

Performance Comparison of Machine Learning Algorithms for Received Signal Strength-Based Indoor LOS/NLOS Classification of LTE Signals

Halim Lee, Jiwon Seo[†]

School of Integrated Technology, Yonsei University, Incheon 21983, South Korea

ABSTRACT

An indoor navigation system that utilizes long-term evolution (LTE) signals has the benefit of no additional infrastructure installation expenses and low base station database management costs. Among the LTE signal measurements, received signal strength (RSS) is particularly appealing because it can be easily obtained with mobile devices. Propagation channel models can be used to estimate the position of mobile devices with RSS. However, conventional channel models have a shortcoming in that they do not discriminate between line-of-sight (LOS) and non-line-of-sight (NLOS) conditions of the received signal. Accordingly, a previous study has suggested separated LOS and NLOS channel models. However, a method for determining LOS and NLOS conditions was not devised. In this study, a machine learning-based LOS/NLOS classification method using RSS measurements is developed. We suggest several machine-learning features and evaluate various machine-learning algorithms. As an indoor experimental result, up to 87.5% classification accuracy was achieved with an ensemble algorithm. Furthermore, the range estimation accuracy with an average error of 13.54 m was demonstrated, which is a 25.3% improvement over the conventional channel model.

Keywords: indoor navigation, machine learning, received signal strength, line-of-sight, non-line-of-sight

1. 서론

최근 모바일 기기의 다양화 및 개인화가 이루어짐에 따라, 모바일 기기를 통해 긴급구조, 위치 검색, augmented reality (AR) 등의 위치기반서비스를 제공받으려 하는 수요가 꾸준히 증가하고 있다. 현재 대부분의 모바일 기기에서 사용자의 위치를 획득하기 위하여 사용되고 있는 항법 시스템은 위성항법시스템 (GNSS; global navigation satellite system)이다 (Seo et al. 2011, Lee et al. 2017, Dabove & Pietra 2019). 위성항법시스템을 이용하면 전파 방해가 없는 실내 환경에서 모바일 기기의 위치를 수 미터 수준으로 추정할 수 있다 (Angelis et al. 2012). 그러나, 위성항법 신호는 지상에서 그 세기가 매우 약하기 때문에 건물 외벽 등의 장애물에 의해 신호가 차단되기 쉽다는 한계가 있다 (Lee et

al. 2019, 2022a, 2022b). 따라서 위성항법시스템의 가용성이 매우 떨어지는 실내 환경에서 사용 가능한 항법 시스템의 개발이 꾸준히 요구되어 왔다.

현재까지 제시된 실내항법시스템 중, WiFi (Xiao et al. 2014, Yang & Shao 2015), Zigbee (Fang et al. 2012, Uradzinski et al. 2017), long-term evolution (LTE) (Lee et al. 2020, Jia et al. 2021) 등 무선 통신 신호를 이용하는 항법시스템은 이미 널리 설치되어 있는 통신 인프라를 활용하는 방법으로, 추가 비용이 들지 않으며 범용으로 사용 가능하다는 장점이 있다. 특히 LTE 신호의 경우, 다른 무선 통신 시스템에 비하여 기지국 데이터베이스 관리가 용이하다는 장점이 있다. LTE 신호를 이용하여 위치를 추정하기 위해서는 도착시간 (TOA; time-of-arrival) (Shamaei et al. 2018, Kang et al. 2019), 신호 세기 (RSS; received signal strength) (Li 2007, Xiao et al. 2014), 채널 임펄스 응답 (CIR; channel impulse response) (Lee et al. 2020) 등의 신호 측정치를 활용할 수 있다. 그 중 신호 세기의 경우, 간단한 소프트웨어 및 하드웨어 디자인 만으로도 측정이 가능하다는 장점이 있다.

신호 세기를 이용하여 실내에서 모바일 기기의 위치를 추정하기 위해서는 전파 채널 모델을 활용할 수 있다. 전파 채널 모델은 신호 수신 거리에 따른 신호 감쇠 정도를 수식화한 것이다. 전

Received Nov 09, 2022 Revised Nov 25, 2022 Accepted Nov 26, 2022

[†]Corresponding Author

E-mail: jiwon.seo@yonsei.ac.kr

Tel: +82-32-749-5833 Fax: +82-32-818-5801

Halim Lee <https://orcid.org/0000-0002-2957-0221>

Jiwon Seo <https://orcid.org/0000-0003-1781-533X>

파 채널 모델을 이용하여 송수신기간 거리를 추정할 때, “송신기로부터 같은 거리에서 수신된 신호이더라도, 수신 신호의 가시선(LOS; line-of-sight) 혹은 비가시선(NLOS; non-line-of-sight) 조건에 따라 채널 특성이 달라질 수 있다”(Lee & Seo 2022). 이에 Lee & Seo (2022)는 LOS/NLOS로 세분화된 전파 채널 모델을 제시하였고, 해당 전파 채널 모델이 LOS/NLOS를 구분하지 않는 기존 전파 채널 모델에 비하여 뛰어난 거리 추정 정확도를 가짐을 보인 바 있다.

