

# 심층 인공신경망을 활용한 Smoothed RSSI 기반 거리 추정

권혁돈<sup>1</sup>, 이솔비<sup>2</sup>, 권정혁<sup>3</sup>, 김의직<sup>4\*</sup>

<sup>1</sup>한림대학교 소프트웨어학부 학사과정, <sup>2</sup>한림대학교 융합소프트웨어학과 석박사통합과정,

<sup>3</sup>한림대학교 스마트컴퓨팅연구소 연구교수, <sup>4</sup>한림대학교 소프트웨어학부 부교수

## Smoothed RSSI-Based Distance Estimation Using Deep Neural Network

Hyeok-Don Kwon<sup>1</sup>, Sol-Bee Lee<sup>2</sup>, Jung-Hyok Kwon<sup>3</sup>, Eui-Jik Kim<sup>4\*</sup>

<sup>1</sup>B.S. Course, Division of Software, Hallym University

<sup>2</sup>Integrated M.S. and Ph.D Course, Department of Convergence Software, Hallym University

<sup>3</sup>Research Professor, Smart Computing Laboratory, Hallym University

<sup>4</sup>Associate Professor, Division of Software, Hallym University

**요약** 본 논문에서는 단일 수신기가 사용되는 환경에서 정확한 거리 추정을 위해 심층 인공신경망 (Deep Neural Network, DNN)을 활용한 Smoothed Received Signal Strength Indicator (RSSI) 기반 거리 추정 기법을 제안한다. 제안 기법은 거리 추정 정확도 향상을 위해 Data Splitting, 결측치 대체, Smoothing 단계로 구성된 전처리 과정을 수행하여 Smoothed RSSI 값을 도출한다. 도출된 다수의 Smoothed RSSI 값은 Multi-Input Single-Output (MISO) DNN 모델의 Input Data로 사용되며 Input Layer와 Hidden Layer를 통과하여 최종적으로 Output Layer에서 추정 거리로 반환된다. 제안 기법의 우수성을 입증하기 위해 제안 기법과 선형회귀 기반 거리 추정 기법의 성능을 비교하였다. 실험 결과, 제안 기법이 선형회귀 기반 거리 추정 기법 대비 29.09% 더 높은 거리 추정 정확도를 보였다.

**주제어** : 거리 추정, BLE 비콘, DNN, Feedback Filter, Smoothed RSSI

**Abstract** In this paper, we propose a smoothed received signal strength indicator (RSSI)-based distance estimation using deep neural network (DNN) for accurate distance estimation in an environment where a single receiver is used. The proposed scheme performs a data preprocessing consisting of data splitting, missing value imputation, and smoothing steps to improve distance estimation accuracy, thereby deriving the smoothed RSSI values. The derived smoothed RSSI values are used as input data of the Multi-Input Single-Output (MISO) DNN model, and are finally returned as an estimated distance in the output layer through input layer and hidden layer. To verify the superiority of the proposed scheme, we compared the performance of the proposed scheme with that of the linear regression-based distance estimation scheme. As a result, the proposed scheme showed 29.09% higher distance estimation accuracy than the linear regression-based distance estimation scheme.

**Key Words** : Distance Estimation, BLE Beacon, DNN, Feedback Filter, Smoothed RSSI

본 연구는 2022년도 중소벤처기업부의 기술개발사업 지원에 의한 연구임 [S3278476]. 이 논문은 2020년도 정부 (교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (No. 2020R111A3052733).

이 성과는 정부 (과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2021R1C1C2095696).

\*교신저자 : 김의직(ejkim32@hallym.ac.kr)

접수일 2023년 02월 16일

수정일 2023년 3월 12일

심사완료일 2023년 3월 17일

## 1. 서론

무선 통신 기술과 하드웨어 및 센서 기술의 발전으로 수집된 사용자 위치 정보에 기반하여 내비게이션, 물류 추적과 같은 위치 기반 서비스가 지속적으로 증가하고 있다 [1]. 일반적으로 Global Positioning System (GPS)은 실외 위치 측위를 위해 보편적으로 사용된다 [2]. 이는 GPS가 3개 이상의 GPS 위성으로부터 수신된 신호를 이용하여 수 m 내외의 높은 정확도의 위치 정보를 제공하기 때문이다. 그러나 실내에서는 건물 외벽 및 다양한 장애물에 의한 전파 간섭으로 인해 GPS의 신호 수신이 어렵다. 이러한 이유로 실내에서는 Wi-Fi, Bluetooth Low Energy (BLE), Ultra-wideband (UWB), Radio Frequency Identification (RFID) 등을 활용한 위치 측위 방법이 주로 사용된다 [3,4,5]. 그 중에서도 특히 BLE 기반의 위치 측위 방법은 낮은 전력 소모와 높은 접근성으로 각광받고 있다 [6].

