해 노이즈가 포함된 데이터를 사용한다. Model decision 모듈은 수신환경 분류 결과값과 노이즈가 제거된 데이터를 입력받아 수신환경에 적합한 HAR 모델을 선택하고 노이즈가 제거된 데이터를 입력값으로 사용한다. Activity recognition phase는 데이터 수신환경을 기반으로 학습한 LoS/NLoS 기반 HAR 모델을 이용한다. LoS/NLoS 기반 HAR 모델은 사람의 행동을 앉기, 걷기, 서 있기, 부재증으로 분류한다. 제안 시스템에 포함된 모델은 순환신경망 (Recurrent Neural Network, RNN) 기반 Gated Recurrent Unit (GRU)을 사용하였다. 제안 시스템을 구현하기 위해 TensorFlow와 Keras를 사용하였다. 또한, 제안 시스템의 우수성을 입증하기 위해 대조군과의 행동 인식 정확도를 비교하였다. 대조군은 데이터 수신환경을 고려하지 않고, 제안 시스템에 포함된 HAR 모델과 동일하게 설정하였다. 그 결과, 제안 시스템은 대조군 대비 16.25% 더 높은 행동 인식 정확도를 달성하였다.

본 논문은 다음과 같이 구성된다. 2장에서는 HAR 관련 연구에 관해 서술한다. 3장에서는 CSI 기반 HAR 시

시스템을 설명한다. 4장에서는 실험 환경 및 결과를 서술한다. 마지막으로 5장에서 결론을 맺는다.

2. 관련 연구

본 장에서는 기존에 제안된 CSI 기반 HAR 연구에 관해 서술한다. CSI 기반 HAR 연구들은 데이터 수신환경을 LoS 환경과 NLoS 환경으로 구분한다. LoS 환경은 신호 발생기와 수신기 사이의 장애물이 존재하지 않아 노이즈의 영향이 적은 상황에서의 행동 인식을 고려하며, NLoS 환경은 장애물에 의해 노이즈가 심한 상황에서의 행동 인식을 고려한다.

2.1 LOS 환경을 고려한 HAR 기법

J. Ding and Y. Wang의 연구에서 저자는 LoS 환경에서 수신된 CSI 데이터를 기반으로 사람의 행동을 예측하는 Human Activity Recognition approach using deep Recurrent Neural Network (HARNN) 모델을 제안하였다 [7]. HARNN 모델은 2개의 의사결정 모듈로 구성된다. 첫 번째 의사결정 모듈은 CSI 데이터의 분산과 상관계수를 기반으로 사람에 의한 환경변화를 감지한다. 이후, 두 번째 모듈은 행동 변화를 인식하기 위해 Long Short-Term Memory (LSTM) 기반 모델을 사용한다. B. A. Alsaify et al.의 연구에서 저자는 Support Vector Machine (SVM)을 이용하여 사람의 행동을 인식하는 HAR을 시스템을 제안하였다 [8]. 또한, 저자는 SVM의 성능을 높이기 위해 분할 알고리즘을 사용하였다. 해당 분할 알고리즘은 표준편차와 Root Mean Square Error (RMSE)를 이용해 행동의 시작과 끝을 예측한다. 이후, 행동 인식에 불필요한 데이터를 제거한 뒤 행동 인식을 수행한다. R. Alazrai et al.의 연구에서 저자는 CSI 진폭의 변화를 통해 사람과 사람 간의 상호작용을 인식하는 End-to-End Deep Learning Framework (E2EDLF)를 제안하였다 [9]. E2EDLF는 수집된 CSI 데이터의 진폭을 사용하여 CSI 이미지를 생성하고, 생성된 CSI 이미지로부터 행동 변화에 따른 특징을 추출한다. 이후, CSI 이미지를 입력값으로 하는 Convolutional Neural Network (CNN) 모델을 사용하여 사람과 사람 간의 상호작용을 식별한다.

