

Wi-Fi CSI 데이터를 활용한 재실 인원 감지

오태린, 김범석, 정기원, 김민석*
충남대학교, *충남대학교

5234065@o.cnu.ac.kr, seeksick1009@o.cnu.ac.kr, kwjung2571@o.cnu.ac.kr, *kms4105@cnu.ac.kr

Occupancy Estimation Using Wi-Fi CSI Data

Oh Tae Rin, Kim Beom Seok, Jung Ki Won and Kim Min Seuk*
Chungnam National Univ, *Chungnam National Univ

요 약

본 연구는 송수신기가 고정된 device-free 환경에서 Wi-Fi 신호의 (Channel State Information) CSI 의 진폭을 분석하여 실내 인원을 감지하는 시스템을 제안한다. CSI 진폭의 동적 변화를 보다 정밀하게 구분하기 위해 진폭 값을 기반으로 슬라이딩 윈도우 기법을 적용하였으며, 각 샘플에 대해 진폭의 분산과 곡률으로부터 계산한 곡률 값을 기반으로 한 평균과 표준편차 특징을 추출했다. 추출된 특징을 다양한 머신러닝 및 딥러닝에 적용하여 성능을 검증했으며, 제안하는 시스템은 실제 환경에서 96 % 의 높은 정확도를 보인다. 이는 실내 인원 변화에 따른 CSI 신호의 변동성을 토대로 효과적으로 재실 인원 수를 구분할 수 있음을 시사한다.

I. 서 론

최근 (Internet of Things) IoT 기술의 발전으로 Wi-Fi 기반의 비접촉 센싱 기술에 대한 관심이 높아지고 있다. Wi-Fi 는 대부분의 실내 환경에 이미 구축되어 있어 별도의 센서 장비 없이 구현이 가능하며, 영상이 아닌 전파 신호를 기반으로 하므로 사생활 침해가 없다는 장점을 가진다. [1]

Wi-Fi 통신에서 얻을 수 있는 정보에는 단일 신호 세기 값인 (Received Signal Strength) RSS 와, 고차원 정보인 (Channel State Information) CSI 가 있다. RSS 는 신호 세기를 하나의 스칼라 값으로 나타내기 때문에 환경 변화에 따른 정밀한 감지에는 한계가 있다. 반면, CSI 는 (Orthogonal Frequency Division Multiplexing) OFDM 기술을 통해 각 부반송파의 진폭과 위상 정보를 포함하는 복소수 형태로 제공되며, 미세한 움직임이나 인원 변화로 인한 다중 경로의 변화까지 정밀하게 분석이 가능하다. 이러한 특성을 활용하여, 본 연구에서는 Wi-Fi 기반의 비접촉 센싱에 정밀한 환경 감지를 하는 CSI 정보를 활용하여 실내 인원 감지 시스템을 설계하였다.

본 연구의 주요 기여는 다음과 같다.

1. device-free 방식을 적용하여 Wi-Fi 송수신기가 고정되어 있는 상황에서 사람의 움직임에 의한 CSI 특징을 효과적으로 추출하였다.
2. CSI 진폭 값에서 분산과 곡률을 추출하고 슬라이딩 윈도우를 적용해 기계학습 및 딥러닝의 입력으로 사용하는 기법을 적용하여 인원 변화에 민감한 신호 변동을 효과적으로 판별했다.
3. 여러 기계학습 및 딥러닝 기법을 적용하여 최고 96 % 의 재실 인원 감지 성능을 얻어 그 실효성을 입증하였다.

II. 시스템 모델

2.1 시스템 구조

그림 1 은 제안하는 인원 감지 프레임워크를 나타낸다. CSI 데이터를 수집한 후에 진폭을 추출하여 슬라이딩

윈도우 기법을 적용한다. 이후 분산과 곡률 특징을 추출하여 머신러닝과 딥러닝 모델에 적용한다.




그림 1 인원 감지 프레임워크

2.2 특징 추출

CSI 데이터로부터 패킷-부반송파 행렬 형태의 진폭 값을 추출했다.[2] 시계열 특징을 활용하고자 슬라이딩 윈도우를 적용했다.[3] 또한 홑 크기를 최대한 작게 설정하여 윈도우 경계에서의 패킷 손실을 최소화했다.

진폭의 분산은 정적/동적 상태를 구분하는 지표가 된다. 부재 시에는 진폭이 안정되어 분산 값이 낮게 나타났고, 재실 시에는 사람의 움직임으로 인해 진폭 변동성이 커져 분산 값이 뚜렷하게 증가했다.

또한 우리는 곡률 특성을 도입했다. 곡률은 인원 수가 증가하여 다중 경로가 발생할수록 함께 높아지는 특징이 있다. 따라서 각 윈도우에서 계산된 곡률의 평균과 표준편차를 사용하여 인원 수 추정의 정확도를 높였다.

