

SAE-CCNN: 건물 윤곽 정보를 결합한 심층 신경망 기반 실내 측위 기법

오용정, 노혜민, 신원재*

부산대학교 전자공학과

oyj8519@pusan.ac.kr, nohmin06@pusan.ac.kr *wjshin@pusan.ac.kr

SAE-CCNN: Deep Neural Network Based Indoor Positioning Technique By combining Boundary Information of Building

Yongjeong Oh, Hea-Min Noh, Wonjae Shin*

Department of EE, Pusan National Univ.

요약

본 논문에서는 심층 신경망 기반 실내 측위 모델에서 건물 윤곽 정보를 활용하는 기법에 관해 기술한다. 일반적으로 심층 신경망 모델은 성능 향상을 위해 적합한 신경망 구조를 찾거나 신경망의 하이퍼-파라미터(hyper-parameter)를 조절하는 등의 방법을 사용한다. 이는 실내 측위의 특성을 고려하지 않은 방법으로, 위치 추정값이 건물 외부에도 존재할 수 있다는 근본적인 문제점을 해결할 수 없다. 따라서 본 논문에서는 문제의 해법으로 건물 윤곽 정보를 추출하여 심층 신경망 학습에 사용하여 추정 성능을 개선하는 방안을 제안한다. 모의실험을 통하여 제안하는 방법이 기존 심층 신경망보다 실내 측위 정확도가 더 우수함을 확인하였다.

I. 서론

Wi-Fi fingerprinting 기반 실내 측위 기술은 무선장치에서 다수의 Wi-Fi 신호의 RSSI(Received Signal Strength Intensity)를 측정하여 해당 무선장치 사용자의 위치를 추정하는 기술로, 현재 Wi-Fi의 보편화로 실내 측위 기술 중 가장 활발하게 연구되고 있다[1].

최근에는 심층 신경망을 통해 Wi-Fi fingerprinting을 다루는 기법이 떠오르고 있는데, 특히 SAE-CNN의 실내위치 추정 기법은 복수의 다층 건물(multi-building, multi-floor) 환경에서 건물, 층 추정 정확도가 각각 100%, 94%로 기존 기법들과 비교하여 매우 우수한 성능을 보인다[1]. 논문[1]에서는 SAE(Stacked Auto-Encoder)로 Wi-Fi fingerprinting의 특징을 추출하여 CNN(Convolutional Neural Network)을 통해 건물과 층을 분류(classification)로, 위치는 평균 회귀(regression)로 예측하는데, 건물과 층, 위치 3가지를 개별적으로 학습하기 때문에 정보의 연관성을 잃는다. 또한, 추정된 위치가 건물 외부에 있는 등 성능 저하되고, 신뢰할 수 없다는 문제점이 있다.

따라서 본 논문에서는 실내 측위 성능 개선을 위해 건물을 미리 식별하고, 해당 건물의 윤곽선 정보를 실내 측위 학습 모델의 사전 정보로 활용한다. 구체적으로 말하면, 추정 결과가 건물 내에 위치하도록 제약식을 정의하고 기존 회귀 예측에 사용되는 손실함수에 소프트 제약을 부가하는 방법을 제안한다[3]. 이 기법을 SAE-CCNN(Constrained CNN)이라 한다. 모의실험 결과를 통해 SAE-CCNN이 기존의 SAE-CNN과 비교하여 성능이 개선됨을 확인하였다.

II. 시스템 및 데이터 구조

II-A. 시스템 모델

본 논문에서 제안하는 SAE-CCNN은 논문[1]의 SAE-CNN 구조에 기반을 둔다. SAE-CNN은 건물, 층, 위치를 개별적으로 학습하는 병렬 구조(parallel model)를 가진다. 하지만 제안하는 SAE-CCNN은 건물 식별 모델을 먼저 학습하여 대상이 있는 건물을 예측하고,

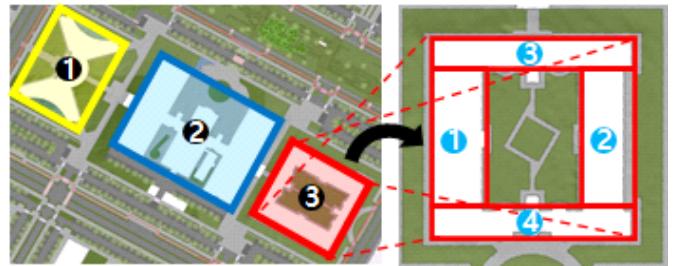


그림 1. UJIIndoorLoc의 건물 구조(좌)와 확대한 건물 3의 구조(우)

예측된 건물 윤곽선 정보에 입각하여 실내 측위 모델이 학습하는 순차적 구조(sequential model)를 갖춘다. 건물을 먼저 식별함으로써 대상의 위치를 대략 특정할 수 있고, 사용하는 건물 식별 모델의 정확도가 100%이므로 예측값을 충분히 믿을 수 있다. 또한, 건물 윤곽선 정보를 활용함으로써 위치 추정 결과가 건물 내부에 존재하도록 제약할 수 있다.

