

<https://doi.org/10.7236/IIBC.2018.18.1.129>

IIBC 2018-1-18

WiFi 핑거프린트 위치추정 방식의 적응형 KNN에서 평균 범위 설정에 관한 연구

A Study on Average Range Setting in Adaptive KNN of WiFi Fingerprint Location Estimation Method

오종택*

Jongtaek Oh*

요약 실내에서의 위치를 추정하기 위한 기술 연구가 활발하게 진행되고 있다. 특히 추가적인 기반 시설을 필요로 하지 않는 WiFi fingerprint 방식은 경제성이 높아서 부분적으로 실용화되고 있다. 사전에 여러 지점에서 측정된 무선 랜 수신 신호의 세기 정보와 추후에 특정 지점에서 측정된 세기 정보를 비교하여 유사한 지점을 해당 지점으로 추정하는 KNN 방식은 간단하지만 성능이 좋다. 그러나 기존의 KNN 방식은 평균하는 후보 위치들의 개수 K가 일정하므로, 특정 지점에 따라 위치 추정 오차가 최적화되지 못하는 문제가 있다. 본 논문에서는 특정 지점마다 K 값을 적응적으로 변화시키는 KNN 방식에서 평균 범위를 설정하는 알고리즘을 제안하고 실험 데이터에 적용하여 그 성능을 평가하였다.

Abstract Research on the technique for estimating the indoor position has been actively carried out. In particular, the WiFi fingerprint method, which does not require any additional infrastructure, is being partially used because of its high economic efficiency. The KNN method which estimates similar points to the corresponding points by comparing intensity information of the WLAN reception signal measured at various points in advance with intensity information measured at a specific point in the future is simple but has a good performance. However, in the conventional KNN scheme, since the number K of average candidate positions is constant, there is a problem that the position estimation error is not optimized according to a specific point. In this paper, we proposed an algorithm that adaptively changes the K value for each point and applied it to experimental data and evaluated its performance.

Key Words : WiFi fingerprint, KNN, indoor positioning, adaptive algorithm

1. 서론

실내 구조물의 크기가 커지고 내부 구조가 복잡해짐에 따라서 인간의 실내 체류 시간이 많이 늘어나고 실내에서의 위치를 확인하는 필요성이 커지고 있다. 따라서

실내 위치 인식 기술에 대한 연구가 다양하게 진행되고 있다. 크게 구분해 보면, 전파 신호나 초음파 신호를 송신 또는 수신하는 노드를 여러 개 설치하고 송신기와 수신기 사이의 신호 지연 시간차이를 측정하여 위치를 계산하는 Time of Arrival (TOA) 계열의 위치 추정 방식이

*정회원, 한성대학교 전자정보공학과
접수일자: 2018년 1월 4일, 수정완료: 2018년 2월 4일
게재확정일자: 2018년 2월 9일

Received: 4 January, 2017 / Revised: 4 February, 2018

Accepted: 9 February, 2018

*Corresponding Author: jt oh@hansung.ac.kr

Dept. of Electronics Information Eng., Hansung University, Korea

있다. 또한 지점마다 수신 신호의 세기가 다른 속성을 이용하여 위치를 추정하는 fingerprint 방식이 있다. 일종의 지문 인식과 유사하다. 최근에 무선랜 공유기가 저렴해지고 보편화됨에 따라 거의 모든 실내 지점에서 여러 개의 무선랜 공유기 신호가 수신되므로 추가적인 무선랜 공유기의 설치가 없어도 WiFi fingerprint 방식으로 실내 위치 추정이 가능해졌다^[17].

실내 위치 인식 기술에는 다양한 방식이 있지만, 최근에는 무선랜 공유기의 전파 신호 세기를 사전에 측정하여 데이터베이스를 구축하고, 임의의 위치에서 측정된 신호 세기와 비교하여 위치를 추정하는 WiFi fingerprint 방식이 활발하게 연구되고 있고, 실제로 시스템이 구축되고 있다^[57].

