

딥러닝 기반 Wi-Fi 핑거프린트 실내 측위 기법 동향 및 전망

노혜민*, 오용정*, 이남윤**, 신원재^o

A Survey of Deep Learning-Assisted Indoor Localization with Wi-Fi Fingerprinting: Current Status and Research Challenges

Hea-Min Noh*, Yongjeong Oh*, Namyoon Lee**, Wonjae Shin^o

요약

최근 5G 시대를 맞이하여 스마트 기기와 함께 사물인터넷 기술의 급속한 발전과 활용 분야의 확대에 따라, 무선 신호를 이용한 실내 측위 기법이 활발히 연구되고 있다. 다양한 실내 환경에서 높은 위치 추정 정확도와 낮은 복잡성을 가지는 실내 측위 기법을 개발하는 것은 매우 어려운 일이다. 여러 실내 측위 기법 중에서 Wi-Fi 신호를 활용한 핑거프린트 기법은 별도의 장비 설치 및 인프라 구축이 필요 없이, 위치 추정이 가능하므로 최근 학계 및 산업체로부터 많은 주목을 받고 있다. 최근에는 비약적으로 발전한 머신러닝 및 딥러닝 기술들이 Wi-Fi 핑거프린트 방식에도 접목되면서, 실내 측위 정확도가 대폭 향상되고 있다. 따라서 본 논문에서는 머신러닝 및 딥러닝 기술을 활용한 Wi-Fi 핑거프린트 실내 측위 기법에 대한 최신 기술 동향 및 장단점에 대해 소개한다. 또한, 기술된 Wi-Fi 핑거프린트 실내 측위 기술 동향을 기반으로 새로운 연구 방향 및 이슈들에 관해 논한다.

키워드 : 실내 측위, Wi-Fi 핑거프린트, 머신러닝, 딥러닝

Key Words : Indoor localization, Wi-Fi fingerprint, Machine learning, Deep learning

ABSTRACT

In the recent 5G era, according to the rapid development of Internet-of-Things technologies along with smart devices and expansion of its application, the indoor localization techniques using wireless signals have been extensively studied. It is a very challenging task to develop an indoor localization technique with high location accuracy and low complexity in various indoor environments. Among many indoor localization techniques, fingerprint technique using Wi-Fi signals has been received the greatest interest from academia and industry because location estimation is possible without the need for installing separate equipment and constructing infrastructure. Recently, the accuracy of indoor localization has been largely improved as machine learning and deep learning technologies, which have been rapidly developed, have been incorporated into Wi-Fi fingerprints. Therefore, in this paper, we introduce the state-of-the-art trends and pros-and-cons of indoor localization techniques based on Wi-Fi fingerprint utilizing machine learning and deep learning technologies. Furthermore, we discuss new research directions and issues based on the described trends of indoor localization techniques for Wi-Fi fingerprint.

* 본 연구는 2020학년도 부산대학교 BK21 FOUR 대학원혁신지원사업에 의한 연구임.

• First Author : Pusan National University Department of Electronics Engineering, nohmin06@pusan.ac.kr, 학생회원

^o Corresponding Author : Ajou University, Department of Electrical and Computer Engineering, wjshin@ajou.ac.kr, 정회원

* Pusan National University Department of Electronics Engineering, oyj8519@pusan.ac.kr

** POSTECH Department of Electrical Engineering, nylee@postech.ac.kr, 종신회원

논문번호 : 2020102-030-C-RU, Received February 6, 2021; Revised February 15, 2021; Accepted February 16, 2021

1. 서론

실내 측위(indoor localization) 기술은 사물인터넷(internet of things) 서비스를 고도화하는데 필수적인 역할을 한다^{1,2)}. 건물의 대형화 및 사람들의 실내 활동 증가로 인해 실내 내비게이션과 같은 실내 측위 기반 서비스(location-based service)의 수요가 급격히 증가하고 있다. 현재 구글에서 Wi-Fi 기반의 측위 기술을 이용하여 실내 공간에서 사용자가 요청한 경로를 알려주는 서비스를 제공하고 있으며, 구글 외 다양한 국내외 기업들이 실내 측위 기반 서비스에 주목하고 있다.

실외 환경에서 대표적으로 사용되는 측위(outdoor localization) 기술은 GPS(Global Positioning System)를 이용하는 것이다. GPS 기반 측위 기술은 실외에서 우수한 위치 추정 성능을 보이는 장점이 있다. 그러나 실내에서는 반사 및 회절로 인한 GPS 수신 신호의 부정확도로 인해 측위 성능이 현저히 저하된다는 문제점이 있다³⁾. 이러한 문제점을 극복하기 위해 실내에서는 GPS 신호를 대신하여 UWB(Ultra-Wideband), RFID(Radio Frequency Identification), Wi-Fi 등의 무선 신호들을 활용하여 사용자의 위치를 추정하는 기술들이 고려되고 있다^{4,5)}. 특히 Wi-Fi의 경우, 실내 측위를 위한 별도의 인프라를 구축할 필요가 없어, 추

가적인 비용이 발생하지 않아 Wi-Fi 신호를 기반으로 한 실내 측위 기술들이 활발하게 연구 및 개발되고 있다⁶⁾.

UWB, RFID, Wi-Fi 등의 무선 신호를 활용하는 대표적인 측위 기술은 <그림 1>과 같이 세 가지로 분류할 수 있다. 위치 추정 대상과 다수의 접속점(Access Point, AP) 사이의 거리를 측정하는 기법인 TOA(Time of Arrival), 각도를 측정하는 기법인 AOA(Angle of Arrival), 참조 위치(Reference Point, RP)마다 다수의 접속점으로부터 오는 수신 신호 세기(Received Signal Strength, RSS)를 기록한 데이터베이스를 기반으로 사용자의 위치를 추정하는 핑거프린트(fingerprint) 기법이 있다. TOA, AOA 기법들은 신호의 직진파(Line of Sight, LOS) 성분들을 주로 활용하여 위치를 추정하는 특징을 지니고 있다. 그러므로, 비교적 장애물이 적은 실내외에서는 신호의 직진파 성분이 노이즈, 신호 간섭에 강하기 때문에 두 기법을 활용한 알고리즘의 위치 추정 정확도가 우수하다. 그러나 대부분의 실내 환경에서는 다중경로(multipath)에 의한 자기 신호 간섭이 발생하고, 변화하는 주변 환경에 따라 신호가 지속적으로 변하기 때문에 TOA 및 AOA 기법들로 정확한 실내 측위 성능을 달성하기는 어렵다^{7,8)}. 따라서 신호의 직진파 성분과 다중경로 성분의 세기를 모두 활용하여 구축된 데이터베이스를 기반으로 위치를 추정하는 핑거프린트 기술은 높은 실내 측위 정확도로 인해 현재 학계에서 활발히 연구되고 있다.

핑거프린트 기술을 이용할 경우 발생하는 어려움 중 하나는 핑거프린트 데이터베이스 내의 데이터를 분석하여 알고리즘을 개발하는 것이다. 왜냐하면, 핑거프린트 데이터베이스의 규모는 일반적으로 매우 크고, 복잡성도 높기 때문이다. 이러한 문제를 해결하기 위해 최근 대용량의 복잡한 데이터를 효율적으로 처리하는 머신러닝 및 딥러닝 기법을 활용한 핑거프린트 기술이 각광받고 있다.

머신러닝이란 특정한 영역에서 발생하는 데이터베이스 또는 축적된 경험을 통해 기계가 스스로 학습을 수행 후, 새롭게 발생한 데이터에 대해 분류 또는 추정 문제를 해결하려는 기법으로 높은 정확도를 자랑한다. 특히 머신러닝의 대표적인 알고리즘 중 딥러닝이 그 우수성을 인정받아 최근 주목받고 있는데, 딥러닝이란 비선형적 함수, 가중치(weight), 그리고 편향치(bias) 등으로 구성된 심층 신경망(Deep Neural Network, DNN)을 학습시키는 방식으로 다량의 데이터나 복잡한 자료들 속에서 핵심적인 내용 또는 특징

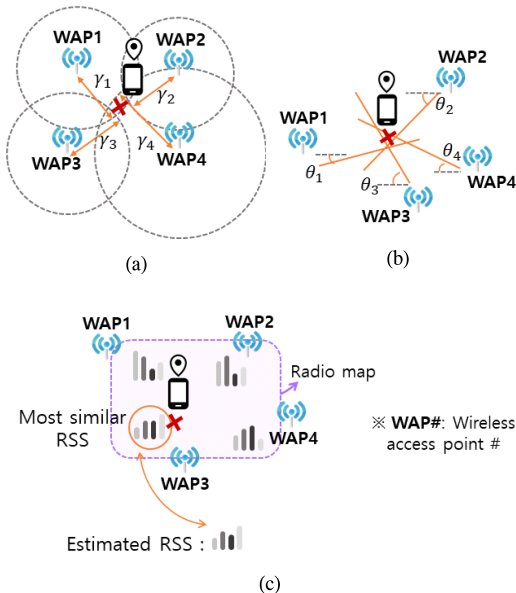


그림 1. 대표적인 무선신호 측위 기법 (a) Time of Arrival(TOA), (b) Angle of Arrival(AOA), (c) 핑거프린트 Fig. 1. Typical methods of Localization (a) Time of Arrival(TOA), (b) Angle of Arrival(AOA), (c) Fingerprint

을 추출하여 분류 또는 추정 문제를 해결하려는 기법이다. 본 논문에서는 핑거프린트 데이터베이스 내의 막대한 데이터를 효과적으로 처리하는 머신러닝 및 딥러닝 기반 핑거프린트 실내 측위 기술에 대해 상세히 알아볼 예정이다.