총 K 개의 신호 측정 위치에서 N 번씩 RSS 측정이 이루어질 때, k 번째 신호 측정 위치의 i 번째 신호 세기 측정치 $P_{i,k}$ 는 Eq. (1)과 같이 표현된다 (Al-Hourani et al. 2014, Esrafilian et al. 2020, Lee & Seo 2022).

$$P_{i,k} = (P_{\text{LOS},i,k})^{w_k} (P_{\text{NLOS},i,k})^{(1-w_k)},$$

$$w_k = \begin{cases} 1, & \text{if LOS} \\ 0, & \text{if NLOS} \end{cases}, i \in [1, N], k \in [1, K] \quad (1)$$

여기서 w_k 는 k 번째 RSS 측정 위치의 LOS/NLOS 조건을 나타내는 이진 변수이고, $P_{\text{LOS},i,k}$ 와 $P_{\text{NLOS},i,k}$ 는 각각 다른 채널 파라미터를 가지는 로그-거리 경로 손실 모델로 수식화 될 수 있다 (Li 2007, Al-Hourani et al. 2014, Esrafilian et al. 2020). 실제 모바일 기기에서 Eq. (1)의 전파 채널 모델을 적용하기 위해서는 LOS 또는 NLOS 조건을 나타내는 이진 변수인 w_k 의 추정이 선행되어야 한다. 그러나, Lee & Seo (2022)는 w_k 를 결정하는 방법을 제시하지 않았으며, 해당 이진 변수가 미리 결정되어 있다고 가정하였다.

이러한 선행 연구의 한계를 극복하기 위하여, 본 연구에서는 신호 세기 측정치로부터 LOS/NLOS 조건 (즉, Eq. (1)에서 w_k)을 자동으로 판별할 수 있는 머신러닝 알고리즘을 개발하였다. 기존에도 머신러닝을 이용하여 ultra-wideband (UWB)나 WiFi 등 무선 신호의 LOS/NLOS 조건을 판별한 연구 (Marano et al. 2010, Xiao et al. 2014, Barral et al. 2019, Fan & Awan 2019, Jiang et al. 2020, Dong et al. 2022)가 진행된 바 있다.

UWB 신호를 기반으로 LOS/NLOS 조건을 판별한 선행 연구 (Marano et al. 2010, Fan & Awan 2019, Jiang et al. 2020)의 경우, 머신러닝의 입력 데이터로 주로 CIR을 사용하였다. CIR은 송수신기간 전파 채널의 임펄스 응답으로, RSS와 비교하여 채널에 대한 더 많은 정보를 포함한다는 장점이 있다. 그러나, 상용 모바일 기기에서 LTE 신호로부터 CIR을 취득하기 위해서는 특수한 펌웨어가 요구되는 등 하드웨어 및 소프트웨어의 변경이 필요하다. 따라서 LTE CIR 기반 LOS/NLOS 조건 판별 기술은 범용적으로 사용되기에 한계가 있기 때문에 본 연구에서는 상용 모바일 기기로도 쉽게 취득이 가능한 RSS의 사용을 가정하였다.

Xiao et al. (2014), Barral et al. (2019), Dong et al. (2022)은 UWB나 WiFi 신호의 RSS를 사용한 LOS/NLOS 조건 판별 기법을 제안한 바 있다. Barral et al. (2019), Dong et al. (2022)은 TOA, round-trip time (RTT) 등 시간 기반 거리추정치들 RSS와 함께 사용한다고 가정하였으며, 머신러닝 특징(feature)으로는 평균, 분산, 왜도, 첨도 등의 단순한 통계적 특성만을 고려하였다. Xiao et al. (2014)는 Rician K factor, χ^2 goodness of fit 등의 특징을 추가로 활용한 WiFi LOS/NLOS 조건 판별 연구를 진행하였으나, support vector machine (SVM), Gaussian process (GP) 등의 단

순한 머신러닝 알고리즘의 성능만을 평가하였다.

이러한 선행 연구와는 달리, 본 연구에서는 RSS 데이터의 다양한 통계적 특성으로부터 머신러닝을 위한 특징을 추출하였으며, ensemble과 deep neural network (DNN) 알고리즘을 추가로 고려하여 LOS/NLOS 조건 분류를 진행하였다. 또한, 본 연구에서는 선행 연구에서 고려하지 않았던 LOS/NLOS로 세분화된 채널 모델을 이용한 송수신기간 거리 추정에 대해서도 다루었다.