이 방식에서는 사전에 위치 측정 구역에서 일정 간격으로 무선랜 공유기의 수신 신호 세기를 측정하여 파일로 저장한다. 파일에는 측정 위치의 좌표와 각각의 무선랜 공유기들의 Media Access Control (MAC) 주소와 Service Set Identifier (SSID) 번호, Received Signal Strength (RSS)의 평균값 등이 저장된다. 그 후에, 위치를 확인하려는 지점에서 다시 무선랜 공유기들의 RSS의 평균값을 측정하고 이 값들을 파일에 저장된 데이터들과 비교하여 가장 유사한 데이터의 위치를 현재 위치로 추정하는 방식을 K Nearest Neighbour (KNN)라고 한다^[811].

KNN 방식에서는 두 가지 RSS 데이터의 유사도가 큰 순서로, K 개의 후보 좌표들의 평균을 구하여 위치를 추정한다. 그런데 추정 위치마다 위치 추정 오차가 가장 작은 최적의 K 값이 다른데, 그것을 알 수 없으므로 기존에는 적절한 K 값을 고정시켜 사용하였다. 따라서 추정 위치마다 최적화된 K 값을 사용하지 못하므로 전체적으로 위치 추정 정확도가 떨어지는 문제가 있다.

본 논문에서는 추정 위치에 따른 두 가지 RSS 데이터의 유사도 패턴과 최적의 K의 상관 관계를 분석하여 그 속성을 파악하고, 추정 위치에 따라 적응적으로 K 값을 변경함으로써 적절한 평균 범위를 설정하는 알고리즘을 제안하였다. 또한 실제 측정 데이터에 이 알고리즘을 적용하여 그 성능을 증명하였다.

II. KNN에서의 유사도 패턴

WiFi fingerprint 방식에 KNN 기술을 적용하기 위해

서는 우선 위치 확인 구역에서 일정 간격으로 무선랜 공유기들의 RSS 데이터를 측정 및 저장해야 한다. 식 (1)은 해당 RSS 데이터, T에 대한 정의식이다^[8].

$$T = \{T_i = (L_i, RSS_i) | i = 1, 2, \dots, M\}, \quad (1)$$

$$L_i = \{(x, y) | x, y \in R^2\},$$

$$RSS_i = \{AP_j^i | j = 1, 2, \dots, N\},$$

$$AP_j^i = \{AP_{js}^i | s = 1, 2, \dots, S\}$$

여기서 L_i 는 사전 측정 지점의 좌표이고, RSS_i 는 해당 지점에서의 무선랜 공유기의 수신 신호세기, M은 측정 지점의 총 수, x 및 y는 측정 지점의 상대 좌표 (단위: 미터), AP_j^i 는 측정 지점 i에서 신호가 수신되는 무선랜 공유기 j이고 총 개수는 N개이며, AP_{js}^i 는 위치 i에서 무선랜 공유기 j로부터 수신된 RSS를 s번째로 샘플링한 값이고 총 개수는 S개이다. 개발된 스마트폰 앱으로 측정시에 주변의 무선랜 공유기의 개수에 따라 샘플링 시간이 달라지는데, 2.4GHz와 5.8GHz의 무선랜을 지원하는 스마트폰은 한 번 수신 데이터를 수집하는 데에 보통 3초 정도가 소요된다. 무선 신호의 페이딩 영향이 매우 크므로, 실제로는 샘플링 한 값을 모두 사용하지 않고 그 평균값을 사용한다. 따라서 WiFi fingerprint 데이터로 저장되는 데이터의 양은, $M \times N \times S$ 개이다. 또한 위치 확인을 하려는 구역의 수가 증가하면, 데이터의 양은 그만큼 증가한다.

