JDCS
디지털콘텐츠학회논문지
Journal of Digital Contents Society
Vol. 27, No. 10, pp. 3013-3021, Oct. 2026

Check for updates

공간모델링과 AI 학습 모델이 적용된 UWB 측위 보정 시스템의 구현

김 하 연[1] · 정 의 성[2] · 김 명 환[3] · 백 수 진[4] · 정 승 민[4*]
[1]한신대학교 AI·SW대학 석박사통합과정
[2]메타리얼㈜ 대표
[3]㈜심스리얼리티 대표
[4]한신대학교 AI시스템반도체학 교수

Implementation of a UWB Positioning Correction System Applying Spatial Modeling and an AI Learning Model

Hayeon Kim[1] · Eu-Sung Jung[2] · MyungHwan Kim[3] · SuJin Baek[4] · Seungmin Jung[4*]

[1]Integrated Master's and Doctoral Course, Department of AI and Software, Hanshin University, Osan 18101, Korea
[2]CEO, Metareal Co., Ltd., Osan 18101, Korea
[3]CEO, SimsReality Co., Ltd., Daejeon 34014, Korea
[4]Professor, AI System Semiconductor, Hanshin University, Osan 18101, Korea

[요 약]

본 논문은 UWB 환경을 가상으로 모사하는 RTLS 시뮬레이터를 제안하고, 거리 보정 알고리즘의 검증 환경으로 활용한다. 생성 데이터에 XGBoost 기반 거리 보정과 2단계 삼변측량을 적용하고, 1차 삼변측량으로 추정한 위치를 보정 모델 입력으로 재사용하여 성능을 높였다. 면적이 4배 차이 나는 두 공간(20×10m, 40×20m)을 셀 단위로 분할하여 학습에 쓰지 않은 위치에서 시드를 달리한 5회 반복 실험으로 평가한 결과, 평균 위치 오차(MAE)는 각각 약 52%, 43%, 95백분위수 오차(p95)는 각각 약 60%, 56% 감소하였고, NLOS 확률 0~50% 전 구간에서 일관되게 개선되었다. 측위 연산 한 사이클도 평균 2.13ms로 실시간 적용이 가능하여, 제안 시뮬레이터가 UWB 거리 보정 알고리즘의 검증과 개선에 효과적인 평가 환경임을 확인하였다.

[Abstract]

We propose a real-time location system simulator that virtually emulates and uses an ultra-wideband (UWB) environment to validate range-correction algorithms. We apply an XGBoost-based range correction and two-stage trilateration to the generated data, and reuse the position estimated by the first-stage trilateration as an input for the correction model to improve the performance. Evaluated at positions unseen during the training by cellwise splitting two spaces differing four-fold in area (20 × 10 m and 40 × 20 m), and averaged over five runs with different random seeds, the mean position error (MAE) decreased by approximately 52% and 43%, and the 95th-percentile error (p95) by 60% and 56%, respectively, with consistent improvements across non-line-of-sight probabilities ranging from 0% to 50%. A single positioning-computation cycle takes 2.13 ms on average, enabling real-time operations and confirming that the proposed simulator provides an effective evaluation environment for validating and improving UWB range-correction algorithms.

색인어 : UWB, RTLS, NLOS, 위치 보정, XGBoost
Keyword : Ultra-Wideband, Real-Time Location System, Non-Line of Sight, Positioning Correction, XGBoost

http://dx.doi.org/10.9728/dcs.2026.27.10.3013

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-CommercialLicense(http://creativecommons.org/licenses/by-nc/3.0/) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 22 July 2026; **Revised** 18 August 2026
Accepted 04 September 2026

***Corresponding Author; Seungmin Jung**
Tel: ※ 개인정보 표시제한
E-mail: jasmin@hs.ac.kr

Ⅰ. 서 론

위치 정보는 다양한 산업과 서비스에서 핵심 자원으로 자리 잡고 있다. 실외 환경에서는 GPS(Global Positioning System)를 통해 비교적 정확한 위치 추정이 가능하지만, 위성 신호가 도달하기 어려운 실내 환경에서는 그 활용이 제한된다. 이에 따라 실내 측위를 위한 다양한 기술이 연구되어 왔으며, 대표적으로 Wi-Fi, 저전력 블루투스(BLE), RFID, 초광대역(UWB) 등이 있다[1]. 이 중 Wi-Fi와 BLE 기반 측위는 기존 인프라나 저가의 비콘을 활용할 수 있어 구축 비용이 낮지만, 수신 신호 세기(RSSI)에 의존하기 때문에 정확도가 수 미터 수준에 머문다[2]. 이에 비해 UWB는 수 cm에서 수십 cm 수준의 높은 정확도를 제공하여 정밀 측위가 요구되는 응용 분야에서 주목받고 있다[3].