BLE 기반 위치 측위 서비스에는 매우 적은 전력 소모만으로도 메시지 전송이 가능하고, 작은 크기 및 높은 사용자 접근성을 특징으로 하는 BLE 비콘이 많이 사용된다. 또한, BLE 비콘은 무선 통신을 위해 다른 디바이스와 연결하는 시간이 짧고, 그 연결 과정이 상대적으로 간편하다. BLE 비콘의 동작을 살펴보면 BLE 비콘은 주기적으로 고유한 정보를 포함한 메시지를 불특정 다수에게 송신한다. 이를 수신한 디바이스는 해당 메시지에 포함된 정보를 통해 BLE 비콘을 식별할 수 있으며, 메시지 수신 시 얻을 수 있는 수신 신호 강도 (Received Signal Strength Indicator, RSSI)가 해당 BLE 비콘과의 거리 추정에 활용될 수 있다. 그러나 RSSI는 장애물 및 신호 간섭 등에 의해 다중 경로 페이딩 및 신호 세기 감쇄로 그 값의 편차가 크다. 이러한 큰 폭의 RSSI 값의 변동은 큰 거리 추정 오차를 야기한다는 단점이 있다. 이를 해결하고자, 삼변측량 (Trilateration), 핑거프린팅 (Fingerprinting), 선형회귀 (Linear Regression) 등을 이용한 다양한 연구들이 수행되었다 [7,8,9].

삼변측량 기법과 핑거프린팅 기법은 3개 이상의 수신기와 BLE 비콘을 이용하여 거리를 추정한다. 삼변측량 기법은 3개의 수신기에서 RSSI를 수집한 후 BLE 비콘으로부터의 거리를 추정하는 기법이다 [7]. 각 수신기를 중심으로 원을 그려 3개의 원의 접점을 찾고 BLE 비콘의 위치를 판단한다. 핑거프린팅 기법은 서비스 영역을 미리 임의의 여러 개의 셀로 나누고 특정 셀에 존재하는 수신기를 통해 BLE 비콘의 RSSI를 수집하고 이를 데이터


베이스화한다 [8]. 이후, 수집된 RSSI 값을 기반으로 사용자의 위치를 판단한다. 선형회귀 기반 거리 추정 기법은 독립변수인 RSSI 값과 종속변수인 거리 간의 관계를 모델링하여 거리를 추정한다 [9]. 삼변측량과 핑거프린팅을 이용한 거리 추정 기법은 RSSI 값을 이용한 거리 추정을 위해 다수의 수신기가 필요하다. 따라서, 비용 증가 및 유지 보수 측면에서 단점이 있다. 선형회귀 기반 거리 추정 기법은 RSSI 값과 거리 간의 선형적인 관계만을 나타내므로, 단일 수신기가 사용되는 환경에서 RSSI 값을 이용한 거리 추정 기법은 한계가 있다. 이를 해결하기 위해 최근 심층 인공신경망 (Deep Neural Network, DNN) 모델과 결합한 RSSI 기반 거리 추정 기법이 연구되고 있다 [10]. 하지만 단일 RSSI 값을 이용하여 거리를 추정하는 방법 역시 RSSI 값의 변동이 큰 경우 거리 추정 오차가 크다는 단점이 있다.