2.2 LOS/NLOS 환경을 고려한 HAR 기법

H. Li et al.의 연구에서 저자는 Wi-Fi 기반 행동

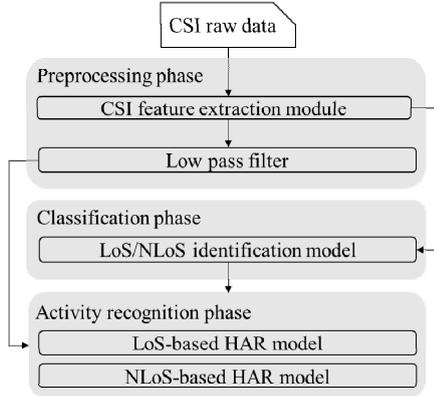
인식 시스템인 Wi-Motion을 제안하였다 [10]. Wi-Motion은 CSI로부터 추출된 특징을 진폭 및 위상 분류기로 전달한다. 이후, Wi-Motion은 분류기의 결과값을 조합해 SVM 모델에 입력값으로 사용함으로써 사람의 행동을 인식한다. A. Natarajan et al.의 연구에서 저자는 RSSI 및 CSI 기반 Human Motion Detection 시스템을 제안하였다 [11]. 해당 시스템은 랜덤 포레스트, 그라디언트 부스팅, Extreme Gradient (XG) 부스팅과 같은 트리 기반 앙상블 머신러닝 모델을 이용해 각 모델별 행동 인식 결과를 도출한다. 이후, 각 모델로부터 도출된 결과값에 가중치를 적용하고 그 값을 모두 결합한다. 이후, 결합된 값을 사용하여 사람의 행동을 인식한다. M. S. Islam et al.의 연구에서 저자는 Spatio-Temporal Convolution with Nested Long Short-Term Memory (STC-NLSTMNet) 모델을 제안하였다 [12]. STC-NLSTMNet은 Depthwise Separable Convolutional Block (DS-Conv)과 Feature Attention Module (FAM)을 사용해 CSI 데이터에서 공간적 특징을 추출하고, Nested Long Short-Term Memory (NLSTM)를 사용해 CSI 데이터에서 고유한 시간적 특징을 탐색한다. 이를 통해 STC-NLSTMNet은 사람의 행동을 보다 정확하게 인식한다.

앞서 언급한 관련 연구들은 LoS 환경만 고려하거나 LoS 환경과 NLoS 환경을 모두 고려하였다. 그러나, 특정 환경에서 수신된 데이터를 기반으로 학습된 HAR 모델은 CSI 데이터 수신환경이 변화하는 경우 장애물에 의한 진폭 감쇄와 지연 오프셋으로 인해 HAR 모델의 성능 저하를 피할 수 없다. 따라서, CSI 데이터 수신환경에 관계없이 행동 인식을 수행하기 위해 데이터 수신환경을 분류하는 HAR 모델이 요구된다.

3. 제안 시스템

본 장에서는 CSI 데이터를 활용하여 데이터 수신환경에 관계없이 HAR의 정확도 향상을 위해 LoS/NLoS identification 모델을 포함한 CSI 기반 HAR 시스템을 제안한다. 제안 시스템의 구조는 [Fig. 1]과 같으며, Preprocessing phase, Classification phase, Activity recognition phase로 구성된다. Preprocessing phase에서는 CSI 원시 (Raw) 데이터의 전처리가 수행되며, CSI 진폭 데이터 셋과 노이즈가 제거된 CSI 진폭 데이터 셋이 도출된다. Classification phase에서는, CSI 진폭 데

이터 분석을 통해, 데이터 수신환경이 LoS 환경 또는 NLoS 환경으로 결정된다. 마지막으로, Activity recognition phase에서는 Classification phase의 결과를 기반으로 NLoS-based HAR 모델과 LoS-based HAR 모델 중 하나가 선택되고, 노이즈가 제거된 CSI 진폭 데이터 셋이 선택된 모델에 입력되어 사람의 행동 인식 결과가 도출된다.



