

Deep Learning-based UWB Distance Measurement for Wireless Power Transfer of Autonomous Vehicles in Indoor Environment

Hye-Jung Kim[†] · Yong-ju Park^{††} · Seung-Jae Han^{†††}

ABSTRACT

As the self-driving car market continues to grow, the need for charging infrastructure is growing. However, in the case of a wireless charging system, stability issues are being raised because it requires a large amount of power compared with conventional wired charging. SAE J2954 is a standard for building autonomous vehicle wireless charging infrastructure, and the standard defines a communication method between a vehicle and a power transmission system. SAE J2954 recommends using physical media such as Wi-Fi, Bluetooth, and UWB as a wireless charging communication method for autonomous vehicles to enable communication between the vehicle and the charging pad. In particular, UWB is a suitable solution for indoor and outdoor charging environments because it exhibits robust communication capabilities in indoor environments and is not sensitive to interference. In this standard, the process for building a wireless power transmission system is divided into several stages from the start to the completion of charging. In this study, UWB technology is used as a means of fine alignment, a process in the wireless power transmission system. To determine the applicability to an actual autonomous vehicle wireless power transmission system, experiments were conducted based on distance, and the distance information was collected from UWB. To improve the accuracy of the distance data obtained from UWB, we propose a Single Model and Multi Model that apply machine learning and deep learning techniques to the collected data through a three-step preprocessing process.

Keywords : UWB, Indoor Localization, Wireless Power Transfer, SAE J2954, Autonomous Vehicle

실내환경에서의 자율주행차 무선 전력 전송을 위한 딥러닝 기반 UWB 거리 측정

김혜정[†] · 박용주^{††} · 한승재^{†††}

요약

최근 자율주행차 시장이 지속해 성장함에 따라 충전 인프라에 대한 필요성이 커지고 있다. 그러나 무선 충전 시스템의 경우 기존 유선 충전에 비해 대출력이 요구되어 안정성 문제가 제기되고 있다. 자율주행차 무선 충전 인프라를 구축하기 위한 표준으로는 SAE J2954가 존재하며 해당 표준에서는 차량과 전력 전송 시스템 간의 통신 방법에 대해 정의한다. SAE J2954에서는 자율주행차량의 무선 충전 통신 방법으로 Wi-Fi, Bluetooth 및 UWB와 같은 물리적 미디어를 사용해 차량과 충전 패드 간의 통신을 활성화할 것을 권장한다. 특히 UWB는 실내 환경에서 견고한 통신 능력을 보이고 간섭에 민감하지 않기 때문에 실내의 충전 환경에서 적합한 솔루션이다. 해당 표준에서는 무선전력전송 시스템을 구축하기 위한 프로세스로 충전 시작부터 충전 완료까지를 여러 단계로 구분하였다. 본 연구에서는 UWB 기술을 사용하여 무선전력전송 시스템의 한 가지 프로세스인 Fine alignment의 수단으로 사용한다. 실제 자율주행차 무선전력전송 시스템에 적용 가능성을 판단하기 위해 거리에 따라 실험을 수행하였으며 UWB로부터 거리 정보를 수집하였다. UWB로부터 얻어진 거리 데이터의 정확도를 향상시키기 위해 수집한 데이터를 세 단계의 전처리 과정을 거쳐 머신러닝과 딥러닝 기법을 적용한 Single Model과 Multi Model을 제안한다.

키워드 : UWB, 실내측위, 무선전력전송, SAE J2954, 자율주행차

※ 본 연구는 2021 과학기술정보통신부의 재원으로 정보통신 기획평가원(IITP) 지원을 받아 수행된 연구임(No. 2021-0-00058, 무선 전력 전송 융합활성화 센터 구축 및 운영).

※ 본 연구는 2022년 산업통상자원부의 재원으로 한국산업기술평가관리원 (KEIT) 지원을 받아 수행된 연구임(No. 20018930, 전기차 충전을 위한 오픈 매칭형 에너지 ODD(On-Demand Delivery) 서비스 개발).

[†] 준회원 : 연세대학교 컴퓨터과학과 석사

^{††} 비회원 : 한국전자기술연구원 스마트네트워크연구센터 팀장

^{†††} 비회원 : 연세대학교 컴퓨터과학과 교수

Manuscript Received : July 28, 2023

First Revision : September 21, 2023

Accepted : October 5, 2023

* Corresponding Author : Seung-Jae Han(seungjaehan@yonsei.ac.kr)

1. 서 론

무선전력전송(WPT, Wireless Power Transfer)은 물리적인 연결없이 전기 에너지를 전송하는 기술을 말하며 무선 충전을 가능케 할 수 있다. 미래 자동차는 자율주행차, 전기차라는 두 개의 키워드를 중심으로 연구가 활발히 진행되고 있으며 그중에서도 무선 충전 기술이 주목받는 신형 기술이다. 현재 유선 충전이 상용화되어 있지만 충전하기 위해 꽂는 인렛의 규격이 국가별로 상이하기 때문에 규격화되기 어려운 점이 있다. 무선 충전은 플러그를 차량에 연결할 필요가 없어 유선 충전의 단점을 개선해 편리함을 제공한다. 자율주행차 무선전력 전송을 시작하기 전 무선전력전송 송수신 패드 간의 정렬(alignment)은 필수적으로 규정되어야 한다. 보통 휴대폰을 충전하기 위해 사용되는 15W는 저전력이라 표현되며 그 외의 가전, 로봇의 경우 중전력, 자율주행차를 충전하기 위한 전력은 11kW의 대전력으로 표현한다. 이렇게 큰 대전력을 전송해야 하는 충전을 시작하기 전, 정렬 확인(alignment check)가 이루어진다. 현재 전기차 및 자율주행차를 위한 표준으로는 국제자동차기술자협회(SAE)에서 표준화한 J2954가 가장 많이 사용되고 있으며 본 표준 3장에서는 충전하기 전 차량을 탐색(navigate)하는 방법의 하나로 안내(guidance)를 송수신 패드 통신으로 제시한다.[3]

본 연구는 무선전력전송 시작 전 차량의 송수신단 패드의 거리를 UWB 모듈을 통해 측정하고 오차 정렬(mis-alignment)을 줄이기 위해 진행되었다. 거리를 측정하기 위해서 레이더, 레이저 등 많은 기술이 사용된다. 예를 들어, 건설 현장에서 실제 거리를 측정하는 데 사용되는 레이저 거리 측정기(LDM)의 경우 대상 물체를 향해 레이저 빔을 쏘고 반사되는 데 걸리는 시간을 측정하여 거리를 계산하는 레이저이다. LDM은 높은 정확도와 휴대성이 편리하다는 이점이 있으나 장애물이나 이물질을 관통할 수 없고 간섭에 취약하며 다양한 디바이스와 혼합하여 사용하는 것에 한계가 있다. 이 외에도 차량 통신을 위해 GPS와 Wi-Fi 등이 사용되고 있다. GPS와 Wi-Fi는 차량 간 정보 교환을 위해 사용되지만 GPS의 경우 실내의 벽, 장애물에 의해 신호가 반사될 수 있으며 Wi-Fi의 경우 신호 간섭에 영향을 많이 받기 때문에 본 연구에서는 실내 환경에서 견고한 UWB를 사용한다.

