A Study of Multi-Target Localization Based on Deep Neural Network for Wi-Fi Indoor Positioning

Jaehyun Yoo

School of AI Convergence, Sungshin Women's University, Seoul 02844, Korea

ABSTRACT

Indoor positioning system becomes of increasing interests due to the demands for accurate indoor location information where Global Navigation Satellite System signal does not approach. Wi-Fi access points (APs) built in many construction in advance helps developing a Wi-Fi Received Signal Strength Indicator (RSSI) based indoor localization. This localization method first collects pairs of position and RSSI measurement set, which is called fingerprint database, and then estimates a user's position when given a query measurement set by comparing the fingerprint database. The challenge arises from nonlinearity and noise on Wi-Fi RSSI measurements and complexity of handling a large amount of the fingerprint data. In this paper, machine learning techniques have been applied to implement Wi-Fi based localization. However, most of existing indoor localizations focus on single position estimation. The main contribution of this paper is to develop multi-target localization by using deep neural, which is beneficial when a massive crowd requests positioning service. This paper evaluates the proposed multi-localization based on deep learning from a multi-story building, and analyses its learning effect as increasing number of target positions.

Keywords: indoor positioning system, Wi-Fi RSSI, fingerprint localization, deep neural network, multi-localization

1. 서론

범지구적 위성 항법 신호가 도달하지 못하는 실내 공간의 정 확한 위치를 추정하기 위해 다양한 방법들이 개발되고 있다. 무 선신호를 이용한 실내 측위는 그 측위 방법에 따라 종류가 나뉜 다. Time of Arrival, Angle of Arrival (Cho et al. 2017) 과 같은 전 통적인 측위 방법은 여러 군데 설치한 비콘에서 수신한 신호와 전파 모델을 이용하여 송수신 시간, 각도, 거리 등을 추정하여 위 치를 계산한다. 와이파이 무선신호 위치 측위 방법은 건물에 미 리 설치한 공유기들의 신호 세기를 수집하고 패턴을 분석하여 위 치를 추정한다. 이 방법은 비콘 설치와 정확한 전파 모델이 필요 하지 않다 (Yoo et al. 2017). 본 논문은 와이파이 신호세기를 이용 한 실내 측위 기술을 중점적으로 다룬다.

와이파이 실내 측위 방법은 사전에 정의한 각 위치마다 주변

Received Aug 10, 2020 Revised Feb 10, 2021 Accepted Feb 11, 2021 [†]Corresponding Author E-mail: jhyoo@sungshin.ac.kr Tel: +82-2-920-7695 Jaehyun Yoo https://orcid.org/0000-0002-6167-2842 공유들로부터 수집한 신호세기 지문 (Fingerprint) 데이터베이스 가 필요하다. 벽, 구조물과 같이 전파를 가로막는 장애물들이 많 은 실내 환경에서는 지문 데이터가 많을수록 측위 정확도가 높아 진다. 거리에 따른 와이파이 신호 세기의 분해능을 고려하여 통 상적으로 1~2 m 간격마다 지문 데이터를 수집하여 학습 데이터 베이스를 구축한다. 측위 서비스 제공 시에는 현재 수신된 신호 세기 집합을 기존에 수집한 데이터베이스와 비교하여 현재 위 치를 예측한다. 이는 기계학습에서 학습 단계-테스트단계 절차 와 같기 때문에 k-Nearest Neighbors, Support Vector Machine, Gaussian process, Deep Neural network 등 다양한 기계학습 기 법들이 적용되어 왔다. 본 논문에서는 심층 신경망(deep neural network)을 이용하여 실내 측위 기법을 개발하는 것에 집중한다.