[Fig. 1] Proposed system architecture

CSI Raw 데이터는 직교 주파수 분할 기법 (Orthogonal Frequency Division Multiplexing, OFDM)을 통해 반송파가 다수의 부반송파로 분리된 형태로 표현된다. m 개의 송신 안테나와 n 개의 수신 안테나를 사용하는 Multiple-Input Multiple-Output (MIMO) 안테나를 이용하는 경우 CSI Raw 데이터 (CSI)는 식 (1)과 같이 표현될 수 있다.

$$CSI = \begin{bmatrix} H_{1,1} & H_{1,2} & \cdots & H_{1,n} \\ H_{2,1} & H_{2,2} & \cdots & H_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ H_{m,1} & H_{m,2} & \cdots & H_{m,n} \end{bmatrix} \quad (1)$$

식 (1)에서 $H_{m,n}$ 는 m 번째 송신 안테나 및 n 번째 수신 안테나에 대한 채널 상태 정보를 의미한다. i 번째 송신 안테나 및 j 번째 수신 안테나에 대한 채널 상태 정보는 식 (2)와 같이 표현된다.

$$H_{i,j} = [c_{n_1} \ c_{n_2} \ \cdots \ c_{n_k}] \quad (2)$$

식 (2)에서 c_{n_k} 는 k 번째 부반송파를 나타내며 진폭과 위상정보를 포함한 복소수의 형태로 표현된다.

Preprocessing phase에서는 CSI feature extraction 모듈과 저주파 통과 필터가 활용된다. CSI feature extraction 모듈은 수신된 CSI 데이터 내 불필요 성분

을 제거하고, 진폭 계산을 통해 CSI 진폭 데이터 셋을 도출한다. 구체적으로, CSI feature extraction 모듈은 행동 인식에 불필요한 null 부반송파, 직류 성분, 파일럿 부반송파에 해당하는 부분을 제거한다. 이후, 복소수로 표현된 CSI 데이터의 진폭을 계산하고, 해당 진폭 정보로 구성된 H' 를 도출한다. CSI feature extraction 모듈을 통해 도출된 H' 는 식 (3)과 같이 표현된다.

$$H'_{i,j} = [\alpha_1 \ \alpha_2 \ \cdots \ \alpha_{k-l}] \quad (3)$$

식 (3)에서 H' 는 부반송파의 진폭 정보인 α 로 구성된다. l 은 null 부반송파, 직류 성분, 파일럿 부반송파에 해당하는 부반송파의 개수를 의미한다. H' 로 구성된 CSI 진폭 데이터 셋 CSI' 은 식 (4)와 같다.

$$CSI' = \begin{bmatrix} H'_{1,1} & H'_{1,2} & \cdots & H'_{1,n} \\ H'_{2,1} & H'_{2,2} & \cdots & H'_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ H'_{m,1} & H'_{m,2} & \cdots & H'_{m,n} \end{bmatrix} \quad (4)$$

다수의 CSI' 를 입력으로 사용하는 LoS/NLoS identification 모델을 위해, CSI feature extraction 모듈은 식 (5)와 같이 다수의 CSI 진폭 데이터 셋으로 구성된 X 를 도출한다.

$$X = [CSI'_1 \ CSI'_2 \ \cdots \ CSI'_s] \quad (5)$$

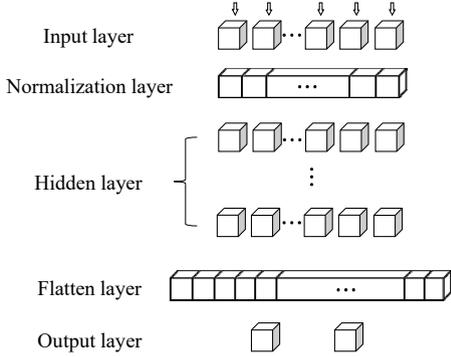
식 (5)에서 s 는 X 내 포함된 CSI' 의 수를 나타내고, CSI'_s 는 s 번째 CSI' 를 나타낸다.

저주파 통과 필터는 X 의 노이즈를 줄이기 위해 사용되며, 노이즈가 제거된 CSI 데이터 셋 (X')은 HAR 모델의 입력으로 활용된다. 인간의 행동으로 발생하는 신호 변화는 낮은 주파수 대역에서 발생된다. 따라서, 사람에게 행동과 관계없이 발생하는 노이즈를 감소시키기 위해 저주파 통과 필터가 사용된다. 저주파 통과 필터의 결과 (즉, X')는 식 (6)과 같이 나타낼 수 있다.