UWB 기술은 장애물 및 다중 경로와 같은 환경에서 높은 수준의 정확도를 제공한다. UWB는 이물질이나 환경적인 요인에 의한 간섭에 강인하도록 설계되었다. UWB 신호 처리로는 시간 영역 분석, 펄스 형성 및 간섭 제거 알고리즘 등 간섭으로부터 원하는 신호를 추출 가능한 기술 등이 존재하며 넓은 범위의 주파수에 걸쳐 에너지를 확산하여 협대역 간섭이나 노이즈에 강인하다. 또한 신호의 전력 수준이 낮고 지속 시간이 짧아 보안 측면에서도 장점이 있다. 무선전력전송 기술은 차량뿐만 아닌 가전이나 로봇과 같은 자율 시스템이 적용될 수 있는 다양한 분야에 적용할 수 있으며 송수신 패드의 정확한 정렬은 효율적이고 안전한 전력 전송을 위해 필수적인 기

술이다. 기존의 정렬 방법에는 수동적인 방법과 센서를 통해 시각적 기반 방식이 존재하나 시간이 많이 소요되고 환경에 따라 오류가 발생하기 쉽기 때문에 무선전력전송 시스템에 적용하기에 한계점이 있었다.

무선 충전을 위해 송수신 패드의 정렬을 맞춰야 하는 이유는 효율성과 안전성을 말할 수 있다. 무선전력전송과 같은 고출력 시스템에서는 송수신단 코일을 적절하게 정렬하지 않고 충전을 시작할 시 효율성이 감소한다. 효율성이 감소하면 충전이 느리게 진행될 뿐만 아니라 에너지 손실로 인한 열 발생이 일어날 수 있다. 또한, 코일이 정렬되지 않았다면 전자기장이 더 강하게 발생하여 인체에 유해하다. 이러한 문제점으로 최근의 자율주행 차량 같은 고출력 시스템에서는 다양한 센서를 사용하여 송수신간의 이격거리를 측정하는 센서를 사용하고 있으며 본 연구에서는 UWB 모듈을 사용하여 차량의 송수신단 패드의 이격거리를 측정하고 무선전력전송 시스템에서의 송수신 패드 정렬 정확도를 향상시킨다. UWB 모듈은 고정밀 거리 측정이 가능하며 신호의 다중경로, 신호 감쇠 및 간섭에 견고성을 제공해 실내측위에서 이점을 제공한다.

UWB 모듈은 송수신 패드에 각각 부착되어 거리가 측정되고 측정된 결과를 바탕으로 Machine learning과 Deep learning 모델 학습에 활용한다. 학습된 모델은 송수신 패드의 최적 정렬 위치를 예측할 수 있고 오차 정렬을 줄여 무선전력전송 시스템의 전반적인 효율성 향상에 기여한다. 기존 정렬의 한계를 극복하고 UWB 기반 거리 측정 시스템이 IoT 및 로봇 등 애플리케이션의 광범위하게 적용될 수 있는 가능성을 보여준다. 본 연구는 무선전력전송에 초점을 맞추었지만, UWB를 기반으로 제안된 프레임워크는 두 물체 간의 정확한 거리 측정 및 정렬을 필수적으로 요구하는 애플리케이션에서도 사용 및 확장가능하다.

2. 관련 연구

2.1 무선전력전송 시스템 통신 연구

1) Wi-Fi(Wireless Fidelity)

Wi-Fi는 2.4GHz 및 5GHz 주파수 대역에서 사용되는 무선 통신 기술로, 무선전력 시스템에서 가장 많이 연구된 방법이다. 중거리까지의 고속 데이터 전송이 가능해 송수신 패드 간의 제어 신호 및 상태 정보 전송으로 유용하다.

2) UWB(Ultra-Wideband)

IEEE 802.15.4a 표준에 따르면 3.1GHz~10.6GHz 주파수 범위에서 500MHz의 대역폭을 사용하는 기술로, 넓은 대역폭에서 임펄스를 사용하여 장애물을 통과에 용이하여 복잡한 실내 환경에서도 정확한 측위와 통신을 제공한다. UWB는 효율적인 충전을 위한 송수신 패드의 정확한 위치 결정 연구가 선행되었으며 센티미터의 정확도를 달성할 수 있다. 저전력 및 고정밀 위치 결정이 가능해 무선전력전송 시스템 데이터 통신에 적합하다.

3) BLE(Bluetooth Low Energy)

BLE는 2.4GHz 주파수 대역에서 작동하며 위치 기반 서비스, IoT, 웨어러블 및 스마트 홈 등 광범위하게 사용된다. 전력 소모가 적은 근거리 무선 통신에 적합한 프로토콜로 연구되었다.

2.2 무선전력전송 시스템 효율성 연구

1) 적응형 튜닝(Adaptive tuning)

자율주행차량의 위치에 따라 바닥에 설치된 충전 패드의 공진 주파수에 대한 피드백을 이용하는 방법이다. 수신된 피드백을 기반으로 공진 주파수가 일치하도록 조정하여 전체적인 전력 전송 효율을 개선시킨다.

2) 동적 전력 제어(Dynamic power control)

송수신 패드 거리에 따라 충전 패드의 전력 출력을 조정하는 방법으로 충전 과정 중 자율주행차량이 이동할 수 있는 상황에 고려될 수 있는 방법이다. 과전력 또는 저전력으로 인한 에너지 손실을 방지하여 무선전력전송 시스템의 안정적인 작동에 기여한다.

3) 위치 결정 알고리즘(Positioning algorithms)

송신 패드로부터 자율주행차량에 부착된 수신 패드로의 상대적인 배치를 최적화하는 방법으로 센서나 카메라를 사용한다. 센서나 카메라의 선택에 따라 정확도, 시스템 복잡성 및 환경 조건 등이 달라질 수 있다는 점을 고려해야 한다. Fig. 1에 각 센서들의 가능한 배치를 보여준다.