와이파이 무선신호 실내 측위를 위해 심층 신경망을 적용할 때는 무선신호 집합을 신경망 입력단으로 구성하고 위치를 출력 단으로 설정한 후, 은닉 신경망을 학습하여 입력과 출력 사이의 측위 모델을 구한다. 학습 단계에서는 측위 지역 전체에 걸쳐 수 집한 신호세기 지문 데이터를 사용하여 모델을 학습하고, 테스트 단계에서는 학습한 모델에 query 신호세기 집합을 입력하여 예 측 위치를 구한다. 실시간 서비스 품질에 있어서 학습 처리 시간 은 영향이 없는 반면 테스트 단계의 측위 계산 속도가 중요하다. 신경망 기반의 무선신호 실내 측위 대부분은 단일 이용자의 위치 추정에 집중되어 있다 (Wang et al. 2017, Bae et al. 2018, Rizk et al. 2019). 기존의 신경망 기반 측위 기술은 다수의 이용자 가 측위 서비스를 요구하는 경우 요청받은 횟수만큼 추정 계산을 수행할 수밖에 없으므로 실시간 처리 속도 면에서 매우 비효율적 이다. 실내 측위 서비스는 주로 앱, 서버 등을 이용하여 스마트기 기를 통해 제공되는데 공항, 쇼핑몰, 백화점 등 대형건물에서 측 위 서비스를 이용하는 접속자가 많을 것으로 예상할 수 있다. 따 라서, 다수 이용자에게 동시에 측위 서비스를 제공하기 위한 새 로운 측위 방법이 개발되어야 한다.

많은 위치를 동시에 추론하고자 할수록 기계학습 입력데이터 의 차원이 높아진다. 심층 신경망은 이미지와 같은 차원이 높은 데이터를 학습하는 추론 능력이 뛰어나기 때문에, 심층 신경망을 다중 위치 추정 문제에 적용하기 알맞다. 또한, 본 논문은 데이터 정규화와 전처리를 이용하여 신경망학습이 잘 되도록 유도한다. 본 논문에서 사용한 실험 데이터는 5층 건물에서 수집되었고, 위 치와 층을 모두 구별하는 측위 시스템을 개발하였다.

본 논문의 구성은 다음과 같다. 2장은 개발한 심층 신경망 기 반의 다중 실내 측위 방법을 기술하고 3장은 실내 측위 학습 실험 결과를, 4장과 5장은 각각 토론과 결론을 서술하였다.

2. 와이파이 전자지문 기반의 실내 측위

2.1절은 와이파이 무선신호세기 지문 데이터를 이용한 실내 측 위 방법을 서술하고, 2.2절은 학습에 사용될 데이터 전처리 방법 을 설명한다. 2.3절은 심층 신경망을 이용한 다중 측위 학습 방법 을 기술한다.

2.1 와이파이 신호세기 지문 기반 실내 측위

실내 측위 서비스를 구축하고자 하는 건물에 총 M개의 공유 기가 있다고 가정한다. 또한, 와이파이 신호세기 지문 데이터가 수집되는 위치가 사전에 지정되어 있다고 가정한다. 복층 건물 인 경우 위치가 [x 좌표, y 좌표, 층]과 같이 3차원 벡터로 표현된 다. 각 위치마다 M개의 공유기로부터 수집된 신호세기값들을 저 장하여 {(위치, M개의 무선신호세기 집합)} 쌍으로 이루어진 지 문 데이터베이스를 구축할 수 있다. Table 1은 지문 데이터베이스 형태를 보여준다. 어느 한 지점에서 건물에 존재하는 모든 공유 기의 신호가 수신되지 않기 때문에 지문 데이터베이스는 빈 공간 (Null)으로 채워진 요소가 매우 많다. Null은 기계학습에서 처리할 수 없고, 신호가 도달하지 않은 공유기는 수집 위치와 거리가 먼 것으로 해석할 수 있으므로 Null 대신 -100 dB 값으로 임의로 변 환한다.

지문 데이터베이스을 이용하여 실내 측위를 수행하기 위한 가 장 기본적인 방법은 수집된 데이터베이스와 현재 지문데이터를 비교하여 위치를 계산하는 것이다. 이를 직관적으로 이해할 수 있는 것이 *k*-NN을 활용한 측위 방법이다. 측위 서비스를 받기 원 하는 사용자의 현재 위치에서 수신한 query 무선신호세기 집합 을 지문 데이터베이스의 무선신호세기 집합 중 가장 근접한 *k*개

Table 1. Example of Wi-Fi RSSI fingerprint database.

	AP 1	AP 2	 AP M
Position1	-85 dB	-68 dB	 Null
Position2	-75 dB	-51 dB	 Null
PositionN	Null	Null	 -38 dB

의 위치를 찾고 평균 혹은 역거리가중법에 의해 보간점을 계산하 여 현재 위치 값을 추정한다 (Lim & Kim 2015). 하지만, 공유기의 총 개수가 많아질수록 데이터 차원이 높아져 *k*-NN과 같은 단순 한 대조 방법은 측위 정확도가 높지 않은 편이다.

