

실내 환경에서의 측위를 위한 전파 지문 기반의 병렬 인공신경망 학습 기법

박 찬 욱*, 최 용 훈^o

Parallel Artificial Neural Network Learning Scheme Based on Radio Frequency Fingerprint for Indoor Localization

Chan-Uk Park*, Yong-Hoon Choi^o

요 약

실내 측위 분야에서 가장 보편적으로 사용되는 전파 지문 기반의 측위 기법은 데이터 비교 알고리즘이 성능에 가장 큰 영향을 미친다. 본 논문에서는 인공신경망 학습을 통해 전파 지문 측위를 수행하며, 제안한 학습 방법은 기존의 유클리드 거리 비교 기반의 전파 지문 측위 알고리즘에 비해 높은 성능을 보인다. 본 논문에서는 실내 측위에 적합한 학습 구조뿐만 아니라, 데이터 확장 기법도 제안하며, 제안한 데이터 확장 기법은 다양한 측위 기술에 부분적으로 적용이 가능하다. 실험을 통해 제안한 기술이 기존의 유클리드 거리 기반의 측위 기법보다 높은 성능을 보여주는 것을 확인할 수 있다.

Key Words : Indoor Positioning, LBS(Location-Based Service), Neural Network, Deep Learning, Data Augmentation

ABSTRACT

The positioning technique based on radio wave fingerprint, which is most commonly used in the indoor positioning field, is most affected by the data comparison algorithm. In this paper, we perform radio wave fingerprint positioning through artificial neural network learning, and the proposed method shows higher performance than the existing Euclidean distance comparison based radio fingerprint positioning algorithm. In this paper, we propose a data extension method as well as a learning structure suitable for indoor positioning, and the proposed data extension method can be partially applied to various positioning techniques. Experimental results show that the proposed technique shows higher performance than the conventional Euclidean distance based positioning method.

1. 서 론

최근 위치 기반 서비스의 증가로 더욱 정확한 측위 알고리즘에 대한 수요가 높아지고 있다. 실내 측위 분

야에서 가장 보편적으로 사용되^[1] 전파 지문 측위 기법은 실내의 무선 신호 데이터들을 DB(Database)로 구축하여 실제 위치와 비교하는 방식이다.^[3] 전파 지문 측위 기법의 정확도는 DB의 데이터로 측위 데

※ 본 연구는 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(NRF-2016R1D1A1B03934507).

※ 본 연구는 2017년도 광운대학교 교내학술연구비의 지원을 받아 수행되었음.

• First Author : (ORCID:0000-0003-0762-2745)Kwangwoon University of School of Robotics, sau403@gmail.com, 학생회원

◦ Corresponding Author : (ORCID:0000-0002-1460-0520)Kwangwoon University of School of Robotics, yhchoi@kw.ac.kr, 종신회원
논문번호 : KICS2018-02-045, Received February 28, 2018; Revised May 18, 2018; Accepted May 21, 2018

이터의 실제 위치를 얼마나 잘 예측하는지가 중요하다. 기존의 연구에서는 주로 DB의 데이터와 실제 위치의 데이터를 유클리드 거리(Euclidean Distance) 기반의 수학적 방법으로 비교하여 위치를 추정하였다.^[4] 본 논문에서는 더욱 정확한 위치 추정을 위한 인공신경망 학습 기법을 제안한다. 먼저 실내 위치 데이터에 적합한 데이터 확장 기법(Data Augmentation)^[10]을 제안한다. 데이터 확장 기법을 사용하여 학습 데이터를 일반화(Generalization) 함으로서 실제 위치에 대한 예측 성능이 향상되었다. 또한, 본 논문에서는 실내 측위에 적합한 학습 구조를 제안한다. 실내 측위에 적합한 학습 구조를 통해 인공신경망의 회귀(Regression) 문제에서 발생하는 위치 추정 오차를 줄이는 효과를 확인할 수 있다. 본 논문에서 제안하는 기법은 기존에 연구된 측위 기법에 부분적으로 적용이 가능하며, 대부분의 측위 알고리즘에서 위치 추정 성능이 향상됨을 확인할 수 있다. 본 논문의 2장에서는 논문의 이해를 돕기 위한 기반 기술들에 대해 서술한다. 3장에서는 본 논문에서 제안하는 기법들에 대해 서술한다. 4장에서는 본 논문의 기법과 기존에 연구된 측위 알고리즘에 대한 성능 평가 실험에 대해 서술하고, 5장에서는 결론과 향후 연구 방향에 대하여 서술한다.