- a) 카메라: 송수신 패드의 이미지 또는 비디오의 캡처를 기반으로 다음 이미지를 분석해 자율주행차량의 위치 및 방향을 결정하는 방법이다.
- b) 라이다 센서: 레이저 펄스를 방출해 물체에서 반사되는 시간을 측정하는 고가의 센서로 레이저 광선과 관련된 추가적인 안전 고려 사항이 추가 요구될 수 있다.
- c) 레이더 센서: 자기파를 전송해 경로에 있는 물체로부터 반사되는 반사파의 시간, 주파수 및 위상을 측정해 물체의 거리, 속도, 위치 및 각도를 결정하는 방법이다. 장거리에서 장애물을 통과하는 능력이 뛰어나며 카메라 센서에서 영향받을 수 있는 안개 같은 기후 조건에서도 사




Fig. 1. Positioning of Sensors Used in Positioning Algorithms

용할 수 있다. 하지만 다른 무선 주파수 장치와의 잠재적인 간섭을 고려해야 한다.

- d) 자기장 센서: 자율주행차량이 충전 패드 주위로 이동할 때 주변 환경의 자기장 세기를 측정하는 방법이다.
- e) 초음파 센서: 초음파는 20kHz 이상 사람의 청력보다 높은 주파수를 이용한다. 고주파 음파를 방출해 물체에 반사되어 음파가 돌아오는 시간을 측정해 송수신 패드 간의 거리를 측정하는 방법이다.

3. UWB를 활용한 거리 측정

3.1 TWR 활용

최근 실내 환경에서 사람이나 물체의 움직임을 탐지하기 위해 사용되는 기술을 실내 측위(indoor localization 또는 positioning)라 하며 해당 기술에서는 UWB가 광범위하게 사용되고 있다. UWB는 넓은 대역폭을 사용해 높은 데이터 속도와 낮은 전력 소비를 가능케 한다. 또한, 임펄스를 통해 다른 무선 신호의 간섭에 내성이 있다. 이러한 특성으로 UWB는 무선 통신 애플리케이션 및 실내 측위 분야에서 활발하게 사용되고 있다.

UWB는 Tag와 Anchor 시스템을 이용해 실내 측위 및 추적에 사용할 수 있다. Tag는 움직이는 사람 및 사물에 부착되어 고정된 위치에 부착된 Anchor로 UWB 신호를 전송한다. Tag와 Anchor 두 지점 간 수평거리를 결정하는 과정을 레인지(Ranging)이라고 하며 UWB에는 ToA(Time of Arrival), TWR(Two Way Ranging), AoA(Angle of arrival) 등 UWB 펄스의 도착 시간 및 각도를 이용하여 다양한 범위 및 위치 정보를 측정하는 레인지 방법이 있다.

TWR은 송수신 장치의 양방향 통신으로 거리를 측정하는 방식이며 송수신 시간 정보가 포함된 메시지를 교환하여 거리가 측정된다. Fig. 2와 같이 Anchor 측에서 poll 메시지를 Tag 측으로 전송한다. Tag 측에서는 Anchor 측으로부터 메

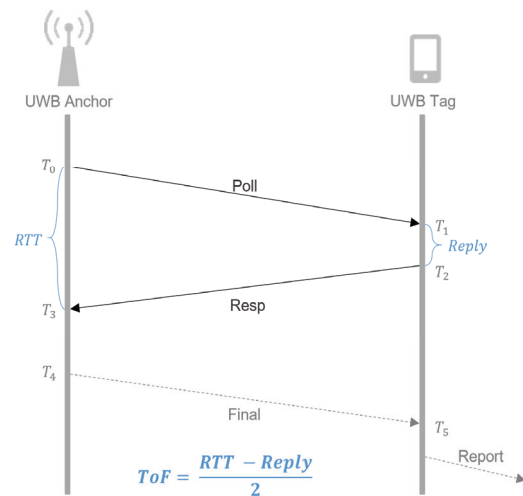


Fig. 2. TWR Communication Method of UWB

시지를 수신하여 이에 대한 응답으로 Resp 메시지를 보낸다. TWR는 ToF기술을 활용한다. ToF는 UWB 신호가 송신기로부터 수신기로 이동하고 다시 돌아오는 데 걸리는 시간을 측정하여 거리를 계산하는 ranging 방법이다.

3.2 UWB 거리 측정 데이터 전처리

전처리는 UWB 모듈로부터 수집된 데이터 세트를 학습시키기 전 데이터의 이상치를 제거하거나, 전체적인 값을 증가시키거나 감소시킴으로써 데이터를 축소하거나 확대하고, 필터를 사용함으로써 수행될 수 있다. 전처리는 모델의 성능을 향상시키고 데이터를 효과적으로 학습하도록 기여한다.

1) 이상치 제거

이상치를 제거하는 것은 존재하는 데이터 중에 크게 다른 값을 가지는 데이터를 제거하는 것을 말한다. 이상치는 측정 시 발생하는 오류, 노이즈 외에 또 다른 요인들로 인해 다양하게 발생할 수 있다. 만약 이상치가 제거되지 않은 데이터 세트를 그대로 학습시킨다면 극단적인 값들에 의해 모델이 옳지 않은 예측을 하게 하거나 성능에 좋지 않은 영향을 줄 수 있다. 이상치를 제거하기 위한 기술로는 여러 개가 존재하지만 본 연구에서는 사분위수 범위(IQR) 방법을 사용한다. 데이터의 제1사분위수(Q1), 제3사분위수(Q3)를 계산하여 Q3에서 Q1을 빼 IQR을 계산한다. 최종적으로 범위는 $(Q1 - 1.5 * IQR, Q3 + 1.5 * IQR)$ 이 되며 해당 범위를 벗어나는 모든 데이터를 이상치라고 표현하며 제거된다.

2) Scale 조정

Scale 조정은 전체적인 데이터 값을 축소하거나 확대하는 전처리 방법이다. UWB 모듈 특성상 데이터가 실제값보다 높게 측정되는 경향이 있거나 낮게 측정되는 경향을 반영해 전체 데이터를 각 1cm, 3cm, 5cm, 7cm, 9cm씩 일정 수치 감소시키거나 증가시킨다. Scale 조정을 통해 데이터를 보다 관리 가능한 범위로 가져오며 일부 학습에서 효과적으로 작용한다.

