

채널 상태 정보를 이용한 딥 러닝 기반 실내 위치 확인 시스템

장 중 봉* · 최 승 원**

Deep Learning-based Indoor Positioning System Using CSI

Zhang Zhongfeng · Choi Seungwon

〈Abstract〉

Over the past few years, Wi-Fi signal based indoor positioning system (IPS) has been researched extensively because of its low expenses of infrastructure deployment. There are two major aspects of location-related information contained in Wi-Fi signals. One is channel state information (CSI), and one is received signal strength indicator (RSSI). Compared to the RSSI, the CSI has been widely utilized because it is able to reveal fine-grained information related to locations. However, the conventional IPS that employs a single access point (AP) does not exhibit decent performance especially in the environment of non-line-of-sight (NLOS) situations due to the reliability degeneration of signals caused by multipath fading effect. In order to address this problem, in this paper, we propose a novel method that utilizes multiple APs instead of a single AP to enhance the robustness of the IPS. In our proposed method, a hybrid neural network is applied to the CSIs collected from multiple APs. By relying more on the fingerprint constructed by the CSI collected from an AP that is less affected by the NLOS, we find that the performance of the IPS is significantly improved.

Key Words : Indoor Positioning System, Channel State Information, Non-line-of-sight, Hybrid Deep Neural Network, Multiple Fingerprints

I. 서론

실외 환경에서 GPS(Global Positioning System)는 LOS(Line-of-sight) 신호로 인해 높은 정확도를 달성할 수 있다. 그러나 GPS 신호를 사용하는 실내 측위 성능은 건물 막힘으로 인해 상당히 저하된다[1]. GPS

신호에 비해 Wi-Fi 신호는 광범위한 배포와 쉬운 액세스로 인해 실내 환경에서 더 안정적이고 신뢰할 수 있다. 따라서 정확한 실내 위치 파악을 위해 Wi-Fi 신호를 이용하는 연구가 활발히 이뤄지고 있다.

Wi-Fi 신호를 활용하는 방법론은 두 그룹으로 요약할 수 있다. 하나는 수신 신호 세기(Received Signal Strength Indicator, RSSI)를 이용하고, 다른 하나는 채널 상태 정보(Channel State Information, CSI)를 이용한다. 다중 경로 페이딩 효과 [2]로 인해 고정

* 한양대학교 전자컴퓨터통신공학과 박사과정

** 한양대학교 전자전기공학부 교수

된 위치에서도 수신 신호 세기가 시간이 지남에 따라 변하기 때문에 수신 신호 세기를 기반으로 한 측위의 정확도는 상대적으로 낮다. 수신 신호 세기와 달리 채널 상태 정보 기반의 실내 위치 확인 시스템 (Indoor Positioning System, IPS) 은 OFDM(Orthogonal Frequency Division Multiplexing) 심볼에서 부반송파에 대해 전달하는 충분한 정보로 인해 광범위하게 연구되고 있다.

수년에 걸쳐 행동 인식(Activity Recognition) [3, 4] 및 실내 측위[5, 6]를 위해 채널 상태 정보를 기반으로 하는 수많은 측위 기술이 제안되었다. 제안된 기술들은 K-최근접 이웃 알고리즘(K-nearest neighbour, KNN) [7],가중 K-최근접 이웃 알고리즘(weighted K-nearest neighbour, WKNN) [8], 서포트 벡터 머신(support vector machine, SVM) [9]과 같은 머신 러닝 알고리즘이 우수한 성능을 달성 할 수 있음을 보여준다. 이러한 알고리즘은 주로 데이터의 기능을 기반으로 하기 때문이다. 따라서 더 나은 성능을 얻으려면 기능을 선택하는 방법이 중요하다. 일반적으로 기능 인식 및 선택에는 전문적인 경험이 필요하다. 그러나 특징 추출에 필요한 데이터의 양이 많을 경우 수작업은 위협적인 작업이 될 수 있다. 이 문제를 해결하기 위해 [2]에서는 심층 신경망(Deep Neural Network, DNN) 솔루션이 제안되었다. 심층 신경망은 데이터의 특징을 자동으로 캡처 할 수 있는 학습 과정을 통해 뉴런의 가중치를 조정하여 임의의 수학 함수를 표현할 수 있다 [10].