II. 관련 연구

2장에서는 본 논문의 이해를 돕기 위한 기반 기술들에 대해 설명한다. 먼저, 측위 알고리즘의 종류와 위치 계산 방식에 대해 설명한다. 이어서, 기존 기계 학습을 이용한 전파지문 방식에서 가장 뛰어난 성능을 보여주는 것으로 알려진 유클리드 거리 비교 방식의 측위 알고리즘을 설명한다. 또한 인공신경망을 이용한 전파 지문 측위방식에 대해 설명하며 기존 연구에서 보완해야 할 점에 대해서도 설명한다.

2.1 삼각 측량법과 전파 지문 측위 기법

기존의 측위 알고리즘은 크게 '수학적 계산을 통한 예측' 방식과 기존에 구축해 둔 측위 DB와 현재 위치 데이터를 비교하는 '전파 지문' 방식 두 가지로 분류할 수 있다. '수학적 계산을 통한 예측' 방식의 예는 '삼각 측량법'으로 널리 알려진 다각 측량 알고리즘이 있다. 이는 무선 신호의 세기를 통해 위치를 예측하며, 필터 등을 통해 보완하는 기법이다.^[2] 그러나 실내 공간에서의 무선 신호의 감쇄, 간섭 등의 이유로 무선 신호를 통해 정확한 거리를 알 수 없는 점으로 인해,

실내 측위에는 적합하지 않다. 전파 지문 방식은 AP(Access Point)의 신호들을 DB로 저장하여 측위를 수행할 해당 공간의 신호와 비교하는 방식의 측위 알고리즘이다. 이는 무선 신호의 감쇄와 간섭 등이 발생하는 실내 공간에 적합하다.^[3]

2.2 유클리드 거리 비교 기반 전파지문 측위 기법

위치 데이터와 DB를 비교하는 알고리즘은 전파 지문 측위에서 위치 정확도에 가장 큰 영향을 미친다. 기존 연구의 데이터 비교 알고리즘 중 하나는 유클리드 거리(Euclidean distance) 차이를 통해 데이터와 DB를 비교하는 것이다.^[4] 그러나 측위를 수행하고자 하는 환경의 AP 개수가 많아질수록 비교할 데이터의 차원 크기가 커지고, 그에 따라 유클리드 거리차가 모호해지는 현상이 발생한다.^[4] 이러한 현상을 해소하기 위해 고차원의 AP 데이터에서 높은 성능을 보여주는 '로그 가우스 거리(Logarithmic Gaussian Distance)'를 이용한 기존의 연구가 진행된 바 있다.^[5] 또한 이를 응용한 '선택도 기반 클러스터링(Affinity Propagation Clustering)'을 사용함으로써 측위를 수행할 환경의 데이터를 분류하고, 연관성 있는 데이터들의 집합 안에서 유클리드 거리를 비교하는 방식의 연구가 진행된 바 있다.^[6] 위 연구는 기존에 진행된 유클리드 거리 비교 기반 측위에서 가장 높은 성능을 보여준다.^[7] 따라서 본 논문의 성능 측정을 위한 벤치마크로 사용된다.

2.3 인공신경망을 이용한 전파 지문 측위 기법

최근 딥 러닝을 비롯한 인공신경망 기반 기계학습 알고리즘 연구의 발전함에 따라서 다양한 분야에 인공신경망을 접목시키려는 연구가 진행 중이다. 이에 따라 측위 분야도 인공신경망을 적용하려는 연구가 진행된 바 있다.^[8,9] 그 중 하나는, 무선 네트워크 인터페이스 카드(Network Interface Card)의 드라이버를 수정하여 교정된 채널 상태 정보(Channel State Information) 데이터를 얻어 딥 러닝 학습에 이용하는 연구가 있다.^[7] CSI 데이터를 활용한 측위는 높은 위치 정확도를 제공하지만, AP의 하드웨어를 수정해야 하므로 데이터 수집에 어려움이 있다. 본 논문에서는 기존 전파지문 측위 연구에서 가장 보편적으로 사용되는 Wi-Fi AP의 RSS(Received Signal Strength) 데이터 기반으로 측위를 진행하였다. 따라서 기존에 진행된 연구에 바로 적용해 볼 수 있다는 장점이 있다. 측위에 인공신경망을 접목시킨 다른 연구로는, 심층 인공신경망 네트워크(Deep Neural Network)와 히든