본 논문에서는 DNN 모델을 활용한 Smoothed RSSI 기반 거리 추정 기법을 제안한다. 제안하는 기법은 단일 수신기를 사용하는 환경에서 RSSI 기반 거리 추정의 정확도를 향상시키는 것을 목표로 한다. 이를 위해, 제안 기법에서는 변동성이 심한 RSSI 값의 이상치 및 결측치가 데이터 분석에 미치는 영향을 최소화하기 위한 전처리 과정이 수행된다. 전처리 과정에서는 수집된 데이터셋이 일정한 시간 구간으로 분할된다. 이후, 분할된 각 데이터셋 내 RSSI 값의 이상치 및 결측치를 Feedback Filter 및 Zero Padding을 통해 제거 및 대체하여 Smoothed RSSI 값이 도출된다. 제안 기법은 거리 추정의 오차를 최소화하기 위해, 전처리 과정을 통해 도출된 다수의 Smoothed RSSI 값을 동시에 입력받아 거리를 추정하는 Multi-Input Single-Output (MISO) DNN 모델을 포함한다. MISO DNN 모델에 입력된 다수의 Smoothed RSSI 값은 Input Layer의 입력값으로 사용된다. 이후, 다수의 Hidden Layer를 거쳐 최종적으로 Output Layer에서 추정 거리로 반환된다. MISO DNN 모델의 구현을 위해 Tensorflow와 Keras를 사용하였다 [11]. 이후, 제안 기법의 성능을 검증하기 위해 선형회귀 기반 거리 추정 기법을 대조군으로 설정해 거리 추정 정확도를 비교하였다. 그 결과 제안 기법은 선형회귀 기반 거리 추정 기법 대비 평균적으로 29.09% 더 높은 정확도를 달성하였다.

본 논문의 구성은 다음과 같다. 2장에서는 제안하는 시스템 모델을 설명한다. 3장에서는 제안하는 MISO DNN 모델을 활용한 Smoothed RSSI 기반 거리 추정 기법에 대해 서술한다. 4장에서는 실험 환경 및 결과를 서술한다. 마지막으로 5장에서 결론을 맺는다.

## 2. 시스템 모델

[Fig. 1]은 본 논문에서 고려하는 시스템 모델을 보여준다. 그림에서, 시스템은 BLE 비콘, 비콘 리시버, 서버 (Server)로 구성된다. BLE 비콘은 Universally Unique Identifier (UUID), Major, Minor 및 수신강도를 포함한 메시지를 주기적으로 브로드캐스트한다. UUID는 해당 BLE 비콘이 사용되는 어플리케이션을 구분하기 위해 사용된다. Major는 동일한 UUID를 갖는 BLE 비콘의 하위 그룹 정보를 식별하기 위한 값이고, Minor는 동일한 Major 그룹 내 각 BLE 비콘을 식별하기 위한 값이다. 수신강도는 BLE 비콘의 송신 전력 세기를 나타낸다. 비콘 리시버는 다수의 BLE 비콘들이 전송하는 메시지를 수신하고 수신된 메시지 각각의 RSSI 값을 측정한다. 이후, 비콘 리시버는 수신한 BLE 비콘 메시지로부터 Minor를 추출한다. 이후, Minor, 측정된 RSSI 값, BLE 비콘 메시지 수신 시간을 서버로 전송한다. 서버는 Database, 전처리 과정 (Data Preprocessing), MISO DNN 모델을 포함한다. Database에는 비콘 리시버로부터 전달받은 값들이 저장된다. 전처리 과정에서 Data Splitting, 결측치 대치 (Missing Value Imputation), Smoothing 단계가 순차적으로 수행된다. MISO DNN 모델은 전처리 과정을 통해 도출되는 다수의 Smoothed RSSI 값을 Input Data로 입력받아 Output Layer에서 추정 거리를 반환한다.



[Fig. 1] System model

## 3. 제안 기법

본 장에서는 단일 수신기를 사용하는 환경에서 다수의 BLE 비콘으로부터 수집된 RSSI 값을 사용하여 실내에서 거리를 추정하기 위해, MISO DNN 모델을 활용한 Smoothed RSSI 기반 거리 추정 기법에 대해 자세히 설명한다. [Fig. 2]는 MISO DNN 모델을 활용한 Smoothed RSSI 기반 거리 추정 기법의 파이프라인을 보여준다. Raw Data는 Database에 저장된 Minor, RSSI,

BLE 비콘 메시지 수신 시간을 포함한다. Data Splitting 단계에서 Raw Data는 가장 먼저 일정한 시간 간격  $t$ 를 기준으로 분할된다. 분할된 각 Raw Data는 Minor 값에 의해 BLE 비콘 별로  $m$ 개의 데이터셋들로 나누어진다.  $m$ 은 BLE 비콘의 수와 동일하다. 이후, 각 데이터셋에서 RSSI 값만을 추출하여 하나의 벡터로 변환한다. 각 벡터는 다수의 RSSI 값을 포함하며, 식 (1)과 같이 표현된다.