본 논문의 세부 구성은 다음과 같다. II장에서는 본 논문의 바탕 기술이 되는 Wi-Fi 핑거프린트 기법에 대해 소개한다. III장에서는 머신러닝 및 딥러닝에 적용될 수 있는 실내 위치 모델(location model)과 좌표 체계를 소개한다. 이와 더불어 각 위치 모델에 따른 학습 방법 및 대표적으로 사용하는 손실 함수를 정의한다. 그리고 IV장에서는 대표적인 머신러닝 기법인 k -NN과 SVM을 활용한 Wi-Fi 핑거프린트 실내 측위 기법에 대해 알아본다. 이후, 딥러닝 기법 중 합성곱 신경망과 순환 신경망을 활용한 핑거프린트 실내 측위 기법을 소개한다. 또한, 알파고와 같은 게임 분야에서 우수한 성능을 보인 강화학습을 활용한 실내 측위 기법에 관해 설명한다. V장에서는 앞서 기술한 Wi-Fi 핑거프린트 실내 측위 기술 동향을 기반으로 새로운 연구 방향 및 이슈들에 대해 논하고, VI 장에서 논문의 결론을 지으며 마무리한다.

II. Wi-Fi 핑거프린트 기법 개요

Wi-Fi 핑거프린트 기반 실내 측위 기법은 임의의 참조 위치에서 접속점들로부터 오는 수신 신호 세기(Received Signal Strength, RSS)들이 다양한 환경적 요소(측정 환경, 신호 감쇠 등)로 인한 오차를 포함하는 것에 기인하여, 확률적 기반의 알고리즘을 이용하는 모델링 방법이다. Wi-Fi 핑거프린트 기법의 과정을 <그림 2>와 같이 요약 및 도시하였는데, 두 단계 1) offline phase, 2) online phase로 구성되는 것을 알 수 있다. 두 단계의 세부적인 내용은 다음과 같다.

1) offline phase에서는 건물 내부에서 임의로 또는 일정 간격마다 선정된 M 개의 참조 위치(Reference Point, RP)에서 N 개의 접속점(Access Point, AP)들로부터 오는 수신 신호 세기를 수집하여 기록한다. 임의의 참조 위치에서 측정된 수신 신호 세기 값은 아래 식과 같이 벡터 형태로 표현할 수 있다.

$$\mathbf{r}_i = [r_{i1}, r_{i2}, \dots, r_{iN}], \quad i = 1, \dots, M, \quad (1)$$

여기서 r_{ij} 는 i 번째 참조 위치에서 측정된 j 번째 접속점의 수신 신호 세기 값을 의미한다. 그리고 i 번

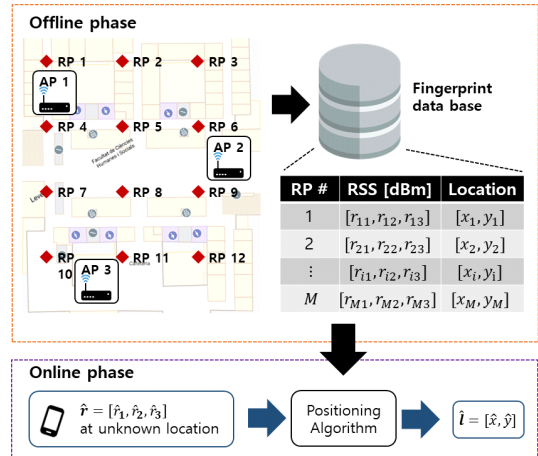


그림 2. Wi-Fi 핑거프린트 기반 실내 측위 기법 개요
Fig. 2. Outline of Wi-Fi fingerprint based indoor localization

째 참조 위치의 위치 \mathbf{l}_i 를 2차원 좌표계를 사용했을 때 다음 식과 같이 표현할 수 있다.

$$\mathbf{l}_i = [x_i, y_i], \quad i = 1, 2, \dots, M \quad (2)$$

핑거프린트 데이터베이스를 구성하는 각 데이터는 이산적인 $\{\mathbf{r}_i, \mathbf{l}_i\}_{i,t}$ 로 표현되고, 여기서 t 는 측정 시각이다.

핑거프린트 데이터베이스를 구축한 후, 수신 신호 세기 \mathbf{r} 과 위치 \mathbf{l} 사이의 연관성을 여러 알고리즘을 통해 학습할 수 있다. 이때 수집된 데이터의 양과 수집할 당시 주변 환경의 변화, 기기의 종류 등 다양한 요소들이 알고리즘 학습을 어렵게 만든다. 이러한 문제를 해결하기 위해 수집된 핑거프린트 데이터베이스를 분석하여 신뢰할 수 없는 데이터를 제거함으로써, 데이터베이스의 품질을 높일 수 있는 연구가 있다^[9]. 현재 실내 측위 연구를 위한 다양한 Wi-Fi 핑거프린트 데이터베이스들이 구축되어있고, 이에 관한 내용은 뒤에서 상세하게 설명한다.

2) online phase에서는 사용자의 단말기로부터 측정된 수신 신호 세기 값 $\hat{\mathbf{r}}$ 을 앞선 offline phase에서 학습된 알고리즘에 입력함으로써 사용자의 추정 위치 $\hat{\mathbf{l}}$ 을 산출한다. 이를 사상 함수(mapping function)로 나타내면 아래 식과 같은데,

$$F: \hat{\mathbf{r}} \rightarrow \hat{\mathbf{l}}, \quad (3)$$

딤러닝 기반 실내 측위에서는 학습된 심층 신경망이 사상 함수 F 의 역할을 대신하게 된다.

모든 과정 중 offline phase에서의 데이터 수집 과정이 가장 번거롭고 시간 소모가 크다. 이 과정을 실내 측위 연구자들이 대중에게 공개한 다양한 Wi-Fi 핑거프린트 데이터베이스로 대체할 수 있다. 특히 실내 위치 인식 및 내비게이션 기술과 관련하여 매년 IPIN(Indoor Positioning and Indoor Navigation) 국제 학술대회가 개최되고 있다. 이 대회에서 사용된 일부 데이터베이스들이 대중에게 공개되어 대회 참여자들의 차후 연구를 돕고, offline phase에서의 노동집약적인 데이터 수집 과정을 생략할 수 있게 하였다. IPIN 대회에 사용된 데이터베이스와 그 이외에도 많이 사용되는 데이터베이스들을 <표 1>에 정리하였다. 이 중, 성능 평가로 가장 많이 이용되는 데이터베이스는 IPIN 2015 대회에 사용된 UJIIndoorLoc 데이터베이스로^{[10],[11]}, 본 논문에서 소개할 실내 측위 기법들의 성능 비교에 쓰일 예정이다. 해당 데이터베이스는 스페인에 위치한 Jaume I 대학의 세 건물에서 수집한 데이터(수신 신호 세기, 참조 위치 등)로 구성되어 있다. 구체적으로 <그림 3>과 같이 나란히 위치한 세 개의 건물에서 총 520개의 접속점으로부터 측정된 수신




그림 3. UJIIndoorLoc 데이터베이스의 건물 도면[10,11]
Fig. 3. Floor plan of buildings in UJIIndoorLoc database[10,11]

신호 세기는 -100 ~ 0 dBm 사이의 값으로 기록되었고, 신호를 감지하지 못했을 경우에는 100으로 표기되었다. 측정된 수신 신호 세기와 함께 각 참조 위치는 위도, 경도, 층, 그리고 건물 번호로 구성되어 있고, 측정했을 당시의 시간도 기록되어 있다. 데이터베이스는 2013년도에 약 2 ~ 3주를 간격으로 총 두 달간 수집되었고, 하나의 참조 위치에서 수신 세기 신호는 1 ~ 2분 간격으로 최대 10번 이하로 반복 측정되었다. 그리고 UJIIndoorLoc 데이터베이스의 통계치는 <표 2>에 정리하였다.

지금까지 Wi-Fi 핑거프린트 기법의 개요를 두 단계 (offline and online phase)로 나누어 살펴보고, 활용 가능한 데이터베이스에 대해 알아보았다. Wi-Fi 핑거프린트 기법의 핵심은 offline phase에서 구축된 데이터베이스로부터 위치 추정에 최적화된 알고리즘을 학습하는 것이다.

