

# Distributed Human Activity Recognition System for Scalable Wi-Fi Sensing

InJae Ryou

Department of AI and Software (Software) at Gachon University  
sts07142@naver.com

## 요 약

본 논문에서는 Wi-Fi 기반 Human Activity Recognition (HAR) 시스템에서의 데이터 사용량을 줄이고 악의적인 도청자로부터의 도청방지를 위해 새로운 데이터 구조와 분산 센싱 시스템을 제안한다. CSI 데이터는 주변 환경에 민감하게 변화하며 데이터를 수집하는 과정에 상당한 비용이 발생한다. 이를 위해 적은 양의 데이터로도 HAR이 가능한 분산 센싱 시스템이 필요하다. 이와 더불어 도청자로부터 도청된 CSI 데이터의 효용성을 줄이기 위해 새로운 데이터 구조가 제시된다. 새로운 데이터 구조와 분산 센싱 시스템의 조합을 통해 저 데이터로도 같은 HAR 성능을 유지하면서 더 넓은 센싱 범위와 정확도로 도청자로부터의 도청에 안전하게 사용 가능하다.

## 1. 도입

인간 활동 인식(Human Activity Recognition, HAR)을 위해 Wi-Fi와 같은 실내 무선 네트워크를 사용하는 것이 최근 몇 년 동안 더 많은 관심을 받고 있다. Wi-Fi를 이용한 감지는 CSI(Channel State Information)를 기반으로 진행되며 이를 Wi-Fi 센싱이라고 부른다. CSI 데이터[1]는 물리 계층에서 수신기가 채널로부터 수신한 신호의 세부적인 특성과 채널의 상태에 대한 정보를 포함하고 있다. 카메라 기반 및 웨어러블 기술의 기술과 대비하여 기존의 Wi-Fi를 통해 추가적인 인프라를 요구하지 않는다. 카메라 기반의 센싱과 달리 조명 조건에 영향을 받지 않으며, 센서 기반 센싱과 달리 벽을 통과할 수 있다. 그 결과 Wi-Fi 센싱 기술은 기존의 제약을 극복할 수 있는 대안으로 연구가 활발히 진행이 되고 있다.

Wi-Fi의 센싱의 이러한 특성으로 활동 인식[1][3-5], 사람 인증[6], 손짓 인식[7-9]과 같은 다양한 애플리케이션들이 활성화되었으며 좋은 성능을 보여주었다[8].

기존 Wi-Fi 감지 시스템의 중요한 숨겨진 문제 중 하나는 Wi-Fi 감지가 실제로 Wi-Fi 통신과 공존할 수 없다는 것이다. Wi-Fi 장치가 센싱에 사용될 때 통신 기능이 저하된다. 이것이 Wi-Fi 감지가 실제 환경에서 채택되는 것을 방해하는 큰 문제라고 생각한다. 이 문제의 근본적인 이유는 Wi-Fi 감지가 높은 Sampling Rate를 필요로 하기 때문이다. 손동작과 같은 사람의 움직임 정보를 완전히 캡처하려면 1초에 충분한 Sampling Rate의 CSI 샘플을 추출해야 한다.

Wi-Fi 기반 HAR 시스템의 성능은 송신기(Tx)와

수신기(Rx) 간의 위치에 크게 의존하는 환경 종속성 문제가 존재한다. Rx와 Tx가 가까이 있을 때는 높은 정확도를 보이지만, 거리가 멀어질수록 HAR 성능이 저하된다.

또한, Wi-Fi 센싱으로 인한 보안 및 개인정보 노출 위험도 있다. 도청자는 벽을 통과시켜 Wi-Fi 신호를 가로채어 개인의 활동 정보를 수집할 수 있으며, 이는 프라이버시 침해로 이어질 수 있다. CSI 신호를 도청하여 사용자에게 대한 방 안의 존재유무[17], 벽 뒤의 걷는 방향[18]과 같은 정보를 얻는데 악용할 수 있다. 특히, 기존 HAR 사용자는 도청자의 존재를 알지 못하기 때문에 더욱 취약한 부분이다. 또한, 단일 기기 기반의 시스템은 데이터가 한 곳에서 집중적으로 수집되기 때문에 도청의 위험성이 더욱 높아진다.