2.2 주성분 분석과 표준화를 이용한 학습 데이터 전처리

일반적으로 한 위치에서 유의미한 와이파이 무선신호세기 가 도달하는 공유기의 수는 전체 공유기의 수 M보다 매우 적다. 따라서, 일반적인 건물에서 수집된 데이터베이스에는 -100 dB 로 채워진 불필요한 데이터 원소가 많다. 이는 위치 추정 정확도 를 저하하기 때문에 데이터 전처리에 의한 특징점 추출이 중요 하다 (Yoo 2019). 본 논문은 주성분 분석 (principal component analysis) 기법을 이용하여 무선신호세기 데이터의 특징을 추 출한다. 주성분 분석의 구체적인 내용은 참조논문 (Abdi & Williams 2010)에 자세히 서술 되어있으며, 본 논문은 주성분 분 석을 와이파이 신호세기 특징점 추출에 적용하는 것에 집중하며 간략 기술한다.

집합 *D*={(*x_i*, *y_i*)}^{*N*}_{*i*=}를 와이파이 신호세기 지문 데이터베이스라 고 정의한다. 이 때 x_i를 공유기들로부터 수신된 무선신호세기 집합, *y_i*를 위치로 식 (1), (2)와 같이 정의한다.

$$x_i = [r_i^1, r_i^2, \cdots, r_i^M]^{\mathrm{T}} \in \mathbb{R}^M,$$
(1)

$$y_i = [s_i, p_i, f_i]^{\mathrm{T}} \in \mathbb{R}^3.$$
 (2)

식 (1)에서 *rⁱ*는 *i*번째 위치에서 *j*번째 공유기로부터 수신된 무선 신호세기이며, 식 (2)에서 *s_bp*^{*i*}는 각각 2차원 좌표상에 위치이고 *f*_i는 층이다. 식 (1)과 (2)의·^T는 전치 연산자이다.

주성분 분석은 일반 고유값 문제를 풀어 특징점 추출을 위해 사용될 변환 행렬을 계산한다. 불필요한 데이터가 포함된 원본 데이터 $x_i \in R^M$ 를 변환 행렬 $Q \in R^{L \times M}$ 를 통해 특징 데이터 $\bar{x}_i \in R^L$ 로 변환한다. 먼저, 데이터의 평균 μ 을 이용하여 식 (3)과 같이 공 분산 행렬 P를 계산한다.

$$\mu = \frac{1}{N} \sum_{i=1}^{N} x_i,$$

$$P = \sum_{i=1}^{N} x_i x_i^{\mathrm{T}} - N \mu \mu^{\mathrm{T}}.$$
(3)

여기서 공분산 P는 대칭 정사각행렬이며 이것의 일반 고유값을 $\{\lambda_i\}_{i=1}^{M}$, 일반 고유벡터를 $\{v_i\}_{i=1}^{M}$, 라하자. 고유값이 크기 순서대로 나열된다고 가정할 때 (즉, $\lambda_1 \ge \lambda_2 \ge \dots \ge \lambda_M$), 각 고유값의 쌍에 해 당하는 고유벡터 또한 크기 순서대로 나열된다. M개의 고유벡터 중 크기 순서대로 L개까지 선정하여 식 (4)와 같이 변환행렬 $Q \in R^{L \times M}$ 를 정의할 수 있다. 이 때, $L(\le M)$ 값은 설계자가 결정한다.

$$Q = \left[v_1^{\mathrm{T}}, v_2^{\mathrm{T}}, \cdots, v_L^{\mathrm{T}}\right] \in R^{L \times M}.$$
 (4)

여기서 구한 변환행렬을 변환식 $\bar{x}_i \leftarrow Q \cdot x_i$ 를 이용하여 특징 데이 터를 구한다.