표 1. 공개된 Wi-Fi 핑거프린트 데이터베이스
Table 1. Public Wi-Fi fingerprint databases

Title	Year	Details
Fingerprint traceset from mannhein/compass dataset	2008	[12],[13]
Indoor WLAN measurement database	2014	[14]
UJIIndoorLoc Database	2014	[10],[11]
Indoor User Movement Prediction from RSSI data Data Set	2016	[15],[16]
Geotec Database	2016	[17],[18]
IPIN Database 2016	2016	[19],[20]
kth/rss dataset	2016	[21]
WiFi RSSI, Bluetooth and magnetometer DataSet	2016	[22],[23]
Alcalá Tutorial Database	2017	[24],[25]
Tampere	2017	[26]
Geo-Magnetic field and WLAN dataset Data Set	2017	[27],[28]
IPIN Competition Database 2016	2017	[29]
IPIN Competition Database 2017	2017	[30]
IPIN Competition Database 2018	2018	[31]
IPIN Competition Database 2019	2019	[32]

표 2. UJIIndoorLoc 데이터베이스의 통계치
Table 2. Statistics of UJIIndoorLoc database

# of training samples	19,937
# of test samples	697
# of APs	520
# of floors	4~5

III. 실내 위치 모델 및 좌표체계

본 장에서는 머신러닝 및 딤러닝에 적용될 수 있는 실내 위치 모델(location model)과 좌표체계에 관해 알아본다. 위치 모델은 실내 공간에서의 특정 위치를 일관되고 체계적인 방식으로 기술할 수 있도록 하며, 머신러닝 및 딤러닝 기반 실내 측위 기술의 출력 형태를 결정한다. 대표적으로 활용되는 위치 모델로는 기호적 위치 모델, 지리 위치 모델이 있는데 자세한 내용은 다음과 같다.

3.1 기호적 위치 모델

기호적 위치 모델(symbolic location model)은 실제 지리적 위치를 사용하지 않고 추정하고자 하는 실내 공간을 건물의 층, 방 등의 작은 공간들로 나눈 후, 기호(symbol)를 부여하여 실내 공간의 위치를 모델링하는 것이다. 이를 <그림 4-(a)>에 나타내었다. 이 모델을 사용했을 경우 위치 추정 결과가 실내 공간 내부에 있다는 확실한 보장성을 부여할 수 있다. 그러나 전체 공간을 작은 공간으로 나누는 명확한 기준을 세우기 어렵고, 실내 내비게이션 서비스에서 필요한 정확한 거리 계산이 어렵다는 단점이 있다. 머신러닝 및 딥러닝에서 기호적 위치 모델을 적용할 경우, 공간적 분류 문제로 풀이하는데, 이때 사용되는 대표적인 손실 함수는 아래 식과 같이 교차 엔트로피 오차(Cross Entropy Error, CEE)이다.

$$L_{CEE} = \sum_{k=1}^K a_k \ln b_k, \quad (4)$$

여기서 a 는 정답을 나타내는 수로 정답일시 1, 오답일시 0의 값을 가진다. b 는 신경망의 출력값, K 는 학습 데이터의 개수를 나타낸다. 위 손실 함수는 비단 본 논문에서 다루는 실내 측위 문제뿐만 아니라 딥러닝 기반의 분류(classification) 문제를 해결할 때 사용하는 대표적인 손실 함수이다.

3.2 지리 위치 모델

지리 위치 모델(geometry location model)은 <그림 4-(b)>와 같이 실제 지리적 위치를 나타내는 지리 좌표값(geometry coordinates)을 사용하여 실내 공간의 위치를 모델링 하는 것이다. 이 모델은 기호적 위치 모델과 달리 정확한 거리 계산을 할 수 있어, 다양한 실내 측위 서비스를 제공할 수 있다. 그러나 위치 추

정 결과가 실내 공간 내부에 있다는 확실한 보장성을 부여할 수는 없다. 지리 위치 모델을 머신러닝 및 딥러닝에 적용할 경우, 수치를 예측하는 회귀 문제로 풀이한다. 이때, 예측된 위치 좌표와 정답 좌표 사이의 오류를 줄이기 위해, 주로 아래의 식과 같이 평균 거리 오차(Mean Square Error, MSE) 손실 함수를 사용한다.

$$L_{MSE}(\mathbf{w}) = \frac{1}{K} \sum_{i=1}^K (l_i - \phi(\mathbf{r}_i, \mathbf{w}))^2, \quad (5)$$

여기서 l_i 는 정답 값, $\phi(\mathbf{r}_i, \mathbf{w})$ 는 심층 신경망의 예측값, 그리고 K 는 학습 데이터의 개수이다. 정답 값 l_i 는 앞서 Wi-Fi 핑거프린트 기법의 offline phase를 알아본 바와 같이 주로 2차원 좌표계를 사용한다.

요약하면 머신러닝 및 딥러닝에 기호적 위치 모델을 적용할 경우 분류 문제로 풀이하고, 지리 위치 모델을 적용할 경우 회귀 문제로 풀이한다는 것이다. 다음 장에서는 본 절에서 살펴본 두 위치 모델을 적용한 머신러닝 및 딥러닝 기반 Wi-Fi 핑거프린트 실내 측위 기법들에 대해 상세히 알아본다.

IV. 머신러닝 및 딥러닝 기반 실내 측위

본 장에서는 본격적으로 머신러닝 및 딥러닝 기반 Wi-Fi 핑거프린트 실내 측위 기술에 대해 알아본다. 먼저 기존 머신러닝 기반 실내 측위 기법을 간략히 서술하고 그 한계점을 알아본 후, 딥러닝 기반 실내 측위 기술을 알아본다.

4.1 기존 머신러닝 기반 실내 측위 기법

본 절에서는 기존 머신러닝 기반 실내 측위 기법 중 대표적인 두 알고리즘, 1) k -NN(k -Nearest Neighbor)과 2) SVM(Support Vector Machine)을 소개하고, 3) 실내 측위 분야에서 두 알고리즘이 가지고 있는 한계점에 대해 알아본다.

4.1.1 k -NN 알고리즘

k -NN 알고리즘은 새로운 데이터를 입력받았을 때, 구축된 데이터베이스에서 새로운 데이터와 가장 유사한 k 개 데이터를 선정 및 참조하여 분류 또는 회귀 문제를 풀이하는 알고리즘으로, 머신러닝 분야에서 매우 간단하지만, 효과적인 알고리즘 중 하나이다. Wi-Fi 핑거프린트 기법을 적용한 k -NN의 경우, 사용




그림 4. 실내 공간의 위치를 명시하기 위한 위치 모델
Fig. 4. Location models for specifying locations of indoor space

자의 위치를 추정할 때, 측정된 수신 신호 세기를 데이터베이스 내의 수신 신호 세기 모두와 비교한다. 그 후, 가장 유사한 값을 가지는 k 개의 수신 신호 세기를 선정하여 해당 참조 위치를 참고하여 사용자의 위치를 추정한다. 선정된 참조 위치 정보들로부터 거리 제곱 평균 등 다양한 계산과정을 통하여 사용자의 위치를 최종적으로 결정하는데, 이때 사용하는 계산 방법에 따라 weighted k -NN^[33], soft-range limited k -NNs^[34] 등으로 나뉠 수 있다.

4.1.2 SVM 알고리즘

SVM(Support Vector Machine) 알고리즘은 패턴 인식 분야에서 제안된 알고리즘으로, 데이터가 가지는 특징을 구분하는 최적의 초평면(hyperplane)을 찾는 것을 목적으로 가진다. 특히 SVM 알고리즘은 저차원의 데이터를 활용한 이진 선형 분류 문제를 풀이하는데 특화되어있는데, 커널 함수(kernel function)를 사용함으로써 저차원의 데이터를 고차원의 특징 공간 영역으로 변경하여 비선형적 분류 문제를 풀이하는 것도 가능하다. 분류 문제에서 사용된 SVM의 원리를 기반으로 하여 회귀 문제를 풀이할 수도 있는데, 이때는 SVR(Support Vector Regression)이라고 명칭하기도 한다. Wi-Fi 핑거프린트 실내 측위 기법을 SVM에 적용했을 경우, 먼저 offline phase에서 Wi-Fi 핑거프린트 데이터베이스로부터 데이터를 잘 구분하는 SVM 모델을 학습한다. online phase에서 수신 신호 세기를 받아오면, 학습된 SVM 모델에 입력하여 유사도가 높은 참조 위치들을 찾아 거리 제곱 평균 계산을 통해 사용자의 위치를 추정한다^[35,36].

4.1.3 기존 머신러닝 알고리즘들의 한계

위에서 제시한 기존 머신러닝 알고리즘들(k -NN, SVM)은 각각 실내 측위 분야에서 여러 가지 한계점을 가지고 있다. 먼저, k -NN 알고리즘은 사용자의 위치를 추정하기 위해 단말기에서 측정된 수신 신호 세기를 구축된 모든 Wi-Fi 핑거프린트 데이터와 비교해야 하므로 연산 집약적(computation-intensive)이고, online phase에서도 핑거프린트 데이터베이스를 저장하고 있어야 하므로 알고리즘의 크기가 매우 커지는 문제점이 있다. 다음으로 SVM 알고리즘은 k -NN 알고리즘과 달리 핑거프린트 데이터베이스를 offline phase에서 SVM 모델을 학습할 때에만 사용하지만, 복잡한 하이퍼-파라미터(hyper-parameter) 조정과 저차원의 데이터를 고차원의 특징 공간 영역으로 변경하는 커널 함수(kernel function) 선택과정에서, 많은

테스트가 요구된다. 이러한 과정은 매우 복잡하고 알고리즘의 최적화를 어렵게 하며, 데이터의 수가 많을수록 학습 속도가 느려진다는 한계점이 있다. 최근 많은 실내 측위 연구자들은 이러한 한계점들을 딥러닝과 Wi-Fi 핑거프린트 기술을 결합함으로써 해결하고자 한다.

