

UWB 내장형 차량용 키를 위한 랜덤 포레스트 기반 고정밀 측위 알고리즘

이 상 진*, 박 지 웅*, 고 영 배^o

Random Forest Based Precise Localization Algorithm for UWB-Embedded Car Keys

Sang-jin Lee*, Ji-Woong Park*, Young-Bae Ko^o

요 약

본 논문은 UWB 내장형 차량용 키의 LOS/NLOS 상태를 Random Forest 모델을 통해 구분함으로써 키의 정확한 위치를 추정하는 새로운 알고리즘을 제안한다. 기존의 오차보정에 관한 연구에서는 LOS 환경에서 수집된 데이터를 분석하여 NLOS 환경으로 진입하였을 때 물체의 위치를 예측하는 방법을 활용한다. 하지만 차량 환경에서는 초기 데이터 수집이 어려운 상황에서 고정밀 측위가 요구되기 때문에 기존 알고리즘을 적용하기에는 부적합하다. 본 논문에서는 UWB 센서를 통해 실시간으로 측정된 거리정보를 랜덤 포레스트 기계학습 모델 기반으로 학습하여 NLOS 환경 여부를 구분하고 각 센서에서 측정된 거리정보의 신뢰성을 기반으로 오차를 보정하는 기법을 제안하였다. 실험 결과, 제안기법은 94.6%의 높은 정확도를 나타내었고 측위 오차 측면에서 기존 오차 보정 알고리즘인 Kalman-Filter와 비교하여 매우 우수한 성능을 보였다.

Key Words : UWB Localization, Random Forest, NLOS Detection, Error Mitigation, Car

ABSTRACT

This paper proposes a novel localization algorithm for a UWB-embedded car key, by which its LOS(Line-of-Sight) or NLOS(Non-Line-of-Sight) condition can be identified based on the Random Forest model and hence its location can be precisely estimated. Most of existing studies utilize the method of analyzing data collected in the LOS environment and predicting the position of objects when they enter the NLOS environment. However, they do not work well in the cases of vehicular environments because it is not easy to collect those data. In this paper, we presented an algorithm to correct errors based on the reliability of measured distance information in each sensor by distinguishing the NLOS environment through the Random Forest model using distance information measured in real-time. According to the experimental results, the proposed algorithm have showed a high accuracy of 94.6% and very good performance in terms of localization error, compared to the well-known error correction algorithm, Kalman-Filter.

※ 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2020R1A2C1102284)

• First Author : Ajou University Department of Information and Communication Engineering, lsj3704@ajou.ac.kr, 학생회원

◦ Corresponding Author : Ajou University Department of AI Convergence Network, youngko@ajou.ac.kr, 종신회원

* Ajou University Department of AI Convergence Network, z7080z@ajou.ac.kr, 학생회원

논문번호 : 202108-198-C-RN, Received Agust 19, 2021; Revised September 17, 2021; Accepted October 4, 2021

I. 서 론

최근 UWB(Ultra Wideband) 무선 통신 기술을 활용한 차량용 디지털 키의 개발이 활발히 시도되고 있다^[1]. UWB는 500MHz 이상의 초광대역으로 무선 신호를 초당 수 천 회에서 수백만 회까지의 출력 펄스로 전송하여 높은 분해능을 가지는 통신기술로, 가시성이 확보된 LOS(Line-of-Sight) 환경에서 정밀한 거리 측정을 통한 측위가 가능하다. 또한 광대역 특성으로 인해 간섭에 강하여 비가시적 NLOS(Non-Line-of-Sight) 환경에서도 위치 추정이 가능하기 때문에 특히 실내 환경에서 고정밀 측위가 필요한 응용 서비스에서의 활용도가 점점 높아지고 있다^[2].

UWB 기반 무선 측위 기술은 크게 세 가지로 구분된다. 첫째는 UWB Anchor 노드와 Tag 사이의 전파 도달 시간을 단순 측정하여 위치를 구하는 ToA(Time of Arrival) 기법이고 둘째는 이들 사이의 전파 도달 시간에 따른 상대적 차이를 이용하여 위치를 구하는 TDOA(Time Difference of Arrival) 기법, 셋째는 Tag에서 Anchor로부터 수신한 신호의 도래각을 측정하여 위치를 구하는 AOA(Angle of Arrival) 기법이다^[3]. 고정밀 측위를 위한 대표적인 오차 보정 알고리즘으로는 실제 측정값과 앞에 제시된 기법들에 의해 계산된 예측 값의 오차 공분산을 기반으로 칼만 이득을 계산하여 반복적인 업데이트를 통해 오차를 보정하는 KF (Kalman-filter) 기법, 그리고 측정값과 특정 통계 모델에 따른 관측치가 주어질 때 우도 함수(Likelihood Function)를 최댓값으로 하는 매개 변수를 추정하는 방법인 MLE(Maximum Likelihood Estimation) 등이 사용되고 있다^[3].