논문 [5-10]에서 액세스 포인트(Access Point, AP)의 수는 1 개로 제한되어 있다. 즉, 모든 위치의 고유한 특성으로 핑거프린트가 하나뿐임을 의미한다. 이러한 논문에서 주장된 결과가 합리적으로 보이지만 실험이 수행 된 환경은 주로 LOS의 경우이다. NLOS(non-line-of-sight)가 다수의 벽, 파티션 등이 존재할 때 일반적 일 수 있는 지배적인 신호 전파 경로인 경우 관련 문헌에서 실내 위치 확인 시스템의 성

능 측면에서 문제가 적절하게 고려되거나 해결되지 않았다. 위의 문제를 해결하기 위해 본 논문에서는 다중 AP와 다중 합성곱 신경망과 융합 신경망(fusion neural network, FNN)을 결합한 하이브리드 신경망을 활용하여 견고성을 높이는 새로운 방법을 제안한다. 본 논문의 주요 기여 항목은 다음과 같이 요약된다.

- NLOS가 신호 전파에서 지배적인 역할을 하는 실내 환경에 존재하는 다중 경로 효과 및 그림자 페이딩과 같은 잠재적 문제를 해결한다.
- 단일 AP를 위치에 대한 핑거프린트 맵 구성 소스로 사용할 때 실내 위치 확인 시스템 성능에 대한 제한 사항을 해결한다.
- 실내 위치 확인 시스템의 견고성을 높이기 위해 모든 위치에 대해 다중 핑거프린트를 생성하기 위해 여러 AP의 채널 상태 정보를 활용하는 새로운 방법을 제안한다.
- 여러 AP의 위치와 여러 채널 상태 정보 간의 관계를 모델링하는 새로운 신경망을 제안한다.

나머지 논문은 다음과 같이 구성된다. 섹션 II에서는 실내 위치 확인 시스템 구조, 채널 상태 정보 및 데이터 수집 프로세스에 대해 간략한 소개한다. 섹션 III에서는 제안된 심층 신경망과 훈련을 위한 데이터 흐름을 포함하는 상세한 심층 학습 솔루션에 대해 설명한다. 섹션 IV에서는 실험 결과를 보여주고 결과에 대해 분석하며, 섹션 V에서 결론을 이야기한다.

II. 데이터 준비

2.1 실내 위치 확인 시스템

실내 위치 확인 시스템은 두 단계로 나눌 수 있다.

첫 번째 단계는 오프라인 단계이고 두 번째 단계는 온라인 단계이다.

오프라인 단계에서는 서로 다른 AP의 참조 지점 (Reference Point, RP)에서 수집된 훈련 데이터 집합을 사용하여 손실 함수 및 최적화 알고리즘을 기반으로 신경망의 가중치가 업데이트되는 딥 러닝 프로세스를 수행한다. 계산된 손실이 임계 값보다 낮기 때문에 학습이 완료되고 신경망 모델과 뉴런의 가중치가 핑거프린트 데이터베이스에 저장된다. 온라인 단계에서 테스트 지점 (Testing Point, TP)에서 수집된 테스트 데이터 집합은 저장된 신경망 모델의 입력과 위치를 추정하기 위한 뉴런의 가중치로 핑거프린트 데이터베이스에 입력된다.

2.2 채널 상태 정보

채널 상태 정보는 신호가 전파되는 무선 채널에 대한 세분화된 정보를 포함한다. 송신기에서 수신기로 전파하는 동안 신호가 경험하는 무선 주파수(Radio Frequency, RF) 프런트 엔드 장애가 위치마다 다르기 때문에 채널 상태 정보를 사용하여 실내 위치에 대한 고유한 핑거프린트 맵을 구성할 수 있다.