다음 장부터는 최근 활발히 연구되고 있는 딥러닝 기법 중 합성곱 신경망, 순환 신경망 그리고 강화학습에 대해 상세히 살펴보고, 각 기법이 실내 측위 분야에 어떻게 적용이 되었는지 소개한다. 특히 각 기법의 학습 방법을 위주로 설명하고, UJIIndoorLoc 데이터베이스를 활용한 신경망들의 성능까지 비교 분석한다.

4.2 합성곱 신경망 기반 실내 측위 기법

4.2.1 합성곱 신경망 개요

합성곱 신경망(Convolutional Neural Network, CNN)은 영상처리나 신호처리 분야에서 많이 사용하는 컨볼루션(convolution) 연산을 적용함으로써 모델의 복잡도를 낮추고, 주어진 데이터로부터 좋은 특징을 추출하여 분류 또는 회귀 문제를 효과적으로 해결하려는 신경망이다. 구체적으로 <그림 5>와 같이 먼저, 입력 데이터의 간단한 특징들을 커널(kernel)들을 통해 추출하고, 다음 층에서는 앞서 학습한 간단한 특징들을 조합하여 복잡한 특징들을 표현한다. 즉, 신경망이 깊어질수록 입력 데이터를 다양한 패턴의 조합으로 표현할 수 있게 된다. 결과적으로 합성곱 신경망은 작은 크기의 커널을 이용하여 학습을 하고, 계산을 하기 때문에 신경망의 메모리 및 계산 효율이 높은 장점이 있다. 또한, 분류 문제에서 우수한 성능을 보인다. 다음 절에서는 본 논문에서 다루는 실내 측위에서 합성곱 신경망이 어떻게 적용되는지 알아본다.




그림 5. 합성곱 신경망의 일반적인 구조(2D-CNN)
Fig. 5. The general structure of convolutional neural network(2D CNN)

4.2.2 합성곱 신경망 기반 실내 측위 기법

합성곱 신경망 기반 실내 측위 기법은 offline phase에서, 핑거프린트 데이터베이스에 기록된 수신 신호 세기들의 주요 특징, 즉 패턴을 추출하여 참조

위치 정보와 연결하는 알고리즘을 학습한다. online phase에서는 사용자의 단말기에서 수신한 신호를 학습된 알고리즘에 입력하여 사용자의 위치를 예측한다. 합성곱 신경망은 특히 분류 문제를 잘 다룬다는 특성 때문에, 실내 위치를 기초적 위치 모델을 나타내어 공간적 분류 문제를 풀이하는 연구가 활발하다. 즉, 기초적 위치 모델을 사용하여 건물이나 층을 분류하는 문제가 주로 연구되었다. <표 3>에는 최근 제안된 합성곱 신경망 기반 실내 측위 기법과 완전 연결형(fully connected) 심층 신경망의 층 분류 정확도를 비교하였다. 이때 모든 신경망은 UJIIndoorLoc 데이터베이스를 사용하였다. <표 3>에서 합성곱 신경망 기반 실내 측위 기법 CNNLoc^[37]가 96%, 완전 연결형 구조 기반 실내 측위 기법 Scalable DNN^[38]이 92.9%의 층 분류 정확도를 기록해, 합성곱 신경망이 분류 문제를 잘 다루는 것을 확인할 수 있다.

한편, 지금까지 살펴본 층 분류와 같이 분류할 경우의 수가 적은 상황을 제외하고, 2차원 공간을 기초적 위치 모델로 나타냈을 경우를 고려해보자. 2차원 전체 공간을 작은 공간으로 나눌 때, 실내 공간이 넓을수록 설정해야 하는 작은 공간의 개수가 증가하는데, 이는 추정해야 할 경우의 수가 많아지는 것을 의미한다. 이러한 경우 알고리즘은 매우 어려운 분류 문제를 풀기 때문에 성능을 보장할 수 없고, 결과적으로 대형 건물에서의 정밀한 측정이 어렵다는 한계를 가진다.

한편, 합성곱 신경망은 분류 문제를 잘 해결할 뿐만 아니라 2차원 이미지를 학습하는데 우수한 성능을 보인다는 것에 기인하여, 벡터로 표현할 수 있는 수신 신호 세기를 2차원 이미지로 전환하여 알고리즘을 학습하려는 연구가 이루어졌다^[39-41]. 예를 들어, 논문 [38]에서는 <그림 6-(a)>와 같이 1차원의 수신 신호 세기 r_i 벡터를 2D 배열로 재정렬하여 이미지화하였고, 논문 [42]에서는 <그림 6-(b)>와 같이 연속 웨이블릿 변환(Continuous Wavelet Transform, CWT) 기법을 통해 이미지화하였다.

합성곱 신경망은 다른 신경망 구조와 쉽게 결합하

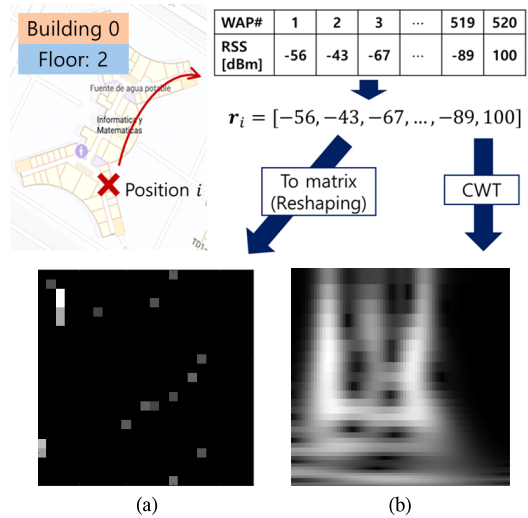


그림 6. UJIIndoorLoc의 RSS 예시 (a) 2-D 이미지로 나타낸 RSS 값^[38] (b) RSS 값의 CWT 변환 이미지^[42]
 Fig. 6. Example of a RSS sample in UJIIndoorLoc (a) 2-D image of the sample^[38] (b) CWT of the sample^[42]

여 사용되기도 하는데, 앞서 봤던 층 분류에서 우수한 성능을 보인 CNNLoc^[37]의 경우 수신 신호 세기 r_i 를 SAE(Stacked Auto-Encoder)를 통해 전처리함으로써 데이터의 차원을 줄이는 방법으로 더욱 효과적인 학습을 끌어냈다.

합성곱 신경망은 분류 문제를 잘 해결한다는 점, 이미지 처리에 특화되어있는 점, 그리고 다른 신경망 구조와 쉽게 결합할 수 있다는 점 등이 실내 측위 문제를 다룰 때 큰 장점이 된다. 그러나 합성곱 신경망은 지리 위치 모델을 사용하여 정확한 좌표를 추정하는 회귀 문제를 푸는 데는 아직 큰 성과를 보이지 못하고 있다. 다음부터 소개할 내용은 합성곱 신경망인 ResNet(Residual Network)의 skip connection을 기반으로 한 논문 [43]를 간략하게 소개하고, 그 성능을 비교 분석한다. 소개에 앞서 명백히 말하자면 논문 [43]에서 제안하는 신경망은 ResNet을 완전 연결형 신경망에 활용한 구조로, 논문의 완성도를 위해 본 절에서 소개한다.