이러한 기존의 UWB 기반 측위 방식은 정확한 초기 값이나 물체의 이동속도 및 방향에 대한 다양한 정보를 요구하며 데이터를 수집하고 이를 분석하여 NLOS 환경에서의 위치를 예측하는 방법이다. 하지만 차량용 키의 경우 사용자가 자동차 도어 개폐 등을 위한 제어 신호를 발생시키는 순간 실시간으로 계산되는 거리 정보를 기반으로 동작한다. 또한 차량에 신호를 주고받는 통신 센서를 차량에 탑재할 경우 차체에 의한 지속적인 NLOS가 발생한다. 이러한 차량에 특성에 의해 일정 주기동안 정확한 데이터를 수집하는 방법에서 한계를 보인다. 따라서 사전 데이터를 수집하는 과정이 필요한 기존의 KF와 같은 오차보정 방식을 UWB 기반 차량용 디지털 키에 적용하기에는 어려움이 있다.

본 논문에서는 데이터를 사전에 수집하고 분석하는

과정 없이 실시간으로 입력받은 거리 데이터만을 활용하여 UWB 칩이 장착된 차량용 키의 위치를 추정하기 위한 새로운 알고리즘을 제안한다. 차량용 디지털 키의 특성상 cm 단위의 고정밀 측위가 필수적으로 요구되는데 특히 NLOS 여부를 정확하게 식별해내는 것이 매우 중요한 이슈이다. 제안 기법에서는 이러한 문제 해결을 위해 RF (Random Forest) 기계 학습 모델을 활용한다.

제안 기법의 타당성 검증을 위하여 Decawave 사의 MDEK-1001 UWB 센서를 실제 차량에 부착한 후 발생 가능한 다양한 시나리오에서 거리 정보 데이터를 수집하였고 이를 랜덤 포레스트 모델을 통하여 학습시켰다. 그리고 NLOS로 구분되는 거리정보 및 위치정보의 오차 값을 논문에서 제안하는 알고리즘을 이용하여 보정 후 대표적인 오차 보정 알고리즘인 칼만 필터 방식과 비교함으로써 성능을 확인하였다.

II. 관련 연구

UWB 센서를 활용한 무선 측위에서 NLOS 상황으로 인한 정확도 저하 문제를 해결하기 위한 방법은 [그림 1]에서 보는 바와 같이 LOS와 NLOS를 식별(Detection)하기 위한 기술과 오차를 최대한 보정(Mitigation)하기 위한 기술로 나눌 수 있다^[4]. 최근에는 기존 기법들과 함께 기계학습 기법을 활용한 NLOS 식별에 대한 연구가 활발히 진행되고 있다.

2.1 NLOS 식별 관련 연구

먼저 범위 추정(Range Estimate)을 기반으로 한 방식^[5,6]은 실외환경을 기준으로 설계되었지만 실시간 거리정보 이외에 과거 데이터의 분산을 이용하여 현재의 상태를 구한다는 점에서 차량용 키에 적용하기에는 다소 무리가 있다. 다음으로 채널 통계(Channel Statistics) 기반 NLOS 식별 기법들^[7]은 진폭, 평균, RMS (Root Mean Square) Delay와 같은 다중 경로의 구성요소들의 통계를 활용하는 방식이다. 상당히 높은 측위 정확도를 나타내지만 역시 범위 추정 기반의 기법들과 동일한 이유로 거리정보만을 이용하여 측위를 진행해야 하는 차량용 키 적용성에 한계가 있을 것으로 사료된다.

세 번째, 위치 추정 (Position Estimate)을 기반으로 한 방법이다. 이는 범위 추정치의 중복성에 기초한 방법이다. 즉, 다른 기법들의 데이터를 도출하고 주어진 정보를 기반으로 NLOS 환경을 식별한다. 최소 최대 제곱(Min-Max Square) 또는 LS (Least Square) 접근

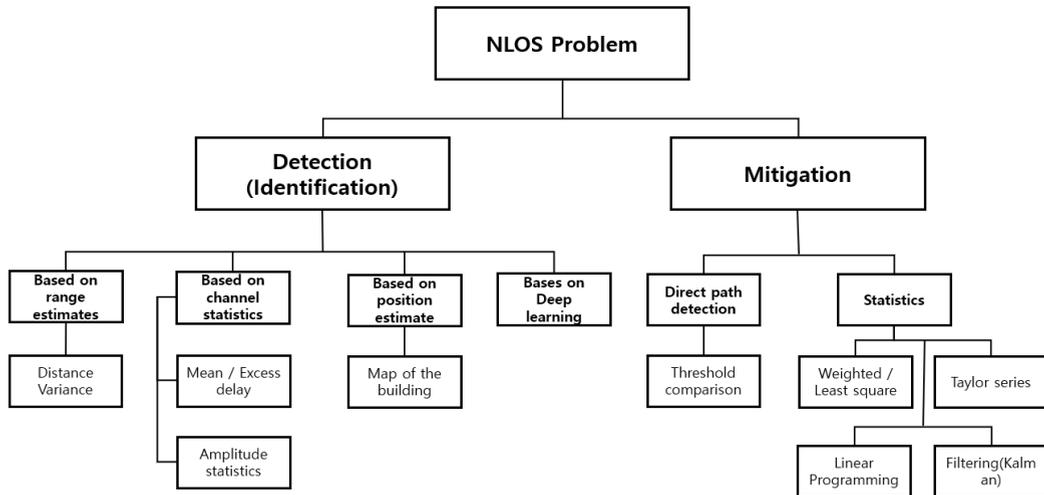


그림 1. 고정밀 측위를 위한 NLOS 식별 기법과 오차보정 기법 분류도[4]
 Fig. 1. Classification diagram of NLOS identification and Error correction for localization

법을 대표적인 예로 들 수 있다⁵⁾. 끝으로 최근에는 딥러닝 기반 연구가 활발히 진행되고 있는데 예를 들어 [8]에서는 의사결정 트리 (Decision Tree), SVM (Support Vector Machine), MLP (Multi-Layer Perception) 등의 다양한 기계학습 모델 기반 NLOS 식별 기법들이 소개되었다.