II-B. 데이터 개요

본 논문에서는 WiFi fingerprinting 기반 실내 측위 성능 평가로 가장 흔히 사용하는 자료인 UJIIndoorLoc 측위 자료를 이용한다[2]. 해당 자료는 그림 1과 같이 스페인 UJI Riu Sec 캠퍼스의 3개의 다층 건물에서 총 520개의 WAPs(Wireless Access Points)으로부터 실측한 RSSI 값과 측정한 위치의 건물, 층, 좌표 데이터로 구성된다. Wi-Fi fingerprinting은 520개의 -104dBm ~ 0dBm 범위를 가지는 RSSI로 이루어져 있고, 좌표 데이터는 UTM(Universal Transverse Mercator) 좌표계로 나타내어진 종·횡 좌표로써, 그림 1과 같이 실제 지도와 일치한다. 본 논문에서는 위치 오차가 가장 많이 나타나는 건물 3을 대상으로 하였다. 차후 Constrained CNN 학습을 위해 그림 1과 같이 회전하고, 건물을 4개의 직사각형의 구역으로 나누어 구성하였다.

III. 건물 윤곽 정보 활용 기법 - Constrained CNN

본 장에서는 SAE-CCNN의 실내 측위 모델에서 사용하는 손실함수에 관해 기술한다. 이는 기존 SAE-CNN[1]의 실내 측위 모델 손실함수에

소프트 제약을 추가함으로써 건물 윤곽선 정보를 신경망에 제공할 수 있다. 기존의 SAE-CNN의 실내 측위 모델에서는 식 (1)과 같이 손실함수 $L_{MSE}(\mathbf{w})$ 을 최소화하는 가중치(weight) \mathbf{w} 를 학습하여 결과를 추정한다.

$$\min_{\mathbf{w}} L_{MSE}(\mathbf{w}) \quad (1)$$

여기서, $L_{MSE}(\mathbf{w})$ 는 MSE(Mean Squared Error) 손실함수로 추정값과 참값의 오차를 줄이는 방향으로 심층 신경망이 학습한다. 하지만, 범위의 제한은 없으므로, 위치 추정 결과가 건물 3의 중앙 부분과 같은 건물 외부로 잘못 추정되는 치명적인 오류가 높은 빈도로 발생한다. 따라서, 본 논문에서는 건물 윤곽에 대한 정보를 제공하는 방법으로 위치 추정 결과가 건물 내부에 존재하도록 제약식을 추가한 소프트 제약식[2]을 제안한다. 제안하는 제약식은 아래와 같다.

$$\min_{\mathbf{w}} (L_{MSE}(\mathbf{w}) + \lambda C(\mathbf{w})) \quad (2)$$

여기서, $C(\mathbf{w})$ 는 제약식, λ 는 $C(\mathbf{w})$ 의 하이퍼파라미터로, 제약식의 비중을 조정한다. 본 논문에서 사용한 제약식은 다음과 같은 접근을 통해 정의한다.

Algorithm 1 Compute Constraint

- 임의의 점과 넓이 \mathbf{A} 의 직사각형이 평면 위에 있다고 가정한다.
- 임의의 점과 직사각형의 꼭짓점들을 이은 선분을 대각선으로 하는 4개의 직사각형 넓이의 합을 \mathbf{B} 라 한다.
- 임의의 점이 직사각형 내부에 위치할 경우 $\mathbf{B} - \mathbf{A} = 0$ 이고, 외부에 위치할 경우 $\mathbf{B} - \mathbf{A} > 0$ 임을 이용하여 $\mathbf{B} - \mathbf{A} = 0$ 을 제약식으로 정의한다.

Algorithm 1으로 임의의 점이 하나의 직사각형 내부에 위치하는지 쉽게 판별할 수 있다. 이를 확장하여 그림 1과 같이 건물 윤곽선 정보를 다수의 직사각형 구역으로 구성한다. 예측한 좌표가 4개의 구역 중 하나에 포함되면 건물 내부라고 판단하도록 제약식을 정의하면 아래 식과 같다.

$$\min_{\mathbf{w}} (L_{MSE}(\mathbf{w}) + \lambda \min(C_1(\mathbf{w}), C_2(\mathbf{w}), C_3(\mathbf{w}), C_4(\mathbf{w}))) \quad (3)$$

IV. 모의실험 성능 분석

모의실험을 실행하여 제안하는 SAE-CCNN의 실내 측위 모델 성능을 기존의 SAE-CNN과 비교하여 분석하였다. 모의실험에 사용된 SAE-CCNN의 실내 측위 모델에 사용된 파라미터는 표 1에 정리하였다.