이후에 위치를 확인하려는 임의의 위치에서의 무선랜 공유기 수신 신호는 측정 위치에 따라 아래 식 (2)와 같이 정의한다.

$$L_u = \{(x_u, y_u) | x_u, y_u \in R^2\}, \quad (2)$$

$$RSS_u = \{AP_j^u | j = 1, 2, \dots, N\},$$

$$AP_j^u = \{AP_{js}^u | s = 1, 2, \dots, S\}$$

여기서 L_u 는 위치를 확인하려는 지점의 실제 좌표이고, x_u 및 y_u 는 실제 측정 지점의 상대 좌표 (단위: 미터), RSS_u 는 해당 지점에서의 무선랜 공유기 수신 신호세기, AP_j^u 는 측정 지점에서 신호가 수신되는 무선랜 공유기 j이고 총 개수는 N개이며, AP_{js}^u 는 측정 위치에서 무선랜 공유기 j로부터 수신된 RSS를 s번째로 샘플링한 값이고 총 개수는 S개이다.

결국은 AP_{js}^i 의 평균값들과 AP_{js}^u 의 평균값들을 비교하여 가장 유사한 AP_{js}^i 의 지점 i를, 위치를 확인하려는 지점의 좌표로 추정한다. 이 방식을 Nearest Neighbour

방식이라고 한다. 또한 유사도가 큰 지점의 좌표부터 내림차순으로 정렬한 후, 차례대로 K 개의 좌표를 평균하여 위치를 추정하는 방식을 KNN이라고 한다. 이 때, K 개의 좌표를 균등하게 평균하지 않고 유사도에 따라 가중치를 다르게 주면 위치 추정 정확도가 높아진다.

유사도를 측정하는 방식은 일반적으로 다음 식(3)과 같이 Euclidean 거리로 차이값을 계산한다^[11].

$$Dist_{iu} = \frac{1}{N} \sqrt{\sum_{j=1}^N (AP_j^i - AP_j^u)^2} \quad (3)$$

또한 식 (4)는 가중치를 고려하여 위치를 확인하려는 지점의 좌표 \hat{L}_u 를 추정하는 식이다.

$$\hat{L}_u = \frac{\sum_{i=0}^K \frac{1}{Dist_i + \epsilon} L_i}{\sum_{i=0}^K \frac{1}{Dist_i + \epsilon}} \quad (4)$$

여기서 K는 유사도가 큰 좌표부터 평균하는 좌표들의 개수이고, $Dist_i$ 는 해당 지점 L_i 에서의 RSS들과 위치를 확인하려는 지점에서의 RSS들과의 Euclidean 거리이며 유사도와는 반비례의 관계이며, ϵ 은 분모가 0이 되는 것을 막기 위한 매우 작은 수이다.

후보 좌표들을 평균하는 개수인 K와 유사도와의 관계를 분석하기 위해 전형적인 패턴을 보이는 몇 군데 지점에 대한 Euclidean 거리를 그려본다. 그림 1의 (a)는 벽막힘이 없는 넓은 홀 (Place A)에서 1 미터 간격으로 RSS를 측정할 경우이다. 위치를 확인하려는 미지의 위치 (6, 3)에서 측정된 무선랜 공유기들의 RSS들과 식 (3)으로 Euclidean 거리를 구하고, 그 역수를 정규화 하여 그린 것이다. 밝은 부분이 두 RSS 사이의 유사도가 큰 지점이다. (b)는 동일한 구역의 (15, 4) 지점에서 측정된 RSS와의 유사도를 그린 것이다. 그림 2는 칸막이가 있는 방 구조물 (Place B)의 경우이고 2m 간격으로 WiFi fingerprint 데이터가 측정되었다.

여기서 특정 실내 기준점을 기준으로 상대 위치 좌표를 (x, y)로 표시한다. 그림 1 (a)에서는 실제 위치 (6, 3)이 아니라 (4, 3)의 위치가 가장 밝으므로 Euclidean 거리가 가장 작은 지점과 실제 위치와는 차이가 큰 것을 알 수 있고, 상대적으로 밝은 지점이 여러 개가 있는 것이 확인되었다. 이에 비해 (b)에서는 실제 위치 (15, 4)와 유사도가 가장 큰 지점이 정확하게 일치되고, 상대적으로 밝은 지역이 거의 없다. 그림 2의 경우도 (a)에서는 밝은

부분이 한 곳이고 이 지점이 실제 위치이지만, (b)에서는 상대적으로 밝은 부분이 여러 개가 발견된다.