2.2 Error Mitigation 관련연구

[그림 1]에서 측위 오차 보정 기법은 크게 두 가지로 구분된다. 직접 경로 식별 (Direct Path Detection) 방식은 태그에서 수신된 신호들 중 가장 빠른 경로를 감지하는 방법으로 검출된 직접 경로 (DDP)와 검출되지 않은 직접 경로 (UDP)라는 두 가지 주요 클래스로 분류하여 오차의 크기에 따라 NLOS를 식별하고 이전의 DDP 상황에서 추정된 오차 통계만큼 감소시키는 방법이다⁶⁾. 하지만 차량 환경에서는 지정된 환경이 아닌 여러 가지 환경에 노출되어 오차의 정도에 대한 통계를 정확하게 낼 수 없다.

또 다른 방식은 통계적 기법, 즉 LS, Linear Programming, KF 알고리즘 기반으로 위치 오차를 보정하는 것이다. 이들 역시 과거의 데이터를 기반으로 현재를 예측하는 방법들로 주기가 긴 데이터들로 실시간성을 요구하는 차량환경에 적용시키기에는 적절하지 않다. 대표적으로 KF 기반 방식은 잡음이 포함된 측정치를 바탕으로 선형 역학계의 상태를 추정하는 재귀 필터이며 과거의 측정데이터와 새로운 측정

데이터를 활용하여 추정 값을 반복적으로 업데이트하는 과정을 통해 데이터 내에 포함된 잡음을 제거하여 새로운 값을 추정한다. [10]에서는 KF를 이용하여 UWB 센서기반 측위 오차를 크게 줄여 높은 정확도를 달성하였다. 하지만 실내 환경에서 실험을 진행하였고 초기 값과 물체의 속력 및 이동 방향에 관한 안정된 데이터를 이용하였다는 문제점이 있다. 차량용 디지털 키의 경우 LOS 환경에서 NLOS로 진입하는 환경보다 NLOS에서 LOS 환경으로 진입하는 경우가 많기 때문에 초기 값의 측정이 쉽지 않다는 점을 고려할 때 차이점이 클 것으로 예상된다. 관련 문헌 [11]에서는 실내 뿐 아니라 다양한 실외 환경에서도 높은 측위 정확도 결과를 제시하였으나 Anchor 노드 내부에 Tag가 존재하는 상황을 가정하고 있기 때문에 차량 내외부에 설치되는 Anchor 노드들과 물리적으로 이격되는 차량용 키의 특징과는 본질적인 차이가 있다.

III. 시스템 모델링

[그림 2]는 제안하는 시스템 모델이다. 세부적인 내용은 각 절에서 보다 구체적으로 설명한다.

3.1 Two-Way Ranging(TWR) Algorithm

본 논문에서 제안하는 시스템 모델은 UWB Anchor 노드와 Tag가 상호 교환하는 무선 신호의 왕복시간을 통해 거리를 추정하는 TWR 방식을 활용한

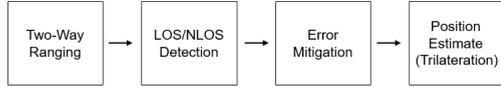


그림 2. Random Forest 기반 UWB 측위 시스템 모델
Fig. 2. Localization system model

다^[12].

위 그림은 TWR 방식을 통해 거리 값을 결정하는 순서를 나타낸다. 송신 노드가 T1 시간에 자신의 ID를 담은 데이터 패킷을 전송하면 수신 노드는 이를 T2 시간에 받는다. 이후 T3 시간에 수신 노드 역시 자신의 ID를 담은 패킷을 송신노드에게 전송한다. 이를 T4 시간에 수신한 노드는 다시 한 번(T5) 패킷을 전송함으로써 2-way 전송 과정을 수행한다. 이 과정동안 신호를 교환한 시간 정보를 전파 속도를 곱해 거리 정보를 결정할 수 있다. 위의 내용을 수식으로 설명하면 다음과 같다.

$$2T_s = (T_4 - T_1) - (T_3 - T_2) \quad (1)$$

$$2T_r = (T_6 - T_3) - (T_5 - T_4) \quad (2)$$

$$T = \frac{T_r + T_s}{2} \quad (3)$$

이 과정을 통해 계산된 시간 값에 전파 속도(C)를 곱하면 거리(D)를 추정할 수 있다. 이 때 전파 속도는 빛의 속도와 같다.