본 논문의 2장에서는 LOS와 NLOS 조건을 구별하기 위한 머신러닝 특징 추출 방법 및 머신러닝 알고리즘에 대해 다룬다. 3장에서는 데이터 수집을 위한 실험 환경 및 세팅에 대해 다루며, 4장에서는 실험 데이터를 바탕으로 머신러닝 알고리즘의 성능을 분석하였다. 마지막으로 5장에서는 결론을 제시하였다.

2. 머신러닝 기반 LOS/NLOS 조건 분류 기법

LTE 기지국에서 송신된 신호는 실내 환경에서 장애물에 부딪혀 반사, 산란 되는 등 여러 경로로 전파되어 수신기에 도달할 수 있다. 일반적으로, LOS는 송신기와 수신기 간의 직선 경로가 확보되는 신호 수신 조건을 뜻하며, NLOS는 송신기와 수신기 간의 직선 경로가 확보되지 않고 반사 혹은 산란된 경로만 확보되는 조건을 뜻한다 (Xiao et al. 2014). LOS 및 NLOS 조건은 송수신기간 기하학적 배치와 주변 장애물 여부에 의해 결정된다.

본 연구에서는 Fig. 1과 같이 신호 세기 측정값을 통해 송수신기간 LOS/NLOS 조건을 자동으로 판별할 수 있는 머신러닝 알고리즘을 개발하였다. k 번째 신호 측정 위치에서 측정된 신호 세기 샘플의 training set을 $[P_{1,k}, P_{2,k}, \dots, P_{N,k}]$ 라고 할 때, 각 set에서 특징을 추출하여 머신러닝의 입력 데이터로 사용하였다. 학습을 위한 특징으로는 신호 세기 샘플의 표준 편차 (σ_k), 첨도 (Kurtosis), 왜도 (Skewness), Rician K factor ($Rician_k$), χ^2 goodness of fit (χ_k^2)가 사용되었으며, 자세한 내용은 2.1절에 서술하였다. LOS/NLOS 조건을 나타내는 이진변수 w_k 의 참값 (ground truth)은 지도를 이용하여 구하였다. 마찬가지로, test set (Fig. 1에서 신호 측정 위치의 인덱스를 j 로 표시하였음)에 대해서도 training set과 같은 방식으로 특징을 추출하여 머신러닝의 입력 데이터로 사용하였다. 머신러닝의 최종 출력값은 LOS/NLOS 조건의 추정치인 $\hat{w}_j$ 이다. 다양한 머신러닝 알고리즘을 이용하여 LOS/NLOS 조건 분류를 진행한 뒤 성능을 비교하였으며, 자세한 내용은 2.2절에 서술하였다.

2.1 머신러닝을 위한 특징 추출

송신기로부터 출발한 신호가 여러 경로로 전파되어 수신기에 도달할 때, LOS 혹은 다른 신호에 비하여 강한 세기로 도달한 신호가 존재할 경우, 해당 채널을 Rician 분포 채널로 모델링 할 수 있다 (Xiao et al. 2003, Jayaweera & Poor 2005). 반면, LOS 경로가 존재하지 않고, 다중의 반사 산란 경로를 통해 도달한 신호만 존재할 경우, 해당 채널을 Rayleigh 분포 채널로 모델링 할 수 있다 (Xiao et al. 2003, Zheng & Xiao 2003). 이에 Xiao et al. (2014)은 수집된 신호 세기 샘플의 통계적 특성으로부터 Rician 분포 채널과 Rayleigh 분포 채널을 구분할 수 있음을 보인 바 있다. 본 연




Fig. 1. Machine learning-based LOS/NLOS classification algorithm.

구에서는 Xiao et al. (2014)을 참고하여 다음과 같이 머신러닝을 위한 특징 (feature)을 선택하였다.