$$\vec{v}_i = [RSSI_1, RSSI_2, \dots, RSSI_{k-1}, RSSI_k] \quad (0 < i \leq m) \quad (1)$$

식 (1)에서  $i$ 는 데이터셋의 인덱스를 나타낸다.  $k$ 는 각 벡터에 포함된 총 RSSI 값의 개수로, 벡터의 크기를 나타내며 시간 간격  $t$  동안 수신된 BLE 비콘 메시지 수에 의해 결정된다. Missing Value Imputation 단계에서는 각각의 벡터가  $1 \times n$  형태로 변환된다.  $k$ 가  $n$ 보다 큰 경우,  $n$ 번째 이후의 RSSI 값들은 벡터에서 제거된다.  $k$ 가  $n$ 보다 작은 경우, Zero Padding을 사용해  $n-k$ 개의 결측치를 0으로 채운다.  $k$ 와  $n$ 이 같은 경우 Missing Value Imputation 단계는 생략된다. Smoothing 단계에서는 Missing Value Imputation 이후 도출된 벡터에 포함된 RSSI 값의 이상치 보정을 위해 Feedback Filter가 사용된다. Feedback Filter를 통과한 RSSI 값은 식 (2)와 같이 계산된다.

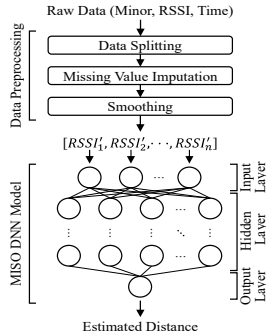
$$RSSI'_j = \alpha \times RSSI_j + (1 - \alpha) \times RSSI'_{j-1} \quad (1 < j \leq n) \quad (2)$$

식 (2)에서  $RSSI'_j$ 는 값은 Feedback Filter에 의해 이상치 보정이 완료된 RSSI 값이다.  $\alpha$ 는 0과 1 사이 ( $0 < \alpha \leq 1$ ) 구간의 실수값을 나타내며, Feedback Filter의 계수를 의미한다.  $\alpha$ 가 클수록 Feedback Filter에 입력되는  $RSSI_j$  값에 더 큰 가중치가 부여된다.  $RSSI_j$ 는 Feedback Filter를 통과하기 이전의 벡터 내  $j$ 번째 RSSI 값이다.  $RSSI'_{j-1}$ 는 Feedback Filter를 통과한 벡터 내의  $(j-1)$ 번째 Smoothed RSSI 값을 나타낸다. 값이 0인  $RSSI_j$ 는 Feedback Filter를 통과하지 않는다. 결과적으로, Feedback Filter는  $(j-1)$ 번째 Smoothed RSSI 값인  $RSSI'_{j-1}$ 과  $RSSI_j$  값을 이용하여 이상치 보정을 수행한다. 최종적으로 전처리 과정을 통해 도출된 다수의 Smoothed RSSI 값을 포함하는 벡터가 MISO DNN 모델의 Input Data로 사용된다.

MISO DNN 모델은 Input Layer, Hidden Layer, Output Layer로 구성된다. 각 Layer는 특정 개수의 노드들로 구성되며, 각 노드들은 Layer 간 연결을 위한 활성화 함수를 갖는다. 주로 Sigmoid, Hyperbolic Tangent, ReLU가 노드의 활성화 함수로 사용된다[12].

각 노드는 활성화 함수에 따라 도출된 값을 다음 노드로 전달한다. 각 Layer 간 노드들은 서로 연결되어 있으며, 노드들을 연결하는 선은 가중치를 갖는다. 초기에 임의로 설정된 가중치는 역전파 학습 (Back-propagation) 알고리즘을 통해 학습을 거치며 Output Layer의 손실을 줄이는 방향으로 갱신된다 [13]. 이에 따라, MISO DNN 모델의 Input Data는 각 Layer의 노드들을 거치며 수행되는 가중치 연산을 통해 최종적으로 Output Layer에서 하나의 결과값으로 반환된다.