마르코브 모델(Hidden Markov Model)이 혼합된 학습 네트워크를 사용하여 측위를 수행한 연구가 있다.^[9] 학습 네트워크의 응용은 주어진 데이터 내에서 측위 정확도를 향상시킬 수 있지만, 측위 정확도가 학습 데이터의 품질에 종속된다는 약점이 있다. 본 논문에서는 학습 데이터의 품질을 향상시키는 방법을 통해 위 선형 연구의 약점을 해결하였다.

III. 제안 기법

3장에서는 본 논문이 제안하는 측위 기법에 대해 설명한다. 기존 인공신경망을 이용한 측위 모델의 단점을 보완하기 위한 측위 데이터 확장 기법을 설명하며, 실내 측위에 적합한 인공신경망 학습 기법을 설명한다.

3.1 측위 데이터에 효과적인 데이터 확장(Data Augmentation) 기법

인공신경망 모델의 취약점 중 하나는 학습이 진행될수록 학습 데이터에 과 학습(Over-fitting)되어 테스트 성능이 감소하는 현상이 발생하는 것이다. 학습 데이터 일반화(Data Generalization)를 수행함으로써 이러한 현상을 예방하고, 데이터를 예측 성능이 향상되는 효과를 얻을 수 있다^[10]. 본 논문에서는 무선 신호 데이터에 적합한 데이터 확장(Data Augmentation) 기법으로 데이터 일반화를 수행하였다.

그림 1은 본 논문에서 수행한 데이터 확장 기법을 설명하는 그림이다. 데이터 확장을 수행할 세 점을 각각 D_1, D_2, D_3 새로 추가된 데이터를 D_4 라고 할 때, D_1, D_2, D_3, D_4 는 다음과 같은 식을 만족한다.

$$\overline{D_1 D_4} = \overline{D_2 D_4} = \overline{D_3 D_4} \quad (1)$$




그림 1. 실내 측위 데이터를 위한 데이터 확장 기법(Data Augmentation)
Fig. 1. Data Augmentation Scheme for Indoor Positioning Location Data

$$D_4 \text{의 좌표 } x, y: x_4 = \frac{1}{3}(x_1 + x_2 + x_3), y_4 = \frac{1}{3}(y_1 + y_2 + y_3) \quad (2)$$

$$D_4 \text{와 } P_n \text{의 직선거리} = \overline{D_4 P_n} = \frac{\overline{D_1 P_n} + \overline{D_2 P_n} + \overline{D_3 P_n}}{3} \quad (3)$$

그림 1의 a는 새로 추가된 데이터 D_4 의 좌표에 대한 설명을 돕기 위한 그림이다. D_4 의 좌표는 D_1, D_2, D_3 와 같은 거리에 위치하는 지점이며, 이는 $\Delta(D_1, D_2, D_3)$ 의 무게중심에 해당한다. 그림 1의 b는 새로 추가된 데이터 D_4 의 무선 신호 세기 정보에 대한 설명을 돕기 위한 그림이다. D_4 는 D_1, D_2, D_3 와의 거리가 같은 지점에 위치하기 때문에, D_4 와 P_0 의 거리는 D_1, D_2, D_3 에서 수신하는 P_0 의 RSS의 평균값으로 계산한다. 위 데이터 확장 기법은 다음과 같은 상황에서 실제 데이터와 가장 유사한 데이터를 만들 수 있다.