이러한 문제를 해결하기 위해 수집된 CSI 데이터를 암호화하는 기법[11-12]을 활용할 수 있다. 데이터 암호화는 기존 데이터를 암호화 알고리즘을 사용하여 데이터를 보호함으로써 도청자가 데이터를 가로채더라도 내용을 해독할 수 없게 만드는 기법이다. 예를 들어, AES, RSA 등의 암호화 기술을 통하여 데이터를 안전하게 수집하고 전송할 수 있다. 하지만 암호화 기술을 적용하거나 데이터 패턴을 변형하는 과정에서 중요한 정보가 손실될 수 있어 분석 정확도에 영향을 미칠 수 있다[13].

본 논문에서는 위에서 언급했던 문제 사항들을 극복하고 보다 적은 데이터로 Wi-Fi 센싱을 진행하기 위해 분산 시스템 상황 속 새로운 데이터의 구조를 도입하여, 도청을 효과적으로 방지하는 Scalable Wi-Fi 분산형 인간 활동 인식 시스템을 제안한다. 그림 1은 논문에서

제안하고자 하는 새로운 데이터 구조로 기존의 시계열 데이터를 다양한 기기에서 수집할 때, 시간 순으로 통합하거나 기기별로 차원을 나누는 것이 아닌, 특정 구간마다 임의의 영역과 순서를 가진 데이터구조로 설정하는 것이다. 이와 같이 순차적으로 진행되는 데이터 구조를 통해, 도청자가 보는 데이터 패턴과 실제 동작 패턴이 다르게 작동하여 HAR 추론을 방지할 수 있다. 또한, 일부의 RPI는 자신의 차례가 아닌 시간 동안 센싱을 하지 않고 쉬는 효과를 만들 수 있고 IoT 환경에서 유리하게 적용될 수 있다. 제안하는 시스템은 기존보다 더 적은 데이터로도 높은 정확도와 넓은 센싱 범위를 가지며 도청자로부터의 보안능력을 향상시킬 수 있다. 이를 통해 보다 적은 데이터로 정확하고 도청 위험에 대해 신뢰할 수 있는 Wi-Fi 센싱 시스템을 구축할 수 있다.




그림 1. 제안하고자 하는 데이터 구조

## 2. 배경 및 관련연구

### 2.1 Channel State Information

CSI는 수신기(Rx)가 송신기(Tx)로부터 수신한 무선 신호의 세부적인 특성과 채널의 상태에 대한 정보이다. 이때 부반송파(Subcarrier) 수준에서 채널을 측정하고, 이 측정값은 주변 환경의 변화에 의해 영향을 받는다. 즉, 회절, 반사 및 산란 후 물리적 환경에서 무선 신호가 전파되는 방식을 반영한 통신 링크의 채널 특성이다[2].




그림 2. 실내환경에서의 Wi-Fi 신호전달[10]

### 2.2 Sampling Rate

Sampling Rate는 Wi-Fi 센싱 시스템에서 주어진 시간 내에 얼마나 자주 CSI 데이터를 수집하는지에 대한 정보이다. 이산적인 신호를 만들기 위해 연속적 신호에서 얻어진 단위시간 당

Sampling 횟수를 말한다. 높은 Sampling Rate는 보다 높은 HAR 정확도를 추론할 수 있지만, 적절한 Sampling Rate를 선택하는 것이 Wi-Fi 센싱 시스템의 정확도와 에너지 소비를 균형 있게 유지하는 데 필수적이다[14-15]. 인간 활동 인식을 위해 연구에서 1000, 500, 100, 50Hz 등의 높은 Sampling Rate 환경에서 90% 이상의 정확도를 달성하였다[14].