이 논문에서는 2.4GHz 대역에서 Wi-Fi 신호를 생성하기 위해 FPGA (Field Programmable Gate Array)가 있는 소프트웨어 정의 하드웨어인 USRP (Universal Software Radio Peripheral)를 사용한다. \vec{T} 및 \vec{R} 는 USRP에 의해 생성된 송신 및 수신 신호를 나타낸다. 수신된 신호는 다음과 같이 표시된다.

$$\vec{R} = \vec{H} \cdot \vec{T} + \vec{N} \quad (1)$$


여기서 \vec{T} 는 송신된 신호, \vec{R} 는 수신된 신호, \vec{N} 는 가산성 백색 가우시안 잡음을, \vec{H} 는 채널 상태 정보를 나타낸다. \vec{H} 는 \vec{R} 및 \vec{T} 를 사용하여 채널 추정을 수행하여 얻을 수 있다.

채널 상태 정보의 i 번째 부분송파인 H_i 는 복소수이며, 다음과 같이 정의된다.

$$H_i = |H_i| e^{j\angle H_i} \quad (2)$$

여기서 $|H_i|$ 와 $\angle H_i$ 는 각각 i 번째 부분송파에 대한 채널 상태 정보의 진폭과 위상이다.

우리는 채널 상태 정보의 진폭만을 고려하고 불완전한 하드웨어로 발생하는 임의의 지터와 노이즈로 인한 위상 정보를 무시한다 [11].



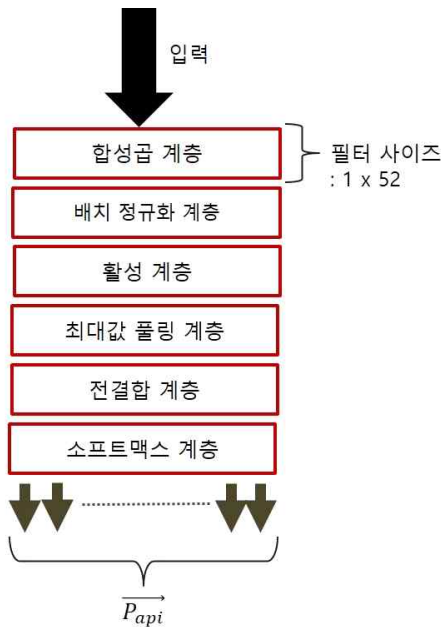
<그림 1> 24RP와 15TP를 갖는 실험실

2.3 데이터 수집

그림 1에서 보듯이 수신 안테나는 RP 및 TP에서 Wi-Fi 신호를 수신한다. AP의 위치를 선택하는 원칙은 모든 포인트가 LOS에서 적어도 하나의 AP를 갖도록 하는 것이다. 근접한 AP는 간섭을 피하기 위해 서로 다른 채널을 사용하여 데이터를 송수신할 수 있다는 점을 고려할 때 3개의 AP에서 동시에 데이터를 수집할 것인지 아니면 각 AP 위치에서 개별적으로 데이터를 수집할 것인지는 큰 차이가 없다. 따라서, 편의상 수신 안테나를 3개 위치에 배치하고 AP 위치별로 3회 데이터 수집 과정을 수행했다.

실험이 수행된 그림 1에 표시된 실험실 (6.0m × 5.5m)에는 풍부한 NLOS 환경을 만들기 위해 충분한 벽과 의자 및 칸막이와 같은 장애물이 있다. 24 RP와 15 TP는 80cm의 간격으로 선택되며, 이는 대략 성인 한 걸음의 길이이다. 각 포인트에 대해 1000 개의 채널 상태 정보 샘플을 수집했다.

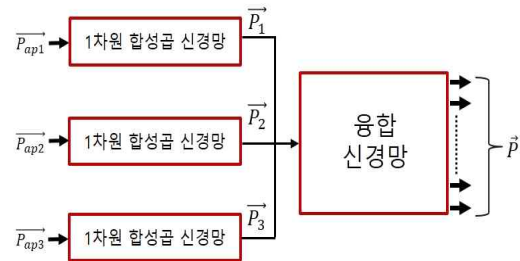
각 표본에 대해 52 개의 부반송파 값이 있다는 점을 감안할 때 훈련 데이터 집합의 크기는 $N_r \times N_s \times N_c \times N_a$ 이고 테스트 데이터 집합의 크기는 $N_t \times N_s$, 여기서 N_c × 각각 RP와 TP의 수, N_s 은 샘플 수, N_c 은 부반송파 수, N_a 은 안테나 수를 나타낸다.