그림 1. A 장소에서의 전형적인 유사도 패턴.

(a) 위치 (6, 3), (b) 위치 (15, 4)

Fig. 1. Typical similarity pattern for place A.

(a) position (6, 3), (b) position (15, 4)

한 편, 표 1은 그림 1과 2에 대한 각 지점에서의 유사도를 내림차순으로 정렬한 것이고 해당 추정 좌표(est.)가 함께 표시되어 있다. (6, 3)과 (4, 8)은 각각 그림 1 (a)와 그림 2 (b)에 해당하는 것으로, 차이값(diff)이 작은, 즉 유사도가 높은 지점들이 여러 개 있는 경우이고, 이에 반해 (15, 4)와 (30, 10)은 유사도가 높은 지점이 하나이다.




그림 2. B 장소에서의 전형적인 유사도 패턴.
 (a) 위치 (32, 4), (b) 위치 (40, 8)
 Fig. 2. Typical similarity pattern for place B.
 (a) position (32, 4), (b) position (40, 8)

표 1. 두 장소에서 각각 두 개의 지점에 대한 WiFi fingerprint 데이터와의 유사도

Table 1. Similarity to WiFi fingerprint data for two locations in two locations, respectively

| No | Place A | | | | Place B | | | |
|----|---------|-------|-------|-------|---------|-------|--------|-------|
| | 6, 3 | | 15, 4 | | 32, 4 | | 40, 8 | |
| | est. | diff | est. | diff | est. | 차이 | est. | diff |
| 1 | 3, 3 | 1.0 | 15, 4 | 1.0 | 32, 4 | 1.0 | 42, 8 | 1.0 |
| 2 | 8, 1 | 1.088 | 17, 3 | 1.214 | 30, 2 | 1.720 | 38, 8 | 1.048 |
| 3 | 4, 1 | 1.092 | 17, 2 | 1.393 | 34, 4 | 1.966 | 44, 8 | 1.130 |
| 4 | 4, 3 | 1.096 | 11, 6 | 1.446 | 28, 2 | 2.045 | 40, 8 | 1.152 |
| 5 | 8, 4 | 1.139 | 12, 2 | 1.446 | 32, 2 | 2.129 | 42, 10 | 1.247 |
| 6 | 10, 5 | 1.164 | 10, 1 | 1.513 | 34, 2 | 2.243 | 36, 8 | 1.262 |
| 7 | 10, 4 | 1.178 | 12, 6 | 1.521 | 30, 4 | 2.246 | 42, 12 | 1.286 |
| 8 | 8, 5 | 1.182 | 17, 1 | 1.540 | 28, 4 | 2.526 | 44, 10 | 1.314 |
| 9 | 7, 3 | 1.229 | 15, 6 | 1.548 | 36, 2 | 2.602 | 34, 8 | 1.315 |
| 10 | 10, 6 | 1.246 | 17, 4 | 1.567 | 36, 4 | 2.938 | 40, 10 | 1.456 |

표 2는 식 (4)에 의한 K 값에 따른 KNN 방식의 추정 좌표(est.)와 위치 추정 오차(err)이다. (15, 4)와 (30, 10)에서는 K=1일 때 최적으로 위치가 추정된다. 이것에 반해서, (6, 3)과 (40, 8)의 위치에서는 각각 K=7 및 9 일 때 위치 추정 위치가 가장 작다. 즉, 위치를 확인하려는 지점마다 최적의 K 값이 다르다. 따라서 기존의 고정된 K 값의 KNN 방식은 측정 위치 전체적으로 위치 추정 오차가 크다. 따라서 본 논문에서는 다음 장에서 새로운 알고리즘을 제안했다.