다음은 위치 데이터 $y_i = [s_i, p_i, f_i]^T \in R^3$ 의 표준화에 대해 서술 한다. 위치 벡터 y_i 내의 2차원 좌표 값은 일반적으로 미터 단위 로 표현되고 층 값은 정수로 표현되어 두 사이 데이터 값의 규모 (scale)가 다르다. 또한, 실내공간 특성상 2차원 위치가 복도 같은 곳에 집중되어 있기 때문에 위치데이터가 고루 분포되어 있지 않 다. 이러한 특성은 심충 신경망을 포함한 모든 일반적인 기계학 습의 정확도를 낮춘다. 본 논문에서는 위치 데이터에 대해 표준 화(standardization)를 이용하여 식 (5)와 같이 변환 위치데이터 를 얻는다.

$$\bar{y}_i \leftarrow (y_i - \mu_s) / \sigma_s. \tag{5}$$

여기서 μ_s와 σ_s 는 위치 데이터 집합 {y_i_j^k_{i=1}의 평균과 표준편차이다. 정리하자면 주성분 분석을 통해 x_i는 x̄_i로, 표준화를 통해 y_i는 ȳ_i 로 처리되어, 원본 지문 데이터 집합 D={(x_i, y_i)}^N_{i=1}가 특징 학습 데 이터 D̄={(x̄_i, ȳ_i)}^N_{i=1}로 변환된다.

2.3 심층 신경망 기반의 다중 측위 모델 학습

심층 신경망은 여러 단(layer)의 신경망 구조를 가지며 각 신경 노드의 입력과 출력은 학습 파라미터로 구성된 선형조합 관계를 갖는다. 신호가 다음 단의 신경 노드로 전파될 때 비선형 모델인 Rectified Linear Unit (ReLU) 활성화 함수에 의해 출력된다. 따라 서 여러 단으로 신호가 전파될수록 비선형성이 높아진다. 유의미 한 학습이 진행되기 위해 적절한 은닉층 수와 신경 노드 수를 개 발자가 정해야 한다.

Fig. 1a는 일반적인 단일 위치 학습을 위한 심층 신경망 구조를 보여준다. 이 경우 신경망의 입력단은 식 (1)에 정의된 M개의 무 선신호 세기값을 입력으로 사용한다.

Fig. 1b는 다중 위치 인식을 위한 신경망 구조로서 Fig. 1a에 묘 사한 단일 위치 신경망을 병렬로확장한 구조이다. Fig. 1b에서 보 듯이 동시에 학습하고자 하는 위치 수를 늘릴수록 더 많은 신경 망 노드가 필요하게 되고 그에 따른 학습 파라미터의 수가 증가 해야한다. Fig. 1b와 같이 입력 데이터와 출력 데이터를 확장하면 데이터 차원이 증가하게 되는데, 심층 신경망을 포함한 일반적인 기계학습 기법은 데이터 차원이 높을수록 학습 데이터 양 또한 많아야 한다 (Bishop 2006).

2.2절에서 서술된 전처리 과정을 거친 데이터 집합 $\bar{D}=\{(\bar{x}_i, \bar{y}_i)\}_{i=1}^{N}$ 는 단일 측위를 위한 데이터 집합이다. 충분한 양의 다중 위치 학 습을 위한 데이터 생성을 위해 (즉, Fig. 1b가 표현하는 입출력 데 이터셋으로 만들기 위해), \bar{D} 로부터 렌더링 작업이 필요하다.

추정하고자 하는 다중 위치 개수를 K라고 할 때, 신경망의 입력 데이터와 출력 데이터 구성은 각각 식 (6), (7)과 같다 (Fig. lb 참조).

$$X_{i} = [\bar{x}_{1}^{\mathrm{T}}, \bar{x}_{2}^{\mathrm{T}}, \cdots, \bar{x}_{K}^{\mathrm{T}}]^{\mathrm{T}},$$
(6)

$$Y_i = [\bar{y}_1^{\mathrm{T}}, \bar{y}_2^{\mathrm{T}}, \cdots, \bar{y}_K^{\mathrm{T}}]^{\mathrm{T}}.$$
 (7)



Fig. 1. (a) Deep neural network structure for single position learning, (b) Extended deep neural network structure for multiple positions learning.

Table 2. Algorithm of rendering multi-target fingerprint training data sets.