3) 칼만 필터(Kalman filter)

본 연구에서 칼만 필터는 거리 측정 데이터의 전처리 용도로 사용되었지만 일반적으로 컴퓨터 비전, 센서 융합 등 다양한 분야에서 사용되고 있는 필터이다. 칼만 필터는 동적 시스템에서의 이미지, 센서에서 얻은 데이터 값 등에 대해 실제 값을 가늠할 수 있는 형태로 사용되는 알고리즘이다. UWB 모듈로부터 얻은 데이터를 기반으로 칼만 필터는 현재 값과 추정 값을 예측한다. filter는 예측값을 통해 업데이트하고 불확실한 값들에 대해 처리하기 때문에 노이즈나 측정 오류의 영향을 줄이는 데 기여하여 전체적으로는 데이터의 평활화를 이룰 수 있다. 칼만 필터의 전처리 데이터를 사용할 경우 모델의 성능을 개선하는 데 도움을 줄 수 있다. 칼만 필터는 Python에서 칼만 필터 구현을 제공하는 pykalman, filterpy 등의 라이브

러리를 또는 프레임워크를 사용하여 소프트웨어로 구현될 수 있다.

3.3 UWB 거리 측정 정확도 개선을 위한 Single Model

1) Linear Regression

UWB 모듈에서 얻어진 측정 거릿값과 실제 거릿값 사이가 선형 관계에 있는 경우, 이 선형 관계를 관측하여 정확한 예측을 하기 위해 선형 회귀를 사용한다. 선형 회귀는 모델 결과를 왜곡할 수 있는 극단적인 이상치 값을 처리하는 데 효과적이다. 이러한 특성으로 선형 회귀는 극단적인 이상치 값을 제거하고 예측 정확도를 향상시킬 수 있다. 선형 회귀를 통해 UWB 측정 거릿값과 예측 거릿값 사이의 선형 관계를 모델링하여 예측 정확도를 향상시키는 것이 목표이다.

2) SVR(Support Vector Regression)

SVR은 선형 회귀와는 다르게 입력과 타겟 변수 간의 비선형 관계를 모델링할 수 있기 때문에 노이즈 데이터를 처리하여 데이터를 예측할 수 있는 장점이 있다. 데이터가 복잡하거나 비선형 관계에 있을 때는 선형 회귀보다 적합하게 사용될 수 있기 때문에 SVR을 선정하였다. SVR 알고리즘 최적화를 위한 파라미터로는 kernel, C, Epsilon, gamma 등이 있다. SVR에서 사용되는 매개변수는 학습 데이터의 과적합 또는 과소적합을 방지하고 최적화될 수 있도록 조정되어야 하며 본 연구에서는 grid search를 통해 최적의 하이퍼파라미터가 선정되었다. SVR은 고차원 공간에서 예측된 거릿값과 측정 거릿값 사이의 마진(margin)을 최대화 하기위한 초평면을 찾고 [8] 입력 변수와 출력 변수 간의 비선형 관계를 모델링하여 예측 정확도를 향상시키는 것이 목표이다.

3) MLP(Multi Layer Perceptron)

MLP는 여러 계층의 뉴런으로 구성된 일종의 신경망으로 은닉층(hidden layer)를 통해 네트워크의 입력층(input layer)의 더 복잡한 피쳐(feature)를 학습시키고 모델의 정확도를 향상시킨다. MLP는 분류, 회귀 및 패턴 인식을 비롯한 작업이 가능하며 데이터의 복잡한 패턴과 관계를 학습하기 때문에 입출력 간의 관계가 복잡한 경우에도 비선형 함수를 근사화시킬 때 유용한 Deep learning 기법이다. MLP 최적의 성능을 결정하기 위해 다양한 요소가 고려되어야 한다. 실제값인 라벨과 함께 학습 데이터가 네트워크에 전달되며 각 계층으로부터 가중치, 편향을 계산해 다음 계층과 연결되며 활성화 함수와 함께 계산되는 매개변수이다. 실제값과 예측값 간의 차이를 측정하는 손실 함수는 이러한 매개변수를 최소화되는 방향으로 조정되며 이러한 프로세스는 옵티마이저 알고리즘을 통해 수행된다. 또한 과적합을 방지하기 위한 다양한 방법이 적용될 수 있다. 본 연구에서는 UWB 모듈에서부터 측정된 거리와 정확도 사이의 관계를 모델링하기 위해 MLP가 사용되었으며 사

용되는 매개변수가 다양하기 때문에 하이퍼파라미터 최적화를 위해 randomized search를 사용하여 가능한 조합을 탐색한 효율적인 최적화를 고려하였다. 결론적으로 입력과 출력 사이의 복잡한 비선형 관계를 학습하는 능력이 있는 MLP를 통해 UWB 측정 거릿값 자체의 특징을 추출하여 정확도를 개선시킬 수 있다.

4) LSTM(Long Short-Term Memory)

LSTM은 UWB 신호와 같은 시계열 데이터를 처리하도록 설계된 일종의 RNN 유형으로 정확성을 향상시키기 위해 UWB 애플리케이션에서도 다양하게 사용된다. LSTM은 기존의 RNN과 달리 긴 데이터 시퀀스로부터 특정 정보를 선택적으로 저장하거나 잊어버릴 수 있는 메모리 셀이 존재한다. 이렇게 LSTM은 데이터로부터 시간적 종속성을 캡처하는데 용이 [10]하기 때문에 시간 및 거리에 따른 장치 이동의 특성이 반영되어 측정된 UWB 거리 데이터의 정확도를 향상시킬 수 있다. 또한 입력 데이터의 가변 길이 시퀀스를 처리할 수 있어 UWB 모듈로부터 측정되는 횟수가 다른 데이터 세트에서 적합하게 사용되어 UWB 측정 거리의 정확도를 개선시킬 수 있다. 본 연구에서는 LSTM의 하이퍼파라미터를 최적화하기 위해 MLP와 마찬가지로 randomized search를 수행하였다.

5) CNN(Convolutional Neural Network)

CNN은 이미지나 비디오 및 신호 처리 작업에서 공간 및 시간 패턴을 학습하는데 일반적으로 사용되는 신경망이다. 이러한 특성으로 컴퓨터 비전에서 많이 사용되지만, CNN은 합성곱층, 풀링층(convolution layer, pooling layer)을 통해 입력 데이터에서 피처를 추출한다. convolution layer는 다중으로 사용하게 되면 점점 복잡해지는 패턴과 입력 데이터 간의 관계를 학습하여 최종 예측 정확도를 향상시킬 수 있다. UWB로부터 측정된 거리 데이터와 같은 시계열 데이터와 같은 연속적인 값에서도 특징을 추출하고 Tag와 Anchor 사이의 실제 거리를 더욱 정확하게 예측하는데 용이하여 많이 적용되어 왔다. UWB로부터 측정된 거리를 시간 경과에 따라 패턴을 학습해 거리를 예측한다. CNN은 관련 피처를 학습하기 위해 네트워크 아키텍처 및 하이퍼파라미터가 신중하게 조정되어야 하며 본 연구에서는 randomized search를 통해 하이퍼파라미터를 최적화하였다.