표 2. 두 장소에서 각각 두 개의 지점에 대한 K 값에 따른 위치 추정 오차

Table 2. Position estimation error for two locations in two locations, respectively

| K | Place A | | | | Place B | | | |
|----|---------|-----|----------|-----|----------|-----|----------|-----|
| | 6, 3 | | 15, 4 | | 32, 4 | | 40, 8 | |
| | est. | err | est. | err | est. | err | est. | err |
| 1 | 3.0,3.0 | 3.0 | 15.0,4.0 | 0.0 | 32.0,4.0 | 0 | 42.0,8.0 | 2.0 |
| 3 | 4.9,1.7 | 1.7 | 16.2,3.1 | 1.5 | 31.9,3.4 | 0.6 | 41.3,8.0 | 1.3 |
| 5 | 5.3,2.4 | 0.9 | 14.6,3.4 | 0.7 | 31.3,3.0 | 1.2 | 41.2,8.4 | 1.2 |
| 7 | 6.6,3.0 | 0.6 | 13.7,3.4 | 1.4 | 31.5,3.0 | 1.1 | 40.6,8.8 | 1.0 |
| 9 | 6.8,3.2 | 0.8 | 14.1,3.5 | 1.0 | 30.1,1.1 | 1.1 | 40.3,8.8 | 0.9 |
| 11 | 7.2,3.4 | 1.2 | 14.1,3.4 | 1.0 | 32.2,3.0 | 1.0 | 40.2,9.2 | 1.2 |
| 13 | 7.4,3.4 | 1.5 | 14.0,3.4 | 1.1 | 32.4,3.1 | 1.0 | 40.3,9.5 | 1.5 |
| 15 | 7.5,3.3 | 1.6 | 13.4,3.3 | 1.7 | 32.4,3.3 | 0.8 | 40.0,9.6 | 1.6 |
| 17 | 7.8,3.3 | 1.8 | 13.2,3.2 | 1.9 | 32.3,3.4 | 0.7 | 39.6,9.8 | 1.8 |

III. 적응형 KNN 알고리즘

그림 1 및 2와 표 1 및 2를 종합적으로 분석하면, 위치를 확인하려는 지점에서 측정된 RSS 값들과 사전에 측정된 WiFi fingerprint 데이터의 유사도를 비교한 결과값들을 크게 두 가지의 경우로 구분할 수 있다. 즉, 유사도가 상대적으로 큰 지점이 유일한 경우와, 유사도가 상대적으로 큰 지점들이 여러 개인 경우로 나눌 수 있다. 따라서 전자의 경우에는 K 값이 작은 경우에 위치 추정 오차가 작아지고, 후자의 경우에는 K 값이 상대적으로 커서 유사도가 상대적으로 큰 지점들을 모두 포함하여 평균을 구해야 위치 추정 오차가 작게 된다. 본 논문에서 제안한 적응형 KNN 알고리즘은 위치 추정 지점마다 유사도의 패턴에 따라서 K 값이 달라지도록 설정하는 것이다.

표 1을 예로 들면, 유사도가 가장 큰 지점의 차이 값(diff)을 기준으로 일정 비율 이내의 좌표들만 식 (4)를 이용하여 위치를 추정할 때 포함시키는 것이다. 이렇게 하면, 유사도가 상대적으로 큰 지점이 유일한 경우에 작은 K 값을 선택하게 된다. 반대의 경우에는 여러 개의 좌표들이 평균화에 포함된다. 이 일정 비율의 값이 하나의 설계 파라미터가 된다. 다음 장에서는 이에 대한 성능을 분석해 보고, 최적의 비율을 구한다.