Input:	$\overline{D} = \{(\overline{x}_i, \overline{y}_i)\}_{i=1}^N$ single target fingerprint training data
Output:	$F = \{(X_i, Y_i)\}_{i=1}^c$, multi-target fingerprint training data
Initialization:	Set the desired number of training data set c and the number of
	multi-target K, and == as empty sets.
1:	for
2:	for
3:	Sample randomly from subject to and
4:	Add the samples by and .
5:	end for
6:	(Here, the i-th data in equations (6) and (7) are made.)
7:	end for

식 (6), (7)에서 $\bar{x}_j^{\mathsf{T}} \$ $\bar{y}_j^{\mathsf{T}} \doteq 2.2$ 장에 기술된 데이터베이스 $\bar{D}=\{(\bar{x}_i, \bar{y}_i)\}_{i=1}^N$ 에서 추출된다. 여기서 주목해야 할 점은, 신호세기 와 위치 벡터 쌍 $(\bar{x}_j^{\mathsf{T}} \$ $\bar{y}_j^{\mathsf{T}})$ 원소들이 식 (6), (7)과 같이 집합으로 형성될 때, 그들의 정렬 순서에 따라 이종의 데이터로 정의된다. 예를 들어, $X_1=[\bar{x}_1^{\mathsf{T}}, \bar{x}_2^{\mathsf{T}}, \cdots, \bar{x}_k^{\mathsf{T}}]$ 와 $X_2=[\bar{x}_k^{\mathsf{T}}, \bar{x}_{k-1}^{\mathsf{T}}, \cdots, \bar{x}_1^{\mathsf{T}}]$ 은 신경망 입장에



Fig. 2. Fingerprint data distribution on a multi-story experimental building.

서 다른 데이터로 인식된다. 따라서, 다중위치학습에 사용할 적 절한 양의 새로운 학습데이터는 \overline{D} 에서 무작위로 추출을 반복하 고 정렬하여 생성될 수 있다. 단, \overline{D} 에서 중복된 데이터를 취하지 않도록 임의의 $j \neq k \in \{1, \dots, N\}$ 에 대해 $\overline{y}_j^{\mathsf{T}} \neq \overline{y}_k^{\mathsf{T}}$ 을 만족시키며 데이 터를 추출한다. 결과적으로 식 (6)과 (7)의 데이터를 모아 다중 측 위를 위한 새로운 학습데이터 $F=\{(X_i, Y_i)\}_{i=1}^{c}$ 를 생성할 수 있으며, 이 때 학습 데이터 양을 나타내는 계수 c는 개발자가 정한다. Table 2 는 앞서 기술한 단일 측위 학습 데이터 $\overline{D}=\{(\overline{x}_i, \overline{y}_i)\}_{i=1}^{N}$ 를 이용하여 다 중 측위 학습 데이터 $F=\{(X_i, Y_i)\}_{i=1}^{c}$ 를 생성하는 알고리즘을 요약 한다.

3. 실험 결과

3.1실험 환경

개발한 위치 인식 기법을 평가하기 위해 Fig. 2와 같이 60×60 m 크기의 5층 건물에서 실험을 수행하였다. 와이파이 지문 데이 터 수집을 위해 약 1.5 m 간격으로 무선신호세기와 위치 데이터를 복도에 따라 수집하였고 총 2,207개의 학습데이터와 100개의 테 스트 데이터를 수집하였다. 테스트 데이터는 1~5층 학습 데이터 사이에 고루 분포하도록 수집하였다. 무선신호세기 데이터 차원 은 공유기 수 M으로 결정되며, 본 실험건물에서 검색된 공유기 는 총 M=508개이며 수집된 위치 수는 N=2207이다. 식 (2)의 2차 원 위치 값은 Universal Transverse Mercator 좌표계에 따라 수집 및 저장되고 층은 1~5 사이 값을 갖는다.

심층신경망은 Tensorflow (2020)를 이용하여 학습 및 테스트 가 수행되었다. 신경망 학습 파라미터는 Xavier 방법을 통해 초기 화되었고, 활성화 함수는 ReLU 함수로 정의되었고, 경사 하강법 은 Adam-Optimizer를 통해 수행되었고 학습 비용함수의 손실함 수는 Root Mean Square Error로 정의하였다.

3.2 결과

실내 측위를 위한 심층 신경망의 구조는 fine tuning을 통해 1개의 은닉층과 220개의 노드 수로 이루어졌다. 본 실험에서

 Table 3. Experimental results of learning and test with respect to the number of prediction positions.