3.4 UWB 거리 측정 정확도 개선을 위한 Multi Model

Multi Model에 해당하는 Hybrid Model과 Ensemble Model은 Machine learning과 Deep learning을 통해 구축되었다. Hybrid 및 Ensemble은 종종 Single Model보다 성능이 뛰어난 것으로 확인되었으며 두 모델 모두 여러 모델을 결합하여 약점을 극복하고 정확도를 향상시키는 것이 기본 아이디어이다. 여러 연구에서 Hybrid와 Ensemble을 결합하여 사용하거나 Ensemble의 하위 구조로 Hybrid Model을 설명하는




Fig. 3A. Structure of Hybrid Model




Fig. 3B. Structure of Ensemble Model

관점도 있지만, 이 둘을 개별적인 Multi Model로 보는 관점도 있다. 본 연구에서는 Fig. 3A의 경우와 같이 각 Model을 독립적으로 훈련시킨 후 모델의 예측이 아닌 출력의 차원을 결합한다는 점에서 Hybrid Model을 정의한다. Fig. 3B Ensemble의 경우 각 모델에 대해 예측이 최종 예측을 얻기 위해 평균화와 같은 방법을 통해 결합한다.

1) Hybrid Model

Hybrid Model은 전반적인 모델의 성능을 향상시키는 것으로 알려져 있으며 다양한 유형의 모델이나 기술을 결합한 방법이다. Hybrid Model의 아이디어는 하나의 모델의 강점이 다른 모델의 약점을 보완하여 더 정확하고 강력한 모델을 만들 수 있다는 것에서 시작한다. 서로 다른 알고리즘의 강점을 결합하게 되면 개별 모델을 사용한 경우에 비해 더 많은 정보를 추출할 수 있어 상대적으로 작은 데이터 세트에서도 유용하게 사용될 수 있다. 예를 들어, UWB 거리 측정 데이터를 Linear regression과 LSTM을 결합한 Hybrid Model을 통해 거리를 예측한다면 데이터의 Linear regression의 선형적인 특성과 LSTM의 시간 종속성을 캡처하는 두 가지 특성을 모두 고려할 수 있다. 따라서 서로 다른 모델의 출력을 결합하거나 기술을 통합하여 Single Model보다 더 높은 정확도를 가지는 모델을 만들고 학습하는 방법이다. 본 연구에서는 Linear regression과 SVR을 각 MLP에 결합하여 선형적인 특성과 비선형적인 특성을 강점으로 이용하여 정확도를 비교하였다.

- a) Linear regression 및 MLP 기반: 데이터 변수 간의 선형 및 비선형 관계를 모두 캡처하기 위해 모델링하였다. Linear regression은 이상치를 제거 및 과적합을 줄이는데 효과적이며, MLP를 통해 고차원 데이터를 처리하여 보이지 않는 데이터의 일반화가 가능한 특성을 이용하였다.
- b) SVR 및 MLP 기반 Hybrid Model: SVR과 MLP는 모두 비선형 모델로 표현할 수 있으나 SVR은 커널 함수를 사용하여 데이터의 비선형 관계를 캡처할 수 있도록 설계되었으며, MLP의 경우 여러 계층의 비선형 변환을 사용

한 모델이다. 결론적으로 SVR과 MLP 기반 Hybrid Model은 SVR을 통해 모델을 정규화하고 MLP 모델에서 문제가 될 수 있는 과적합을 방지하는데 용이하다.

2) Ensemble Model

Ensemble Model은 동일하거나 서로 다른 다양한 알고리즘을 사용하여 예측을 평균화로 결합하기 때문에 모델의 최종 출력의 전반적인 정확도를 향상시킬 수 있을 뿐만 아니라 일반화되기 때문에 과적합을 줄일 수 있는 모델이다. Bagging, Boosting 및 Stacking 방식을 통해 예측을 결합하여 더 정확한 모델을 만들며 현재 많이 사용되는 Ensemble Model은 Random Forest이다. Ensemble Model은 개별 모델의 bias나 variance가 높을 때 정확도 향상을 위해 효과적으로 사용된다. Ensemble Model은 다양한 유형의 모델을 하위 집합으로 두고 각 하위 모델의 예측을 결합하여 최종 추정치를 생성하여 UWB 측정 거리를 추정하기 위해 사용한다. 본 연구에서는 3개의 LSTM 기반, 3개의 CNN 기반, 단일 LSTM 및 CNN 기반 Ensemble Model을 이용하여 각 Ensemble 모델의 강점을 이용하였다.

- a) LSTM 기반 Ensemble Model: 세 개의 LSTM 모델을 사용하는 경우 세 개의 LSTM 모델에 다양한 아키텍처를 적용하여 독립적으로 학습시킨다. 3개의 LSTM 구조를 사용하여 서로 다르고 넓은 패턴을 캡처할 수 있으며 예측을 평균화하기 때문에 단일 LSTM을 사용하는 것보다 과적합에 더 강할 수 있다.
- b) CNN 기반 Ensemble Model: CNN은 LSTM 기반 Ensemble Model과 같은 장점이 있지만 Convolution layer와 filter에 의해 의미 있는 패턴을 발견하는 로컬한 특성이 없다면 CNN을 사용하더라도 제대로 학습되지 않는다는 문제점이 발생한다. 로컬 특성은 주기적 패턴 또는 시간 종속의 특성을 나타낼 수 있다.
- c) CNN 및 LSTM 기반 Ensemble Model: CNN과 LSTM 구조의 강점을 결합하여 CNN은 입력 데이터로부터 로컬 특성과 LSTM은 시계열 특성을 이점으로 가질 수 있어 각 Single Model로 학습될 때보다 성능이 개선될 수 있다. CNN에서 로컬한 특성이 존재하지 않는 단점을 축소해 LSTM으로 극복할 수 있다.