<그림 2> 1차원 합성 신경망 구조

그림 2에서 볼 수 있듯이 1000x52 크기의 한 AP의 데이터는 합성곱 계층, 배치 정규화 계층, 활성화 계층, 최대값 풀링 계층, 전결합 계층, 소프트맥스 계층으로 구성된 1 차원 합성곱 신경망 (one-dimensional CNN, 1dCNN)에 입력된다. 활성화 계층의 활성화 함수에 대해 정규화 선형 유닛 (Rectified Linear Unit, ReLU) 함수를 사용하였다.

1차원 합성곱 신경망의 출력은 모든 위치의 확률로 구성된 확률 벡터 P_{api} 이다. 여기서 api 는 AP의 인덱스를 나타낸다. 확률이 가장 높은 위치가 예상 위치로 간주된다.



<그림 3> 하이브리드 신경망

그림 3에서 볼 수 있듯이 1차원 합성곱 신경망의 결과, 즉 3 개의 AP에서 얻은 P_{api} 는 융합 신경망에 입력되어 추가로 결합되어 최종 추정 위치에 도달한다. 이러한 방식으로 NLOS의 영향으로 핑거프린트가 불안정해지면 다른 AP를 기반으로 하는 다른 핑거프린트의 정확한 추정에 더 많은 빛을 발할 수 있다. 따라서 견고성이 크게 향상 될 수 있다. 1차원 합성곱 신경망 및 융합 신경망에 대한 자세한 정보는 표 I에서 볼 수 있다.

III. 딥 러닝 솔루션

3.1 신경망 구조

<표 1> 신경망 구조

계층	전결합 계층	융합 신경망
손실 함수	Cross Entropy	Mean Squared Error
입력 계층	1 x 50	90 x 1

내부 계층1	Dense 150	Dense 256
내부 계층2	Dense 100	Dense 128
내부 계층3	Dense 50	Dense 64
출력 계층	1 x 30	1 x 30

3.2 Algorithms

소프트맥스 함수를 사용하여 P_api를 계산하였다. 소프트맥스 함수는 다음과 같다.

$$s^i = \frac{e^{s_i}}{\sum_{j=1}^K e^{s_j}}, \quad i \in [1, 2, \dots, K], \quad (3)$$

여기서 K는 RP의 개수이고, s_i and s_i' 는 각각 i번째 위치에 대한 예측점수와 정규화된 점수이다. 수식 3을 통해 모든 예측 점수가 0~ 1 범위로 정규화 된다.

실험 중 과적합을 방지하기 위해 정규항을 사용하고 최적화 과정에서 레이어의 활성화 값에 페널티 항을 추가하여 가중치와 출력에 적용한다.

그런 다음 정규화 된 점수에 1 차원 합성곱 신경망의 크로스 엔트로피 손실 함수를 적용하여 다음과 같이 손실을 계산한다.

$$L = -\log(s_t'), \quad (4)$$

여기서 s_t'는 t번째 위치에서 얻은 정규화된 예측 점수를 의미한다.

융합 신경망의 경우, 손실함수로 평균 제곱 오차 (Mean Square Error, MSE)를 적용한다.

옵티마이저의 경우, 기본 설정으로 β₁ = 0.9, β₂ = 0.999 를 갖는 Adam 옵티마이저를 선택했다. 미니 배치 사이즈는 128이고 학습률은 0.001 입니다. 각 에폭 전에 모든 훈련 데이터는 섞인다.

IV. 실험 결과

이 섹션에서는 세 개의 AP를 활용 한 실험 결과를 제공한다. 표 2에서 보는 바와 같이 단일 AP 만 사용하는 경우와 AP 3 개를 함께 사용하는 경우의 평균 오차와 표준 편차로 수치 결과를 제시한다. 평균 오차와 표준편차는 정확한 위치와 예측한 위치에 대한 평균 오차와 표준편차이다.

