

위치 변화에 강건한 Wi-Fi CSI 기반 활주로 이물질(FOD) 탐지 및 재질 분류

오승민*, 한승재

연세대학교

*osm3939@yonsei.ac.kr, seungjaehan@yonsei.ac.kr

Unseen-Location-Robust Wi-Fi CSI - Based Runway FOD Detection and Material Classification

Seung-min Oh, Seung-Jae Han

Yonsei Univ.

요약

본 논문은 상용 Wi-Fi 인프라에서 획득한 채널상태정보(CSI)를 이용해 활주로의 이물질(FOD) 존재 탐지와 재질 분류를 다룬다. Wi-Fi CSI의 환경 변화 민감성을 해결하기 위해 위치 변화에 강건한 학습 절차를 설계했다. 핵심 아이디어는 위치 분산을 가정한 에피소드 학습으로 도메인 일반화를 하고 무라벨 타깃 도메인을 활용한 의사라벨 자가학습으로 분포 적응을 결합하는 것이다. 실제 축소 모형 환경에서 측정된 데이터로 실험한 결과, 제안 기법은 미학습 위치 일반화를 달성하였으며, 범용성 검증을 통해 모델 확장의 유효성을 확인하였다.

I. 서론

인천국제공항 제2활주로에 도입되어 운용 중인 FOD 자동 탐지 시스템은 레이더·광학 복합센서로 구성되어 높은 탐지 성능을 보이지만, 도입 및 유지 비용이 높아 타 공항으로 확대 설치가 제한되고 있다.

이에 본 논문은 상용 Wi-Fi를 센서로 활용하는 CSI 기반 접근을 제안한다. Wi-Fi CSI는 기존 인프라를 활용하므로 설치 비용이 적고 높은 해상도로 물체를 탐지할 수 있다는 장점이 있지만, 위치·장애물·시간대 등 환경 변화에 민감해 정확도가 크게 떨어지는 문제가 있다. 이에 따라 새로운 위치나 환경에서 데이터 추가 수집과 재학습 비용이 발생한다 [1]. 본 연구는 위치 변화에 대한 일반화에 집중하여 데이터 추가 수집과 재학습 비용을 줄이는 것을 핵심 목표로 설정한다. 이를 위해 우리는 3-분기 일관된 융합 표현 위에, 학습시 관측하지 못한 위치에서도 성능이 유지되도록 설계한 에피소드 학습(도메인 일반화)과 무라벨 타깃 데이터를 활용하는 의사라벨 자가학습(도메인 적응)을 결합한 학습 모델을 제시한다.

II. 본론

본 논문은 학습하지 않은 위치에서도 높은 성능을 유지하도록 모델을 총 4단계로 설계하였다: (i) 데이터 수집, (ii) 데이터 전처리, (iii) 도메인 일반화(DG) 기법인 에피소드 학습, (iv) 도메인 적응(DA) 기법인 의사라벨 기반 자가학습. 그림 1은 모델의 전체 프레임워크를 보여준다.

데이터는 활주로 관심영역(ROI)을 가로지르는 Wi-Fi 링크에서 CSI를 수집한다. 전처리 단계에서는 CSI를 진폭과 위상으로 나누고, 진폭으로부터 스펙트럼 그래프를 생성하여 특징 추출을 강화한다. 이렇게 구성한 3-분기(진폭, 스펙트럼 그래프, 위상)를 기준 프레임(FOD 없는 상태) 대비 차분하고 z-정규화를 적용한다. 이때 3-분기는 동일한 원시 프레임을 공유하도록 정렬하여 라벨과 물리적 교란을 일관되게 유지 시킨다. 이렇게 함으로써 특징 융합 시 분기 간 불일치 문제를 해소했다.




그림 1. 제안 모델 프레임워크

모델은 분기별 특징 추출기(2DCNN, ResNet18)에서 얻은 표현을 128차원 융합 공간으로 투영·가중합하고, 단일 분류 헤드로 예측한다. 융합부의 가중은 학습을 통해 위치 변화에 따라 정보력이 높은 분기 쪽으로 자연스럽게 재배치된다(그림 2).