인공 신경망이 깊어지면 딥러닝의 이론적인 문제인 그라디언트 소멸 문제(vanishing gradient problem)가 나타나는데, 이러한 현상은 딥러닝의 성능 향상에 큰 한계가 되어 학습이 잘 이루어지지 않는 결과를 낳는다. ResNet(Residual Network)은 이러한 한계를 극복하기 위해 잔차 학습(residual learning) 개념을 도입한다. 잔차 학습은 <그림 7>과 같이 기존 가중치 층(weight layer)들이 쌓여 있는 구조에서 skip

표 3. UJIIndoorLoc 데이터베이스에서 층 분류 정확도 비교
 Table 3. Comparison of floor accuracy in UJIIndoorLoc database

Algorithm	SAE+ Classifier [38]	Scalable DNN[38]	CNN-based[38]	CNNLoc [37],[45]
Floor Accuracy	91.1%	92.9%	95.4%	96%




그림 7. ResNet의 skip connection
Fig. 7. Skip connection in ResNet

connection을 추가한 것으로, 이전 상태 p 를 출력에 전달한다. 이러한 기본 가중치 층 구조에 단순 덧셈 연산이 추가된 형태를 통해 연산 증가량은 거의 없으면서 그래디언트 소멸 문제를 방지하여 깊은 신경망 구성을 가능하게 한다. ResNet은 이미지 분류 문제를 뛰어난 성능으로 해결하기 위해 <그림 7>의 가중치 층(weight layer)을 합성곱 신경망으로 구성한다. 그러나 논문 [43]에서는 사용자가 위치한 좌표(위도, 경도)를 회귀 문제로 해결하기 위해 합성곱 신경망 대신 완전 연결형 신경망에 skip connection 기법을 도입하였다. <표 4>에서는 실내 측위 문제를 지리 위치 모델을 사용하여 회귀 문제로 풀이한, k -NN, 완전 연결형 심층 신경망, 합성곱 신경망 기반 실내 측위 기법과 함께, 논문 [43]에서 제안하는 신경망의 평균 거리 오차를 제시하였다. 이때 <표 3>과 마찬가지로 모든 신경망은 동일하게 UJIIndoorLoc 데이터베이스를 사용하였다. 평균 거리 오류(average distance error)는 사용자가 실제로 위치한 위도, 경도와 신경망이 예측한 위도, 경도를 유클리드 거리(Euclidean distance)를 통해 계산한 결과이다. <표 4>에서 심층 신경망을 적용한 DNN^[44]는 k -NN 기반의 RADAR^[44]보다 뛰어난 성능을 보였고, 심층 신경망을 사용하였을 때 위치 추정 과정의 계산 시간이 약 0.03초로 k -NN과 비교하여 16배 이상 감소함을 논문 [44]에서 확인할 수 있다.

표 4. UJIIndoorLoc 데이터베이스에서 평균 거리 오류 비교
Table 4. Comparison of average distance errors in UJIIndoorLoc database

Algorithm	Method	Average distance error (m)
RADAR[44]	k -NN	9.5
DNN[44]	DNN	8.15
CNNLoc[37],[45]	CNN	11.78
ResNet[43]	ResNet	5.23

따라서 기존 머신러닝보다 딥러닝 기반 실내 측위 기법이 훨씬 우수한 것을 알 수 있다. 한편, 분류 문제에서 가장 우수한 성능을 보였던 CNNLoc^[37,45]에서는 회귀 문제의 위치 추정 성능은 11.78 m로 다소 열등한 결과를 보인다. 반면, 논문 [43]에서 제안된 신경망은 평균 거리 오류가 5.23 m로 다른 심층 신경망보다 훨씬 우수한 위치 추정 정확도를 보인다.

지금까지 살펴본 심층 신경망들은 단일 수신 신호 세기와 해당 참조 위치 정보의 연관성을 학습하기 위해 데이터베이스의 측정 시간 정보는 무시하고 학습 데이터는 무작위 순서로 입력된다. 즉, 단말기에서 얻은 단일 수신 신호 세기만으로 바로 위치를 추정할 수 있다. 이와 달리, 단말기의 처음 위치를 알고 있을 때 일정 시간 동안 단말기가 이동하면서 신호를 연속적으로 입력받아 처음 위치로부터의 이동 궤적을 추정하는 실내 측위 기법에 관한 연구가 있다. 이는 주로 로봇 주행, 경로 예측 및 안내에 사용될 수 있다. 연속 신호를 사용하기 때문에 신호의 왜곡에 강하다는 장점이 있지만, 다수의 입력을 받아야 하고 처음 위치라는 사전 정보가 필수적이다. 다음 절에서는 이러한 연속 데이터(sequence data)를 다루는 순환 신경망 기반 실내 측위 시스템을 소개한다.

4.3 순환 신경망 기반 실내 측위 기법

4.3.1 순환 신경망 개요

순환 신경망(Recurrent Neural Network, RNN)은 연관성(correlation)을 가지는 연속 데이터를 다루는 신경망이다. 일반적인 머신러닝 및 딥러닝 알고리즘은 입력 데이터가 독립 동일 분포(Independent Identically Distribution, IID)를 가진다고 가정하여 데이터의 입력순서와는 무관하게 현재 입력에 대해서만 학습한다. 하지만 순환 신경망에서는 현재 입력뿐만 아니라 과거 입력과 과거 time step의 은닉층으로부터의 정보를 학습한다. 즉, 과거의 정보를 사용하여 신경망을 구축하고, 새롭게 얻은 정보를 통해 신경망을 계속 업데이트한다.

순환 신경망의 구조는 <그림 8>과 같이 입력층(input layer) r , 은닉 층(hidden layer) h , 출력층(output layer) \tilde{l} 로 이루어져 있다. 입력층으로부터 전달되는 변수값들의 선형 결합(linear combination)을 비선형 함수로 처리하여 출력층 또는 다른 은닉층으로 전달하게 된다. 여기서 U , V , W 는 각 층에서의 가중치 행렬이다.




그림 8. 순환 신경망 구조
Fig. 8. Structure of the recurrent neural network

4.3.2 순환 신경망 기반 실내 측위 기법

순환 신경망 기반 실내 측위 기법은 연속데이터를 통해 학습하기 때문에 데이터베이스로부터 실내 경로를 생성하는 과정이 필요하다. 물론 경로로 이루어진 데이터베이스가 있으면 생략할 수 있지만, 실내에서 만들어질 수 있는 경로는 매우 다양하므로 데이터베이스를 구축하기 힘들다. 따라서, UJIIndoorLoc 데이터베이스와 같이 실내 경로 데이터가 없고, 사용자의 위치와 해당 수신 신호 세기 정보가 기록된 일반적인 핑거프린트 데이터베이스를 기반으로 무작위로 실내 경로를 생성하여 이를 연속적인 학습 데이터로 사용한다. 실내 경로는 사람이 움직일 수 있는 최대 거리 등을 기반으로 정의된 위치 확률 모델을 통해 생성될 수도 있다. 논문 [46]에서는 위치 확률 모델 $P(\mathbf{l}_i)$ 을 참조 위치 i 에서의 위치 $\mathbf{l}_i(x_i, y_i)$ 와 샘플링 (sampling) 시간 간격 Δt 동안 사람이 움직이는 최대 거리 $d_{\max} = v_{\max} \times \Delta t$ 라고 하여 다음 식으로 정의하였다.

$$P(\mathbf{l}_i) = \frac{1}{2\sigma^2(1 - e^{-\frac{d_{\max}^2}{2\sigma^2}})} \times \exp\left(-\frac{(x_i - x_{\text{pre}})^2 + (y_i - y_{\text{pre}})^2}{2\sigma^2}\right), \quad (6)$$

여기서 $(x_{\text{pre}}, y_{\text{pre}})$ 는 \mathbf{l}_i 의 가장 최근 위치, σ 는 표준 편차이다.

순환 신경망은 현재 입력을 통해 사용자의 위치를 추정하는 합성곱 신경망과 달리, 과거의 입력, 과거의 입력을 통해 추정된 위치, 그리고 현재의 입력 사이의 시간적 유사성을 통해 최적의 경로를 탐색함으로써 사용자의 현재 위치를 예측한다. 따라서 순환 신경망에서는 데이터 입력 시간을 T 라 할 때, T 시간 동안의 시간 연속성을 가지는 데이터를 학습 데이터로 사용한다. 즉, 위치 좌표 데이터는 $\mathbf{l}_i(i = 1, \dots, T)$ 의 세




그림 9. P-MIMO LSTM 신경망 구조[47]
Fig. 9. Structure of P-MIMO LSTM[47]

트가 된다. 추정 위치가 $\tilde{\mathbf{l}}_i(i = 1, \dots, T)$ 일 때, 순환 신경망의 손실 함수는 아래의 식과 같다[47].

$$L_{\text{RNN}}(\mathbf{l}, \tilde{\mathbf{l}}) = \frac{\sum_{i=1}^T \|\mathbf{l}_i - \tilde{\mathbf{l}}_i\|_2}{T}, \quad (7)$$

여기서 $\|\cdot\|$ 는 유클리드 거리(Euclidean distance)이다. 논문 [47]의 순환 신경망은 <그림 9>와 같이 새로운 정보가 들어올 때마다 예측값 $\tilde{\mathbf{l}}_i$ 을 계속 업데이트한다. $\tilde{\mathbf{l}}_i^j$ 를 학습 time step j 에서의 예측값 $\tilde{\mathbf{l}}_i$ 라 할 때, T 라는 입력에 대해 신경망은 예측한 값의 세트 $[\tilde{\mathbf{l}}_T^1, \tilde{\mathbf{l}}_T^2, \dots, \tilde{\mathbf{l}}_T^{T-1}]$ 을 얻는다. 예를 들어, 학습 time step 1에서는 $\tilde{\mathbf{l}}_1^1$, 2에서는 $[\tilde{\mathbf{l}}_2^1, \tilde{\mathbf{l}}_2^2]$, 3에서는 $[\tilde{\mathbf{l}}_3^1, \tilde{\mathbf{l}}_3^2, \tilde{\mathbf{l}}_3^3]$ 를 얻는다. 사용자의 현재 예측 위치는 최종적으로 아래의 식과 같이 $T-1$ 동안 각 학습 time step $j(j = 1, \dots, T-1)$ 에서의 예측값 $\tilde{\mathbf{l}}_T^j$ 의 평균값으로 결정된다.