- $\Delta(D_1, D_2, D_3)$ 내부에 AP 신호가 없을 때
- $\Delta(D_1, D_2, D_3)$ 내부에 무선 신호의 감쇄, 반사를 일으키는 환경이 없을 때
- D_1, D_2, D_3 이 건물의 같은 층에 있을 때

하지만 전파 지문 측위 데이터 셋의 정보만으로는 각 AP들의 위치와 건물의 구조 등을 파악하는 것은 쉽지 않다. 따라서 본 논문에서는 다음과 같은 알고리즘을 통하여 데이터 확장 기법을 수행하였다.

알고리즘 1, 2 는 데이터 확장 기법 알고리즘이다. 첫 번째 데이터부터 순서대로 데이터 확장을 진행한다. 순서대로 선택된 데이터를 기준점으로 가장 가까운 순서대로 같은 층에서 측정된 2개의 데이터를 추가로 선택한다. 그 후 선택된 3개의 점으로 삼각형을




그림 2. 데이터 확장 기법에 따른 측위 정확도
Fig. 2. Position Accuracy Based on Data Extension Scheme

```

1: function DATAUGMENTATION(PositioningDataArray)
2:   len = PositioningDataArray.length
3:   Let TriangleList be new linked list
4:                                     ▷ Prevent selection of the same triangle
5:   Let ExceptDataList be new linked list
6:   Let AugmentedDataList be new linked list   ▷ Newly added data
7:
8:   for i = 0 to len do
9:     D1 = PositioningDataArray[i]
10:    ExceptDataList.put(D1)
11:    D2 = SearchNearestPoint(D1,
12:    PositioningDataArray, ExceptDataList)
13:    ExceptDataList.put(D2)
14:
15:    for j = 0 to TriangleList.length do
16:      if D1 in TriangleList & D2 in TriangleList then
17:        ExceptDataList.putAll(TriangleList[j])
18:      end if
19:    end for
20:
21:    Let CenterDot be new PositioningData
22:    CenterDot.x = (D1.x + D2.x)
23:    CenterDot.y = (D1.y + D2.y) / 2
24:    D3 = SearchNearestPoint(CenterDot, PositioningDataArray, Except-
25:    DataList)
26:    ExceptDataList.put(D3)
27:
28:    Let T = new Triangle(D1, D2, D3)
29:    TriangleList.put(T)
30:
31:    Let D4 be new PositioningData
32:    D4.x = (D1.x + D2.x + D3.x) / 3
33:    D4.y = (D1.y + D2.y + D3.y) / 3
34:    AugmentedDataList.put(D4)
35:  end for
36:
37:  return AugmentedDataList
38: end function

```

알고리즘 1. 위치 데이터 확장
Algorithm 1. Positioning Data Augmentation

```

1: function SEARCHNEARESTPOINT(RefPoint, PositioningDataArray, Ex-
2: ceptDataList)
3:   ▷ params : Base points, datasets, and selective prevention datasets
4:   NearestDistance = Integer.MAX
5:   NearestPoint be new PositioningData
6:
7:   for locData in PositioningDataArray do
8:     if locData.z != RefPoint.z then
9:       continue
10:    end if
11:
12:    Distance =  $\sqrt{(RefPoint.x - locData.x)^2 + (RefPoint.y - locData.y)^2}$ 
13:
14:    if NearestDistance > Distance & locData not in ExceptDataList
15:      & Distance ≠ 0 then
16:        NearestDistance = Distance
17:        NearestPoint = locData
18:      end if
19:    end for
20:
21:    return NearestPoint
22: end function

```

알고리즘 2. 가장 가까운 위치 데이터 검색
Algorithm 2. Search Nearest Positioning Data

만든 후 데이터 확장을 진행한다. 이 때, 데이터의 중복 생성을 막기 위해 사용된 삼각형의 정보를 저장하여 향후 중복검사를 수행한다. 위와 같은 절차로 생성된 데이터의 개수는 원본 데이터의 개수와 같다. 따라서 원본 데이터를 포함하여 2배의 학습 데이터를 얻어낼 수 있다. 확장된 데이터가 측위 정확도에 영향을 미치는지 실험하기 위해 확장 기법을 수행한 데이터와 원본 데이터를 사용하여 여러 기법으로 측위를 수

행하였다.