# of estimated position	Learning iteration	Computation time (sec)	# of training data	Average test error (± std)
1	3500	170.49	2575	2.29±0.002
10	5000	394.43	67080	2.60 ± 1.55
15	10000	994.16	67080	2.68±0.03
20	15000	1818.18	77400	6.07±1.48
25	15000	2474.04	103200	9.93±2.86

은닉층을 2층 이상으로 설계할 경우 학습 성능이 저하되었는 데, 이는 원본 데이터를 주성분 분석을 통해 특징점 추출을 진 행하였기 때문에 데이터의 차원과 복잡성이 감소하였기 때문 이다. 반면, 주성분 분석 기법에 의해 축소되는 데이터 차원은 L=15로 정하였다. 이 근거는 주성분 분석 원리상 변환되는 특 징데이터의 값을 확인하면, 일정한 차원 이상(본 논문에서는 L=15)의 데이터 값은 그 특징을 잃고 작은 값으로 수렴하는 경 향을 보이기 때문이다.

Fig. 3은 각각 추정할 위치 개수가 10개, 15개, 20개, 25개 일 때 학습 epoch에 따른 테스트 성능을 나타낸다. 그래프 y축 에 있는 테스트 에러(test error)는 2차원 좌표상의 유클리디 안 거리와 3차원 좌표(층)에 대한 1 m 페널티의 합으로 정의되 며, 모든 테스트 데이터 100×K개의 평균으로 계산된다. 측위 공간은 1~5층 사이의 60×60 m이지만, 심층망의 출력 값은 실 제 공간 이내로 제한되지 않기 때문에 학습 초기 단계에 테스 트 에러는 매우 클 수 있다. Fig. 3에서 보듯이 학습 결과 모두 epoch이 증가함에 따라 테스트 에러가 수렴하며 줄어드는 것 을 볼 수 있다. 하지만 동시 추정 위치 수가 늘어나면 수렴된 테스트 평균 오차가 커진다. 학습 최적화 과정에서 높은 테스 트 에러가 간헐적으로 발생하는데, 이는 신경망 학습 파라미터 변화에 의한 다중 측위 신경망 모델의 민감성을 보여준다. 학 습률(learning rate)의 크기가 클수록 학습이 진행되는 과정에 서 심층 신경망의 파라미터 갱신값 변화율도 크다. 일반적으로 학습 초기 단계에서는 상대적으로 큰 학습률로 설정하고, 후반 단계에는 학습률을 낮춰 학습 수렴성을 높인다. 본 실험에서는 7000 epoch 이상 학습을 하는 경우에 7000 epoch 전후로 학 습률을 0.01에서 0.001로 변경하여 수렴성을 확보하였다.

Table 3은 학습 수, 학습 소요 시간, 학습 데이터 수 및 평균 오차를 보여준다. Table 3의 다섯 번째 열에 표기된 평균 오차/ 표준 편차 오류는 학습 단계 마지막 epoch으로부터 100번째 전까지 테스트 에러만을 평균 낸 것이다. 추정 위치 수 K에 따 라 학습 수와 소요 시간, 데이터 수가 증감하며, K가 클수록 평 균 오차가 커지는 것을 확인할 수 있다. 본 실험에서 위치 추정 수가 10개와 15개인 경우 단일 위치 추정 정확도와 큰 차이 없 이 좋은 성능을 얻을 수 있었다.

4. 토론

이번 장에서는 제안한 심층 신경망 기반의 다중 측위 기법의 장점을 실시간 측위 서비스 측면에서 단일 측위 방법과 차이점 을 통해 분석한다. 학습한 측위 모델을 이용하여 서비스 이용자에



Fig. 3. Positioning test error by deep neural network according to the number of the estimated positions, (a) 10, (b) 15, (c) 20, (d) 25.