$$D = T \times C \quad (4)$$

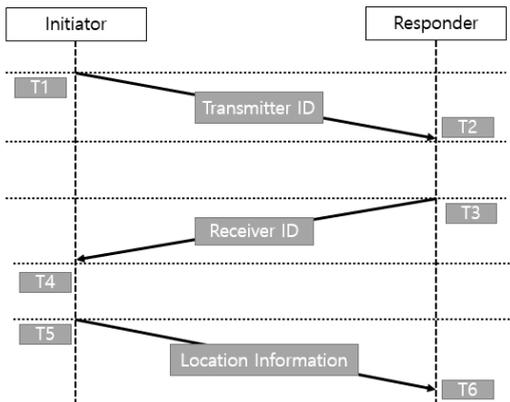


그림 3. Two-Way Ranging 기반 거리 추정 방식
Fig. 3. TWR method

3.2 LOS/NLOS Detection

기계학습 기반 NLOS 식별 방식의 가장 큰 장점은 관찰된 데이터를 분석하여 효과적인 의사결정을 내릴 수 있다는 점이라 하겠다^[13-17]. 이는 실시간으로 입력 받은 데이터를 기반으로 빠르게 NLOS 환경을 인지해야 하는 차량용 키 적용에 있어 특히 주요한 특징이다.

[그림 4]는 [그림 8]에서 보이는 것과 같이 실내, 실외 주차장환경에서 4개의 Anchor를 차량에 부착한 이후 10개의 Tag 위치를 지정하여 LOS 상황과 NLOS 상황을 인위적으로 만들어 [그림 5]처럼 Tag와 각 Anchor사이의 TWR 거리를 측정 후 LOS 환경과 NLOS 환경에서 측정된 값의 차이를 나타내는 그래프이다. 측정된 결과를 보면 LOS 환경에서 측정된 거리 값의 경우 오차를 거의 포함하지 않기 때문에 Tag의 위치가 차량의 중심에서 멀어짐에 따라 각 Anchor에서 측정된 거리 값이 거리가 증가함에 따라 일정하게 증가한다. 하지만 NLOS 환경의 경우 가장 신뢰성이 높은 Anchor4에서 측정된 거리값을 제외 한 나머지 Anchor에서 측정된 거리 값은 차량의 중심으로부터 멀어짐에 따라 거리 값이 일정하게 증가하지 않고 장애물의 형태, 매질 등 다양한 변수로 인해 일정치 않은 오차를 포함하여 예측 불가능한 값을 보였다. 기계학습 모델 중 SVM, CNN 등과 같은 분류기법은 측정된 데이터의 값이 어떤 영역에 분포하는지에 따

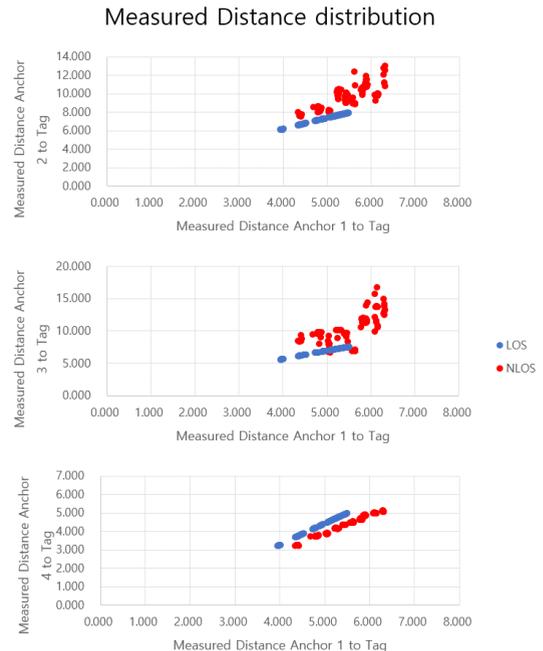


그림 4. 측정 거리 분포도
Fig. 4. Measurement distance distribution

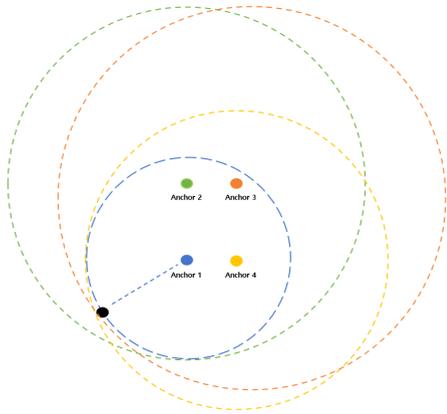


그림 5. 데이터 분류 최댓값
Fig. 5. Maximum data classification

라 분류하여 예측하는데 측위의 경우에는 오차가 일정하지 않고 위치의 변화에 따라 측정값의 분포가 달라지기 때문에 구분하기 어렵다. 따라서 본 논문에서는 데이터의 분포가 아닌 조건에 의해 분류하는 RF 모델을 활용하였는데 이는 개별 트리 모델의 단점인 학습 데이터의 미세한 변동과 적은 오차에도 결과 값이 크게 영향을 받는 단점을 보완한 방법이다.

다음은 RF 기반 학습 기법을 위하여 설정한 가정 사항이다.