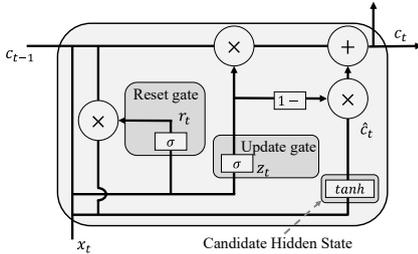
$$X' = [CSI''_1 \ CSI''_2 \ \cdots \ CSI''_s] \quad (6)$$

Classification phase에서는, [Fig. 2]의 구조를 갖는 LoS/NLoS identification 모델이 활용되며, 해당 모델은 X 를 분석하여 데이터 수신환경을 LoS 환경 또는 NLoS 환경으로 분류한다. LoS/NLoS identification 모델은 Input layer, Normalization layer, Hidden layer, Flatten layer, Output layer로 구성된다. Input layer는 CSI feature extraction 모듈의 결과 데이터 (즉, X)를 입력받아 Normalization layer로 전달한다. Normalization layer는 입력받은 데이터를 0-1 사이의 값으로 변환한다. Hidden layer의 유닛은 입력 데이터

의 시계열 특성을 고려하기 위해 GRU로 구성되며, 각 GRU는 [Fig. 3]과 같은 구조를 갖는다.



[Fig. 2] LoS/NLoS identification model scheme



[Fig. 3] Structure of GRU

GRU는 입력값 x_t 를 받아 업데이트 게이트, 리셋 게이트를 통해 c_t 를 계산한다. 이후 루프를 통해 셀 정보를 다음 유닛으로 넘기는 구조를 갖는다. 업데이트 게이트는 이전 상태 정보 c_{t-1} 를 현재 시간 t 로 가져오는 가중치를 결정한다. 업데이트 게이트 값인 z_t 는 식 (7)과 같이 계산된다.

$$z_t = \sigma(W_{xz}x_t + W_{hz}c_{t-1} + b_z) \quad (7)$$

식 (7)에서 σ 는 시그모이드 함수, W 는 네트워크 가중치 매트릭스를 의미하며, b 는 바이어스 벡터를 의미한다. 또한, 리셋 게이트는 이전 유닛의 정보에 대한 가중치를 결정한다. 리셋 게이트 값인 r_t 는 0-1 사이의 값을 가지며 식 (8)과 같이 계산된다.

$$r_t = \sigma(W_{xr}x_t + W_{hr}c_{t-1} + b_r) \quad (8)$$

식 (8)에서 \hat{c}_t 는 업데이트 게이트와 리셋 게이트를 조합하여 현재 시점 t 의 가중치를 결정하며 식 (9)와 같이 계산된다.

$$\hat{c}_t = \tanh(W_{xc}x_t + W_{hc}(r_t \otimes c_{t-1}) + b_c) \quad (9)$$

최종적으로, 현재 유닛의 가중치를 결정하는 c_t 는 식 (10)과 같이 계산된다.

$$c_t = z_t \otimes c_{t-1} + (1 - z_t) \otimes \hat{c}_t \quad (10)$$

Flatten layer는 Hidden layer에서 반환된 데이터의 형태를 변형하지 않고 1차원 벡터로 변환한다. 이후, Output layer는 Flatten layer의 결과값에 따라 데이터 수신환경을 LoS 환경 또는 NLoS 환경 중 하나로 분류한다.

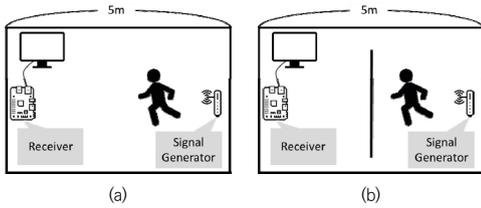
마지막으로, Activity recognition phase에는 LoS-based HAR 모델과 NLoS-based HAR 모델이 모두 존재하며, LoS/NLoS identification 모델의 결과값을 기반으로 하나의 모델이 선정된다. 이후, 저주파 통과 필터를 통과한 CSI 진폭 데이터 (즉, X')가 선정된 모델에 입력된다. LoS-based HAR 모델 및 NLoS-based HAR 모델은 각각 LoS 환경과 NLoS 환경에서 수신된 CSI 데이터 셋을 기반으로 학습되며, 사람의 행동을 걷기, 앉기, 서 있기, 부재중으로 분류한다. 각 모델의 Input layer, Normalization layer, Hidden layer, Flatten layer의 구성은 [Fig. 2]와 동일하다. 그러나, Output layer는 시스템이 분류하는 행동 인식 종류와 동일한 수의 노드로 구성된다.