IV. AKNN의 성능 분석

표 3은 두 장소 (Place A 및 B)에서 각각 두 개의 지점에 대한, 기존의 고정된 K 값의 KNN 방식 및 위치 추정 오차가 가장 작을 때의 K 값의 경우, 제안된 적응형 KNN 방식에 대한 위치 추정 오차 성능을 비교한 결과이다. 본 논문에서 제안된 적응형 KNN 방식의 위치 추정 오차는 최적의 K 값에 대한 KNN 방식보다는 약간 성능이 떨어지지만, 기존의 고정된 K 값의 KNN 방식보다는 평균적으로 약 70% 정도의 매우 큰 성능 향상이 확인되었다. 이 때, 일정 비율은 1.17을 사용하였다.

이 때 유사도가 가장 큰 지점의 차이 값(diff)을 기준으로, 평균화에 포함시키는 좌표들의 일정 비율의 값에 따라서 위치 추정 오차의 성능이 크게 달라진다. K=1인 좌표의 차이값을 기준으로 몇 % 더 큰 차이값의 좌표까지 포함시키느냐에 따라서 위치 추정 오차가 달라지기 때문이다.

표 3. 두 장소에서 각각 두 개의 지점에 대한 기존 방식 및 최적 방식, 제안된 방식의 성능 비교 (일정 비율=1.17)

Table 3. Comparison of existing and optimal methods and proposed methods for two points in two locations, respectively (amplitude ratio=1.17)

| algorithm | Place A | | | | Place B | | | |
|-----------|------------------|-----|-------------------|-----|-------------------|-----|-------------------|-----|
| | 6, 3 | | 15, 4 | | 32, 4 | | 40, 8 | |
| | est. | err | est. | err | est. | err | est. | err |
| fixed K=5 | 5.3,2.4 | 0.9 | 14.6,3.4 | 0.7 | 31.3,3.0 | 1.2 | 41.2,8.4 | 1.2 |
| optimum K | 6.1,2.8 (K=6) | 0.3 | 15.0,4.0 (K=1) | 0.0 | 32.0,4.0 (K=1) | 0 | 40.3,8.8 (K=9) | 0.9 |
| AKNN | 6.1,2.8 (K=6) | 0.3 | 15.0,4.0 (K=1) | 0.0 | 32.0,4.0 (K=1) | 0 | 41.0,8.0 (K=4) | 1.0 |

그림 3은 유사도가 가장 큰 지점의 차이 값을 기준으로 평균에 포함되는 좌표들의 차이값 비율에 대한, 평균 위치 추정 오차를 표시한 것이다. 장소 A에서는 총 9개의 위치 추정 지점에 대한 위치 추정 오차가 평균되었고, 장소 B에서는 총 18개의 지점의 오차가 평균되었다.

장소 A에서는 K=1에서의 좌표에 대한 차이값 비율이 1.17일 때에 가장 위치 추정 오차가 작고, 장소 B에서는 5% 큰 차이값(diff)의 좌표까지 평균에 포함시키는 것이 가장 오차가 작다. 즉, 일정 비율 값도 장소에 따라서 달라져야 하는 것을 확인할 수 있다.

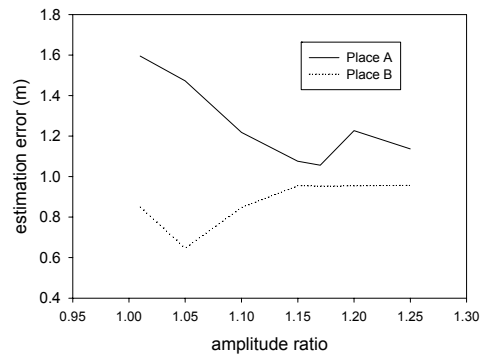


그림 3. B 장소에서의 전형적인 유사도 패턴 (실선은 장소 A, 점선은 장소 B)

Fig. 3. Typical similarity pattern for place B (solid line: place A, dotted line: place B)

V. 결론

본 논문에서는 WiFi fingerprint 방식의 위치 인식 기술에서 적응형 KNN 알고리즘을 적용하여 기존의 방식보다 위치 추정 오차를 대폭 축소시킬 수 있었고, 위치 추정 지점마다 자동으로 평균에 포함시키는 적절한 좌표 수를 선정함으로써, 전체적으로 위치 추정 오차를 줄일 수 있었다. 또한 평균화에 포함시키는 일정 비율 파라미터가 중요한 역할을 하는 것을 확인하였다. 비교적 간단한 알고리즘을 사용하여 1 미터 정도의 위치 정밀도로 위치를 추정할 수 있으므로 실제로 활용이 가능한 기술이다.