- 가) 예측 값은 LOS 또는 NLOS로 분류됨.
- 나) 총 4개의 UWB 센서 중 가장 짧게 측정된 센서를 가장 신뢰성이 높다고 가정하고 이를 기준으로 남은 센서들의 신뢰성을 검증함.
- 다) 2개 이상의 센서가 신뢰성이 낮은 경우를 NLOS로 분류함.

위와 같은 기준으로 가정한 이유는 다음과 같다. 먼저, 가장 짧은 값을 신뢰성이 높다고 가정한 이유는 전파의 특성 때문이다. 즉, 장애물과 만나게 되면 회절, 반사, 또는 굴절하는 성질이 있는 전파의 특성 상 NLOS 환경에서의 거리정보의 오차 값의 99%가 양의 값을 가지기 때문에 측정된 거리 값 중 가장 짧게 측정된 값을 가장 신뢰성이 높다고 가정하였다. 두 번째로 Anchor의 위치가 고정되어 있는 상태에서 Tag의 위치만 변하는 차량용 키를 고려한 실험 환경에서 정확한 하나의 거리 값을 가지고 있다면 나머지 Anchor에서 측정 될 수 있는 거리 값에 대한 최대 허용 범위를 제한할 수 있다. 이러한 사실을 기반으로 최대 허용 범위를 넘어간 경우 신뢰성이 떨어지는 값으로 구분하였다. [그림 5]는 위 설명에 대한 이해를

돕기 위한 참고 그림이다.

마지막으로 ToA 기반의 측위는 3개의 정확한 값이 존재한다면 오차보정 없이 정확한 측위가 가능하기 때문에 NLOS 상태의 기준을 신뢰성이 없는 데이터 2개 이상으로 가정하였다.

하지만 ML기법은 데이터를 수집한 동일한 학습환경에서는 잘 동작하지만 장소, 장애물과 같은 환경이 변화함에 따라 Input data가 바뀌어 ML 모델의 정확도가 감소한다는 한계점을 가지고 있다. 본 논문의 연구에서는 실내 주차장, 실외 주차장 등의 한정적인 장소에서 데이터를 수집하였기 때문에 환경이 변화함에 따라 ML모델의 정확도가 감소할 수 있다.

3.3 Error Mitigation

RF를 통한 분류 과정을 거치면 [그림 6]과 같이 가장 신뢰성이 높은 거리 정보와 신뢰성이 부족한 거리 정보가 구분된다. 해당 정보들은 오차를 포함하며 각 Anchor 간의 거리 정보에 대한 오차가 얼마나 포함되어 있는지를 예측할 수 없기 때문에 남은 거리정보만으로 측위를 할 수 없다. 하지만 Tag의 위치는 가장 신뢰성이 높은 정보로 생성된 원의 위에 있다고 예상할 수 있다. 위와 같은 가정을 기반으로 신뢰성이 가장 떨어지는 데이터를 제외하고 비교적 높은 신뢰성을 가진 두 개의 Anchor에서 측정된 거리정보를, 측정된 가장 신뢰할 수 있는 거리정보와 각 Anchor의 거리정보의 차이만큼의 비율을 이용하여 감소시킨다. 여기서 해당 비율을 거리정보를 기반으로 한 이유는 앞서 말한 바와 같이 UWB센서로 측정하는 거리정보들은 양의 값을 가지기 때문에 거리정보가 가질 수 있는 최댓값보다 더 긴 거리로 측정되었다면 해당 거리정보는 더 많은 오차를 포함했을 가능성이 높기 때문이다.

신뢰성이 낮은 거리정보로 생성된 원들은 교점을

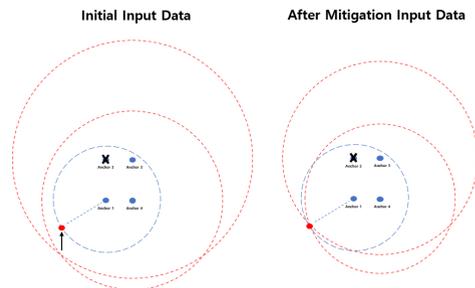


그림 6. Error Mitigation Step
Fig. 6. Error mitigation step

가질 것이고 이를 반복적으로 수행하면 보정된 거리 정보에 의해 생성된 2개의 원의 교점이 신뢰성이 높은 원의 위에 형성되면 해당 좌표를 Tag의 위치로 결정한다. 하지만 신뢰성 낮은 거리정보에 의해 만들어진 원들의 교점이 신뢰성이 높은 원의 위에 생성되지 않는다면 교점과 신뢰성이 높은 원과의 거리가 가장 짧은 좌표를 Tag의 위치로 결정한다. 이러한 보정 과정을 거치면 [그림 6]의 오른쪽 그림과 같이 하나의 좌표 위에 3개의 원의 교점이 존재하게 되며 Tag의 위치 좌표를 근사할 수 있다.