CSI 진폭 y 에 대한 곡률을 구하는 식은 (1) 과 같다.

$$\kappa = \frac{|y''|}{(1+(y')^2)^{3/2}} \quad (1)$$

2.3 기계학습 및 딥러닝

본 연구에서 사용한 데이터셋은 3 개의 클래스(0 명, 1 명, 2 명)로 구성된다. 데이터는 클래스별 3 개씩, 총 9 개의 파일로부터 수집되었으며, 각 파일에서 약 980 개의 윈도우 샘플을 추출하여 전체 데이터셋은 총 8,825 개의 샘플로 구성했다. 모든 샘플 입력은 모델 학습 전에 Min-Max 정규화를 거쳤다.

특징 벡터 분류 성능을 비교 분석하기 위해 머신러닝 모델인 (Support Vector Machine) SVM, (K-Nearest Neighbor) KNN 와 딥러닝 모델인 (Deep Neural Network) DNN 을 사용했다. SVM 은 다중 클래스 분류를 위해 (One-vs-One) OVO 과 (Radial Basis Function) RBF 커널을 사용했다. KNN 은 최근접 이웃의 수인 하이퍼파라미터 K 를 35 로 설정했다. DNN 모델은 입력층, 두 개의 은닉층 그리고 출력층으로 구성된다.

III. 실험 결과

3.1 실험 환경 설정

그림 2 와 같이 가로 6m, 세로가 9m 크기의 실내 강의실 환경에서 송신기와 수신기를 각각 1 대씩 책상 위에 배치하였으며, 두 장치 간 거리는 4m 이다. 각 장치는 Intel 5300 Wi-Fi (Network Interface Card) NIC 에 3 개의 안테나를 장착하였다. 패킷당 30 개의 서브캐리어에 대한 CSI 데이터를 수집하였다, 재실의 경우 송신기와 수신기 사이를 시계 방향으로 이동하는 상황에서 데이터를 수집하였다. 이후, 패킷을 윈도우 크기 W(10, 20, 30)로 샘플링하여 $W \times 30$ 형태의 배열을 구성하고, 진폭의 분산, 곡률의 평균, 표준편차 특징 총 90 개의 값을 추출하여 머신러닝 및 딥러닝 모델의 입력으로 사용하였다. 홉 크기는 5 로 설정하였다.



그림 2

3.2 모델 별 곡률의 영향

그림 3 에서 진폭의 분산(Variance)만을 이용한 경우 SVM, KNN, DNN 의 정확도는 각각 64 %, 68 %, 66 % 로 나타났다. 곡률을 전처리 입력으로 추가한 결과, SVM 과 KNN 의 정확도는 각각 96 %, 92 % 으로 32 %, 24 % 향상되었으며, DNN 은 96 % 로 30 % 향상되었다.




그림 3

3.3 모델 별 윈도우 크기의 영향

윈도우 크기를 W=10, 20, 30 으로 변화시키며 성능을 비교하였다. 그림 4 와 같이 W=10 에서 SVM, KNN, DNN 의 정확도는 각각 88 %, 83 %, 84 % 였다.

W=30 으로 변경 시, SVM, KNN, DNN 의 정확도는 각각 8 %, 9 %, 12% 향상되어 96 %, 92 %, 96 % 를 기록하였다. 이러한 결과는 샘플링 윈도우 크기가 모델 성능에 영향을 미친다는 것을 보여준다.




그림 4

최종적으로 그림 5 의 confusion matrix 와 같이 DNN 과 윈도우 크기 W = 30, 곡률 정보를 입력으로 사용했을 때 96 % 의 재실 인원 감지 성능을 확보하였다.




그림 5

IV. 결론

본 논문에서는 Wi-Fi CSI 데이터를 활용하여 재실 인원 감지를 수행하는 기계학습 및 딥러닝 기법을 제안하였다. CSI 진폭의 분산은 실내 환경의 정적/동적 상태를 명확하게 구분하는 기준을 제공했다. 또한 CSI 진폭의 곡률(Curvature) 특징을 전처리 입력으로 추가하고 슬라이딩 윈도우 기반의 데이터 구성 방식을 적용하여 재실 인원 에 따른 분류 성능을 향상시켰다. 제안하는 기법은 DNN 모델에서 최대 96 % 의 정확도를 달성하여 효과적인 재실 인원 감지 기능을 수행함을 입증하였다.

ACKNOWLEDGMENT

본 연구는 충남대학교 학술연구비에 의해 지원되었음

참 고 문 헌

- [1] I. Sobron, J. Del Ser, I. Eizmendi, and M. Vélez, "Device-free people counting in IoT environments: New insights, results, and open challenges," IEEE Internet Things J., 2018.
- [2] Z. Liu, R. Yuan, Y. Yuan, Y. Yang and X. Guan, "A Sensor-Free Crowd Counting Framework for Indoor Environments Based on Channel State Information," IEEE Sens. J., 2022.
- [3] O. Oshiga, et al., "Human detection for crowd count estimation using CSI of WiFi signals," in Proc. 15th Int. Conf. Electron., Comput. Comput. (ICECCO), Keffi, Nigeria, Dec. 2019, pp. 1-6.