- 신호 세기 샘플의 표준 편차 (standard deviation): 일반적으로 NLOS 조건일 경우 더 큰 값을 가지며, Eq. (2)와 같이 표현됨.

$$\sigma_k = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_{i,k} - \mu_k)^2},$$

$$\mu_k = \frac{1}{N} \sum_{i=1}^N P_{i,k} \quad (2)$$

- 신호 세기 샘플 분포의 첨도 (kurtosis): 확률분포의 꼬리가 두꺼운 정도. 일반적으로 LOS 조건일 경우 반사 및 산란되어 들어오는 신호가 적으므로 확률분포가 얇은 꼬리를 가짐. Eq. (3)과 같이 표현됨.

$$Kurt_k = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{P_{i,k} - \mu_k}{\sigma_k} \right)^4} \quad (3)$$

- 신호 세기 샘플 분포의 왜도 (skewness): 확률분포가 비대칭한 정도. 일반적으로 Rayleigh 분포 채널일 경우 Rician 분포 채널에 비해 큰 값을 가짐. 즉, NLOS 조건일 경우 LOS 조건보다 확률분포의 비대칭도가 더 큼. Eq. (4)와 같이 표현됨.

$$Skew_k = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{P_{i,k} - \mu_k}{\sigma_k} \right)^3} \quad (4)$$

- Rician K factor: 가장 센 신호와 다른 신호의 세기 비. Tepedelenioglu et al. (2003)은 LOS 조건일 경우 NLOS 조

건보다 더 큰 Rician K factor 값을 가지는 것을 시뮬레이션을 통해 경험적으로 보였음. 이론적으로 LOS 경로가 존재하지 않는 Rayleigh fading 일 경우 Rician K factor는 0이 됨 (Xiao et al. 2014). Eq. (5)와 같이 표현됨.

$$Rician_k = \frac{\mu_k^2}{2\sigma_k^2} \quad (5)$$

- χ^2 goodness of fit: Rician 분포와 유사한 정도이며, Eq. (6)과 같이 표현됨.

$$\chi_k^2 = \sum_{i=1}^N \frac{(P_{i,k} - \mu_k)^2}{\mu_k} \quad (6)$$

2.2 머신러닝 알고리즘

본 연구에서 LOS/NLOS 분류를 위해 활용한 알고리즘은 SVM (Noble 2006), GP (Williams & Rasmussen 2006), ensemble (Sagi & Rokach 2018), DNN (Montavon et al. 2018, Lee et al. 2020)이다. 본 논문에서는 Xiao et al. (2014)은 다루지 않았던 ensemble과 DNN을 추가로 고려하였다. 본 논문에서 사용한 머신러닝 알고리즘을 정리하면 다음과 같다.

- SVM: 두 클래스 사이의 마진 (margin)을 최대화하는 분류 경계면을 찾는 기법.
- GP: 관측 데이터를 잘 모델링 할 수 있는 다변량 정규분포 (multivariate Gaussian distribution)를 찾는 기법. 트레이닝 데이터를 바탕으로 정규분포 함수의 사후 분포를 계산함.
- Ensemble: 여러 개의 약 분류기 (weak classifier)를 결합하여 강 분류기 (strong classifier)를 만드는 방법. 본 연구에서는 100개의 결정 트리 (decision tree)를 부스팅 (boosting) 방식으로 결합하였음.
- DNN: 입력층과 출력층 사이에 여러 개의 은닉층 (hidden




Fig. 2. Indoor test environment (reproduction of Fig. 1 of Lee & Seo (2022)).

layer)들로 이루어진 인공신경망. 본 논문에서는 hidden layer의 개수를 3개 또는 5개로 설정하였으며, 각 hidden layer의 크기는 10으로 설정하였으며, 활성화함수로 rectified linear unit (ReLU) 함수를 사용하였으며, 또한, 과적합 (overfitting)을 방지하기 위하여 L2 정규화를 진행하였으며, 정규화 인자는 0.0001로 설정하였음.

3. 실험 환경 및 세팅

본 논문의 실험 환경 및 세팅은 Lee & Seo (2022)와 동일하게 설정하였다. Fig. 2는 신호 세기 측정 실험을 진행한 연세대학교 국제캠퍼스 내 실험 환경의 평면도를 나타낸다. Fig. 2에서 빨간색 전화기 아이콘과 노란색 별 아이콘은 각각 송신기와 수신기의 위치를 나타낸다. 신호 송신기와 수신기로 각각 HP사의 ESG-D300A Digital Signal Generator와 Anritsu사의 MS2712E를 사용하였으며, 송신 신호의 주파수는 LTE Band 1, 7과 유사한 2.4 GHz로 설정하였다. 총 88개의 송-수신기 위치 조합 (송신기 위치 4개, 수신기 위치 22개)에 대해 30번씩 RSS를 측정하여 기록하였다. 또, 수집된 RSS 데이터는 70%와 30%의 비율로 나누어 각각 training과 test에 사용하였으며, 송수신기 간 직선 경로상에 장애물이 없으면 LOS, 장애물이 있으면 NLOS로 구분하였다. 모든 코드는 Matlab으로 작성하였으며, Statistics and Machine Learning Toolbox에서 제공하는 함수를 이용하여 학습을 진행하였다.

