

스마트폰 WiFi 채널 상태 정보를 이용한 딥러닝 기반 사용자 행동 인식 방법

정승현, 김효진*, 서영주

포항공과대학교, *포항공과대학교 인공지능연구원

{jshyun0111, hyojinkim, yjsuh}@postech.ac.kr

Deep Learning-based Human Activity Recognition
Using WiFi Channel State Information on Smartphone

Seung-Hyun Jeong, Hyojin Kim*, Young-Joo Suh

POSTECH, *POSTECH PIAI

요 약

스마트폰과 WiFi 의 대중화로 언제 어디서나 손쉽게 네트워크 접속이 가능해졌고, 이를 바탕으로 다양한 서비스가 제공되고 있다. 본 논문에서는 스마트폰과 무선 공유기를 활용한 딥러닝 기반 사용자 행동 인식 기법을 제안한다. 해당 기법은 다중 경로를 통해 수신되는 WiFi 신호의 특성을 활용하여 사용자의 행동에 따른 WiFi CSI 값의 미세한 변화로부터 사용자의 행동을 인식한다. 또한, 스마트폰의 제한적 하드웨어 자원을 고려하여 비교적 적은 연산량으로도 높은 성능을 나타내는 MobileNetV2 을 활용하였다. 서로 다른 두 환경에서 수행된 실험에서 해당 기법은 평균 93.47%의 정확도로 사용자의 행동을 인식하였다.

I. 서론

최근 IoT 기기와 스마트폰을 비롯한 모바일 기기의 보급에 따라 이를 기반으로 제공되는 서비스 또한 그 영역을 점차 넓혀나가고 있다. 이러한 서비스의 기반 기술 중 하나인 컴퓨터 비전 기술의 경우 시야가 가려지거나 어두운 환경에서는 정상 작동이 불가하고, 사생활 침해 우려가 있다. 반면, WiFi 채널상태정보(Channel State Information, CSI) 값을 기반으로 한 사용자 행동 인식 기술의 경우 빛의 유무와 관계 없이 활용 가능하고, 장애물이나 사생활 침해 문제로부터 비교적 자유롭다. 이러한 점에 주목하여 관련 연구가 활발히 진행되었는데, CSI 값 추출이 가능한 상용 장비는 수년간 Intel IWL5300 칩셋, Atheros AR9580 칩셋 등 소수의 IEEE 802.11n 칩셋에 국한되어 실용성 측면에서 한계가 있었다 [1], [2]. 그런데 최근 상용 스마트폰의 CSI 값 추출을 지원하는 펌웨어 패치 및 툴이 배포되면서 보다 실용적인 연구가 가능해졌다 [3]. 이에 본 논문에서는 상용 스마트폰에서 측정된 CSI 값을 수집하고, 딥러닝 기술을 활용하여 사용자의 행동을 인식하는 기법을 제안한다.

II. 본론

OFDM 기술을 통해 송수신되는 WiFi 신호는 직교하는 여러 개의 부 반송파들로 구성되며, 송신부에서 전송된 신호는 다중 경로를 통해 수신부에 수신된다. 이때, 송신된 신호 X 와 수신된 신호 Y 의 관계는 다음과 같은 식으로 표현할 수 있다.

$$Y = HX + N \quad (1)$$

식 1 에서 H 와 N 은 각각 채널 상태 정보(CSI)와 잡음을 나타낸다. 각 부 반송파는 주파수 대역이 서로 다르고, 이로 인해 사용자의 행동을 비롯한 실내 환경 변화에 각각 다르게 반응한다. 이러한 특성으로 인해 사용자의 행동에 따라 CSI 값의 고유한 변화가 발생하고, 이로부터 사용자 행동을 인식할 수 있다.

제안 기법은 상용 스마트폰인 Nexmon 6P 와 Nexmon CSI Extractor 툴을 이용해 사용자가 행동을 취하는 동안 일정한 주기로 수신되는 패킷의 CSI 값을 수신한다. Nexmon CSI Extractor 툴은 WiFi 패킷 수신 시 측정된 CSI 값을 UDP 패킷의 페이로드 형태로 사용자 공간으로 보내는데, 이를 이용해 WiFi 패킷의 CSI 값을 수집한다. Nexus 6P 내 WiFi 안테나는 2 개로, 각 안테나로부터 수집한 CSI 값은 유의미한 차이를 나타낸다. 이에 제안 기법에서는 사용자 행동 시 각 수신기에서 2 개의 안테나를 모두 활용하여 CSI 값을 수집한다. 사용자의 행동이 끝나면 동일한 안테나에서 수집된 CSI 값 벡터들을 시간 순으로 이어 붙인 matrix 형태로 데이터를 변환한다. 사용자별 행동 수행 시간이 상이할 경우 수집된 CSI 값의 수도 달라지는데, 데이터의 크기를 일정하게 유지하기 위해 최단입점 보간법을 활용해 64*256 형태로 변환한다. 이를 후술할 딥러닝 기술 활용을 위해 64*256*3 형태로 변환한다.