4. 실험 및 결과 분석

UWB 송수신단 설치 및 실험 환경은 SAE J2954 표준에 기반하였다. 자율주행차량에 부착되는 무선전력전송 장치는 수신단 측에 해당하며 VA(Vehicle Assembly)라 불리며 바닥에 부착된 무선전력전송 장치는 송신단 측에 해당하며 GA(Ground Assembly)라고 불린다. UWB Tag는 보통 움직이는 물체에 부착되기 때문에 VA 측에 부착되며, Anchor는 GA




Fig. 4. Install the UWB DW3000 as a VA UWB Tag

에 부착되어 고정된다. 같은 쌍의 Tag와 Anchor가 각자를 인식하기 위해서 각 모듈의 Poll 및 Resp 메시지를 변경했다. 이렇게 두 쌍의 모듈은 UWB 기술을 사용하여 서로 통신할 수 있으며 Tag와 Anchor 사이의 거리 측정이 가능하다. 한 환경당 UWB 모듈을 두 쌍으로 구성했고 여기서 쌍은 Tag역할을 하는 모듈 하나와 Anchor 역할을 하는 다른 모듈을 뜻한다.

UWB 기술은 일반적으로 Bluetooth나 Wi-Fi와 같은 다른 무선 기술에 비해 온습도 및 기압과 같은 환경적인 요인에 영향을 많이 받지 않지만 다양한 환경을 고려하기 위해 실내 및 주차장에서 측정되었다. 기존 UWB의 연구들은 DW1000을 다수 이용했지만, 2020년에 출시된 DW3000은 DW1000의 업데이트 버전으로 전력 소비가 낮기 때문에 자율주행차량에 부착해서 사용되는 경우 용이하다. 차량의 직진 거리만 측정되었으며 지정 거리를 0cm라 했을 때, 20cm씩 전진하며 160cm까지 총 9번 측정하여 각 자리에서 한 UWB 모듈당 100개 데이터를 수집했다. 그럼에도 UWB 모듈을 통해 거리를 측정하는 경우 장애물에 의해 신호가 감쇠되거나 반사되어 다중경로 간섭 등 환경적인 요소로 인해 정확도에 영향을 미칠 수 있다. 이러한 다양한 환경적 요소로 인해 UWB로부터 측정된 거리 데이터는 실제 거리와 비선형적이고 복잡한 관계를 포함한다. 또한 UWB 거리 측정 데이터는 시계열 또는 공간적인 구조를 나타낼 수 있다.

본 연구에서는 무선전력전송을 위한 송수신 패드 정렬을 위해 UWB 모듈로부터 얻은 거리 측정 대규모 데이터 세트를 수집하고 학습하여 정확도를 향상시켰다. 전반적으로 UWB 모듈 및 차량의 무선전력전송 시작이 가능하기 위한 더욱 정확하고 안정적인 시스템을 구축하는 것에 기여하는 것을 목표로 한다. UWB 측정 정확도 향상을 위해 Machine learning과 Deep learning 모델을 사용하였으며 제안 모델은 시계열 데이터를 처리하기 위해 최근 연구가 진행되고 있다. 향후 추가로 데이터가 측정된다면 Machine learning과 Deep learning은 반복적인 훈련을 통해 정확도가 지속해 개선될 수 있다.

먼저 Single Model로는 Linear regression, SVR, MLP, LSTM 및 CNN을 모델링했다. 두 번째로 정확도를 더욱 향상시

기 위해 Multi Model을 사용했고 크게 Hybrid와 Ensemble로 나눌 수 있다. Hybrid Model의 경우 MLP와 linear regression을 결합하였고, MLP와 SVR을 결합했다. Ensemble Model의 경우 3개의 LSTM, 3개의 CNN, LSTM과 CNN을 조합해서 사용했다.

정확도를 향상시키기 위해 여러 모델을 사용한 이유는 모델 다양성이 증가하였기 때문에 각 모델의 장점을 활용하고 과적합을 최소화하기 위함이다. 다양한 모델을 통해 학습시킨 결과를 비교하여 UWB 거리 측정 정확도를 가장 많이 향상시키는 모델을 선택하기 위해 실험이 진행되었다. Single Model과 다른 구조로 Multi Model을 제안한 이유는 Ensemble 및 Hybrid Model이 가질 수 있는 이점은 데이터의 노이즈 및 이상치 변형에 대해 강하기 때문이다. 또한, 일반화를 개선시켜 다양한 데이터 패턴에 적용가능하다. 다음 장의 실험 및 분석에서는 각 모델 성능에 대한 자세한 비교와 장단점에 대해 논의되며 UWB 모듈 정확도를 향상시키는 가장 효과적인 모델을 제시한다.

SAE J2954에서는 x축의 오차를 ±75mm, y축의 오차를 ±100mm로 정의하였다. z축은 차량의 높이에 따라 다를 수 있으며 실험에 사용된 차량의 높이는 240mm이다. 결론적으로 x, y, z축을 고려한 두 UWB 모듈간의 오차는 50mm까지 허용된다. 따라서 본 연구에서는 UWB 모듈의 거리 오차를 50mm 즉, 5cm 이하로 들어오는 것을 목표로 설정한다. 실험의 수행 순서는 여러 단계로 구성된다. 먼저 UWB 모듈로부터 거리를 측정 후 데이터를 전처리하여 노이즈와 이상치를 제거한다. 다음으로 전처리된 데이터는 Machine learning 및 Deep learning의 입력으로 사용되며 정확한 거리를 예측하기 위해 학습된다. 최종적으로 자율주행차량에 부착된 패드와 충전패드 사이의 거리가 예측된다. 예측된 거리는 자율주행차 무선 전력전송을 위한 송수신 패드의 정렬을 결정하는 데 활용되며 궁극적인 목표는 전송 효율이 가장 높은 위치를 예측하여 효율적이고 안전한 무선전력전송을 가능케 하며 Fig. 5와 같이 전체적인 프레임워크로 나타낸다.

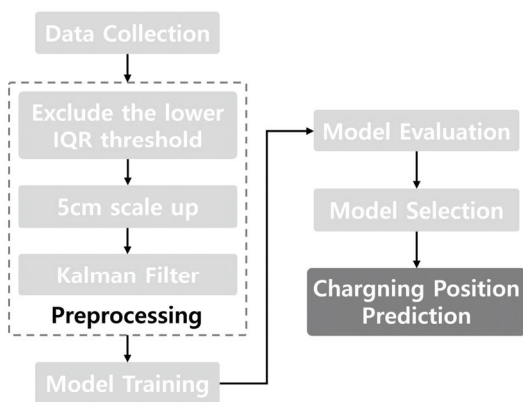


Fig. 5. Framework for Estimating Distance in Wireless Power Transfer of Autonomous Vehicles