$$\mathbf{l}_T = \frac{\sum_{j=1}^{T-1} \tilde{\mathbf{l}}_T^j}{T-1} \quad (8)$$

최근 실내 측위를 위한 다양한 순환 신경망 구조가 연구되고 있다. 논문 [46]에서는 다층 순환 신경망 구조를 사용하였고, [48]에서는 수신 신호 세기의 특징을 추출하여 잡음에 강인한 시스템을 제안하였다. 특히 논문 [49]에서는 두 학습 단계를 가지는 double RNN 구조를 제안하였다. 1단계 location matching에서는 수신 신호 세기로부터 대략적인 위치를 추정하는 과정으로 단일 RNN 형태와 동일하고 출력값 $[\tilde{\mathbf{l}}_1, \dots, \tilde{\mathbf{l}}_T]$ 을 가진다. 2단계 location filtering에서

는 좀 더 정확한 위치 추정을 위한 후처리 과정으로 전 단계의 출력값으로부터 $[\hat{l}_1, \dots, \hat{l}_T]$ 를 얻고, 아래 식의 손실 함수로 학습한다.

$$L([\mathbf{l}_1, \dots, \mathbf{l}_T], [\tilde{\mathbf{l}}_1, \dots, \tilde{\mathbf{l}}_T], [\hat{\mathbf{l}}_1, \dots, \hat{\mathbf{l}}_T]) = \frac{\lambda_1}{2} \sum_{t=1}^T \|\tilde{\mathbf{l}}_t - \mathbf{l}_t\|^2 + \frac{\lambda_2}{2} \sum_{t=1}^T \|\hat{\mathbf{l}}_t - \mathbf{l}_t\|^2 \quad (9)$$

해당 논문은 UJIIndoorLoc 데이터베이스에서 랜덤 워크 방법을 활용하여 생성한 경로를 학습 데이터로 사용하였다.

<표 5>에 순환 신경망 기반의 실내 측위 알고리즘의 위치 추정 성능을 파티클 필터(particle filter)와 칼만 필터(Kalman filter)와 함께 비교하여 나타내었다. 파티클 필터와 칼만 필터는 잡음을 가지는 연속신호로부터 확률 기반 추론으로 움직이는 물체의 위치를 추정하는 대표적인 방법인 베이즈 필터(Bayes filter)의 효율적인 계산을 위한 방법들이다. 여기서도 UJIIndoorLoc 데이터베이스를 사용하여 성능을 비교하였다. 칼만 필터의 경우 파티클 필터보다 우수한 성능을 보이지만, 가우시안 잡음을 가정으로 하므로, 일반적인 실내 신호의 특성에 맞지 않는다는 오류를 범한다. 순환 신경망 기반의 실내 측위 알고리즘 P-MIMO LSTM^[46]와 DL-RNN^[49]는 각각 평균 거리 오차가 5 m 미만으로 가장 우수한 성능을 보인다. 성능 비교에 사용한 UJIIndoorLoc 데이터베이스는 앞 2장에서 설명하였듯이, 모든 데이터가 시간 연속적이지 않고 측정 시각 간격 또한 일정치 않아 완전한 연속 데이터라고 보기 어렵다. 이러한 데이터베이스에서도 경로 생성 과정을 통해 임의의 시간 연속 데이터를 만들어 순환 신경망에 충분히 활용될 수 있다는 점과 함께 우수한 성능을 확인하였다. 이처럼, 순환 신경망 기반 실내 측위 기법은 과거 데이터 축적으로 잡음에

강인한 모델이다. 하지만 초기 위치에 대한 정보가 필수적이기 때문에 일반적인 상황에 적용하기 어렵다는 결정적인 한계를 가진다.

지금까지 딥러닝의 가장 대표적인 신경망 구조인 합성곱 신경망과 순환 신경망을 기반으로 하는 실내 측위 기법의 다양한 연구 사례를 다루었고, 그 성능을 비교 및 분석하였다. 지금까지 살펴본 딥러닝 기반 실내 측위 기법에서는 단말기 위치의 정답 값과 예측값의 평균 거리 오차를 최소화하는 방법으로 알고리즘을 최적화하였다. 이때, 새로운 데이터가 축적되면 알고리즘을 새로이 학습해야 한다는 번거로운 과정이 필요해 아쉬움이 있다.

4.4 강화학습 기반 실내 측위 기법

본 절에서 소개할 강화학습은 앞에서 알아본 문제점에 대한 해결책 중 하나로, 보상이라는 개념을 도입하여 알고리즘을 학습함으로써 새로운 데이터에도 잘 적응한다는 큰 장점을 가져, 신호 변화가 큰 실내 상황에서 효과적일 것으로 기대된다. 강화학습은 <그림 10>과 같이 학습대상(agent)이 주어진 환경(environment)과 상태(state)에 대해 최적의 행동(action)을 선택하는 학습 방법으로, 상태에 따라 변화하는 확률적 모델을 학습한다. 학습대상의 행동이 좋고 나쁜 정도를 평가하여 학습대상에게 알려주는 것을 보상(reward) 또는 강화(reinforcement)라고 하며, 강화학습은 이러한 보상을 최대화하는 방식을 통해 학습한다. 강화학습은 마르코프 의사결정 과정(Markov Decision Process, MDP)으로 공식화된 문제를 푸는 하나의 기법으로 볼 수 있는데, MDP의 행동을 결정하는 정책(policy)은 강화학습 방법에 의하여 학습된다. 실내 측위 문제를 MDP 형태로 공식화한 두 가지 기법^[50,51]이 있는데, 두 기법은 실내 측위 문제를 서로 다른 MDP 형태로 공식화하지만, 단말기의 위치를 추정하는 것을 목표로 설정하여 예측값이 목표에 도달하면 보상을 최대화하는 접근 방법으로 학

표 5. UJIIndoorLoc 데이터베이스에서 순환 신경망 및 기준 위치 추적 알고리즘의 평균 거리 오류 비교
Table 5. Comparison of average distance error between RNN and traditional tracking algorithms in UJIIndoorLoc database

Algorithm	Method	Average distance error (m)
Particle filter[49]	Baysian filter	12.89
Kalman filter[49]	Baysian filter	10.03
P-MIMO LSTM[46]	RNN	4.2(Except Building 2)
DL-RNN[49]	RNN	4.9




그림 10. 강화학습 흐름도
Fig. 10. Framework of reinforcement learning

습한다는 것은 공통적이다. 강화학습 기반 실내 측위 시스템은 실내 측위 문제를 MDP 형태의 공식화와 보상 함수를 적절히 설정하는 것이 핵심으로, 차후 연구가 기대된다.

V. 새로운 연구 방향 및 이슈

지금까지 살펴본 주된 내용은 머신러닝 및 딥러닝 기반 Wi-Fi 핑거프린트 실내 측위 기법이었다. 본 절에서는 지금까지 살펴본 내용 이외에 Wi-Fi 핑거프린트 기법과 관련된 새로운 연구 방향 및 이슈를 크게 네 가지로 나누어 알아본다.

첫 번째로, 앞에서 살펴본 모든 딥러닝 신경망에서 공통으로 나타나는 한계점이 존재하는데, 학습 시에 건물의 구조를 고려하지 않고 거리 오류만을 줄이는 것에 목표를 두어, 신경망이 예측한 좌표가 건물의 외부에 위치할 가능성이 있다는 점이다. 이러한 근본적인 문제의 원인을 파악하고 해결하기 위해, 건물의 윤곽 정보를 활용하여, 새로운 손실 함수를 제안한 연구가 있다⁵²⁾. SAE-CCNN⁵²⁾은 기존 CNNLoc⁴⁵⁾에서 건물 경계를 벗어나는 좌표들에 대해 추가적 벌이익 (penalty)을 반영하여 <그림 11>과 같이 예측된 좌표들이 정해진 건물 내부에 위치할 수 있도록 하고, 결과적으로 실내 측위의 견고함과 정확도를 높였다.

두 번째로, 본 논문에서 다루는 Wi-Fi 핑거프린트 기법은 II장에서 살펴본 바와 같이 offline phase에서 데이터베이스를 구축하는 것이 가장 번거롭고 시간 소모가 크다. 또한, 시간을 들여 데이터베이스를 잘 구축하였다고 하더라도, 실내 공간이 변화할 가능성 때문에, 데이터베이스를 주기적으로 업데이트(update) 해주어야 하는 문제점이 있다. 이러한 문제점을 해결하기 위해 데이터 수집 과정에서 생기는 노력을 줄이기 위한 연구들이 활발히 진행 중이다^{53,54)}.