실험 결과, 데이터 확장 기법을 수행한 데이터 셋에서 전반적으로 높은 정확도를 보여주는 것을 확인할 수 있다. 이는 본 논문의 데이터 확장 기법으로 인해 데이터 셋의 효과적인 일반화가 수행되었음을 증명한 다.

3.2 실내 측위에 적합한 인공신경망 학습 기법

3.2.1 제안 측위 기법의 전체 구조

그림 3은 본 논문에서 제안하는 실내 측위 기법의 전체 구조도이다. 측위를 위해 측정한 원본 데이터를 데이터 확장 기법을 통해 학습 데이터를 생성하고 해당 데이터를 통해 학습을 수행하는 구조이다. 본 논문에서는 측위 기법에 적합한 학습을 수행하기 위해 기존의 인공신경망을 변형한 병렬 인공신경망(Parallel Deep Neural Network, P-DNN)을 통해 학습을 수행하였다.




그림 3. 제안하는 실내 측위 기법 전체 구조도
Fig. 3. Overall structure of proposed indoor positioning scheme

3.2.2 층간 구분을 위한 병렬 인공신경망 학습

기계학습의 알고리즘은 찾고자 하는 결과 값에 따라 분류(Classification) 문제와 회귀(Regression) 문제로 구분할 수 있다. 그림 4는 전파 지문 측위에서의 분류와 회귀문제의 예시이다.

그림 4의 왼쪽은 전파 지문 측위 분류 문제의 예시이다. 학습 데이터를 바탕으로 측위를 수행하고자 하는 장소를 임의의 격자로 나누어 테스트 데이터가 어느 위치에 해당하는지를 추측하는 방식이다. 그림 4의




그림 4. 전파 지문 측위의 분류와 회귀문제
Fig. 4. Classification and regression problem of radio fingerprint for indoor positioning

오른쪽은 회귀 문제의 예시이다. 각 학습 데이터들이 측정된 위치를 x, y 좌표로 DB화 하여 테스트 데이터의 위치를 추측하는 방식이다. 이처럼 전파 지문 측위는 분류, 회귀의 두 가지 방식으로 접근할 수 있다. 본 논문에서는 분류 문제의 경우 격자의 간격에 따라 정확도가 달라지는 점 때문에 성능평가에 복잡함이 있어 회귀 문제를 통해 성능평가를 수행하였다. 그러나 회귀 문제로 접근한 학습 시 실내 측위 환경이 다층 건물인 측위의 경우, 각 건물의 층에 해당하는 z 축의 정확도가 크게 떨어지는 문제가 발생한다. 이와 같은 문제를 해결하기 위해 본 논문에서는 x, y 축과 z 축의 학습을 병렬 인공신경망으로 확장하여 수행하였다. 본 논문에서는 z 축을 건물의 층을 구분하는 분류 문제로 치환하여 그림 5과 같은 구조로 학습을 수행한다.

표 1은 병렬 학습 수행에 따른 학습 정확도를 나타낸다. 실험은 뉴런의 개수가 데이터의 차원의 개수와 같게 설정한 3개의 은닉층 으로 구성된 5-Layer DNN, 그리고 해당 모델에 병렬로 층간 학습을 수행하는 5-Layer P-DNN에서 진행되었다. 각각의 모델에

서 동일한 데이터 셋[11]의 학습을 진행하였을 때 평면 측위(2D) 성능과 다층 측위(3D) 성능의 차이, 본 논문의 병렬 학습 측위 성능의 차이를 측정하였다. 실험 결과, 3D 측위 성능이 z 축 오차의 영향으로 2D 측위보다 낮은 정확도를 보였다. 병렬 학습을 통해 개선된 학습을 수행한 경우 평면 측위의 정확도보다 향상된 성능을 보였다. 이는 층간 구분이 어려운 데이터의 측위를 진행하지 않으므로 학습 데이터의 노이즈를 제거하는 효과를 통해 측위 성능이 더욱 향상됨을 확인할 수 있다.

IV. 실험

4장에서는 본 논문에서 제안하는 기법에 대한 성능평가를 진행하였다. 비교 대상은 본 논문의 기법과 기존의 측위 기법에서 가장 좋은 성능을 보여준 기존의 연구^[7]와 본 논문의 기법을 사용하지 않은 DNN 인공신경망 회귀모델과 비교하였다. 실험 환경은 기존에 연구된 다양한 측위 알고리즘의 성능 평가가 이루어진 데이터 셋^[11]에서 진행하였다.