4. 실험 결과 및 분석

4.1 LOS/NLOS 분류 성능

머신러닝 기법 및 디자인에 따른 LOS/NLOS 판별 정확도는 Fig. 3과 같다. Fig. 3에서 DNN3과 DNN5는 각각 DNN의 hidden layer 개수가 3개인 경우와 5개인 경우를 뜻한다. 5개의 알고리즘 중 가장 뛰어난 성능을 보인 알고리즘은 Ensemble로, 87.5%의 LOS/NLOS 판별 정확도를 보였다. SVM, GP, DNN3, DNN5의




Fig. 3. LOS/NLOS classification accuracy of machine learning algorithms.

LOS/NLOS 판별 정확도는 각각 75.0%, 68.6%, 75.0%, 81.3%였다.

4.2 거리 추정 성능

머신러닝을 이용하여 LOS/NLOS 조건을 구별한 뒤, 세분화된 전파 채널 모델을 적용했을 때의 송수신기 간 거리 추정 성능을 분석하였다. 우선, 신호의 LOS/NLOS 조건을 나타내는 변수를 $s \in \{LOS, NLOS\}$ 라 할 때, Eq. (1)에서 $P_{s,i,k}$ 는 Eq. (7)과 같이 수식화할 수 있다 (Lee & Seo 2022).

$$P_{s,i,k} = P_0 - 10\beta_s \log_{10} \frac{d_k}{d_0} - PL_{wall,s} + n_{i,k} \quad (7)$$

여기서 P_0 는 기준거리 d_0 에서의 신호 세기이다 (본 논문에서는 d_0 를 1 m로 가정). 본 논문에서 P_0 는 미리 알고 있는 상수로 가정하였으며, 실측을 통해 그 값을 구하였다. 또, β_s 는 신호 수신 환경에 의해 결정되는 상수인 path loss exponent (PLE)이며, $PL_{wall,s}$ 는 벽에 의한 추가적인 신호 손실이다. d_k 는 k 번째 측정 위치에서의 송수신기 간 거리이며, $n_{i,k}$ 는 k 번째 측정 위치에서 i 번째 측정에서의 신호 세기 노이즈를 나타낸다. Eq. (7)에서 신호 세기의 단위는 dBm, 거리의 단위는 m를 사용한다.

세분화된 전파 채널 모델을 적용하여 거리를 추정하기 위해서는 Eq. (7)의 채널 파라미터인 $\theta = [\beta_s, PL_{wall,s}]$ 의 추정이 선행되어야

Table 1. Estimated channel parameters.

Parameter	β_{LOS}	β_{NLOS}	$PL_{\text{wall,NLOS}}$
Value	2.11	3.02	3.92




Fig. 4. Estimated LOS and NLOS channel models in test environment.




Fig. 5. Cumulative range error distributions of two methods.

한다. 신호세기 샘플 training set의 인덱스의 집합을 Tr 이라고 할 때, 본 연구에서는 θ 를 Eq. (8)과 같이 최소제곱법 (least squares method)를 이용하여 추정하였다 (Lee & Seo 2022).

$$\begin{aligned}\hat{\theta} &= \underset{\theta}{\operatorname{argmin}} \sum_{k \in Tr} \sum_{i=1}^N n_{i,k}^2 \\ &= \underset{\theta}{\operatorname{argmin}} \sum_{k \in Tr} \sum_{i=1}^N \left(p_{s,i,k} - P_0 + 10\beta_s \log_{10} \frac{d_k}{d_0} + PL_{\text{wall},s} \right)^2\end{aligned}\quad (8)$$

Eq. (8)을 통해 추정된 채널 파라미터는 Table 1과 같으며, 추정된 채널 모델을 그래프로 나타내면 Fig. 4와 같다. Fig. 4에서 빨간색 원과 파란색 원은 각각 LOS 조건과 NLOS 조건에서의 신호 세기 샘플을 나타낸다. 또, 빨간색 직선과 파란색 직선은 각각 LOS




Fig. 6. Number of LTE RSS samples per footstep according to walking speed.

조건과 NLOS 조건에 따른 채널 모델을 나타낸다. $PL_{\text{wall,NLOS}}$ 의 경우, 벽의 재질, 두께 등 송수신기 사이의 전파 환경에 따라 그 값이 결정된다. 본 논문에서는 실험을 진행한 건물의 내벽은 모두 동일한 $PL_{\text{wall,NLOS}}$ 값을 가진다고 가정하였다. 추후 서로 다른 벽에 대해 각각 알맞은 경로 손실을 계산하여 적용한다면 거리 추정 정확도를 더욱 높일 수 있을 것이다. 마지막으로, Fig. 4에서 회색 직선은 LOS와 NLOS 조건을 구분하지 않았을 때 최소제곱법을 이용해 추정한 채널 모델을 나타내며, 이 때 PLE 값은 3.11로 추정되었다.