[그림 7]은 실시간으로 측정되는 거리 정보들의 관계만을 이용하여 해당 위치를 추정하는 오차 보정 알고리즘의 의사코드이다. 코드의 해석은 다음과 같다. 먼저 각 Anchor에서 측정된 거리값을 저장한다. 이 값은 LOS/NLOS 환경을 구분하는 ML 모델의 입력 값이 된다. ML 모델이 거리값을 통해 Tag의 위치를 NLOS 환경으로 분류한다면 본 논문에서 제안한 오차 보정 알고리즘을 적용 시킨 이후 삼변측위를 통해

Algorithm. Error Mitigation.

Input. distance_data_list = $[d_1, d_2, d_3, d_4]$ where each d_i is an input.

d_1 is a distance of Anchor₁ to Tag

d_2 is a distance of Anchor₂ to Tag

d_3 is a distance of Anchor₃ to Tag

d_4 is a distance of Anchor₄ to Tag

Output. State information S and

Coordinates generated using distance_data_list (x, y)

Method.

```

begin
  Deep_learning model  $\leftarrow$  distance_data_list
  if  $S = 0$  then // It means LOS
    begin
      ToA_Algorithm  $\leftarrow$  distance_data_list
      return Coordinates
    end
  else then
    begin
      if  $d_1$  is reliable then // Assume that  $d_1$  is most reliable
        begin
          delete most unreliable  $d_3$  // Assume that  $d_3$  is most unreliable
          while true do
            begin
               $d_2 \leftarrow d_2 - d_2/100$ 
               $d_4 \leftarrow d_4 - d_4/100$ 
              Find_circle_intersection  $\leftarrow d_2, d_4$ 
              if there's a circle_intersection on the circle made at  $d_1$ 
                ToA_Algorithm  $\leftarrow [d_1, d_2, d_4]$ 
                return Coordinates
              end
            end
          end
        end
      end
    end
  end
end

```

그림 7. 제안 알고리즘의 의사코드
Fig. 7. Sudo code of proposal algorithm

Tag의 2차원 좌표를 계산한다.

IV. 실험 환경 및 성능 분석

4.1 실험 환경

[그림 8]은 차량에 UWB 센서를 부착한 위치와 실험환경 모델링을 나타낸다. UWB 거리정보 데이터는 Decawave 사의 MDEK-1001 UWB 센서를 이용하여 수집하였다. UWB 센서는 차량의 전·후위 좌·우측에 부착하였고 차량의 중앙을 중심으로 1 ~ 7m까지의 범위를 설정하고 0.5m 단위로 거리 정보 데이터를 수집하였다. 거리정보 데이터는 LOS 및 NLOS 각각의 환경에서 차량에 부착된 1번에서 4번 Anchor와 TAG 사이에 측정된 TWR 거리 데이터이다. 수집 과정에서 실내 주차장과 실외 주차장을 옮겨가며 차량의 위치를 벽 옆과 다른 차량 사이에 위치시켜 다양한 환경에서의 오차를 발생시켰다.

수집된 데이터는 8:2의 비율로 Training, Test 데이터로 분할하여 실험에 사용하였다. ML모델을 통해 얻어진 State 정보를 기반으로 KF와 본 논문에서 제안한 알고리즘을 적용하여 위치 좌표 값을 계산하였고 측정된 위치를 실제 값과 비교하여 오차의 크기를 (m) 단위로 구하였다.

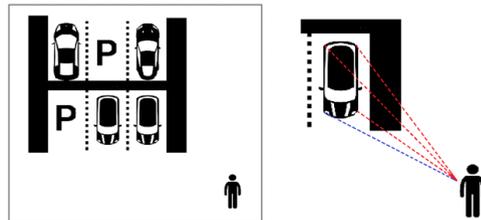


그림 8. Decawave MDEK-1001 UWB 센서가 장착된 실제 차량 기반 실험용 테스트베드 개요도

Fig. 8. The schematic diagram of the test bed

4.2 실험 결과 분석

표 1은 총 3334개의 데이터를 8:2의 비율로 나눠 2668개의 데이터로 RF 모델을 학습시킨 후 666개의 Test data를 이용하여 분류를 진행한 결과이다. RF 모델의 정확도는 94.6%로 높은 분류 성능을 보였다.

[그림 9]는 Tag의 위치를 일정한 간격으로 위치 시킨 이후 해당 위치에서 센서에 의해 측정된 거리값을 활용하여 측위한 결과를 2차원 좌표로 나타낸 그림이다. 차량을 중심으로 한 Tag 위치의 실제 좌표 값과 측정된 좌표에서 KF를 적용한 결과와 제안한 알고리즘을 적용하였을 때의 결과 값을 비교한 결과를 2차

표 1. 다양한 기계학습 모델별 성능 지표
Table 1. Accuracy of various machine learning models.