4. 실험 환경 및 결과

본 장에서는 제안 시스템의 성능 평가를 위해 실험 환경 및 결과에 대해 서술한다. 제안 모델의 우수성을 입증하기 위해 데이터 수신환경을 고려하지 않은 시스템을 대조군으로 설정하였다. 구체적으로, 대조군은 제안 시스템에서 Classification phase가 생략된 구조로 구현되었으며, 제안 시스템과 같은 HAR 모델이 탑재되었다.

4.1 실험 환경

본 실험에서는 [Fig. 4]와 같이 LoS 환경과 NLoS 환경으로 구성된 실험 환경에서 사람이 행동할 때 변화하는 CSI 데이터를 수신해 저장하였다. 그림에서, 신호 발생기는 상용 AP를 활용하였으며, 수신기는 Raspberry Pi 4 Model B와 오픈 소스 라이브러리 Nexmon을 활용해 구현하였다 [13, 14]. 또한, 수신기와 모니터를 연결해 수신상황을 모니터링하였다. 상용 AP와 Raspberry Pi 4 Model B 모두 단일 안테나를 사용한다. 따라서, m 과



[Fig. 4] Experiment environments
(a) LoS scenario (b) NLoS scenario

n 을 1로 설정하였다. 각 장치는 IEEE 802.11a의 표준을 지원한다. 따라서, 부반송파 수는 64개로 설정되었고, 사람의 행동에 따라 변화되지 않는 null 부반송파, 직류 성분, 파일럿 부반송파의 수는 16으로 설정되었다. 신호 발생기와 수신기는 5m의 간격을 두고 배치하였다. LoS 환경은 신호 발생기와 수신기 사이의 장애물이 존재하지 않는 환경으로 구성하였고, NLoS 환경은 신호 발생기와 장애물 사이에 벽이 존재하는 환경으로 구성하였다. 사람의 행동에 따라 변화하는 CSI 진폭 데이터 셋을 구성하기 위해 s 를 20으로 설정하였다. 실험에 사용된 데이터 셋은 LoS 환경과 NLoS 환경에서 사람의 행동을 걷기, 앉기, 서 있기, 부재중으로 구분한 2,000개의 CSI 데이터로 구성된다. 제안 시스템의 성능 검증을 위해, 수집된 데이터 셋을 8:2 비율로 학습 및 검증 데이터 셋으로 나누어 사용하였다. LoS/NLoS identification 모델, LoS 및 NLoS-based HAR 모델의 구현을 위해 TensorFlow와 Keras를 사용하였다 [15]. 자세한 실험 파라미터는 <Table 1>과 같다.

<Table 1> Experimental parameters

Parameter	Value
Number of Tx antennas	1
Number of Rx antennas	1
Number of subcarriers	64
Indexes of null, pilot subcarriers, and DC component	1, 2, 3, 4, 5, 6, 11, 25, 32, 39, 53, 60, 61, 62, 63, 64
Data set	20

4.2 실험 결과

<Table 2>는 LoS/NLoS identification 모델의 데이터 수신환경 분류 결과를 Confusion matrix로 보여준다. LoS/NLoS identification 모델의 분류 정확도는 98%로 측정되었다. LoS/NLoS identification 모델은 저주파 통과 필터를 거치지 않은 CSI 진폭 데이터를 입력받아 수신환경 분류를 수행하였다. CSI 진폭 데이터는

데이터 수신환경에 따라 신호 감쇄 및 왜곡이 끼치는 영향이 다르다. 따라서, LoS/NLoS identification 모델은 CSI 진폭 데이터를 이용해서 LoS 환경과 NLoS 환경을 분류하기 때문에, 제안 시스템이 비교군 대비 높은 분류 정확도를 갖는다.