본 논문에서는 신호의 LOS/NLOS 조건을 나타내는 파라미터 $\hat{w}_k$ 를 머신러닝으로 추정한 뒤, Eq. (1)에 적용하였다. 또한, Eq. (1)의 거리 추정 성능을 LOS/NLOS 조건을 구분하지 않는 통일된 채널 모델 (Fig. 4에서 회색 직선)을 사용하는 경우와 비교하였다. 제안 기법 및 기존 기법의 거리 추정 성능을 누적오차분포 (CDF; cumulative distribution function)로 나타내면 Fig. 5와 같다. 제안 기법을 사용하였을 때, 기존 기법에 비해 평균 거리 추정 오차가 약 25.3% 감소하였으며, 최대 거리추정 오차는 78.5 m에서 61.9 m로 16.6 m 감소하였다.

4.3 보행 속도에 따른 샘플 개수 분석

보행자가 빠르게 움직일수록 한 신호 수집 지점에서 수집할 수 있는 신호 세기 샘플의 개수가 적어지므로, 보행 속도는 본 알고리즘의 성능에 영향을 미칠 수 있다. 따라서 보행 속도에 따라 수집 가능한 신호 세기 샘플의 개수를 분석하였다. LTE 프레임의 길이는 10 ms 이므로, LTE 신호 수신기는 1초에 100개의 RSS 데이터를 수집할 수 있다. 보행자의 보폭이 60 cm라고 가정할 때, 보행 속도에 따른 한 걸음 당 수집 가능한 LTE 신호 세기 샘플의 개수를 그래프로 나타내면 Fig. 6과 같다. Fig. 6에서 가로축은 보행 속도, 세로축은 한 걸음 당 수집 가능한 신호 세기 샘플의 개수를 나타낸다. 본 논문에서 제안하는 LTE 신호의 LOS/NLOS 조건 판별 기법은 한 신호 수집 지점에서 약 30개의 신호 세기 샘플을 필요로 한다. 따라서, 빠른 속도로 보행할 경우 (~9 km/h)에도 제안 기법이 활용될 수 있을 것으로 보인다.

5. 결론

LTE 신호 세기와 전파 채널 모델을 이용하여 실내에서 측위할 때, 신호의 LOS 및 NLOS 조건에 따라 채널 특성이 달라진다는 문제점이 있다. 선행연구에서 이를 극복하기 위해 LOS/NLOS로 세분화된 전파 채널 모델을 제안한 바 있으나, LOS 및 NLOS 조건을 판별하는 알고리즘을 제시하지 않았다는 한계가 있었다. 따라서 본 연구에서는 머신러닝을 이용하여 LOS/NLOS 조건을 자동으로 구별할 수 있는 알고리즘을 개발하였다. 본 논문에서는 머신러닝을 위한 특징을 제시하고, 다양한 머신러닝 알고리즘의 LOS/NLOS 조건 분류 성능을 비교하였다. 그 결과, 최대 87.5%의 LOS/NLOS 조건 분류 정확도를 얻을 수 있었다. 또한, 제안한 머신러닝 알고리즘을 송수신기간 거리 추정에 적용한 결과, LOS/NLOS로 세분화된 채널 모델을 사용하지 않는 기존 기법에 비하여 25.3% 정도의 거리 추정 성능 향상을 보였다. 마지막으로, 보행 속도에 따라 수집 가능한 LTE 신호 세기 샘플 개수를 분석하여 보행 상황에서도 제안 기법이 활용될 수 있음을 보였다.

ACKNOWLEDGMENTS

본 연구는 과학기술정보통신부의 재원으로 한국연구재단, 무인이동체원천기술개발사업단의 지원을 받아 수행되었고 (2020M3C1C1A01086407), 2022년도 정부(경찰청)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구이며 (2019-0-01291, LTE 신호기반 요구조사 정밀위치 측정 기술개발), 2022년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (2021RIA6A3A13046688). 본 논문은 2022년 항법시스템학회 정기학술대회에서 발표한 논문을 확장한 내용임.

AUTHOR CONTRIBUTIONS

Conceptualization, H. Lee and J. Seo; methodology, H. Lee and J. Seo; software, H. Lee; validation, H. Lee; formal analysis, H. Lee; writing—original draft preparation, H. Lee; writing—review and editing, J. Seo; visualization, H. Lee.

CONFLICTS OF INTEREST

The authors declare no conflict of interest.