전처리 과정을 거친 데이터는 학습이 완료된 딥러닝 모델을 통해 사용자 행동 인식에 활용된다. 딥러닝은 데이터의 선형적, 비선형적 특성 모두 효과적으로 추출하여 사용하지만, 일반적으로 아주 높은 연산량과 메모리를 요구한다. 이에 제안 기법에서는 모바일 환경을 고려하여 설계된 MobileNetV2 [4]를 활용하여 전처리된 데이터로부터 사용자의 행동 패턴을 인식하여 분류한다.




그림 1. (a) 교내 중강당

그림 1. (b) 교내 실습실

그림 1. 실험 장소 및 실험 환경

MobileNetV2는 depthwise separable 합성곱 연산 방식, Inverted Residual Block 방식 등을 도입하여 연산량과 메모리 사용량을 획기적으로 낮춘다.

III. 실험 및 성능 평가

환경적 변화에 민감한 WiFi 신호의 특성을 고려하여 그림 1과 같이 포항공과대학교 중강당과 인공연 142호에 위치한 실습실, 서로 다른 두 환경에서 실험을 진행하였다. 2m 높이에 설치된 Netgear R7800를 송신기로 하여 44번 채널을 통해 10ms마다 패킷을 송신하도록 하였고, 다양한 위치에서의 데이터 확보를 위해 4대의 Nexus 6P를 수신기로 사용하였다. CSI 값을 동시에 측정하기 위해 4대의 Raspberry Pi 3B+를 각 수신기에 연결하여 실험을 진행하였다. 10명의 지원자가 두 장소에서 걷기, (앉은 채) 돌기, 앉기, 밀기, 정지, 원 그리기 등 총 6가지 행동을 30회씩 수행하였고, 각 장소에서 수신기 안테나 하나당 1800개, 총 14,400개의 데이터를 수집하였다. 열 명의 데이터 중 여덟 명의 데이터를 학습한 후, 나머지 두 명의 데이터로 성능을 평가하였다. 학습 시 batch size와 learning rate는 각각 16과 0.005로 설정하였고, Adam optimizer(beta1=0.5, beta2=0.999)를 사용하였다. 또한, 학습 초기 종료 기법을 통해 과적합을 방지하였다. 실험에 사용한 장비는 GeForce RTX 2070 SUPER 이고, Ubuntu 20.04 LTS 환경에서 pytorch를 사용하였다.

그림 2는 사용자가 행동을 취하는 동안 수집된 CSI 값을 변환한 데이터이다. 가장 동적인 행동인 '걷기'의 경우




그림 2. (a) 걷기




그림 2. (b) 앉기




그림 2. (c) 정지

그림 2. 사용자 행동 시 수집된 CSI 값 변환 데이터

	걷기	돌기	앉기	밀기	정지	원 그리기
걷기	955	5	0	0	0	0
돌기	2	874	5	3	0	76
앉기	0	17	864	12	0	67
밀기	0	0	7	852	9	92
정지	0	0	0	2	958	0
원 그리기	1	6	8	56	8	881

표 1. 사용자 행동 인식 평가에 대한 혼동 행렬

시간 변화에 따른 CSI 값의 변화가 두드러지는 반면, '앉기' 수행 시 비교적 변화가 적다. 사용자의 움직임이 없는 '정지'의 경우 CSI의 변화가 거의 나타나지 않는다. 표 1은 평가 데이터를 이용한 사용자 행동 인식 평가 결과이다. 제안 기법의 사용자 행동 인식의 정확도는 약 93.47%로, 가장 동적인 행동인 '걷기'와 사용자의 움직임이 없는 '정지'에 대해서 상대적으로 높은 정확도를 보였다.

IV. 결론

본 논문에서는 상용 스마트폰에서 측정한 CSI 값을 이용한 딥러닝 기반 사용자 행동 인식 기법을 제안하였다. 제한적인 스마트폰의 하드웨어 자원을 고려, 적은 파라미터 수와 연산량으로도 준수한 성능을 나타내는 MobileNetV2를 활용하였다. 실험을 통해 본 논문에서 제안하는 기법의 사용자 행동 인식 정확도가 서로 다른 환경에서도 높은 것을 확인하였다. 추후 연구에서는 적절한 데이터 전처리 기법과 도메인 적응 기법을 도입해 간섭 및 충돌에 따른 패킷 손실과 잦은 환경 변화에도 사용자 행동 인식 정확도를 높게 유지하도록 하여 실용성을 한층 높일 것이다.

ACKNOWLEDGMENT

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20182510102500)

이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2019-0-01906, 인공지능대학원지원(포항공과대학교))

참 고 문 헌

- [1] W. Wang, A. X. Liu, M. Shahzad, K. Ling, and S. Lu, "Understanding and modeling of wifi signal based human activity recognition," Proc. in ACM MobiCom '2015.
- [2] Y. Xie, J. Xiong, M. Li, and K. Jamieson, "mD-Track: Leveraging Multi-Dimensionality for Passive Indoor Wi-Fi Tracking," Proc. in ACM MobiCom '2019.
- [3] F. Gringoli, M. Schulz, J. Link, and M. Hollick, "Free Your CSI: A Channel State Information Extraction Platform For Modern Wi-Fi Chipsets," Proc. in WiNTECH, 2019.
- [4] Mark Sandler, Andrew Howard, Menglong Zhu, Andrey Zhmoginov, and Liang-Chieh Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," Proc. in IEEE CVPR, 2018.