게 측위 서비스를 제공하는 때를 가정하자. 이 때 Table 3에서 측 정된 것처럼 측위 모델을 구하기 위한 학습 소요 시간은 측위 서 비스 실시간성 품질에 포함되지 않는다. 반면, 측위 서비스를 제 공할 때 고려되는 소요시간은 측위 계산 시간(q)과 통신 시간(c)이 주요하다. 서비스 이용자 한 명에게 위치 측위 서비스를 제공하는 시간복잡도를 O(q+c)라고 표현하자. 단일 측위 방법인 경우 n명 에게 측위 서비스를 제공하기위해 n번의 독립적인 위치 측위 계 산이 필요하므로 O(n*q+n*c)가 소요될 것이다. 반면 제안하는 다 중 측위 모델의 경우 n명의 위치를 동시에 추정할 수 있도록 설계 되었다면 (예를 들어 본 논문의 경우 n=15), 측위 서비스 제공 소요 시간은 O(q+n*c)이 된다. 따라서 많은 사용자가 이용할수록 단일 측위 방법 보다 시간을 절약할 수 있으며 실시간성에서 유리하다.

5. 결론

본 논문은 다중 위치 학습 및 추정을 위해 심층 신경망을 활용 한 와이파이 기반 실내 측위를 개발하였다. 와이파이 무선신호세 기 지문 원본 데이터를 주성분 분석 기법으로 전처리 과정을 거 쳐 특징데이터를 추출한 후, 신경망의 입력데이터로 사용한다. 심층신경망은 은닉층 수, 노드 수, 학습 수, 학습 데이터 수를 조 절하며 학습 성능을 최적화하였다. 5층 건물에 대해 측위 실험을 수행하였을 때, 20개 미만의 위치를 동시에 추정할 때 좋은 학습 결과를 도출함을 확인하였다.

ACKNOWLEDGMENTS

This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No.2019R1F1A1057516).

AUTHOR CONTRIBUTIONS

J. Yoo; algorithm development, experiments, and writing.

CONFLICTS OF INTEREST

The author declares no conflict of interest.

REFERENCES

- Abdi, H. & Williams L. J. 2010, Principal component analysis, Wiley interdisciplinary reviews: computational statistics, 2, 433-459. https://doi.org/10.1002/wics.101
- Bae, H. J., Choi, L., & Park, B. J. 2018, Indoor Positioning System using Geomagnetic Field with Recurrent Neural Network Model, Journal of Korean Institute of Next Generation Computing, 14, 57-65.
- Bishop, C. M. 2006, Pattern recognition and machine learning (New York: Springer-Verlag).
- Cho, S. Y., Kang, D., Kim, J., Lee, Y. J., & Moon, K. Y. 2017, Performance Analysis of the Wireless Localization Algorithms Using the IR-UWB Nodes with Non-Calibration Errors, JPNT, 6, 105-116. https://doi. org/10.11003/JPNT.2017.6.3.105
- Lim, C. & Kim, D. 2015, On the Use of Weighted k-Nearest Neighbors for Missing Value Imputation, The Korean Journal of Applied Statistics, 28, 23-31. https://doi. org/10.5351/KJAS.2015.28.1.023
- Rizk, H., Torki, M., & Youssef, M. 2019, CellinDeep: Robust and accurate cellular-based indoor localization via deep learning, IEEE Sensors Journal, 19, 2305-2312. https://doi.org/10.1109/JSEN.2018.2885958
- Tensorflow, [Internet], cited 2020 Aug. 08, available from: https://www.tensorflow.org/
- Wang, X., Gao, L., Mao, S., & Pandey, S. 2017, CSI-based fingerprinting for indoor localization: A deep learning approach, IEEE Transactions on Vehicular Technology, 66, 763-776. https://doi.org/10.1109/TVT.2016.2545523
- Yoo, J. 2019, Feature representation of Wi-Fi signal strength for indoor location awareness, in International conference on control, automation and systems, 15-18 Oct. 2019, Jeju, Korea, pp.1498-1502. https://doi. org/10.23919/ICCAS47443.2019.8971565
- Yoo, J., Johansson, K. H., & Kim, H. J. 2017, Indoor localization without a prior map by trajectory learning from crowdsourced measurements, IEEE Transactions on Instrumentation and Measurement, 66, 2825-2835. https://doi.org/10.1109/TIM.2017.2729438



Jaehyun Yoo received the Ph.D. degrees in the School of Mechanical and Aerospace Engineering, Seoul National University, Seoul, in 2016. He was a postdoctoral researcher at the School of Electrical Engineering and Computer Science, KTH Royal Institute of Technology, Stockholm,

Sweden. He is currently a Professor at the School of AI, Sungshin Women's University. His research interests include machine learning, indoor localization, automatic control, and robotic systems.