REFERENCES

Al-Hourani, A., Kandeepan, S., & Jamalipour, A. 2014, Modeling air-to-ground path loss for low altitude platforms in urban environments, in 2014 IEEE GLOBECOM, 8-12 Dec 2014, Austin, TX, USA, pp.2898-

2904. <https://doi.org/10.1109/GLOCOM.2014.7037248>
 Angelis, G. D., Baruffa, G., & Cacopardi, S. 2012, GNSS/cellular hybrid positioning system for mobile users in urban scenarios, IEEE Transactions on Intelligent Transportation Systems, 14, 313-321. <https://doi.org/10.1109/TITS.2012.2215855>
 Barral, V., Escudero, C. J., & García-Naya, J. A. 2019, NLOS classification based on RSS and ranging statistics obtained from low-cost UWB devices, in Proc. EUSIPCO, 2-6 Sept 2019, A Coruna, Spain, pp.1-5. <https://doi.org/10.23919/EUSIPCO.2019.8902949>
 Dabove, P. & Pietra, V. D. 2019, Towards high accuracy GNSS real-time positioning with smartphones, Advances in Space Research, 63, 94-102. <https://doi.org/10.1016/j.asr.2018.08.025>
 Dong, Y., Arslan, T., & Yang, Y. 2022, Real-time NLOS/LOS identification for smartphone-based indoor positioning systems using WiFi RTT and RSS, IEEE Sensors Journal, 22, 5199-5209. <https://doi.org/10.1109/JSEN.2021.3119234>
 Esrafilian, O., Gangula, R., & Gesbert, D. 2020, Three-dimensional-map-based trajectory design in UAV-aided wireless localization systems, IEEE Internet of Things Journal, 8, 9894-9904. <https://doi.org/10.1109/JIOT.2020.3021611>
 Fan, J. & Awan, A. S. 2019, Non-line-of-sight identification based on unsupervised machine learning in ultra wideband systems, IEEE Access, 7, 32464-32471. <https://doi.org/10.1109/ACCESS.2019.2903236>
 Fang, S. H., Wang, C. H., Huang, T. Y., Yang, C. H., & Chen, Y. S. 2012, An enhanced ZigBee indoor positioning system with an ensemble approach, IEEE Communications Letters, 16, 564-567. <https://doi.org/10.1109/LCOMM.2012.022112.120131>
 Jayaweera, S. K. & Poor, H. V. 2005, On the capacity of multiple-antenna systems in Rician fading, IEEE Transactions on Wireless Communications, 4, 1102-1111. <https://doi.org/10.1109/TWC.2005.846970>
 Jia, M., Lee, H., Khalife, J., Kassas, Z. M., & Seo, J. 2021, Ground vehicle navigation integrity monitoring for multi-constellation GNSS fused with cellular signals of opportunity, in Proc. ITSC, 19-22 Sept 2021, Indianapolis, IN, USA, pp. 3978-3983. <https://doi.org/10.1109/ITSC48978.2021.9564686>
 Jiang, C., Shen, J., Chen, S., Chen, Y., Liu, D., et al. 2020, UWB NLOS/LOS classification using deep learning method, IEEE Communications Letters, 24, 2226-2230. <https://doi.org/10.1109/LCOMM.2020.2999904>
 Kang, T., Lee, H., & Seo, J. 2019, TOA-based ranging method using CRS in LTE signals, Journal of Advanced Navigation Technology, 23, 437-443. <https://doi.org/10.1109/JANT.2019.2903236>