4.1 실험 환경

실험에 사용된 데이터 셋은 실내 측위 연구를 위한 공개 데이터 셋이며 핀란드의 탐 페레(Tampere) 대학 건물에서 21개의 장치로 수집된 4648개의 데이터로 이루어져 있다. 각 데이터의 구조는 992개의 AP에서 측정된 RSSI 값, 측정된 장소의 x, y, z 좌표데이터, 측정날짜 및 장비 정보로 이루어져 있다. 또한 해당 데이터 셋을 설명하는 문서에는 향후 연구에 용이하도록 기존에 연구된 측위 알고리즘에 대한 벤치마크 결과도 제공한다. 실험은 각 측위 알고리즘에 대한 위치 추정 정확도에 대한 오차와 층간 분류 확률 또는 오차, 그리고 위치 추정을 위한 학습에 걸리는 시간을 측정하였다. 실험에 사용된 본 논문의 인공신경망 학습모델은 뉴런의 개수가 데이터의 차원의 개수와 같게 설정한 3개의 은닉층 으로 구성된 5-Layer DNN, 그리고 해당 모델에 병렬로 층간 학습을 수행하는 5-Layer P-DNN이 사용되었다.

4.2 실험 결과

표 2는 각 위치추정 기법에 따른 정확도를 나타낸 표이다. 실험에 사용된 알고리즘은 딥 뉴럴 네트워크(DNN), 병렬 심층 인공신경망 네트워크(P-DNN), 3D 클러스터링(3D clustering), 기존 유클리드 거리 비교 기반 측위에서 가장 높은 성능을 보여준 친밀도 확산

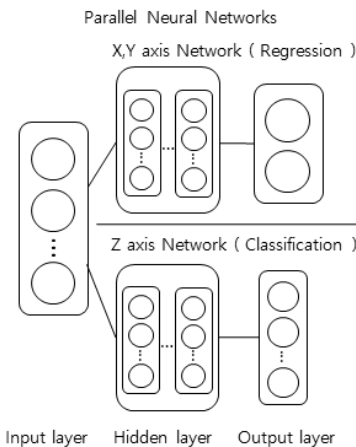


그림 5. 층간 병렬학습 구조도
Fig. 5. Multi-floor parallel learning structure diagram

표 1. 병렬 학습에 따른 정확도
Table 1. Accuracy based on parallel learning

	Mean Error (m)	Floor Detection error(m), percentage(%)
5-Layer DNN (2D)	7.40m	-
5-Layer DNN (3D)	7.84m	0.4m
5-Layer P-DNN	7.28m	94.40%

표 2. 다양한 측위 알고리즘에 따른 측위 정확도
Table 2. Position accuracy according to various positioning algorithms

Algorithm	2D Error (m)	3D Error (m)	Floor Detection Percentage(%)	Training Spend Time(s)
5-Layer DNN	7.409	7.84	-	363s
Data Augmented 5-Layer P-DNN (proposed)	6.943	7.109	94.40%	664s
RSS clustering (affinity propagation) ^[7]	8.086	8.697	90.81%	34s
Data Augmented RSS clustering (affinity propagation) ^[7]	7.8	8.4	91.16%	49s
3D clustering (k-means) ^[7]	14.807	19.519	81.54%	168s
Data Augmented 3D clustering (k-means) ^[7]	14.495	19.484	82.27%	328s

클러스터링 (RSS clustering) 이다. 각 알고리즘들은 본 논문의 데이터 확장 기법을 적용하기 전과 후로 나눠서 실험을 진행하였다. 실험 결과, 본 논문의 데이터 확장 기법을 적용한, 병렬 딥 뉴럴 네트워크가 가장 높은 성능을 보여주는 것을 확인할 수 있다. 또한, 본 논문의 데이터 확장 기법을 적용한 측위 알고리즘이 적용하지 않은 알고리즘 보다 높은 성능을 보임을 확인할 수 있다.