제안하는 Smoothed RSSI 기반 거리 추정 기법에 사용된 MISO DNN 모델의 Input Layer는  $n$ 개의 노드로 구성되며, 각 노드는 Input Data로 들어온 벡터에 포함된 Smoothed RSSI 값과 일대일로 매핑된다. 또한, 역전파 학습 과정에서 Input Layer에 가까워질수록 기울기가 점진적으로 0에 수렴되는 기울기 소실 문제를 해결하기 위해, MISO DNN 모델 내 노드의 활성화 함수로 ReLU를 사용하였다 [14]. 결과적으로 MISO DNN 모델에 입력된 다수의 Smoothed RSSI 값은 각 Layer를 거치며 최종적으로 Output Layer에서 추정 거리를 나타내는 하나의 값으로 출력된다.



[Fig. 2] Proposed scheme

## 4. 실험 및 결과

본 장에서는 MISO DNN을 활용한 Smoothed RSSI 기반 거리 추정 기법의 구현과 성능 평가를 위한 실험 환경 및 실험 결과에 대해 서술한다.

### 4.1 실험 환경

본 실험에서는 비콘 리시버로부터 0.5~8m에 해당하는 거리에 총 13개의 BLE 비콘을 배치하여 120시간 동안 BLE 비콘 메시지를 수집하였다. BeaFon사의 i4와

Raspberry Pi 4 Model B가 각각 BLE 비콘과 비콘 리시버로 사용되었다 [15,16]. Database에 저장된 데이터셋의 전처리를 위해 결정되어야 하는 시간 간격  $t$  및 벡터의 크기  $n$  각각은 5초 및 5로 설정하였다. Feedback Filter 계수  $\alpha$ 는 0.7로 설정하였다. 자세한 실험 환경 변수는 <Table 1>과 같다.

제안 기법에 활용되는 MISO DNN 모델의 구현을 위해 Tensorflow와 Keras가 사용되었다. MISO DNN 모델의 하이퍼 파라미터는 <Table 2>와 같다.

<Table 1> Experiment environment variable

Parameter	Value
Number of BLE Beacons	13
Distance between BLE Beacon and Beacon Receiver	0.5, 1.0, 1.5, 2.0, 2.5, 3.0, 3.5, 4.0, 4.5, 5.0, 6.0, 7.0, 8.0m
Beacon Interval	500ms
Data Collection Time	120hours
Unit Time	5s

<Table 2> Hyperparameters for MISO DNN model

Optimizer	Learning rate	Batch Size	Epoch
Adam	0.0001	50	500

제안 기법의 성능 평가를 위해 기존 거리 추정 기법 중 하나인 선형회귀 기반 거리 추정 기법을 대조군으로 설정하였다. 제안 기법은 전처리 과정을 거친 RSSI값을 포함한 벡터를 이용하여 거리 추정 값을 도출한다. 선형회귀 기법은 전처리 과정을 거친 하나의 RSSI 값을 이용하여 거리 추정 값을 도출한다. 이를 비교하기 위해 평가 지표로는 Root Mean Square Error (RMSE)가 사용되었다. RMSE는 실제 거리와 추정 거리 간의 오차를 의미하며, RMSE 값이 0에 수렴할수록 높은 거리 추정 정확도를 나타낸다. RMSE는 식 (3)에 의해 계산된다.

$$RMSE = \sqrt{\frac{(\hat{y} - y)^2}{s}} \quad (3)$$


식 (3)에서  $\hat{y}$  및  $y$  각각은 추정 거리 및 실제 거리를 나타낸다.  $s$ 는 전체 데이터의 수를 나타낸다.

### 4.2 실험 결과


실험 환경에서 수집된 데이터셋은 총 1,956,668개의 데이터 (RSSI, Minor, BLE 비콘 메시지 수신 시간)로 구성되어 있다. Smoothed RSSI 기반 거리 추정 기법에 활용되는 MISO DNN 모델의 학습 및 검증을 위해, 수집된