Table 1. Grid Search for Optimal Hyperparameters of SVR

SVR			
C	epsilon	gamma	kernel
100	0.01	1	rbf

먼저 UWB 모듈로부터 측정된 로우(raw) 데이터의 오차가 5cm 이하로 들어오는 비율은 28.66%이다. 해당 데이터를 기반으로 이상치 제거, Scale 조정, 칼만 필터 세 가지 방법으로 전처리하였다. 앞서 진행한 세 가지 전처리 과정은 로우 데이터로부터 이상치 중 하한값 제거, Scale up 5cm, 칼만 필터가 단계적으로 추가 적용되었다. 이러한 전처리 방법을 결합하여 이상치의 영향을 줄이고, 모델에 잘 맞도록 scale을 조정하였으며 마지막으로 칼만 필터를 이용하여 실제 상태의 추정치를 구체화해 최종적으로 모델의 전반적인 정확도를 향상시키는 데 기여할 수 있다. 전처리를 진행한 경우 로우 데이터와 비교하여 약 12% 성능이 향상되었다. 데이터 세트는 5:2:3의 비율로 훈련, 검증, 테스트(train, validation, test)로 나누어졌다. 전처리 과정 이후 Single 및 Multi Model을 구축하여 전처리된 데이터 세트의 성능을 평가하고 최종적으로 UWB 모듈의 정확도를 개선하기 위한 가장 효과적인 모델 방식을 식별하기 위함이다.

Linear regression의 경우 다른 모델들에 비해 매개변수가 적기 때문에 따로 튜닝이 수행되지 않았으며 64.52%의 비율로 5cm 이하로 들어오는 범위가 기존 전처리에 비해 향상되었다. SVR의 경우, grid search를 통해 최적의 하이퍼파라미터를 찾은 결과 67.42%로 성능이 향상되었다.

MLP의 경우, 고려해야 할 파라미터가 많아 iteration 2000 번을 수행해 최적의 하이퍼파라미터가 선정되었으며 64.31%로 성능이 향상되었다. LSTM의 경우, MLP와 같은 파라미터

Table 2. Randomized Search for Optimal Hyperparameters of MLP, LSTM, and CNN

	MLP	LSTM	CNN
activation function	leaky relu	leaky relu	relu
batch size	64	32	64
dropout rate	0.2764	0.1404	0.0062
epochs	100	300	300
L1 regularization	1.3372	3.5644	1.5730
L2 regularization	4.4588	3.9133,	3.9308
learning rate	0.0010	3.1318	7.9388
number of layer	1	1	1
number of neuron	311	902	259
filter	-	-	32
kernel size	-	-	2
number of convolutional layer	-	-	2
number of pooling layer	-	-	1
size of pooling layer	-	-	3

Table 3. Proportion of Distance Error Less than 5cm after Training

Single Model					Multi Model				
ML		DL			Hybrid		Ensemble		
LR	SVR	MLP	LSTM	CNN	LR+MLP	SVR+MLP	3LSTM	3CNN	LSTM+CNN
64.52	67.42	64.30	63.45	63.99	68.06	66.99	64.63	61.49	63.88




Fig. 6. Model Accuracy

에 대해 randomized search가 수행되었으며 iteration은 100 번만 수행해도 충분한 결과를 얻을 수 있었다. 최적의 하이퍼 파라미터가 선정되었으며 63.45%로 성능이 향상되었다. CNN의 경우, LSTM과 MLP와 매개변수가 공통으로 고려되는 부분도 존재하지만, filter, kernel size, convolutional layer 수, pooling layer 수 및 크기, kernel size 등이 randomized search에 추가되어 최적의 하이퍼파라미터가 선정되었으며 63.99%로 성능이 향상되었다.

모든 모델은 5cm scale up 기반 칼만 필터를 적용한 동일 UWB 데이터 세트로부터 구축되었으며, 각 Single Model의 경우 SVR이 가장 높은 비율인 67.42%로 전처리 데이터와 비교하여 약 33% 성능이 향상되었고, Multi Model의 경우 Linear regression과 MLP가 결합된 Hybrid Model에서 가장 높은 비율인 68.06%로 전처리 데이터와 비교하여 약 33% 성능이 향상되었다. 따라서 Single Model과 Multi Model을 종합하여 비교해 본 결과, Linear regression과 MLP를 기반한 Hybrid Model에서 가장 많은 성능이 개선되었다. Linear regression을 통해 입력과 타겟 변수 간의 Linear 특성을 잘 파악하였고 반면 MLP에서 비선형 관계를 파악하여 이러한 두 모델을 결합해 두 유형의 강점을 각자 결합함으로써 최종 예측 정확도를 높일 수 있었다고 판단된다.

5. 결 론

본 연구를 통해서 무선전력전송이 이루어지기 위한 일련의 과정들을 알아보고 그중에서도 특히 무선전력전송 송수신 패




Fig. 7. UWB Module Based WPT Alignment Establishment

드 정렬이 전체 무선전력전송 시스템 성능과 효율성에 중요한 역할을 한다는 것을 알게 되었다.

결론적으로 본 연구에서는 UWB 모듈로부터 데이터를 수집하고 다양한 전처리 기법과 Machine learning 및 Deep learning 모델을 적용하여 거리 측정 정확도를 향상시키는 것을 최종 목표로 하였다. 앞서 언급한 여러 모델을 훈련시키고 검증하여 다양한 모델이 다양한 수준의 성능을 보였으며 일부 모델들의 실제 적용 가능성을 볼 수 있었다.

UWB 모듈로 측정된 거리가 5cm 이하로 오차가 발생하는 비율은 로우 데이터에서 29%였으나 학습을 통해 68%까지 도달했다. 다른 센서에 비해 상대적으로 UWB 자체로 정확한 거리 측정을 제공할 수 있지만 본 연구의 결과는 더 넓은 오류 범위 내에서 정확도가 크게 향상되었음을 보여준다. 예를 들어, 같은 UWB 모듈의 7cm 이하로 오차가 발생하는 비율은 39%였으나 학습을 통해 76%로 개선되었으며, 10cm 범위 내에서는 52%였으나 학습을 통해 87%까지의 정확도가 개선되었음을 보여준다.

연구 결과에 따르면 이상치에 대해 하한값을 제거하여 데이터 scale up 및 칼만 필터와 같은 특정 전처리 기술이 모델의 정확도를 향상시키는 것으로 확인하였다. 또한 Hybrid 및 Ensemble과 같은 일부 모델은 Single Model에 비해 개선된 결과를 보여주었다. 이는 데이터 세트의 특성을 잘 반영한 알고리즘을 사용하거나 모델을 결합함에 따라 최적의 하이퍼파라미터를 사용해야 함을 시사한다.