향후 연구 내용으로는, 장소에 따른 최적 일정 비율을 찾는 알고리즘 개발이 필요하며, 궁극적으로는 위치 추정 오차를 최적 K의 경우만큼으로 줄이는 기술 연구가 필요하다.

References

- [1] Fabian Höffinger, Rui Zhang, Joachim Hoppe, Amir Bannoura, Leonhard, M. Reindl Johannes Wendeberg, Manuel Bühler, and Christian Schindelbauer, "Acoustic Self-calibrating System for Indoor Smartphone Tracking (ASSIST)," International Conference on Indoor Positioning and Indoor Navigation, Nov. 2012.
- [2] Ville Honkavirta, Tommi Perälä, Simo Ali-Löytty, and Robert Piché, "A Comparative Survey of WLAN Location Fingerprinting Methods," 6th Workshop on Positioning, Navigation and Communication, pp. 243-251, Hannover, Germany, March 2009. doi:10.1109/WPNC.2009.4907834
- [3] Marius H. Hennecke and Gernot A. Fink, "Towards Acoustic Self-Localization of Ad Hoc Smartphone Arrays," Third Joint Workshop on Hands-free Speech Communication and Microphone Arrays, May 2011.
- [4] David Madigan, Eiman Elnahrawy, Richard P. Martin, Wen-Hua Ju, P. Krishnan, and A. Krishnakumar, "Bayesian Indoor Positioning Systems," Conference on IEEE Computer and Communications Societies, March 2005.
- [5] Azadeh Kushki, Konstantinos Plataniotis, and Anastasios Venetsanopoulos, "Kernel-Based Positioning in Wireless Local Area Networks," IEEE Tr. Mobile Computing, Vol. 6, No. 6, pp. 689-705, June 2007.
- [6] Nattapong Swangmuang and Prashant Krishnamurthy, "An Effective Location Fingerprinting Model for Wireless Indoor Localization," Pervasive and Mobile Computing, Vol. 4, pp. 836-850, 2008.
- [7] Khuong Nguyen, "A Performance Guaranteed Indoor Positioning System using Conformal Prediction and the WiFi Signal Strength," Journal of Information and Telecommunication, Vol. 1, No. 1, pp. 41-65, 2017. doi:10.1080/24751839.2017.1295659
- [8] Jongtaek Oh, "A Study on the Weight of W-KNN for WiFi Fingerprint Positioning," The Journal of The Institute of Internet, Broadcasting and Communication, Vol. 17, No. 6, pp. , Dec. 2017.
- [9] Schäfer, J.: 'Practical concerns of implementing machine learning algorithms for W-LAN location fingerprinting', IEEE Int. Congr. Ultra Mod. Telecommun., St. Petersburg, Russia, October 2014, pp. 310 -317, doi: 10.1109/ICUMT.2014.7002120
- [10] Kamol Kaemarungsi, "Design of Indoor Positioning Systems based on Location Fingerprinting Technique," PhD diss., University of Pittsburgh, 2005.
- [11] S. Zekavat and R. Buehrer, Handbook of position location: Theory, practice, and Advances, IEEE Press, 2012.

저자 소개

오 종 택(정회원)



- 2000.3. ~ 현재 한성대학교 전자정보공학과 교수
- 1993.12. ~ 2002. 한국통신 무선통신연구소 선임연구원
- 1989.3. ~ 1993.2. 한국과학기술원 전기및전자공학과 박사 졸업
- 관심 분야: 지능형 무선통신 네트워크, 기계학습을 적용한 실내위치인식

※ 본 연구는 한성대학교 교내학술연구비 지원과제 임