

# CSI 기반 실내 위치 추정을 위한 구역 선택형 전문가 혼합(RSMoE)

한승우, 문하은, 이서인, 김민석\*  
충남대학교, \*충남대학교

hsw2266@cnu.ac.kr, cherishuu02@o.cnu.ac.kr, sslynn22@o.cnu.ac.kr, \*kms4105@cnu.ac.kr

## Region-Selective Mixture-of-Experts for CSI-based Indoor Localization

Han Seung Woo, Moon Ha Eun, Lee Seo In, and Kim Min Seuk\*  
Chungnam National Univ., \* Chungnam National Univ.

### 요약

Wi-Fi 기반 채널 상태 정보(Channel State Information, CSI)를 활용한 실내 위치 추정은 NLoS(Non-Line of Sight)로 인한 왜곡과 구역별 전파 특성이 크게 달라지는 문제를 동시에 안고 있다. 본 연구는 이 문제를 구역 전문가 라우팅 문제로 재정의하고, 이를 해결하기 위한 구역 선택형 전문가 혼합 모델(RSMoE)을 제안한다. 제안 모델은 먼저 Gating 네트워크로 입력 CSI가 속한 구역을 예측하고, 이후 해당 구역의 단일 전문가 CNN(Convolutional Neural Network) 모델만이 활성화되는 단일 전문가 라우팅을 사용한다. 기존 VSDL(Viewpoint-Selective Deep Learning) 모델의 평균 위치 오차(4.01 m) 대비 3.05 m( $\approx 24\%$  개선)의 평균 위치 오차를 달성하며, 불필요한 연산을 줄이면서도 CSI 특성을 구역별로 분할 학습하여 전문성을 높였다.

### I. 서론

Wi-Fi 기반 채널 상태 정보(Channel State Information, CSI)를 활용한 실내 위치 추정은 고정밀 예측이 가능하다는 장점으로 주목받고 있지만, 실제 환경에서는 벽, 장애물, 건물 구조 등으로 인한 Multipath·NLoS(Non-Line of Sight) 현상으로 높은 변동성과 잡음이 커지는 문제가 있다 [1].

이 문제를 해결하기 위해, 우리는 선행 연구에서 LoS 환경에 있는 뷰를 선별하고 뷰 가중치를 부여하는 VSDL(Viewpoint-Selective Deep Learning) 모델을 제안한 바 있다 [2]. VSDL은 각 AP(Access Point) 그룹의 정보를 뷰 단위로 재가중하여 단일 회귀 모델의 입력으로 사용하였다.

그러나 이러한 구조에는 두 가지 본질적인 한계가 존재한다. 첫째, 단일 회귀 모델은 모든 구역에서 수집된 정보를 하나의 입력으로 함께 처리한다. 이로 인해 특정 구역의 고유한 전파 특성에 맞춘 전문화된 학습이 어렵고, 모든 구역의 정보가 반영된 평균적인 예측을 수행하게 된다. 둘째, 위치 추정을 위해 모든 AP 그룹에 대한 연산이 필요하므로 계산 효율이 저하된다. 가중치가 낮은 구역이라도 연산 과정에서 제외되지 않아, 전체 처리 속도 및 성능이 저하된다.

이러한 한계를 극복하고자, 본 연구에서는 환경을  $K$  개의 구역(Region)으로 분할하고, 각 구역에 특화된 전문가 모델을 할당하여 위치를 추정하는 구역 선택형 전문가 혼합(Region-Selective Mixture of Experts, RSMoE) 아키텍처를 제안한다 [3]. 이 방식은 구역별 모델 전문성을 극대화하고, 불필요한 연산을 줄여 계산 효율을 향상한다. 실제 실험에서 제안 모델이 단일 전역 회귀 모델 대비 의미 있는 성능 향상을 보였으며, 복잡한 실내 환경일수록 구역 기반 분할 학습 방식의 효과가 우수함을 확인하였다.

### II. 본론




그림 1. RSMoE 모델 아키텍처

#### 2.1. 제안 모델 아키텍처

본 논문에서 제안하는 구역 선택형 전문가 혼합 모델(RSMoE)은 분할 정복(Divide and Conquer) 전략에 기반하여, 복잡한 위치 추정 문제를 다수의 단순한 하위 문제로 나누어 해결한다. 이 아키텍처는 서론에서 언급된 단일 회귀 모델의 한계를 극복하기 위해, 그림 1과 같이 Gating 네트워크와 구역별 전문가 CNN(Convolutional Neural Network) 네트워크라는 두 가지 핵심 요소로 구성된다. 전체 모델의 작동 원리는 수식 (1)로 요약할 수 있다.

$$\hat{k} = \underset{k}{\operatorname{argmax}}(G(X)), \quad \hat{y} = E_k(\varphi(X, \hat{K})) \quad \dots \quad (1)$$

#### 가. Gating 네트워크

Gating 네트워크  $G$ 는 전체 1,890 차원의 CSI 입력 벡터  $X$ 를 받아 해당 데이터가 속한 구역을 선별하는 라우터 역할을 수행한다. 이 네트워크는 MLP(Multi-Layer Perceptron) 기반 구조로  $K$  개의 구역에 대한 확률 분포를 예측한 뒤  $\operatorname{argmax}$  연산을 통해 가장 높은

값을 갖는 단일 구역  $k$  를 선택한다. 예측된 확률은 실제 구역 레이블과의 Cross-Entropy 손실을 최소화하도록 학습된다. 이후, 선택된 구역의 전문가만 활성화하는 단일 전문가 라우팅 방식을 사용하여, 계산 효율성을 높이는 동시에 각 구역의 학습을 독립적으로 분리한다.