그림 2. 데이터 전처리 및 3분기 융합

위치 일반화를 위해서는 위치별 미니배치를 교사-학생 양방향 증류로 묶는 에피소드 학습을 적용하여, 위치 특이 정보보다 재사용 가능한 공통 표현을 우선적으로 학습하도록 유도한다(그림 3). 메인 네트워크(학생)는 특징추출기 f 와 분류기 g 로 구성되고, 위치 i 의 교사 네트워크의 특징추출기와 분류기는 f_i, g_i 로 표기한다. 이때 손실은 (i) 메인 기준 감독, (ii) 교사 헤드를 메인 특징에 적용한 교차 감독, (iii) 메인 헤드를 교사 특징에 적용한 교차 감독의 합으로 정의한다.

$$\begin{aligned}
(i) \quad L_1 &= CE(g(f(x)), y), \\
(ii) \quad L_2 &= CE(g_i(f(x)), y), \\
(iii) \quad L_3 &= CE(g(f_i(x)), y) \\
L_{epi} &= L_1 + \lambda_1 L_2 + \lambda_2 L_3
\end{aligned}$$

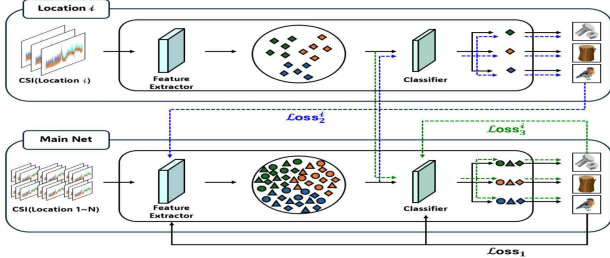


그림 3. 에피소드 학습 절차

이어서 자가학습 단계에서는 전 단계에서 학습한 메인 네트워크를 초기 모형으로 가져와, 무라벨 타깃 도메인 데이터에 의사라벨을 부여한 뒤 신뢰도 임계값을 넘는 샘플만 선별해 재학습함으로써 [3], 위치에 따라 변하는 타깃 분포에 점진적으로 적응하도록 보장한다.

실험은 상용 Wi-Fi 공유기(Tx)와 Raspberry Pi 4B(Rx)를 이용해 실내 환경에서 축소 모형을 구성하였다. 송·수신기 간 거리는 $4m$ 이며, $1cm^3$ 의 표준 시편(금속, 목재, 조류, 종이)을 8개 위치(세로 $50cm$, 가로 $100cm$ 간격)에 두고 각각 2,000개 패킷을 측정하였다(그림 4).




그림 4. 실험 설정 및 표준 시편

실험 결과로 제안 모델은 미학습 위치에서의 FOD 존재 탐지·재질 분류 모두에서 비교군 대비 일관된 우위를 보였다(표 1). 제안 모델이 학습하는 과정의 특징 공간을 시각화해 보면 에피소드 학습 에포크가 경과함에 따라 클래스 간 클러스터를 안정적으로 형성하고, 자가학습 이후에는 경계 간 마진이 더 뚜렷해지는 것을 확인할 수 있었다(그림 5).

표 1. 미학습 위치 일반화 성능 비교

모델	FOD 탐지 정확도	재질 분류 정확도
Baseline CNN	89.41%	61.17%
CsiGAN [4]	88.94%	74.31%
DGSense [5]	91.84%	72.88%
Ours	99.72%	88.62%




그림 5. 특징 공간(Feature Space) 시각화(t-SNE)

범용성 실험 결과에서, 학습에 포함되지 않은 재질(OOD) 탐지 성능과 환경 난이도 A(개활지)·B(외부 장애물)·C(내부 장애물) 변화에 대한 견고성을 동시에 확인할 수 있었다(표 2). 특히 OOD 탐지와 환경 B·C에서의 분류

정확도의 우위는 위치 이외의 요인 변화에도 비교군 대비해서 특징이 급격히 붕괴하지 않음을 시사한다.