<Table 2> Confusion matrix for LoS/NLoS identification model

	LoS	NLoS
LoS	83	0
NLoS	2	75

<Table 3> Confusion matrices for experiment results
(a) proposed system (b) legacy system

	Walking	Sitting	Standing	Empty
Walking	37	0	0	0
Sitting	2	33	0	0
Standing	0	0	42	0
Empty	0	0	0	46

(a)

	Walking	Sitting	Standing	Empty
Walking	32	0	5	0
Sitting	3	27	5	0
Standing	3	8	30	1
Empty	1	2	0	43

(b)

<Table 3> (a) 및 (b)는 제안 시스템과 비교군에 대한 실험 결과를 Confusion matrix로 보여준다. 제안 시스템은 LoS/NLoS identification 모델의 결과값을 이용해 데이터 수신환경을 인식한 이후, 해당 데이터 수신환경을 기반으로 학습된 모델로 행동 인식을 수행한다. 이에 따라, 제안 시스템은 데이터 수신환경을 분류하지 않고 행동 인식을 수행하는 대조군 대비 사람의 행동을 보다 정확히 분류한다. 특히, 데이터 수신환경을 고려하지 않은 대조군의 경우, 다른 행동과 비교하여 앉기와 서 있기의 인식 정확도가 상대적으로 낮았다. 이는 앉기와 서 있기는 걷기에 비해 행동 변화가 크지 않아, 수신환경에서 발생하는 노이즈 및 행동 변화에 의한 신호 차이를 식별하기 어렵기 때문이다. 그 결과, 제안 시스템의 행동 인식 정확도는 98.75%인 반면, 대조군의 행동 인식 정확도는 82.50%로 나타났다. 즉, 제안 시스템이 대조군 대비 16.25% 더 높은 정확도를 달성하였다.

5. 결론

본 논문에서는 데이터 수신환경에 따라 변화하는 HAR 성능 저하 문제를 해결하기 위해 CSI를 활용한 LoS/NLoS 식별 기반 HAR 시스템을 제안하였다. 이를 위해, 제안 시스템은 수신된 데이터에서 HAR에 적합한 특징을 추출한 뒤, 데이터에 포함된 노이즈를 제거하는 과정을 순차적으로 수행한다. 이후, 노이즈가 포함된 데이터를 LoS/NLoS identification 모델의 입력값으로 사용하여 데이터 수신환경을 분류한다. 이후, 수신환경 분류값에 따라 HAR 모델이 결정되고, 결정된 HAR 모델은 노이즈가 제거된 데이터를 입력받아 사람의 행동을 앉기, 걷기, 서 있기, 부재중 중 하나로 분류한다. 제안 시스템의 우수성을 검증하기 위해 모델 구현 및 실험을 수행하였으며, 제안 시스템의 실험 결과를 데이터 수신환경을 고려하지 않은 시스템의 실험 결과와 비교하였다. 실험 결과, 제안 시스템이 대조군 대비 16.25% 더 높은 정확도를 달성하였다.

REFERENCES

[1] M. M. Islam, S. Nooruddin, F. Karray, and G. Muhammad, "Multi-level feature fusion for multimodal human activity recognition in Internet of Healthcare Things", *Inf. Fusion*, Vol.94, pp.17-31, 2023.

[2] E. Ramanujam, T. Perumal, and S. Padmavathi, "Human Activity Recognition With Smartphone and Wearable Sensors Using Deep Learning Techniques: A Review," *IEEE Sens. J.*, Vol.21, No.12, pp.13029-13040, 2021.

[3] Y. Jang, I. Jeong, M. Y. Heravi, S. Sarkar, H. Shin, and Y. Ahn, "Multi-Camera-Based Human Activity Recognition for Human-Robot Collaboration in Construction," *Sensors*, Vol.23, No.15, pp.6997:1-6997:20, 2023.

[4] C. F. Hsieh, Y. C. Chen, C. Y. Hsieh, and M. L. Ku, "Device-Free Indoor Human Activity Recognition Using Wi-Fi RSSI: Machine Learning Approaches," in *Proceedings of the 2020 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-Taiwan)*, Taoyuan, Taiwan, 2020.

[5] P. F. Moshiri, R. Shahbazian, M. Nabati, and S. A. Ghorashi, "A CSI-based human activity recognition using deep learning," *Sensors*, Vol.21, No.21, pp.7225:1-7225:19, 2021.