### 2.3 Wi-Fi 센싱에서의 개인정보 노출

Wi-Fi 기반 센싱은 CSI를 활용하여 비침습적으로 HAR을 인식하는 기술이다. 이러한 Wi-Fi 신호는 공기 중으로 전파되거나 벽이나 장애물을 통과하는 특성이 존재하여, 도청에 취약할 수 있고 이는 개인정보 노출로 이어질 수 있다[17-18]. 악의를 가진 도청자는 Wi-Fi 신호를 가로채어 CSI를 수집함으로써 개인의 활동을 추적할 수 있다.

## 3. 시스템 구조

그림 3은 제안하고자 하는 분산 센싱 시스템의 구조도를 나타내고 있다. 제안하는 시스템은 모델 학습부터 모델 평가까지 크게 4단계로 구분할 수 있으며 데이터 전처리, 제안하는 데이터 구조 적용, 모델 훈련, 모델 평가 순으로 진행이 된다.

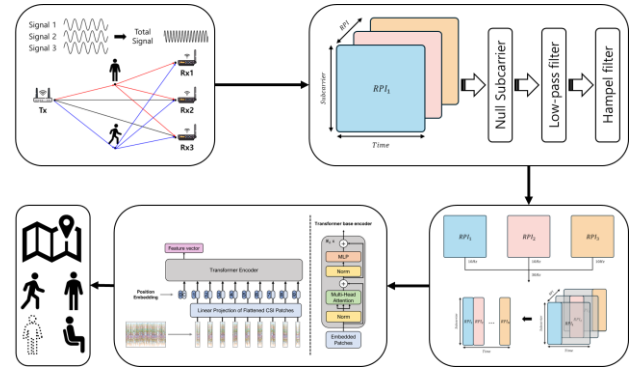


그림 3. 제안하는 시스템의 구조도

### 3.1 데이터 전처리

수집된 CSI 데이터의 원시 상태로는 노이즈와 불필요한 정보가 포함되어 있다. 그러므로 모델 학습에 앞서 데이터 전처리 과정이 필수적이다. 전처리 과정으로 Null Subcarrier 제거, Low-pass filter, Hampel filter를 적용하여 CSI 데이터에 존재하는 노이즈와 불필요한 정보를 제거하였다.

#### 3.1.1 Null Subcarrier

IEEE 802.11 20MHz bandwidth는 64개의 subcarrier로 구성되어 있다. 64개의 subcarrier는

8개의 Guard subcarrier, 4개의 Pilot subcarrier, 52개의 Data subcarrier로 구성된다. 이 중 8개의 Guard subcarrier는 Null subcarrier로 CSI 정보를 포함하지 않고 있다. Null subcarrier를 데이터에서 제거하여 56개의 subcarrier만 HAR 추론에 사용한다.

### 3.1.2 Low-pass filter

Low-pass filter는 고주파 노이즈를 제거하여 저주파 성분만을 남기는 필터이다. CSI 데이터는 사람의 활동과 같은 저주파 변동에 민감하게 반응하여, 해당 필터로 고주파를 제거하고 유의미한 저주파만을 남겨 SNR을 개선한다.

### 3.1.3 Hampel filter

Hampel filter는 중앙값과 3표준편차 이상 차이나는 이상치를 중앙값으로 대체하는 필터이다. CSI 데이터의 분포에 대한 가정 없이 이상치를 효과적으로 처리할 수 있어, 신호의 변동성을 줄이고 이상치를 감소시키는데 유용하다.

## 3.2 제안하는 데이터 구조

제안하고자 하는 데이터의 구조는 그림 1과 같이 RPI의 CSI를 정해진 시간과 Sampling Rate에 따라 수집하고, 수집이 끝나면 다음 RPI가 수집을 진행하여 순서대로 순환하여 수집을 한다. 결과적으로 각각의 RPI는  $T_{collect}/N$  동안만 CSI 데이터를 수집하고, 나머지 시간은 CSI 데이터 수집을 하지 않는 것을 의미한다.