V. 결 론

본 논문에서는 실내 측위를 위한 효과적인 데이터 확장 기법과 실내 측위에 적합한 학습 구조를 제안하였다. 본 논문에서 제안한 데이터 확장 기법은 RSS 데이터에 어떠한 필터도 적용하지 않고 심층 인공신경망으로만 학습하였을 때 기존의 측위 연구보다 뛰어난 정확성을 보여준다.^[10] 이는 향후 연구에 부분적으로 적용할 수 있다. 또한 실내 측위에 적합한 학습 구조를 통하여 측위 정확도를 더욱 향상시켰다. 향후 연구 과제로는 다양한 측위 알고리즘에 적용하여 측

위 정확도를 향상시키는 것이다.

References

- [1] J. J. Yoo and Y. S. Cho, "Trends in technical development and standardization of indoor location based services," *Electron. and Telecommun. Trends.*, pp. 51-61, 2014.
- [2] M. Armstrong and J. Wright, "Mobile call termination" *The Economic Journal*, Vol. 119, Issue 538, pp. F270-F307, June 2009.
- [3] S. He and S.-H. G. Chan, "Wi-Fi fingerprint-based indoor positioning: Recent advances and comparisons," *IEEE Commun. Surveys & Tuts.*, vol. 18, pp. 466-490, 2016.
- [4] C. Feng, W. S. A. Au, S. Valaee, and Z. Tan, "Received-signal-strength-based indoor positioning using compressive sensing," *IEEE Trans. Mob. Comput.*, vol. 11, no. 12, pp. 1983-1993, Dec. 2012.
- [5] S. Shrestha, J. Talvitie, and E. S. Lohan "Deconvolution-based indoor localization with WLAN signals and unknown access point locations," in *Proc. IEEE ICL-GNSS*, pp. 1-6, Italy, Jun. 2013.
- [6] Z. Tian and X. Tang, "Fingerprint indoor positioning algorithm based on affinity propagation clustering," *EURASIP Journal on Wireless Communications and Networking*, 2013:272, 2013.
- [7] A. Cramariuc, H. Huttunen, and E.-S. Lohan, "Clustering benefits in mobile-centric WiFi positioning in multi-floor buildings," *2016 International Conference on Localization and GNSS (ICL-GNSS)*, pp. 1-6, Jun. 2016.
- [8] X. Wang, L. Gao, S. Mao, and S. Pandey, "CSI-Based fingerprinting for indoor localization: A deep learning approach," *IEEE Trans. Veh. Technol.*, vol. 66, pp. 763-776, ISSN 0018-9545, 2017.
- [9] W. Zhang, K. Liu, W. Zhang, Y. Zhang, and J. Gu, "Wi-Fi positioning based on deep learning," *Information and Automation (ICIA)*, pp. 1176-1179, 2014.
- [10] C. Zhang, S. Bengio, M. Hardt, B. Recht, and

O. Vinyals, "Understanding deep learning requires rethinking generalization," in *Proc. International Conference on Learning Representations(ICLR) 2017*, 2017.

- [11] E. S. Lohan, J. Torres-Sospedra, H. Leppäkoski, P. Richter, Z. Peng, and J. Huerta, "Wi-Fi crowdsourced fingerprinting dataset for indoor positioning", *Data* 2017, 2(4), 32., 2017

박 찬 욱 (Chan-Uk Park)



2014년 2월: 경기과학기술대학교 모바일정보융합과 전문학사
2016년 2월: 국가평생교육진흥원 학점은행제 컴퓨터공학학사
2016년 2월~현재: 광운대학교 로봇학과 석사과정
<관심분야> 통신 네트워크, 실내 측위, 머신러닝

최 용 훈 (Yong-hoon Choi)



1995년 2월: 연세대학교 전자공학과 공학사
1997년 2월: 연세대학교 전자공학과 공학석사
2001년 2월: 연세대학교 전기전자공학과 공학박사
2001년 4월~ 2002년 3월: (미)

매릴랜드 주립대 Postdoctoral Research Associate
2002년 6월~2005년 8월: LG전자 책임연구원
2005년 9월~현재: 광운대학교 로봇학부 교수
<관심분야> 통신 네트워크, 머신 러닝