기계학습 모델	분류 정확도
Random Forest	94.6 %
Decision Tree	87.7 %
SVM	87.8 %
KNN	88.4 %
NB	89.3 %

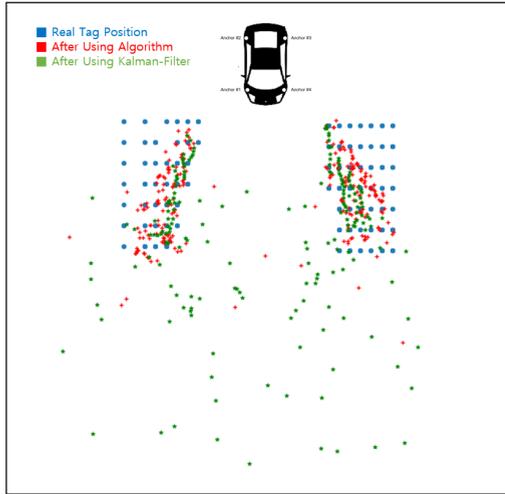


그림 9. 제안 알고리즘을 적용 후의 측정 좌표와 Kalman-filter 적용 후의 측정 좌표 비교
Fig. 9. Comparing the measurement coordinates after applying the proposed algorithm with the measurement coordinates after applying Kalman-filter

원 좌표로 나타낸 그림이다.

[그림 10]은 NLOS 환경에서 Tag의 위치가 차량의 중심에서 멀어짐에 따라 오차를 전혀 보정하지 않고 삼변측위 하였을 때와 KF를 적용한 이후 삼변측위 하였을 때, 마지막으로 제안 알고리즘을 통해 오차를 보정한 이후 삼변측위를 하였을 때 측정된 2차원 좌표의 위치를 실제 Tag의 위치와 비교하였을 때 발생한 오차를 나타낸다. 이 때 Error rate는 실제 Tag의 좌표 값과 측정된 좌표값의 거리 차를 나타낸다. [그림 11]은 [그림 9]에서 발생한 각 좌표의 오차의 크기를 나타낸다. 왼쪽의 Non-Mitigation 결과는 기계학습 모델로 환경을 구분한 이후 NLOS로 분류 되었을 때 어떠한 보정 알고리즘도 거치지 않고 Anchor와 Tag의 거리를 구해서 TOA 기법을 통해 계산한 방법에 대한 오차를 의미한다.

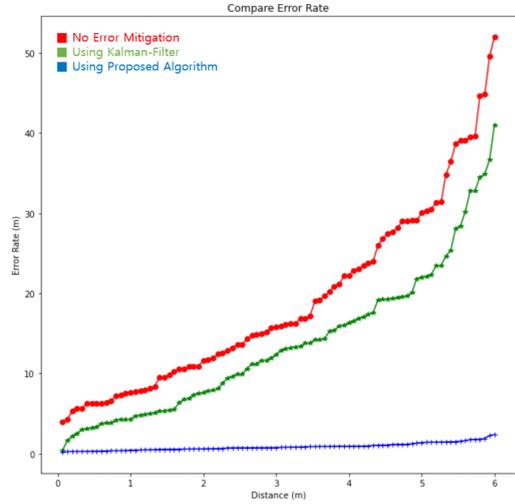


그림 10. NLOS 환경에서 Tag의 위치가 차량의 중심에서 멀어짐에 따라 발생하는 오차율 비교
Fig. 10. Comparison of error rates

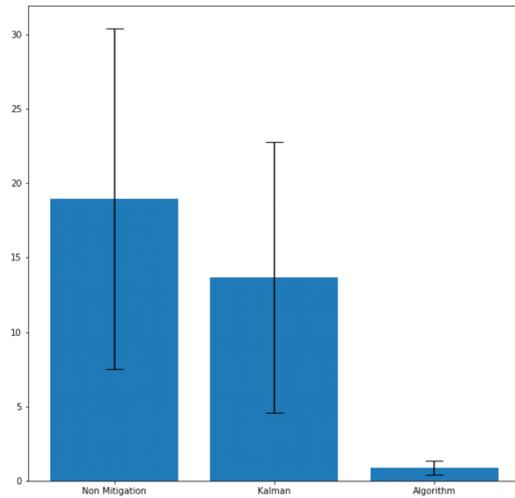


그림 11. 측위 오차율 비교
Fig. 11. Comparison of error rates

[그림 11]의 가운데 그래프는 NLOS 환경에서 KF를 적용하여 오차를 보정하고 TOA 기법을 이용하여 위치 좌표를 계산하였을 때의 오차를 의미한다. KF는 과거의 데이터가 없거나 부정확할 경우 오차 보정율이 떨어져 차량 환경에서 적용하기에는 적절하지 않다는 것을 알 수 있다. 그러나 본 논문에서 제안한 알고리즘의 오차 값은 0.25~1.5(m)로 뛰어난 정확도를 나타낸다.

V. 결 론

본 논문에서는 차량용 디지털 키와 같이 고정밀 측위 정보를 요구하는 응용 서비스의 경우 LOS 환경에서 NLOS 환경으로 이어지는 상황보다 그 반대의 상황이 더 빈번하다는 사실에 착안하여 거리정보를 UWB 무선 통신을 통해 인지하였을 때 초기의 위치를 정확하게 측정하는 알고리즘을 제안하였다. NLOS 환경을 판별하는 방법으로는 UWB 센서를 통해 얻은 거리정보 데이터를 활용하여 ML 앙상블 학습모델인 RF를 통해 구분하였다. 그리고 실제 차량에 Decawave UWB Anchor를 장착한 후 Tag의 위치를 추정한 실험 결과, 기존의 KF 기반 오차 보정 알고리즘을 적용한 경우에 비해 매우 우수한 정확도를 보일 수 있음을 확인하였다.