기존의 데이터 구조는  $S * P * N$ 의 3차원 데이터 구조를 가지지만, 제안하는 데이터 구조는  $S * P$ 의 2차원 데이터 구조를 가지며 각각의 RPI가  $P$ 의 패킷을  $1/N$ 만큼 나누어 수집한다.

Variable	Description
$S$	Number of subcarriers
$W$	Window size
$R$	Sampling rate
$N$	Number of Raspberry Pi
$RPI$	Set of raspberry pi
$P$	Number of packets
$T_{collect}$	Time to collect $p$ packets

표 1. 변수 표기 자료

## 3.3 모델 훈련

### 3.2.1 Transformer

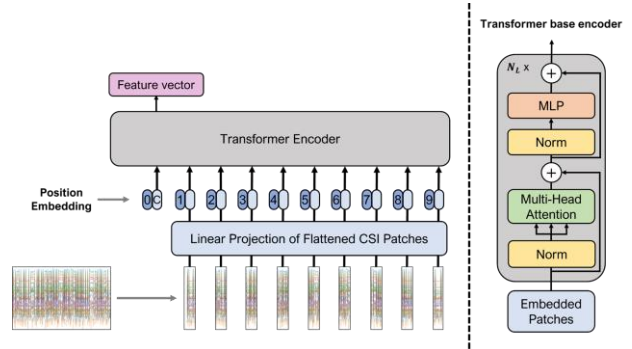


그림 4. Transformer Encoder

그림4는 비전 트랜스포머[16]의 구조를 기반으로 CSI 데이터를 패치별로 나누어 임베딩하는 과정을 나타낸다. 트랜스포머는 동일한 구조의 입력 데이터 생성을 위해 각 CSI 데이터를 패치 단위로 쪼개고 각 패치를 Flatten하여 벡터 값으로 변화시킨다. 각 벡터에 Linear연산을 진행하고 임베딩을 시킨다. 각 패치의 위치를 기억하기 위해서 Position 임베딩 토큰을 부착하고 해당 행렬을 인코더의 입력 값으로 사용한다. 인코더에서 Attention을 진행하고 그 결과 입력으로 주어졌던 시간 패치 간의 관계를 기반으로 추출된 특징 벡터가 도출되게 된다.

### 3.4 모델 평가

훈련 데이터를 통해 학습한 Transformer Encoder를 바탕으로 위치와 행동정보가 포함되어 있는 HAR class에 대해 SoftMax 함수로 예측 결과를 추정한다. SoftMax 함수를 통한 예측 결과와 실제 클래스의 라벨을 비교하여 모델을 평가한다.

## 4. 실험 및 평가

### 4.1 데이터셋

실험을 위해 직접 수집한 데이터셋을 사용하여 실험을 진행하였다. 해당 데이터셋의 내용은 표 2에서 확인할 수 있다.

#### 4.1.1 수집 데이터셋

Nexmon CSI 도구를 활용하여 3개의 Raspberry 4B과 Tp-link N750을 통해 그림 5의 실험 환경에서 5GHz 802.11ac 채널의 20MHz bandwidth에서 10Hz로 CSI를 측정하였으며, 64개의 Subcarrier를 각 클래스에 대해 5분간 수집하였다.