단일 AP의 경우 서로 다른 AP 데이터 집합으로 인해 평균 오차와 표준 편차가 달라진다. 이는 서로 다른 AP 데이터 집합이 각각 다른 NLOS 효과를 겪기 때문이다. AP2 데이터 집합은 1.4517m 평균 오차 및 0.7125m 표준 편차로 최고의 성능을 나타내는 반면 AP3 데이터 집합은 평균 오차 2.1360m 및 표준 편차 1.1832m로 최악의 성능을 나타냄을 알 수 있다. 그러나 AP1, AP2, AP3 데이터 집합을 함께 사용하면 평균 오차가 1.2813m, 표준 편차가 0.6642m 인 단일 AP 데이터 집합을 사용하는 모든 경우보다 시스템 성능이 우수하다는 것을 알 수 있다. 이는 여러 개의 핑거프린트 맵이 더 신뢰할 수 있는 데이터를 학습시킬 수 있기 때문이다. 따라서 단일 AP 데이터 집합을 사용하는 것보다 더 강인한 성능을 갖게 된다.

<표 2> 성능 비교

사용한 AP 수	평균 오차	표준 편차
AP1	2.0541 m	1.1534 m
AP2	1.4517 m	0.7125 m
AP3	2.1360 m	1.1832 m
AP1, AP2, AP3	1.2813 m	0.6642 m

표3은 제안한 다중 AP 핑거프린트를 이용한 하이브리드 신경망 방식이 기존 방법보다 성능이 크게 향상된 결과를 보여준다. 기존 방법인 EVM, Bayesian, and DeepFi와 비교하여 본 논문에서 제안하는 하이브리드 신경망 방식은 각각 34.03%, 35.82%, 그리고

27.85% 성능이 향상되었다.

<표 3> 기존 방법 성능 비교

방법	평균 오차	표준 편차	향상도
Hybrid NN	1.2813 m	0.6642 m	
SVM	1.9421 m	1.4812 m	34.03%
Bayesian	1.9965 m	1.4231 m	35.82%
DeepFi	1.7759 m	0.8713 m	27.85%

V. 결론

이 논문에서는 실내 환경에서 심각한 NLOS 효과로 인한 실내 위치 확인시스템의 성능 저하를 다루었다. 실내 위치 확인 시스템의 견고성을 높이기 위해 세 곳의 서로 다른 위치에 있는 세 개의 AP 포인트를 활용할 수 있는 가능성을 활용하였다. 3 개의 AP에서 받은 채널 상태 정보 값을 활용하여 모든 위치에 대해 3 개의 고유한 핑거프린트 맵을 생성 할 수 있다. 핑거프린트 맵이 많을수록 단일 핑거프린트 맵에 의존하던 실내 위치 확인 시스템의 정확도는 더 많은 핑거프린트 맵에 의존 할 수 있다. 따라서 실내 위치 확인 시스템은 NLOS에 영향을 덜 받은 AP에서보다 안정적인 채널 상태 정보 값을 사용하여 실내 환경에서 보다 강력하게 수행 할 수 있다. 또한, 본 논문에서는 세 가지 채널 상태 정보 데이터 집합의 특징을 추출하고 융합 신경망에서 결합하여보다 정확한 결과를 얻기 위해 하이브리드 신경망을 제안했다. 단일 AP 데이터 집합을 사용한 결과와 3 개의 AP 데이터 집합을 사용한 결과를 비교해 보면 실내 위치 확인 시스템의 견고성이 크게 향상되었음을 알 수 있다. 또한, 기존방식보다 시스템 성능도 크게 향상되었음을 알 수 있다.