References

- [1] W. Hilliard, "Apple Car Key could adopt Ultra Wideband support later in 2021," Apr. 20, 2021, from <https://appleinsider.com/article/>
- [2] I. Oppermann, M. Hamalainen, and J. Linatti, "UWB Theory and Applications," John Wiley & Sons Ltd, pp. 30-39, 2004.
- [3] S. Gezici and H. V. Poor, "Position estimation via ultra-wide-band signals," in *Proc. IEEE*, vol. 97, no. 2, pp. 386-403, 2009.
- [4] J. Khodjaev, Y. Park, and A. S. Malik, "Survey of NLOS identification and error mitigation problems in UWB-based positioning algorithms for dense environments," *Annals of Telecommun.*, vol. 65, pp. 301-311, 2010.
- [5] J. Schroeder, S. Galler, K. Kyamakya, and K. Jobmann, "NLOS detection algorithms for ultra-wideband localization positioning, navigation and communication," *WPNC '07. 4th Wkshps.*, pp. 159-166, 2007.
- [6] J. Borras, P. Hatrack, and N. B. Mandayam, "Decision theoretic framework for NLOS identification," *VTC 98*, pp. 583-587, Ottawa, Canada, May 1998.
- [7] I. Guvenc, C.-C. Chong, and F. Watanabe, "NLOS identification and mitigation for UWB localization systems," *IEEE WCNC 2007*, pp. 1571-1576, Hong Kong, China, Mar. 2007.
- [8] C. Jiang, J. Shen, S. Chen, Y. Chen, D. Liu, and Y. Bo, "UWB NLOS/LOS classification using deep learning method," *IEEE Commun. Lett.*, pp. 2226-2230, 2020.
- [9] M. Heidari, F. O. Akgul, and K. Pahlavan, "Identification of the absence of direct path in indoor localization systems," *IEEE Int. Symp. Pers., Indoor, and Mob. Radio Commun.*, pp. 1-6, 2007.
- [10] S. Wu, Y. Ma, Q. Zhang, and N. Zhang, "NLOS error mitigation for UWB ranging in dense multipath environments," *2007 IEEE Wirel. Commun. and Netw. Conf.*, pp. 1567-1572, Hong Kong, China, Mar. 2007.
- [11] Z. Hao, B. Li, and X. Dang, "An improved kalman filter positioning method in NLOS environment," *Ch. Commun.*, vol. 16, pp. 84-99, 2007.
- [12] B. Barua, N. Kandil, and N. Hakem, "On performance study of TWR UWB ranging in underground mine," *2018 Sixth Int. Conf. DINWC*, pp. 28-31, Beirut, Lebanon, May 2018.
- [13] M. T. Hoang, B. Yuen, X. Dong, T. Lu, R. Westendorp, and K. Reddy, "Recurrent neural networks for accurate RSSI indoor localization," *IEEE Internet Things J.*, vol. 6, no. 6, pp. 10639-10651, 2019.
- [14] C. Jiang, J. Shen, S. Chen, Y. Chen, D. Liu, and Y. Bo, "UWB NLOS/LOS classification using deep learning method," *IEEE Commun. Lett.*, vol. 24, no. 10, pp. 2226-2230, 2020.
- [15] J. Schroeder, S. Galler, K. Kyamakya, and K. Jobmann, "NLOS detection algorithms for ultra-wideband localization," in *Proc. 4th Wkshps. Positioning, Navig. Commun.*, pp. 159-166, 2007.
- [16] M. Zhou, Y. Tang, Z. Tian, L. Xie, and W. Nie, "Robust neighborhood graphing for semi-supervised indoor localization with lightloaded location fingerprinting," *IEEE Internet Things J.*, vol. 5, no. 5, pp. 3378-3387, 2018.
- [17] A. Nessa, B. Adhikari, F. Hussain, and Xavier N. Fernando, "A survey of machine learning for indoor positioning," *IEEE Access*, vol. 8, pp. 214945-214965, 2020.

이 상 진 (Sang-Jin Lee)



2018년 2월 : 건국대학교 전자학
과 학사
2021년 9월 : 아주대학교 IoT 공
학 석사
<관심분야> 머신러닝, 차량용 네
트워크, 사물인터넷(IoT)

고 영 배 (Young-Bae Ko)



1996년 9월~2000년 7월 : Texas
A&M University (College
Station) 컴퓨터공학 박사
2000년 8월~2002년 8월 : IBM
T.J Watson Research Center
(New York) 전임연구원
2002년 9월~현재 : 아주대학교
정보통신대학 소프트웨어학과/AI융합네트워크학과
교수

<관심분야> 차세대 초지능 통신네트워크(6G), 지능형
사물인터넷(AIoT), 고신뢰 저지연 네트워크
(URLLC), 지능형 에지컴퓨팅(Edge Intelligence),
고정밀 실시간 측위 기술 및 서비스 등.

박 지 웅 (Ji-Woong Park)



2016년 2월 : 아주대학교 소프트
웨어융합과 학사
2016년 3월~현재 : 아주대학교
AI융합네트워크학과 석박통
합과정 중
<관심분야> 사물인터넷(IoT), 무
선 네트워크, 인공지능