그림 5. CSI 수집 및 테스트 실험 환경

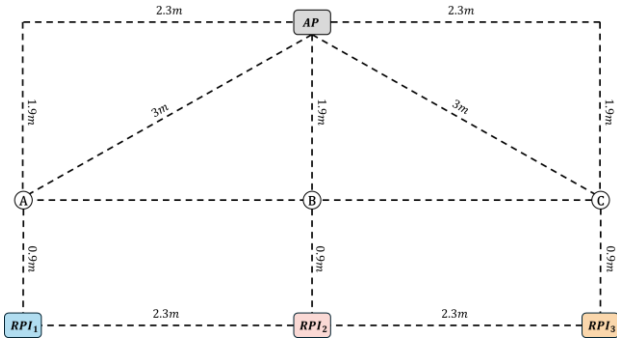


그림 6. 테스트 실험 환경의 제원

Datasets	Collection Datasets
CSI Tool	Nexmon CSI
Tx	TP-Link N750 Wireless Dual Band Gigabit Router
Rx	Raspberry 4B
Frequency Information	5GHz 20MHz Channel40
Sampling rate	10Hz
People	2
Collected Time	5 minutes
Activity names	Empty, Sit, Stand, Walk
Location names	A, B, C
Class number	10
Class names	0_empty, A_walk, A_stand, A_sit, B_walk, B_stand, B_sit, C_walk, C_stand, C_sit
CSI Size	$64 * T_{collect}$

표 2. CSI 데이터셋

#### 4.2 실험

##### 4.2.1 실험1: Rx와 Tx 위치에 따른 환경 종속성

Wi-Fi 센싱 기반 HAR 시스템의 성능은 Tx와 Rx 간의 위치에 따라 크게 영향을 받는다. 본 실험에서는 Rx와 Tx의 위치에 따른 HAR 모델의 정확도를 평가하고, 위치 변화에 따른 환경 종속성을 분석하였다. 특히, Tx와 Rx가 가까울수록 HAR 정확도가 높아지는 경향을 확인하고자 한다. 해당 실험에서는 ResNet50, EfficientNetB4, RNN, LSTM 모델과 10Hz Sampling Rate 환경에서 EfficientNetB4 모델이 타 모델에 비해 가장 높은 성능을 보여 해당 모델로 RPI별 HAR 위치에 따른 정확도를 비교하였다.

실험 결과, 동일한 공간에서도 Rx와 Tx의 위치에 따라 모델의 성능이 달라졌다. 이는 Wi-Fi 신호가 주변 환경의 영향을 크게 받기 때문에, Rx와 Tx의 배치가 중요함을 의미한다. 그림 7은 RPI 별 위치에 따른 HAR 정확도를 나타낸 그래프이다. 그림 7에서 RPI와 가까운 지점에서의 정확도는 최대 100%까지 나온 것을 확인하였다. RPI와 가까운 위치에서의 정확도는 높은 반면, 그렇지 않은 위치에서의 정확도는 상대적으로 낮은 것을 확인하였다. 결과적으로 Rx와 Tx의 위치에 따라 HAR 모델의 정확도가 크게 달라지는 것을 확인할 수 있다. 각각의 RPI의 CSI 데이터를 활용하여 HAR을 추론하는 통합 시스템이 필요하다.

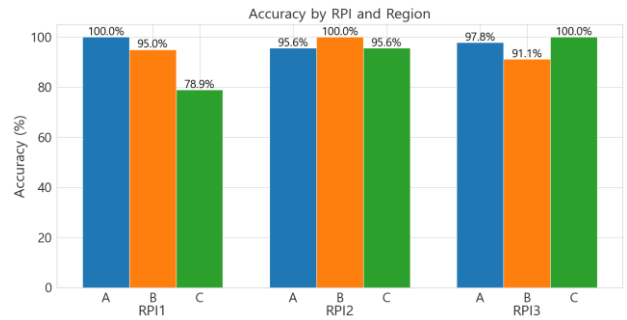


그림 7. RPI와 HAR 위치에 따른 정확도 비교

##### 4.2.2 실험2: Sampling Rate에 따른 정확도

Wi-Fi 센싱에서 Sampling Rate는 모델의 정확도에 중요한 영향을 미치는 요소이다. Sampling Rate는 주어진 시간 내에 얼마나 자주 CSI를 수집하는지를 결정한다. 적절한 Sampling Rate를 선택하는 것은 Wi-Fi 기반 HAR의 성능을 최적화하는 데 필수적이다. 해당 실험에서는 다양한 Sampling Rate가 Wi-Fi 센싱 기반 HAR 시스템의 예측 정확도에 미치는 영향을 분석하기 위해 실험을 진행하였다. ResNet50, EfficientNetB4, RNN, LSTM 모델을 사용하여 Sampling Rate를 10Hz, 5Hz, 2Hz, 1Hz로

조절하여 각각의 RPI에서 실험을 수행하였다.