세 번째로, 지금까지 우리는 Wi-Fi 신호만을 이용

하여 위치를 추정하는 기법들에 대해 알아보았다. 그러나 실내에서 측정할 수 있는 신호는 Wi-Fi 신호 이외에도 Bluetooth, FM 라디오 신호 등 여러 가지가 있다. 논문 [55]에서는 Wi-Fi 신호와 Bluetooth 신호를 함께 측정하여 핑거프린트 데이터베이스를 구축하였다. 이외에도 FM 라디오 신호⁵⁶⁾, 초음파 신호⁵⁷⁾, 지구 자기장 강도⁵⁸⁾ 등의 무선 신호를 Wi-Fi 신호와 함께 이용하여 사용자의 위치를 추정하는 연구들이 있다. 모든 연구에서 나타나는 공통적인 부분은 Bluetooth, FM 라디오, 지구 자기장 강도 등의 무선 신호를 이용했을 때, 별도의 인프라를 구축할 필요가 없어 실내 측위를 위한 추가적인 비용이 발생하지 않는다는 큰 장점이 있다는 것이다.

마지막으로, 실내 측위 기법은 사용자가 실내에 위치하고 있다는 가정하에 작동될 수 있다. 따라서 사용자의 정확한 위치를 추정하기 전에, 사용자가 실외 또는 실내 중 어디에 위치하는지를 판단해야 시스템 개발이 필요하다. 이를 위해 논문[59]에서는 실내에서 측정된 Wi-Fi 핑거프린트 데이터베이스만을 이용하여 사용자의 위치를 실내 또는 실외로 구분하는 OvA(One-vs-All) 방식을 제안하였다. 논문[60]에서는 2가지 단계로 사용자의 실내/외 검출을 시행하는데, 첫 번째 단계는 사용자가 자동차와 같은 이동 수단 내에 있으면 실외에 있다고 검출하고, 견고 있거나 멈추어 있으면 모호하다고 판단 후 다음 단계로 넘어간다. 두 번째 단계는 사용자의 기기로부터 측정된 수신 신호 세기를 이용하여 사용자의 위치를 도심, 시골, 실내 중 1가지로 검출한다.

VI. 결론

본 논문에서는 실내 측위 분야에서 잠재성이 높은 것으로 평가되는 Wi-Fi 핑거프린트 기법에 대해 살펴 보았고, 이를 최근 활발히 연구되고 있는 머신러닝 및 딥러닝 기법들과 결합한 사례들을 살펴보았다. 특히 대표적인 머신러닝 기법들(k -NN, SVM)이 Wi-Fi 핑거프린트 기법과 결합했을 때 가지게 되는 한계에 대해 알아보았고, 이를 극복하기 위한 합성곱 신경망, 순환 신경망 기반 실내 측위 기법 사례를 소개하였다. 또한 각 딥러닝 기반 실내 측위 기술의 장점 및 한계점에 대해 분석하였고, 위치 추정 성능을 비교 및 분석하였다. 향후 딥러닝 기술의 발전과 컴퓨팅 능력의 향상에 따라, 더욱 혁신적인 딥러닝 기반 실내 측위 기술들이 지속해서 개발되어 초연결 시대의 핵심 기반 기술로 자리매김 할 것이라 기대된다.




그림 11. CNNLoc[45](좌)와 (b) SAE-CCNN[52](우)의 테스트 결과 비교
Fig. 11. Comparison of test results between CNNLoc[45](left) and SAE-CCNN[52](right)


References

- [1] H.-U An, et al., “Artificial intelligence-based indoor positioning technology trends and prospects,” *Broadcasting and Media Mag.*, vol. 25, no. 1, Jan. 2020.
- [2] T.-S. Shim, “Study on indoor positioning technology and standardization trends,” in *Proc. Symp. KICS*, pp. 1146-1147, Feb. 2020.
- [3] R. Mautz, “Overview of current indoor positioning systems,” *Geodezija ir kartografija*, vol. 35, no. 1, pp. 18-22, Jan. 2009.
- [4] M. A. Al-Ammar, et al., “Comparative survey of indoor positioning technologies, techniques, and algorithms,” *2014 Int. Conf. Cyberworlds*, pp. 245-252, Santander, Spain, Oct. 2014.
- [5] L. Mainetti, et al., “A survey on indoor positioning systems,” *2014 22nd Int. Conf. SoftCOM*, pp. 111-120, Split, Croatia, Sep. 2014.
- [6] S. Xia, et al., “Indoor fingerprint positioning based on Wi-Fi: An overview,” *ISPRS Int. J. Geo-Inf.*, vol. 6, no. 5, pp. 135-159, Apr. 2017.
- [7] Z. Farid, et al., “Recent advances in wireless indoor localization techniques and system,” *J. Comput. Netw. Commun.*, vol. 2013, Art. no. 185138, Aug. 2013.
- [8] Y. Gu, et al., “A survey of indoor positioning systems for wireless personal networks,” *IEEE Commun. Surv. & Tuts.*, vol. 11, no. 1, pp. 13-32, Mar. 2009.
- [9] A. Khalajmehrabadi, et al., “Structured group sparsity: A novel indoor WLAN localization, outlier detection, and radio map interpolation scheme,” *IEEE Trans. Veh. Technol.*, vol. 66, no. 7, pp. 6498-6510, Jul. 2017.
- [10] J. Torres-Sospedra, et al., “UJIIndoorLoc: A new multi-building and multi-floor database for WLAN fingerprint-based indoor localization problems,” *2014 Int. Conf. IPIN*, pp. 261-270, Busan, Korea, Oct. 2014.
- [11] J. Torres-Sospedra, et al., *UJIIndoorLoc Database*, Available online Retrieved Dec. 28, 2020, from <https://archive.ics.uci.edu/ml/datasets/ujii>
- doorloc
- [12] T. King, et al., “A probabilistic indoor positioning system based on 802.11 and digital compasses,” *1st Int. Workshop on Wireless Network Testbeds, Experimental Evaluation & Characterization (WiN-TECH)*, pp. 34-40, Los Angeles, CA, USA, Sep. 2006.
- [13] T. King, et al., *CRAWDAD Dataset Mannheim/Compass*(v. 2008-04-11), Retrieved Dec. 28, 2020, from <https://crawdad.org/mannheim/compass/20080411/fingerprint>
- [14] E. S. Lohan, et al., *TUT Datasets*, Available online Retrieved Dec. 28, 2020, from <http://www.cs.tut.fi/tlt/pos/Software.htm>, MEASUREMENTS_WLAN_FOR_WEB.zip
- [15] D. Bacciu, et al., “An experimental characterization of reservoir computing in ambient assisted living applications,” *Neural Computing and Appl.*, vol. 24, no. 6, pp. 1451-1464, May 2014.
- [16] D. Bacciu, et al., *Indoor user movement prediction from RSS data data set*, Retrieved Dec. 28, 2020, from <https://archive.ics.uci.edu/ml/datasets/Indoor+User+Movement+Prediction+from+RSS+data>
- [17] J. Torres-Sospedra, et al., “Providing databases for different indoor positioning technologies: Pros and cons of magnetic field and Wi-Fi based positioning,” *Mobile Inf. Syst.*, vol. 2016, pp. 1-22, Jan. 2016.
- [18] J. Torres-Sospedra, et al., *Geotec Database*, Retrieved Dec. 28, 2020, from <http://indoorloc.uji.es/databases/geotecDatabaseWGS.zip>
- [19] J. Torres-Sospedra, et al., “The smartphone-based offline indoor location competition at IPIN 2016: Analysis and future work,” *Sensors*, vol. 17, no. 3, pp. 557-573, Mar. 2017.
- [20] J. Torres-Sospedra, et al., *IPIN 2016 Competition Database*, Retrieved Dec. 28, 2020, from <http://indoorloc.uji.es/ipin2016track3/>
- [21] R. Parasuraman, et al., *CRAWDAD Dataset kth/rss* (v. 2016-01-05), Retrieved Dec. 28, 2020, from <https://crawdad.org/kth/rss/20160105>.
- [22] Z. Tóth, et al., “Miskolc IIS hybrid IPS: Dataset