데이터셋을 7:3 비율로 학습 및 검증 데이터셋으로 나누어 사용하였다. [Fig. 3]과 [Fig. 4]는 각각 MISO DNN을 활용한 Smoothed RSSI 기반 거리 추정 기법과 선형회귀 기반 거리 추정 기법의 결과를 히트맵 (Heatmap)으로 나타낸다. 히트맵은 추정 거리와 실제 거리 쌍으로 식별되는 다수의 셀로 구성된다. 히트맵에서 x축은 추정 거리 (Estimated Distance), y축은 실제 거리 (Actual Distance)를 나타낸다. 히트맵에서 셀의 명도는 해당 거리 쌍의 추정 빈도를 나타내며, 명도가 낮을수록 해당 거리 쌍의 추정 빈도가 높음을 의미한다. 따라서, 거리 추정의 정확도가 높을수록 동일하거나 유사한 추정 거리 및 실제 거리를 갖는 거리 쌍의 추정 빈도가 높아 히트맵 상에서 우하향의 대각선 셀 또는 인접한 셀들의 명도가 낮게 표시된다.

제안 기법은 기존 기법 대비 추정 거리와 실제 거리 값이 서로 동일하거나 유사한 빈도가 더 높았다. 즉, 기존 기법 대비 제안 기법의 히트맵에서 우하향 대각선에 해당되는 셀과 동일하거나 인접한 셀의 명도가 더 낮음을 알 수 있었다. 특히, 제안 기법은 x축 및 y축의 값이 4m 이하에 해당되는 범위에서 상대적으로 정확하게 거리를 추정하였다.



[Fig. 3] Heatmap of proposed scheme



[Fig. 4] Heatmap of existing scheme

〈Table 3〉은 제안 기법과 기존 기법의 RMSE 값을 나타낸다. 실험 결과는 제안 기법이 기존 기법 대비 29.09% 더 높은 거리 추정 정확도를 보여주었다.

〈Table 3〉 RMSE of proposed and existing schemes

Scheme	Proposed Scheme	Existing Scheme
RMSE	1.17	1.65

## 5. 결론

본 논문에서는 단일 수신기를 사용하는 환경에서 RSSI 기반 거리 추정의 정확도를 높이기 위해 MISO DNN을 활용한 Smoothed RSSI 기반 거리 추정 기법을 제안하였다. 이를 위해, 제안 기법에서는 RSSI 값의 이상치와 결측치를 제거 및 대체하는 전처리 과정이 수행된다. 또한, RSSI 값에 기반한 추정 거리의 오차를 최소화하는 MISO DNN 모델이 활용된다. 제안 기법은 전처리 과정을 통해 도출된 다수의 Smoothed RSSI를 Input Data로 받아 MISO DNN 모델의 Output Layer에서 추정 거리로 반환한다. 제안 기법의 성능 평가를 위해 선형회귀 기반 거리 추정 기법을 대조군으로 설정하여 거리 추정 정확도를 비교하였다. 실험 결과, 제안 기법은 선형회귀 기반 거리 추정 기법 대비 29.09% 더 높은 거리 추정 정확도를 보였다.


## REFERENCES

- [1] E.Heidari, A.Gladisch, B.Moshiri, and D.Tavangarian, "Survey on location information services for Vehicular Communication Networks," *Wireless networks*, Vol.20, No.5, pp.1085-1105, 2014.
- [2] S.K.Prasad, J.Rachna, O.I.Khalaf, and D.N.Le, "Map matching algorithm: real time location tracking for smart security application," *Telecommunications and Radio Engineering*, Vol.79, No.13, pp.1189-1203, 2020.
- [3] A.Poulose, and D.S.Han, "UWB indoor localization using deep learning LSTM networks," *Applied Sciences-Basel*, Vol. 10, No.18, pp.6290:1-6290:23, 2020.
- [4] G.Li, E.Geng, Z.Ye, Y.Xu, J.Lin, and Y.Pang, "Indoor positioning algorithm based on the improved RSSI distance model," *Sensors*, Vol.18, No.9, pp.2820:1-2820:15, 2018.
- [5] E.Hatem, B.El-Hassan, M.J.Laheurte, S.Abou-Chakra, E.Colin, and C.Marechal, "Study the estimated distance error in indoor localization using UHF-RFID," in *Proceedings of IEEE Middle East and North Africa Communications Conference (MENACOMM)*, pp.1-5, 2018.
- [6] N.Chuku and A.Nasipuri, "RSSI-Based localization schemes for wireless sensor networks using outlier detection," *Journal of Sensor and Actuator Networks*, Vol.10, No.1, pp.10:1-10:22, 2021.
- [7] M.I.M.Ismail, R.A.Dzyauddin, S.Samsul, N.A.Azmi, Y.Yamada, M.F.M.Yakub, and N.A.B.A.Salleh, "An RSSI-based wireless sensor node localisation using

trilateration and multilateration methods for outdoor environment.” 2019, arXiv:1912.07801. [Online]. Available: <https://arxiv.org/abs/1912.07801>