실험 결과, Wi-Fi 센싱 기반 HAR 시스템에서 Sampling Rate가 모델의 정확도에 중요함을 확인했다. 그림 8은 Sampling Rate 변화에 따른 모델 별 정확도 변화를 나타낸 그래프이다. 각각의 RPI에 대해 1Hz, 2Hz와 같이 매우 낮은 Sampling Rate에서는 유의미한 패턴을 학습하지 못한다. Wi-Fi 센싱 기반 HAR 시스템에서 적절한 Sampling Rate를 선택하는 것이 매우 중요하며, 해당 실험에서는 5Hz 이상의 Sampling Rate에서 HAR 추론에 신뢰성 있는 결과를 도출할 수 있다.

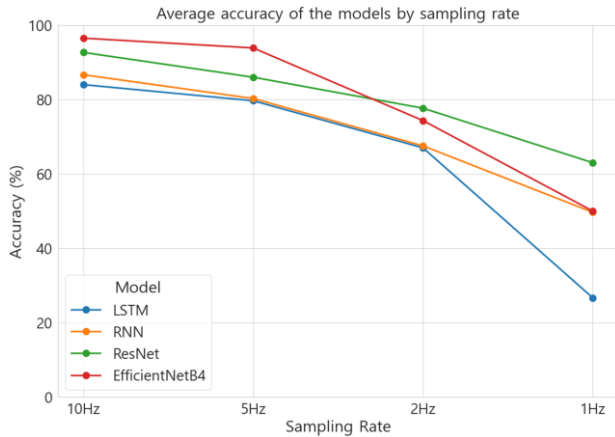


그림 8. Sampling Rate 변화에 따른 정확도 변화

#### 4.2.3 실험3: 데이터 구조에 따른 정확도

본 실험에서는 그림 1과 같이 논문에서 제안하고자 하는 데이터 구조를 적용하여, 기존보다  $1/N$ 의 데이터로 성능을 유지할 수 있는지 확인하고자 한다. 시간 순서대로 정렬된 N개의 RPI에서 수집된 CSI 데이터 중, R만큼의 CSI 데이터를 간격으로 순서대로 수집하는 구조이다. 해당 실험에서는 LSTM, RNN, ViT, ResNet, EfficientNetB4 모델과 10Hz의 Sampling Rate 환경에서 3개의 RPI에서 수집된 데이터를 모두 활용하여, 데이터 구조에 따른 정확도를 비교하였다.

실험 결과, 기존의  $S * P * N$  3차원 데이터 구조와 제안된  $S * P$  2차원 데이터 구조 모두 실험 모델들에 대하여 80% 이상의 HAR 정확도를 달성하였다. 그림 9는 기존 방식의 데이터 구조와 제안한 데이터 구조 간의 모델 별 정확도 비교 그래프이다. 기존 방식의 데이터 구조와 제안된 데이터 구조 모두 80%가 넘는 정확도를 달성하고, ViT, ResNet, EfficientNetB4 모델에서는 오히려 제안된 데이터 구조에서의 정확도가 더 높다. 결과적으로 기존 방식 대비  $1/3$ 의 저 데이터로 제안된 데이터 구조로도 기존과 같은 HAR 성능을 유지하거나 더 향상시킬 수 있다.