- for hybrid indoor positioning,” *2016 26th Int. Conf. RADIOELEKTRONIKA*, pp. 408-412, Kosice, Slovakia, Apr. 2016.
- [23] Z. Tóth, et al., *Miskolc IIS Hybrid IPS: Dataset for Hybrid Indoor Positioning*, Retrieved Dec. 28, 2020, from <https://archive.ics.uci.edu/ml/datasets/Hybrid+Indoor+Positioning+Dataset+from+WiFi+RSSI%2C+Bluetooth+and+magnetometer>
- [24] R. Montoliu, et al., “IndoorLoc platform: A public repository for comparing and evaluating indoor positioning systems,” *2017 Int. Conf. IPIN*, pp. 1-8, Sapporo, Japan, Sep. 2017.
- [25] R. Montoliu, et al., *IndoorLoc Platform Databases*, Retrieved Dec. 28, 2020, from <http://indoorlocplatform.uji.es/>
- [26] E. S. Lohan, et al., “Wi-Fi crowdsourced fingerprinting dataset for indoor positioning,” *Data*, vol. 2, no. 4, pp. 32-47, Sep. 2017.
- [27] P. Barsocchi, et al., “A multisource and multivariate dataset for indoor localization methods based on WLAN and geo-magnetic field fingerprinting,” *2016 Int. Conf. IPIN*, pp. 1-8, Alcalá de Henares, Spain, Oct. 2016.
- [28] P. Barsocchi, et al., *Geo-Magnetic field and WLAN dataset for indoor localisation from wristband and smartphone dataset*, Retrieved Dec. 28, 2020, from <https://archive.ics.uci.edu/ml/datasets/Geo-Magnetic+field+and+WLAN+dataset+for+indoor+localisation+from+wristband+and+smartphone>
- [29] *IPIN Competition Database 2016*, Retrieved Dec. 28, 2020, from <https://zenodo.org/record/2823964#.X75Rs80zaUn>
- [30] *IPIN Competition Database 2017*, Retrieved Dec. 28, 2020, from <https://zenodo.org/record/1161525#.X75R0M0zaU1>
- [31] *IPIN Competition Database 2017*, Retrieved Dec. 28, 2020, from <https://zenodo.org/record/3228012#.X-k5vNgzaUk>
- [32] *IPIN Competition Database 2017*, Retrieved Dec. 28, 2020, from <https://zenodo.org/record/3342526#.XjLp7i2cZ24>
- [33] L. Cheng, et al., “A fingerprint localization method based on weighted k NN algorithm,” *2018 IEEE 18th ICCT*, pp. 1271-1275, Chongqing, China, Oct. 2018.
- [34] M. T. Hoang, et al., “A soft range limited k -nearest neighbors algorithm for indoor localization enhancement,” *IEEE Sensors J.*, vol. 18, no. 24, pp. 10208-10216, Dec. 2018.
- [35] A. Chriki, et al., “SVM-based indoor localization in wireless sensor networks,” *2017 13th IWCNC*, pp. 1144-1149, Valencia, Spain, Jun. 2017.
- [36] Y. Wang, et al., “Localization in wireless sensor networks via support vector regression,” *IEEE 3rd Int. Conf. Genetic and Evolutionary Computing*, pp. 549-552, Guilin, China, Oct. 2009.
- [37] X. Song, et al., “CNNLoc: Deep-learning based indoor localization with WiFi fingerprinting,” *2019 IEEE SmartWorld/SCALCOM/UIC/ATC/CBDCCom/IOP/SCI*, pp. 589-595, Leicester, United Kingdom, Aug. 2019.
- [38] J. Jang, et al., “Indoor localization with WiFi fingerprinting using convolutional neural network,” *2018 Tenth ICUFN*, pp. 753-758, Prague, Czech Republic, Jul. 2018.
- [39] A. Mittal, et al., “Adapting convolutional neural networks for indoor localization with smart mobile devices,” *2018 Great Lakes Symp. VLSI*, pp. 117-122, Chicago, IL, USA, May 2018.
- [40] Z. Liu, et al., “Hybrid wireless fingerprint indoor localization method based on a convolutional neural network,” *Sensors*, vol. 19, no. 20, pp. 4597-4615, Jan. 2019.
- [41] R. S. Sinha, et al., “Comparison of CNN applications for RSSI-based fingerprint indoor localization,” *Electronics*, vol. 8, no. 9, pp. 989-1013, Sep. 2019.
- [42] B. Soro, et al., “Joint time-frequency RSSI features for convolutional neural network-based indoor fingerprinting localization,” *IEEE Access*, vol. 7, pp. 104892-104899, Aug. 2019.
- [43] P. Pandey, et al., “Residual neural networks for heterogeneous smart device localization in IoT networks,” *2020 29th ICCCN*, pp. 1-9,

- Honolulu, HI, USA, Aug. 2020.
- [44] Y. Wang, et al., "Robust and accurate Wi-Fi fingerprint location recognition method based on deep neural network," *Appl. Sci.*, vol. 10, no.1 pp. 321-3341, Jan. 2020.
- [45] X. Song, et al., "A novel convolutional neural network based indoor localization framework with WiFi fingerprinting," *IEEE Access*, vol. 7, pp. 110698-110709, Aug. 2019.
- [46] A. Sahar and D. Han, "An LSTM-based indoor positioning method using Wi-Fi signals," *2nd ICVISP*, Art. no. 43, Aug. 2018.
- [47] T. Hoang, et al., "Recurrent neural networks for accurate RSSI indoor localization," *IEEE Internet of Things J.*, vol. 6, no. 6, pp. 10639-10651, Dec. 2019.
- [48] Z. Chen, et al., "WiFi fingerprinting indoor localization using local feature-based deep LSTM," *IEEE Syst. J.*, vol. 14, no. 2, pp. 3001-3010, Jun. 2020.
- [49] S. Bai, et al., "DL-RNN: An accurate indoor localization method via double RNNs," *IEEE Sensors J.*, vol. 20, no. 1, pp. 286-295, Jan. 2020.
- [50] F. Dou, et al., "Top-down indoor localization with Wi-fi fingerprints using deep Q-network," *2018 IEEE 15th Int. Conf. MASS*, pp. 166-174, Chengdu, China, Oct. 2018.
- [51] M. Mohammadi, et al., "Semisupervised deep reinforcement learning in support of IoT and smart city services," *IEEE Internet of Things J.*, vol. 5, no. 2, pp. 624-635, Apr. 2017.
- [52] Y. Oh, et al., "SAE-CCNN: Deep neural network based indoor positioning technique by combining boundary information of building," in *Proc. Symp. KICS*, pp. 1396-1397, Yongpyong, Korea, Oct. 2020.
- [53] Y. Ji, et al., "ARIADNE: A dynamic indoor signal map construction and localization system," *4th Int. Conf. Mobile Syst. Appl. Serv.*, pp. 151-164, Uppsala, Sweden, Jun. 2006.
- [54] M. Ocana, et al., "Training method improvements of a WiFi navigation system based on POMDP," *IEEE/RSJ Int. Conf. Intell. Robots Syst.*, pp. 5259-5264, Beijing, China, Oct. 2006.
- [55] S. B. Keser, et al., "A priori verification and validation study of RFKON database," *Int. J. Comput. Sci. Theor. App.*, vol. 5, no. 1, pp. 20-27, 2016.
- [56] A. Mukhopadhyay, et al., "A smartphone-based indoor localisation system using FM and Wi-Fi signals," *2017 25th EUSIPCO, Inf. Fusion*, pp. 2473-2477, Kos, Greece, Oct. 2017.
- [57] S. Sosa-Sesma, et al., "Fusion system based on WiFi and ultrasounds for in-home positioning systems: The UTOPIA experiment," *2016 Int. Conf. IPIN*, pp. 1-8, Alcala de Henares, Spain, Nov. 2016.
- [58] Z. Zhong, et al., "XJTLUIndoorLoc: A new fingerprinting database for indoor localization and trajectory estimation based on Wi-Fi RSS and geomagnetic field," *2018 Sixth Int. Symp. CANDARW*, pp. 228-234, Takayama, Japan, Dec. 2018.
- [59] S. He, et al., "Towards area classification for large-scale fingerprint-based system," *2016 ACM Int. Conf. Pervasive and Ubiquitous Computing*, pp. 232-243, Sep. 2016.
- [60] M. Ali, et al., "SenseIO: Realistic ubiquitous indoor outdoor detection system using smartphones," *IEEE Sensors J.*, vol. 18, no. 9, pp. 3684-3693, May 2018.

노 헤 민 (Hea-Min Noh)



2018년 2월: 부산대학교 전자공학과 학사
2020년 2월: 부산대학교 전기전자컴퓨터공학과 석사
<관심분야> 레이더 신호처리, 딥러닝
[ORCID:0000-0003-0349-4301]

신 원 재 (Wonjae Shin)



2005년 2월: 한국과학기술원 전자공학 학사
2007년 8월: 한국과학기술원 전자공학 석사
2007년 8월~2013년 10월: 삼성전자 종합기술원 전문연구원
2013년 11월~2014년 2월: 삼성전자 DMC연구소 책임연구원

2017년 8월: 서울대학교 전기·정보공학부 공학박사
2017년 9월~2018년 2월: Princeton 대학교 박사후연구원

2018년 3월~2021년 2월: 부산대학교 전자공학과 조교수
2021년 3월~현재: 아주대학교 전자공학과 조교수
<관심분야> 차세대 이동통신 시스템, 머신러닝 및 빅데이터 신호처리
[ORCID:0000-0001-6513-1237]

오 용 정 (Yongjeong Oh)



2021년 2월: 부산대학교 전자공학과 학사
2021년 2월~현재: 포항공과대학교 전자전기공학과 석사과정
<관심분야> 통신공학, 머신러닝 및 딥러닝
[ORCID:0000-0002-9068-5853]

이 남 윤 (Namyoon Lee)



2006년 2월: 고려대학교 전파통신공학 학사
2008년 2월: 한국과학기술원 전자공학 석사
2014년 12월: The University of Texas at Austin 박사
2008년 2월~2011년 6월: 삼성종합기술원 연구원/신임연구원

2014년 11월~2015년 5월: NOKIA Research Center, Berkeley, USA 선임연구원

2015년 5월~2016년 2월: Intel Labs, Santa Clara, USA Researcher Scientist

2016년 2월~현재: 포항공과대학교 조교수, 부교수
<관심분야> 차세대 MIMO 송/수신기, 기계학습 기반 통신 네트워크 설계

[ORCID:0000-0003-4321-4108]