- [8] Z.Wu, E.Jedari, R.Muscedere, and R.Rashidzadeh, “Improved particle filter based on WLAN RSSI fingerprinting and smart sensors for indoor localization,” *Computer Communications*, Vol.83, pp.64-71, 2016.
- [9] S.B.LEE, J.H.Kwon, and E.J.Kim, “Linear Regression-Based Distance Estimation Model for Preventing Safety Accidents in School Vehicles,” in *Proceedings of the Korean Institute of Communication Sciences Conference*, pp.1219-1220, 2021.
- [10] Y.H.Kwon and I.B.Jung, “A Location Compensation Method for Smart Mobile Objects using Multilateral Machine Learning,” *KIISE Transactions on Computing Practices*, Vol.26, No. 7, pp.312-321, 2020.
- [11] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin et al., “Tensorflow: Large-scale machine learning on heterogeneous distributed systems,” 2016, arXiv:1603.04467. [Online]. Available: <https://arxiv.org/abs/1603.04467>
- [12] D.C.LEE. “Comparison of Reinforcement Learning Activation Functions to Maximize Rewards in Autonomous Highway Driving,” *The Journal of the Institute of Internet, Broadcasting and Communication*, Vol.22, No.5, pp. 63-68, 2022.
- [13] C.T.Chen, and G.X.Gu, “Generative deep neural networks for inverse materials design using backpropagation and active learning,” *Advanced Science*, Vol.7, No.5, pp.1902607:1-1902607:10, 2020.
- [14] L.Li, M.Doroslovački, and M.H.Loew, “Approximating the gradient of cross-entropy loss function,” *IEEE Access*, Vol.8, pp.111626-111635, 2020.
- [15] Beafon, BLE Beacon of Beafon [Online]. Available: <http://www.beafon.co.kr>
- [16] Raspberry Pi, Teach, Learn, and Make with Raspberry Pi [Online]. Available: <https://www.raspberrypi.org>

**권혁돈(Hyeok-Don Kwon) [정회원]**



■ 2018년 3월 ~ 현재 : 한림대학교 소프트웨어학부 학사과정

<관심분야>

사물인터넷, 무선센서네트워크, 임베디드시스템, 머신러닝

**이솔비(Sol-Bee Lee) [정회원]**



■ 2018년 2월 : 한림대학교 융합소프트웨어학과 (공학사)  
 ■ 2018년 ~ 현재 : 한림대학교 융합소프트웨어학과 석박사통합과정

<관심분야>

사물인터넷, 무선센서네트워크, 무선전력전송, 머신러닝

**권정혁(Jung-Hyok Kwon) [정회원]**



■ 2012년 2월 : 고려대학교 전기전자공학공학과 (공학석사)  
 ■ 2019년 2월 : 한림대학교 융합소프트웨어학과 (공학박사)  
 ■ 2013년 4월 ~ 2015년 6월 : LIG 넥스원 SW연구센터 선임연구원

■ 2019년 3월 ~ 현재 : 한림대학교 스마트컴퓨팅연구소 연구교수

<관심분야>

사물인터넷, 무선센서네트워크, 무선전력전송, 머신러닝, 블록체인

**김의직(Eui-Jik Kim) [정회원]**



■ 2006년 2월 : 고려대학교 전자컴퓨터공학과 (공학석사)  
 ■ 2013년 2월 : 고려대학교 전기전자공학공학과 (공학박사)  
 ■ 2006년 2월 ~ 2009년 7월 : 삼성 전자 DMC연구소 선임연구원

■ 2009년 8월 ~ 2013년 8월 : KT 융합기술원 선임연구원  
 ■ 2013년 9월 ~ 현재 : 한림대학교 소프트웨어학부 부교수

<관심분야>

사물인터넷, 무선센서네트워크, 무선전력전송, 머신러닝, 블록체인