표 2. 범용성 성능 비교

모델	OOD 탐지 정확도	3-분류 정확도		
		환경 A	환경 B	환경 C
Baseline CNN	57.36%	61.17%	46.80%	43.64%
CsiGAN	63.39%	74.31%	63.89%	44.11%
DGSense	46.35%	72.88%	44.11%	47.74%
Ours	86.75%	88.62%	83.80%	57.53%

소거 연구(Ablation Study)에서는 제안 모델의 핵심 기법을 하나씩 소거하며 모델의 성능을 검증하였다. 전체 모델에서 자가학습(Self-training)을 소거 시 분류 정확도는 79.70%로 기존 대비 8.92% 감소했다. 추가로 에피소드 학습까지 소거하면 분류 정확도는 64.75%로 14.95%가 더 감소했다. 이를 통해 에피소드 학습으로 위치 불변의 특징을 형성하고, 그 위에 의사라벨 기반 자가학습으로 타깃 위치 분포에 적응하여 성능을 점진적으로 향상시킴을 확인하였다.

표 3. 소거 연구

모델	3-분류 정확도
Ours	88.62%
W/O Self-training	79.70%
+ W/O Episodic Training	64.75%

III. 결론

본 논문은 (i) 3-분기(진폭, 스펙트로그램, 위상)의 일관된 융합, (ii) 위치 불변 특징을 형성하는 에피소드 학습, (iii) 타깃 위치 분포에 적응하는 자가학습을 결합하여, 위치 변화에 견고한 Wi-Fi CSI 기반 FOD 탐지·분류 모델을 제안하였다. 실험 결과, 학습하지 않은 위치에서 비교 기법 대비 약 8 ~ 16%의 성능 향상을 보였으며, 목표한 위치 일반화를 달성하여 데이터 추가 수집과 재학습 빈도를 의미 있게 줄일 수 있음을 확인하였다. 또한, OOD 탐지 정확도는 23% 이상 개선되었고, 다른 환경에서도 비교 기법 대비 상대적 우위를 유지하여 모델의 범용성과 향후 모델 확장 가능성을 뒷받침했다.

본 연구의 한계는 위치 변화 일반화에 초점을 맞추어 기상, 장애물 배치, 시간대 등 기타 환경 요인 변화를 충분히 포괄하지 못했다는 점이다. 향후에는 본 단계의 결과를 토대로 일반화 범위를 다양한 환경 변화로 확장하고, 실외 환경으로 규모에서의 검증을 통해 운용 적합성을 평가할 예정이다.

참 고 문 헌

- [1] Ma, Y., Zhou, G., and Wang, S., "WiFi Sensing with Channel State Information: A Survey," ACM Computing Surveys, 52(3), Article 46, 2019. <https://doi.org/10.1145/3310194>
- [2] Peng, M., Ge, B., Fu, X., and Kai, C., "Wi-Tar: Object Detection System Based on CSI Ratio," IEEE Sensors Journal, 24(10), 16540 - 16550, 2024. <https://doi.org/10.1109/JSEN.2024.3384703>
- [3] Sohn, K., Berthelot, D., Carlini, N., et al., "FixMatch: Simplifying Semi-Supervised Learning with Consistency and Confidence," NeurIPS, vol. 33, pp. 596 - 608, 2020.
- [4] Xiao, C., Han, D., Ma, Y., and Qin, Z., "CsiGAN: Robust Channel State Information-Based Activity Recognition With GANs," IEEE Internet of Things Journal, 6(6), 10191 - 10204, 2019.
- [5] Zhou, R., Cheng, Y., Li, S., Zhang, H., and Liu, C., "DGSense: A Domain Generalization Framework for Wireless Sensing," arXiv:2502.08155, 2025.