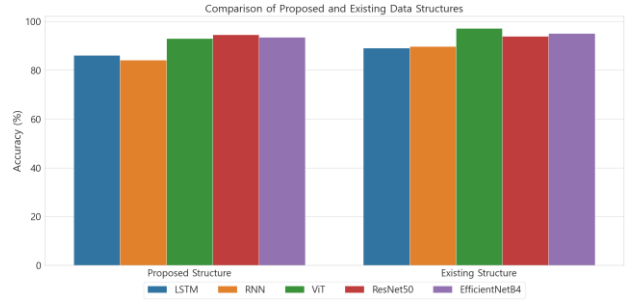


그림 9. 데이터 구조에 따른 정확도 비교

#### 4.2.4 실험4: 제안된 데이터 구조의 도청 방지 성능

본 실험에서는 논문에서 제안하고자 하는 데이터 구조를 적용하여, 도청자가 HAR을 유의미하게 추론할 수 있는지 확인한다. 해당 실험에서는 LSTM, RNN, ViT, ResNet, EfficientNetB4 모델과 10Hz의 Sampling Rate 환경과 3개의 RPI에서 수집된 데이터를 모두 활용하여, 분산 시스템과 제안된 데이터 구조를 알지 못하는 도청자의 정확도를 비교한다. 앞의 실험과 달리 제안된 데이터 구조와 패턴을 모르는 도청자는 CSI 데이터가 분산 시스템을 통해 다양한 RPI에서 수집되고, 제안된 데이터 구조와 패턴을 사용하고 있음을 알지 못한다. 즉, 도청자의 데이터 구조와 제안된 데이터 구조가 서로 다르다.

실험 결과, 분산 센싱 시스템과 제안된 데이터 구조를 적용한 CSI로는 유의미한 HAR 성능을 도출하지 못하였다. 그림 10과 같이 LSTM, RNN, EfficientNetB4 모델에서 최대 25% 이하의 매우 낮은 HAR 정확도를 보인다. 또한, ResNet과 ViT에서도 최대 50% 이하의 정확도를 보인다. 벽을 통과시켜 도청하는 도청자는 제안된 데이터 구조와 패턴을 모르기 때문에 도청된 CSI로 일반적인 데이터 구조와 패턴에 적용하여 HAR을 예측하기 어렵고, 도청된 CSI 데이터의 효용성을 낮춘다. 결과적으로 제안된 데이터 구조와 패턴은 별다른 추가 연산없이 효과적으로 도청자의 HAR 추론을 방해하여 도청을 방지할 수 있다.

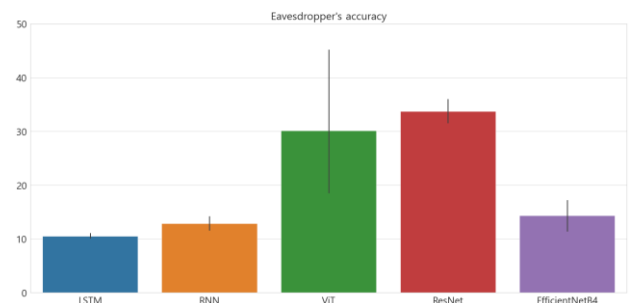


그림 10. 도청자의 모델 별 정확도 비교

## 5. 결론

모델을 학습하는 데 있어 충분한 데이터의 양을 확보하는 것이 중요하다. 하지만 데이터의 수집은 많은 비용과 시간을 소비시킬 수 있다. Wi-Fi CSI는 주변 환경에 따라 포함하는 데이터의 값이 변경된다. 그 결과 Wi-Fi 센싱을 위해서 매번 충분한 양의 데이터를 수집해야 한다. 하지만 Wi-Fi 통신과 동시에 Wi-Fi 수집이 공존하기 어렵다는 문제가 있다. 이를 위해 제안된 분산 센싱 시스템과 제안된 데이터 구조 도입 시  $1/N$ 의 데이터로도 90% 이상의 HAR 정확도를 달성한다. 또한, 기존의 단일 Wi-Fi 센싱 시스템에서는 도청자에 대한 대처가 어렵지만, 제안된 데이터 구조는 별다른 연산없이 효과적으로 도청자의 추론을 방해한다. 결론적으로 제안된 데이터 구조는 기존 대비  $1/N$ 의 CSI 데이터 만으로도 더 넓은 환경 종속성과 높은 HAR 정확도를 달성하며, 도청자로부터의 도청을 효과적으로 방지할 수 있다.