## 나. 구역별 전문가 CNN 네트워크

수식 (1) 에서 Gating 네트워크는 입력  $X$  에 가장 적합한 구역  $k$  를 예측하고, 해당 전문가 네트워크  $E_k$  만이 활성화된다. 이때 변환 함수  $\phi(X, \hat{k})$  는 전체 입력  $X$  에서  $k$  구역에 해당하는 입력만을 동적으로 추출하고 2 차원 이미지 형태로 변환하여,  $E_k$  에 전달하는 역할을 수행한다. 이러한 구조는 단일 회귀 모델이 모든 구역의 특성을 함께 학습해야 했던 한계를 극복하고, 각 전문가가 담당 구역의 고유한 전파 특성에 최적화되도록 한다.

실내 환경에서는 LoS/NLoS 조건과 Multipath 구성의 차이로 인해 구역별 전파 특성이 뚜렷하게 달라진다. 이러한 차이는 동일한 CSI 패턴이라도 구역마다 다른 해석을 요구하므로, 구역별로 독립적으로 학습한 전문가 CNN 은 해당 영역의 고유한 시간(packet sequence)-주파수(subcarrier)의 2 차원 패턴을 보다 정밀하게 학습할 수 있다.

최종 출력인  $(\hat{y}_1, \hat{y}_2)$  위치 좌표는 평균 제곱 오차(Mean Squared Error, MSE) 손실을 최소화하는 방향으로 학습된다. 이러한 Divide-and-Conquer 학습 절차는 각 모듈이 고유 기능에 집중하도록 하여 계산 효율을 높이고, NLoS 환경에서 발생하는 미세한 신호 변화를 효과적으로 포착함으로써, 단일 회귀 모델 대비 위치 추정 정확도와 강건성을 크게 향상한다.

## 2.2. 실험 환경 및 결과




그림 2. 실험 토폴로지 및 위치 추정 결과(충남대학교 도서관)




그림 3. Localization Distance Error CDF

본 연구의 실험 결과는 그림 2 와 그림 3 에 요약되어 있다. 실험은 유동 인구가 많은 충남대학교 도서관 실내 환경에서, 141 개 위치에서 수집된 1,890 차원의 CSI 데이터셋을 사용하였다. 이 중 125 개 위치는 학습에, 16 개 위치는 평가에 활용하였다.

성능 비교 결과, MLP 기반 모델은 4.65 m, CNN 기반 모델은 3.99 m 의 평균 위치 오차 성능을 보였다. 제안하는 RSMoE 구조는 MLP 기반 모델에서 3.56 m, CNN 기반 모델에서 3.05 m 의 평균 오차를 달성하여, 기존 VSDL 모델(4.01 m) 대비 약 24 % 의 성능 개선을 보였다. 이러한 성능 향상은 구역 선택 Gating 네트워크와 구역별 전파 특성에 최적화된 전문가 CNN 네트워크의 구조를 통해, 실제 환경에서 발생하는 미세한 신호 변화와 잡음에 효과적으로 대응한 결과로 분석된다.

그림 2 는 제안된 모델의 우수성을 명확히 입증한다. Gating 네트워크가 약 94 % 의 높은 정확도로 실제 구역을 선별하여 최적의 전문가 모델을 할당함으로써, 최종 예측값은 복잡한 구조 및 NLoS 환경에서도 해당 구역 내에 안정적으로 집중된다.

또한 그림 3 의 누적 분포 함수(CDF) 분석 결과, 오차 범위 내에서 RSMoE 의 누적 비율이 단일 회귀 모델 대비 월등히 높게 나타나, 제안 방식이 전반적인 위치 추정 정확도와 안정성을 모두 개선했음을 입증한다.

## III. 결론

본 논문은 Multipath·NLoS 의 영향으로 구역별 특성이 급격히 달라지는 실내 환경에서 Wi-Fi CSI 기반 위치 추정의 한계를 극복하고자, 구역 선택형 전문가 혼합(RSMoE) 아키텍처를 제안하였다. 제안 모델은 Gating 네트워크가 선택한 구역에 따라 해당 구역에 특화된 전문가 CNN 이 위치를 추정하는 구조로, 실제 데이터셋 실험에서 평균 위치 오차 3.05 m 를 기록해 단일 전역 회귀 모델 대비 약 24 % 의 정확도 향상을 달성하였다. 이는 복잡한 실내 공간을 구역별 하위 문제로 분할해 학습하는 접근이 실질적인 성능 개선으로 이어짐을 입증한다.

향후 연구에서는 군집화 기반 자동 구역 분할과 소프트 라우팅을 도입하여, 다양한 실내 환경과 규모에서의 확장성을 확보하는 동시에 구역 설정과 모델 관리에 필요한 시간적 비용을 줄여 더 실용적인 방향으로 발전시킬 것이다.

## ACKNOWLEDGMENT

본 연구는 충남대학교 학술연구비에 의해 지원되었음.

## 참 고 문 헌

- [1] A. Tzur, O. Amrani, and A. Wool, "Direction finding of rogue Wi-Fi access points using an off-the-shelf MIMO-OFDM receiver," *Physical Communication*, vol. 17, pp. 149-164, 2015.
- [2] 한승우, 문하은, 이서인, 강민서, and 김민석, "Viewpoint-Selective Deep Learning 을 활용한 NLoS 환경에서의 WiFi CSI 기반 실내 측위," in *한국통신학회 학술대회논문집*, 2025, pp. 1045-1046.
- [3] W. Fedus, B. Zoph, and N. Shazeer, "Switch transformers: Scaling to trillion parameter models with simple and efficient sparsity," *J. Mach. Learn. Res.*, vol. 23, pp. 1-39, 2022.