- org/10.12673/jant.2019.23.5.437
- Lee, H., Abdallah, A. A., Park, J., Seo, J., & Kassas, Z. M. 2020, Neural network-based ranging with LTE channel impulse response for localization in indoor environments, in Proc. ICCAS, 13-16 Oct 2020, Busan, Korea, pp.939-944. <https://doi.org/10.23919/ICCAS50221.2020.9268386>
- Lee, H., Kang, T., & Seo, J. 2019, Safety distance visualization tool for LTE-based UAV positioning in urban areas, Journal of Advanced Navigation Technology, 23, 408-414. <https://doi.org/10.12673/jant.2019.23.5.408>
- Lee, H., Pullen, S., Lee, J., Park, B., Yoon, M., et al. 2022a, Optimal parameter inflation to enhance the availability of single-frequency GBAS for intelligent air transportation, IEEE Transactions on Intelligent Transportation Systems, 23, 17801-17807. <https://doi.org/10.1109/TITS.2022.3157138>
- Lee, H. & Seo, J. 2022, LTE RSS-based positioning method using separated LOS and NLOS channel models, in Proc. 2022 IPNT Conference, 2-4 Nov 2022, Gangneung, Korea, pp.69-72. <http://ipnt.or.kr/2022proc/48>
- Lee, H., Seo, J., & Kassas, Z. M. 2022b, Urban road safety prediction: A satellite navigation perspective, IEEE Intelligent Transportation Systems Magazine, 14, 94-106. <https://doi.org/10.1109/MITS.2022.3181557>
- Lee, J., Morton, Y., Lee, J., Moon, H.-S., & Seo, J. 2017, Monitoring and mitigation of ionospheric anomalies for GNSS-based safety critical systems, IEEE Signal Processing Magazine, 34, 96-110. <https://doi.org/10.1109/MSP.2017.2716406>
- Li, X. 2007, Collaborative localization with received-signal strength in wireless sensor networks, IEEE Transactions on Vehicular Technology, 56, 3807-3817. <https://doi.org/10.1109/TVT.2007.904535>
- Marano, S., Gifford, W. M., Wymeersch, H., & Win, M. Z. 2010, NLOS identification and mitigation for localization based on UWB experimental data, IEEE Journal on selected areas in communications, 28, 1026-1035. <https://doi.org/10.1109/JSAC.2010.100907>
- Montavon, G., Samek, W., & Müller, K. R. 2018, Methods for interpreting and understanding deep neural networks, Digital signal processing, 73, 1-15. <https://doi.org/10.1016/j.dsp.2017.10.011>
- Noble, W. S. 2006, What is a support vector machine?, Nature biotechnology, 24, 1565-1567. <https://doi.org/10.1038/nbt1206-1565>
- Sagi, O. & Rokach, L. 2018, Ensemble learning: A survey, Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 8, e1249. <https://doi.org/10.1002/widm.1249>
- Seo, J., Walter, T., & Enge, P. 2011, Availability impact on GPS aviation due to strong ionospheric scintillation, IEEE Transactions on Aerospace and Electronic Systems, 47, 1963-1973. <https://doi.org/10.1109/TAES.2011.5937276>
- Shamaei, K., Khalife, J., & Kassas, Z. 2018, Exploiting LTE signals for navigation: Theory to implementation, IEEE Transactions on Wireless Communication, 17, 2173-2189. <https://doi.org/10.1109/TWC.2018.2789882>
- Tepedelenlioglu, C., Abdi, A., & Giannakis, G. B. 2003, The Ricean K factor: estimation and performance analysis, IEEE Transactions on Wireless Communications, 2, 799-810. <https://doi.org/10.1109/TWC.2003.814338>
- Uradzinski, M., Guo, H., Liu, X., & Yu, M. 2017, Advanced indoor positioning using zigbee wireless technology, Wireless Personal Communications, 97, 6509-6518. <https://doi.org/10.1007/s11277-017-4852-5>
- Williams, C. K. & Rasmussen, C. E. 2006. Gaussian processes for machine learning (MA: MIT press)
- Xiao, C., Zheng, Y. R., & Beaulieu, N. C. 2003, Statistical simulation models for Rayleigh and Rician fading, in Proc. IEEE ICC '03, 11-15 May 2003, Anchorage, AK, USA, pp.3524-3529. <https://doi.org/10.1109/ICC.2003.1204109>
- Xiao, Z., Wen, H., Markham, A., Trigoni, N., Blunsom, P., et al. 2014, Non-line-of-sight identification and mitigation using received signal strength, IEEE Transactions on Wireless Communications, 14, 1689-1702. <https://doi.org/10.1109/TWC.2014.2372341>
- Yang, C. & Shao, H. R. 2015, WiFi-based indoor positioning, IEEE Communications Magazine, 53, 150-157. <https://doi.org/10.1109/MCOM.2015.7060497>
- Zheng, Y. R. & Xiao, C. 2003, Simulation models with correct statistical properties for Rayleigh fading channels, IEEE Transactions on communications, 51, 920-928. <https://doi.org/10.1109/TCOMM.2003.813259>



Halim Lee is an M.S./Ph.D. student in the School of Integrated Technology, Yonsei University, Incheon, Korea. She received the B.S. degree in Integrated Technology from Yonsei University. Her research interests include localization and tracking, urban navigation, and navigation safety.



Jiwon Seo received the B.S. degree in mechanical engineering (division of aerospace engineering) from Korea Advanced Institute of Science and Technology, Daejeon, Korea, and the M.S. degrees in aeronautics/astronautics and electrical engineering and the Ph.D. degree in aeronautics/astro-

navics from Stanford University, Stanford, CA, USA. He is currently an associate professor with the School of Integrated Technology, Yonsei University, Incheon, Korea. His research interests include GPS anti-jamming technologies; alternative positioning, navigation, and timing technologies including eLoran; and intelligent unmanned systems.