그림 2는 학습된 심층 신경망에 시험 데이터(test data)의 위치 추정 결과를 좌표로 나타낸 것으로, 좌측은 SAE-CNN[1]의 결과, 우측은 SAE-CCNN의 결과이다. 그림을 통해 건물 정보를 활용하지 않은 SAE-CNN은 건물 외부로 잘못 추정된 결과가 다수 존재하지만, SAE-CCNN에서는 그 수가 많이 감소하여 건물 정보를 충분히 활용하였음을 확인할 수 있다.

그림 3은 실내 측위 성능 분석을 위해 위치 추정 오차를 최댓값, 최솟값, 평균값으로 타 모델들과 비교하여 분석하였다. 모든 값에서 SAE-CCNN의 오차가 가장 작은 것을 확인할 수 있다. 이 모의실험의 SAE-CCNN에서는 가중치 초기화 기법 중 하나인 He normal initialization과 $\lambda = 0.3$ 을 사용하였다.

또한, 제안하는 방법에서 제약식의 최적의 λ 값을 설정하기 위해 λ 에 따른 성능 분석을 표 2에 정리하였다. λ 가 0.3일 때, 가장 우수한 성능을 보였다.

표 1. SAE-CCNN 실내 측위 모델의 파라미터

| Parameter | Values |
|-----------------------|-----------------------------|
| Weight Initialization | He Normal Initialization |
| Early Stopping | Epoch = 1000, Patience = 50 |
| Optimizer | Adamax(Learning rate=0.005) |

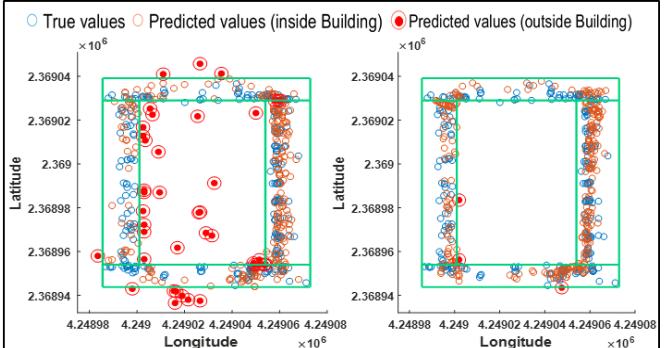


그림 2. 기존 SAE-CNN[2](좌)와 제안된 SAE-CCNN(우)의 평가 데이터 예측 결과 비교

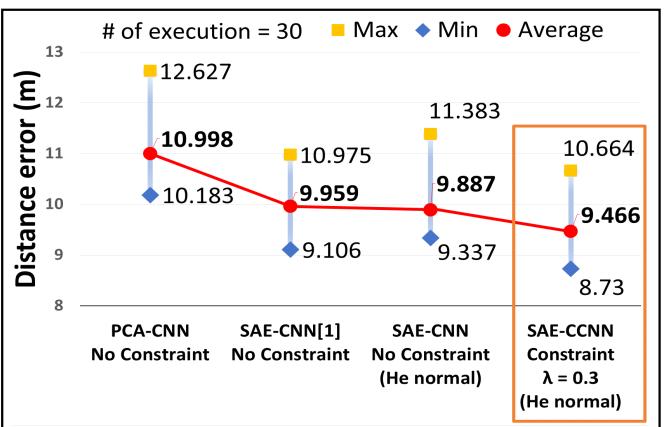


그림 3. PCA-CNN, SAE-CNN[1], SAE-CCNN의 위치 추정 오차 비교

표 2. λ 에 따른 성능 비교

| Distance error (m) | λ | | | | |
|--------------------|-----------|--------|--------|--------|--------|
| | 0.1 | 0.3 | 0.5 | 0.7 | 0.9 |
| Maximum | 11.223 | 10.664 | 10.366 | 10.615 | 11.376 |
| Minimum | 8.786 | 8.730 | 8.904 | 8.777 | 8.622 |
| Average | 9.743 | 9.466 | 9.572 | 9.638 | 9.855 |

V. 결론

본 논문에서는 무선장치 사용자의 실내 측위 시, 사용자가 있는 건물을 먼저 식별하고 해당 건물 윤곽선을 활용한 심층 신경망인 SAE-CCNN을 제안하였다. 그리고 모의실험을 통해 실내 측위 성능이 기존의 SAE-CNN과 비교하여 개선됨을 확인하였다.

참 고 문 헌

- [1] X. Song, et al. "A novel convolutional neural network based indoor localization framework with WiFi fingerprinting," *IEEE Access*, vol. 7, pp.110698 - 110709, 2019.
- [2] J. Torres-Sospedra, et al. "UJIIndoorLoc: A new multi-building and multi-floor database for WLAN fingerprint-based indoor localization problems," in *Proc. Int. Conf. Indoor Positioning Indoor Navigat. (IPIN)*, Oct. 2014, pp.261 - 270.
- [3] Marquez-Neila, P., Salzmann, M., and Fua, P. Imposing hard constraints on deep networks: Promises and limitations. *arXiv preprint arXiv:1706.02025*, 2017.