[6] N. Damodaran and J. Schäfer, "Device Free Human Activity Recognition using WiFi Channel State Information," in *Proceedings of the 2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing*

& Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation, Leicester, UK, 2019.

[7] J. Ding and Y. Wang, "WiFi CSI-Based human activity recognition using deep recurrent neural network," *IEEE Access*, Vol.7, pp.174257-174269, 2019.

[8] B. A. Alsaify, M. M. Almazari, R. Alazrai, S. Alouneh, and M. I. Daoud, "A CSI-based multi-environment human activity recognition framework," *Appl. Sci.-Basel*, Vol.12, No.2, pp.930:1-930:29, 2022.

[9] R. Alazrai, M. Hababeh, B. A. Alsaify, M. Z. Ali, and M. I. Daoud, "An end-to-end deep learning framework for recognizing human-to-human interactions using Wi-Fi signals," *IEEE Access*, Vol.8, pp.197695-197710, 2020.

[10] H. Li, X. He, X. Chen, Y. Fang, and Q. Fang, "Wi-motion: A robust human activity recognition using WiFi signals," *IEEE Access*, Vol.7, pp.153287-153299, 2019.

[11] A. Natarajan, V. Krishnasamy, and M. Singh, "A Machine Learning Approach to Passive Human Motion Detection using WiFi Measurements from Commodity IoT Devices," *IEEE Trans. Instrum. Meas.*, Vol.72, pp.1-10, 2023.

[12] M. S. Islam, M. K. A. Jannat, M. N. Hossain, W. S. Kim, S. W. Lee, and S. H. Yang, "STC-NLSTMNet: An Improved Human Activity Recognition Method Using Convolutional Neural Network with NLSTM from WiFi CSI," *Sensors*, Vol.23, pp.356:1-356:21, 2022.

[13] Teach, Learn, and Make with Raspberry Pi Foundation [Online]. Available: <https://www.raspberrypi.org>

[14] Nexmon [Online]. Available: <https://nexmon.org>

[15] M. Abadi et al. "TensorFlow: A system for large-scale machine learning," in *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI '16)*, GA, USA, 2016.

권혁돈(Hyeok-Don Kwon)

[준회원]



■ 2018년 3월 ~ 현재 : 한림대학교
소프트웨어학부 학사과정

<관심분야>

사물인터넷, 무선센서네트워크, 임베디드시스템, 머신러닝

권 정 혁(Jung-Hyok Kwon) [정회원]



- 2012년 2월 : 고려대학교 전기전자전파공학과 (공학석사)
- 2019년 2월 : 한림대학교 융합소프트웨어학과 (공학박사)
- 2013년 4월 ~ 2015년 6월 : LIG넥스원 SW연구센터 선임연구원

- 2019년 3월 ~ 현재 : 한림대학교 스마트컴퓨팅연구소 연구교수

<관심분야>

사물인터넷, 무선센서네트워크, 무선전력전송, 머신러닝, 블록체인

이 솔 비(Sol-Bee Lee) [정회원]



- 2018년 2월 : 한림대학교 융합소프트웨어학과 (공학사)
- 2024년 2월 : 한림대학교 융합소프트웨어학과 (공학박사)
- 2024년 3월 ~ 현재 : 한림대학교 스마트컴퓨팅연구소 연구교수

<관심분야>

사물인터넷, 무선센서네트워크, 무선전력전송, 머신러닝

김 의 직(Eui-Jik Kim) [정회원]



- 2004년 2월 : 고려대학교 전기전자전파공학부 (공학사)
- 2006년 2월 : 고려대학교 전자컴퓨터공학과 (공학석사)
- 2013년 2월 : 고려대학교 전기전자전파공학과 (공학박사)

- 2006년 2월 ~ 2009년 7월 : 삼성전자 DMC연구소 선임연구원
- 2009년 8월 ~ 2013년 8월 : KT 융합기술원 선임연구원
- 2013년 9월 ~ 현재 : 한림대학교 소프트웨어학부 부교수

<관심분야>

사물인터넷, 무선센서네트워크, 무선전력전송, 머신러닝, 블록체인