Acknowledgement

본 연구는 과학기술정보통신부 및 과학기술인력지원진흥원 2020년 산학연공동연구법인지원사업의 지원을 받아 수행하였음. [2020K000081]

참고문헌

- [1] C.-H. Hsieh, J.-Y. Chen, and B.-H. Nien, "Deep learning-based indoor localization using received signal strength and channel state information," *IEEE Access*, vol. 7, 2019, pp. 33256–33267.
- [2] X. Wang, L. Gao, S. Mao, and S. Pandey, "CSI-based fingerprinting for indoor localization: A deep learning approach," *IEEE Transactions on Vehicular Technology*, vol. 66, no. 1, Mar. 2017, pp. 763–776.
- [3] H. Li, W. Yang, J. Wang, Y. Xu, and L. Huang, "WiFinger: Talk to your smart devices with finger-grained gesture," in *Proc. ACM UbiComp*, 2016, pp. 250–261.
- [4] F. E. I. Wang, J. Feng, Y. Zhao, X. Zhang, S. Zhang, and J. Han, "Joint Activity Recognition and Indoor Localization With WiFi Fingerprints," *IEEE Access*, vol. 7, no. 1, 2019, pp. 80058–80068.
- [5] T. Zhang and Y. Man, "The enhancement of WiFi fingerprint positioning using convolutional neural network," in *Proc. Int. Conf. Comput., Commun. Netw. Technol. (CCNT)*, Wuzhen, China, Jun. 2018.
- [6] X. Wang, X. Wang, and S. Mao, "Cifi: Deep convolutional neural Networks for indoor localization with 5 Ghz Wi-Fi," in *Proc. IEEE Int.*

Conf. Commun. (ICC), May 2017, pp. 1-6.

[7] G. Pecoraro, S. D. Domenico, E. Cianca, and M. D. Sanctis, "CSI-based fingerprinting for indoor localization using lte signals," *Eurasip Journal on Advances in Signal Processing*, vol. 2018, no. 1, p. 49.

[8] J. Machaj, P. Brida, and R. Piche, "Rank based fingerprinting algorithm for indoor positioning" in *IEEE Indoor Positioning and Indoor Navigation (IPIN)*, 2011, pp. 1-6.

[9] S. Palipana, D. Rojas, P. Agrawal, and D. Pesch, "FallDeFi: Ubiquitous fall detection using commodity Wi-Fi devices," in *Proc. IMWUT*, vol. 1, no. 4, 2018, Art. no. 155.

[10] R. Zhou, X. Lu, P. Zhao, and J. Chen, "Device-free presence detection and localization with SVM and CSI fingerprinting," *IEEE Sensors Journal*, vol. 17, no. 23, Dec. 2017, pp. 7990-7999.

[11] H. Zhang, Z. Zhang, S. Zhang, S. Xu, and S. Cao, "Fingerprint-based localization using commercial LTE signals: A field-trial study," *IEEE Veh. Technol. Conf.*, vol. Sept-Sept, 2019, pp. 1-5.



최 승 원
Choi, Seung Won

2012년 3월~현재
HY-MC 연구센터 센터장

2002년~2011년
HY-SDR 연구센터 센터장

1992년~현재
한양대학교 융합전자공학부 교수

1990년~1992년
일본 우정성 통신연구소 선임 연구원

1989년~1990년
ETRI 선임 연구원

1988년~1989년
미국 Syracuse대학 전지 및 전산과 교수

1988년 12월 미국 Syracuse대학 전기공학 (공학박사)

1985년 12월 미국 Syracuse대학 전기공학 (공학석사)


1982년 2월 서울대학교 전기공학 (공학석사)

1982년 2월 한양대학교 전기공학 (공학학사)

관심분야 : SDR, 이동통신, 신호처리
E-mail : choi@dsplab.hanyang.ac.kr

논문접수일 : 2020년 8월 26일
수 정 일 : 2020년 10월 6일
게재확정일 : 2020년 10월 23일

■ 저자소개 ■



장 중 봉
Zhang, Zhong Feng

2018년 3월~현재
한양대학교 전자컴퓨터통신공학과 박사과정

2018년 2월 연변대학교 정보통신공학과 (공학학사)

관심분야 : DSP, vehicular comm, LTE-A, etc
E-mail : zhongfeng.zhang@dsplab.hanyang.ac.kr