향후 연구에서는 현재 연구 결과를 바탕으로 UWB 모듈의 성능 및 전체적인 무선전력전송 시스템에서의 역할을 향상하기 위한 추가적인 방법을 탐색하는 것을 목표로 한다. 먼저 UWB 모듈 자체의 정확도를 향상시키기 위해 전이학습 (transfer learning)의 가능성을 조사할 계획이다. 사전 훈련

(pre-train) 모델을 활용하여 특정 문제에 맞게 파인 튜닝 함으로써 무선전력전송 시스템에서 UWB 모듈의 성능이 더 나은 결과를 얻고 전체적인 무선전력전송 정렬에 기여할 수 있기를 기대한다.

또 다른 측면으로는 UWB 모듈을 사용한 방향 제어를 이루고자 한다. Tag와 Anchor를 한 쌍이라고 볼 때, 4쌍의 Tag와 Anchor로 이루어진 UWB 모듈을 활용하여 송수신 패드 사이의 방향을 제어하는 방식이다. 이 접근 방식은 잠재적으로 무선전력전송 시스템 정렬을 개선할 뿐만 아니라 전체 시스템 성능과 효율성을 향상시킬 수 있을 것으로 기대된다. 이러한 연구 방향을 향후 계획으로 수립함으로써 정렬 및 UWB 모듈 자체의 성능과 관련된 문제를 해결하여 정확하고 효율적으로 적용가능한 WPT 시스템을 구축하는 것을 목표로 한다.

References

- [1] J. F. Torres, D. Hadjout, A. Sebaa, F. Martínez-Álvarez, and A. Troncoso, "Deep learning for time series forecasting: a survey," *Big Data*, Vol.9, No.1, pp.3-21, 2021. DOI: 10.1089/big.2020.0159.
- [2] S. Ardabili, A. Mosavi, and A. R. Várkonyi-Kóczy, "Advances in machine learning modeling reviewing hybrid and ensemble methods," *Engineering for Sustainable Future*, Vol.101, 2020.
- [3] SAE J2954_202208 : Wireless Power Transfer for Light-Duty Plug-in/Electric Vehicles and Alignment Methodology.
- [4] A. Martinelli, S. Jayousi, S. Caputo, and L. Mucchi, "UWB positioning for industrial applications: the galvanic plating case study," *2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Pisa, Italy, 2019, pp.1-7, doi: 10.1109/IPIN.2019.8911746.
- [5] H. Arslan, A. N. Chen, and M. G. Benedetto, "Ultra-Wideband Wireless Communication," Wiley Interscience, Hoboken, New Jersey, 2006.
- [6] A. Alarifi et al., "Ultra wideband indoor positioning technologies analysis and recent advances," *Sensors*, Vol.16, No.5, pp.707, 2016. doi: 10.3390/s16050707
- [7] A. Kuvshinov, D. Knobloch, D. Külzer, E. Vardanyan, and S. Günnemann, "Domain reconstruction for UWB car key localization using generative adversarial networks," *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol.36, No.11, pp.12552-12558, 2022. doi: 10.1609/aaai.v36i11.21526
- [8] C. Cortes and V. Vapnik, "Support-vector networks," *Springer Nature*, Vol.20, pp.273-297, 1995. doi: 10.1007/BF00994018
- [9] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, Vol.86, No.11, pp.2278-2324, 1998, doi: 10.1109/5.726791.
- [10] S. Hochreiter and J. Schmidhuber, "Long short-term memory," in *Neural Computation*, Vol.9, No.8, pp.1735-1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [11] M. Hamalainen, V. Hovinen, R. Tesi, J. H. J. Iinatti, and M. Latva-aho, "On the UWB system coexistence with GSM900, UMTS/WCDMA, and GPS," in *IEEE Journal on Selected Areas in Communications*, Vol.20, No.9, pp.1712-1721, 2002, doi: 10.1109/JSAC.2002.805242.
- [12] Kegen Yu and I. Oppermann, "UWB positioning for wireless embedded networks," *Proceedings 2004 IEEE Radio and Wireless Conference (IEEE Cat. No.04TH8746)*, Atlanta, GA, USA, pp.459-462, 2004, doi: 10.1109/RAWCON.2004.1389176.
- [13] S. Lee 2021. "Ultrawideband (UWB)-based precise short-range localization for wireless power transfer to electric vehicles in parking environments," *PeerJ Computer Science*, Vol.7, pp.e567, doi: 10.7717/peerj-cs.567
- [14] Y. -Y. Chen, S. -P. Huang, T. -W. Wu, W. -T. Tsai, C. -Y. Liou, and S. -G. Mao, "UWB System for Indoor Positioning and Tracking With Arbitrary Target Orientation, Optimal Anchor Location, and Adaptive NLOS Mitigation," in *IEEE Transactions on Vehicular Technology*, Vol.69, No.9, pp.9304-9314, 2020, doi: 10.1109/TVT.2020.2972578.
- [15] G. Shi and Y. Ming, 2016. "Survey of indoor positioning systems based on Ultra-Wideband (UWB) technology," in *Wireless Communications, Networking and Applications*, pp.1269-1278. Springer.



김혜정

<https://orcid.org/0009-0002-1926-3110>

e-mail : rnrdrck@yonsei.ac.kr

2020년 한성대학교 IT융용시스템공학과(학사)

2023년 연세대학교 컴퓨터과학과(석사)
관심분야: 실내측위시스템, 무선전력전송, 사물인터넷, 국제 표준화



박 용 주

<https://orcid.org/0000-0002-7582-7243>

e-mail : suede8247@keti.re.kr

2008년 고려대학교 전기전자전파(학사)

2011년 서울대학교 전기컴퓨터(석사)

2018년 고려대학교 마이크로나노

(박사수료)

2011년 ~ 2012년 삼성전자 반도체연구소 차세대 IP설계센터
선임연구원

2013년 ~ 현 재 한국전자기술연구원 스마트네트워크연구센터 팀장
관심분야: 무선전력전송, SoC 설계, AI 기반 영상처리, 국제
표준화



한 승 재

<https://orcid.org/0000-0002-4393-8475>

e-mail : seungjaehan@yonsei.ac.kr

1989년 서울대학교 컴퓨터공학과(학사)

1991년 서울대학교 컴퓨터공학과(석사)

1998년 Univ. of Michigan, Ann Arbor,

Computer Science &

Engineering(박사)

1998년 ~ 1999년 Univ. of Michigan, Ann Arbor, MI, 연구원

1999년 ~ 2005년 Bell Laboratories, Lucent Technologies,

Murray Hill, NJ, 기술직원

2005년 ~ 현 재 연세대학교 컴퓨터과학과 교수

관심분야: 클라우드-엣지 컴퓨팅, 사물인터넷, 실내 위치 예측,

분산학습, 딥강화학습, 소프트웨어 정의 네트워킹