## References

- [1] Adib, Fadel, and Dina Katabi. "See through walls with WiFi!." Proceedings of the ACM SIGCOMM 2013 conference on SIGCOMM. 2013.
- [2] Yang, Jianfei, et al. "SenseFi: A library and benchmark on deep-learning-empowered WiFi human sensing." Patterns 4.3 (2023).
- [3] Bahadori, Niloofar, Jonathan Ashdown, and Francesco Restuccia. "ReWiS: Reliable Wi-Fi sensing through few-shot multi-antenna multi-receiver CSI learning." 2022 IEEE 23rd International Symposium on a World of Wireless, Mobile and Multimedia Networks (WoWMoM). IEEE, 2022.
- [4] Wang, Wei, et al. "Understanding and modeling of wifi signal based human activity recognition." Proceedings of the 21st annual international conference on mobile computing and networking. 2015.
- [5] Zhang, Jie, et al. "CrossSense: Towards cross-site and large-scale WiFi sensing." Proceedings of the 24th annual international conference on mobile computing and networking. 2018.
- [6] Wang, Dazhuo, et al. "CAUTION: A Robust WiFi-Based Human Authentication System via Few-Shot Open-Set Recognition." IEEE Internet of Things Journal 9.18 (2022): 17323–17333.
- [7] Zhang, Yi, et al. "Widar3. 0: Zero-effort cross-domain gesture recognition with Wi-Fi." IEEE Transactions on Pattern Analysis and Machine Intelligence 44.11 (2021): 8671–8688.
- [8] Xiao, Rui, et al. "Onefi: One-shot recognition for unseen gesture via cots wifi." Proceedings of the 19th ACM Conference on Embedded Networked Sensor Systems. 2021.
- [9] Zheng, Yue, et al. "Zero-effort cross-domain gesture recognition with Wi-Fi." Proceedings of the 17th annual international conference on mobile systems, applications, and services. 2019.
- [10] Ahmed, Hasmath Farhana Thariq, Hafisoh Ahmad, and C. V. Aravind. "Device free human gesture recognition using Wi-Fi CSI: A survey." Engineering Applications of Artificial Intelligence 87 (2020): 103281.
- [11] Rottenberg, François, et al. "CSI-based versus RSS-based secret-key generation under correlated eavesdropping." IEEE Transactions on Communications 69.3 (2020): 1868–1881.
- [12] Zhang, Bo, et al. "Secure Device-to-Device Communication in IoT: Fuzzy Identity from Wireless Channel State Information for Identity-Based Encryption." Electronics 13.5 (2024): 984.
- [13] Mehmood, Muhammad Sheraz, et al. "A comprehensive literature review of data encryption techniques in cloud computing and IoT environment." 2019 8th International Conference on Information and Communication Technologies (ICICT). IEEE, 2019.
- [14] Crepaldi, Riccardo, et al. "CSI-SF: Estimating wireless channel state using CSI sampling & fusion." 2012 Proceedings IEEE INFOCOM. IEEE, 2012.
- [15] Qian, Kun, et al. "Enabling contactless detection of moving humans with dynamic speeds using CSI." ACM Transactions on Embedded Computing Systems (TECS) 17.2 (2018): 1–18.
- [16] Dosovitskiy, Alexey, et al. "An image is worth 16x16 words: Transformers for image recognition at scale." arXiv preprint arXiv:2010.11929 (2020).
- [17] Y. Zhu, Z. Xiao, Y. Chen, Z. Li, M. Liu, B. Y. Zhao, and H. Zheng, "Adversarial WiFi Sensing," arXiv preprint arXiv:1810.10109, 2018.
- [18] S. M. Hernandez and E. Bulut, "Adversarial Occupancy Monitoring using One-Sided Through-Wall Wi-Fi Sensing," in Proceedings of IEEE International Conference on Communications (ICC), 2021,