UWB는 넓은 대역폭을 활용하여 신호의 도달 시간을 정밀하게 측정함으로써 거리를 추정한다. 일반적으로 고정된 앵커가 태그와의 거리를 측정하고, 세 개 이상의 거리를 삼변측량(trilateration)하여 태그의 위치를 산출한다. 그러나 실제 환경에서는 신호 반사와 비가시경로(NLOS; Non-Line-of-Sight), 측정 잡음으로 인해 거리 측정값에 오차가 포함되며, 이는 위치 오차로 그대로 전파된다. 특히 NLOS 상황에서는 신호가 장애물을 우회하거나 반사되어 직선 경로보다 긴 경로를 거치므로, 거리가 실제보다 크게 측정되는 양의 편향(positive bias)이 발생한다[4]. 이러한 편향은 단순 평균이나 칼만 필터(Kalman filter)만으로는 제거하기 어려운 체계적 오차의 성격을 가진다. 이러한 오차를 줄이기 위해 머신러닝 기반 거리 보정 기법이 연구되어 왔으나, 모델의 개발과 평가에는 다양한 환경에서 수집한 실측 데이터가 필요하여 하드웨어 구축과 현장 실험에 많은 시간과 비용이 소요된다. 또한 공간의 크기나 NLOS 발생 빈도와 같은 환경 조건을 체계적으로 변화시키며 데이터를 확보하기 어려워, 보정 알고리즘을 다양한 조건에서 충분히 검증하기가 쉽지 않다. 더욱이 실시간 측위 성능을 검증하기 위해서는 앵커와 이동하는 태그로 구성된 물리적 측위 환경을 실제로 구축하고 운용해야 한다. 이를 위해서는 앵커의 설치와 좌표 보정, 태그 궤적에 대한 기준 위치(ground truth) 측정, 그리고 NLOS·측정 잡음과 같은 환경 요인의 통제가 선행되어야 한다. 이러한 현장 실험(field test)의 준비 과정에는 상당한 인력과 시간이 소요될 뿐 아니라, 동일한 조건을 반복적으로 재현하기도 어렵다. 결국 실측 환경을 갖추는 일 자체가 큰 부담이 되므로, 물리적 환경을 직접 구축하지 않고도 UWB 측정값을 소프트웨어적으로 모델링하여 거리 보정 알고리즘을 개발·검증할 수 있는 접근이 요구된다.

본 연구에서는 UWB 통신 환경을 가상으로 모델링하는 RTLS(Real-Time Locating System) 시뮬레이터를 구축하고, 이를 거리 보정 알고리즘의 검증 환경으로 활용한다. 제안하는 시뮬레이터는 공간 크기와 앵커 위치를 정의하고, 각 앵커-태그 거리에 측정 잡음과 NLOS 편향을 확률적으로 적용하여 실제와 유사한 거리값을 생성하므로, 실제 하드웨어를 구축하지 않고도 다양한 조건에서 거리 보정 알고리즘을 체계적으로 검증할 수 있다. 이렇게 생성한 데이터에는 XGBoost 기반 거리 보정과 2단계 삼변측량을 적용하며, 특히 1차 삼변측량으로 추정한 위치 정보를 보정 모델의 입력 특징으로 재사용함으로써 보정 성능과 최종 위치 추정 정확도를 함께 높인다. 또한 면적이 서로 다른 두 공간을 셀 단위로 분할하여 학습에 사용되지 않은 위치에 대한 일반화 성능을 평균 위치 오차(MAE)와 95백분위수 오차(p95)로 정량적으로 검증하고, 기준 궤적과 보정 전·후의 추정 궤적을 한 화면에서 비교하여 보정 효과를 실시간으로 확인한다.

Ⅱ. 관련 연구

2-1 UWB 측위와 NLOS

UWB 측위는 신호의 도달 시간(ToA; Time of Arrival), 도달 시간 차(TDoA; Time Difference of Arrival), 양방향 거리 측정(TWR; Two-Way Ranging) 등을 이용해 앵커-태그 간 거리를 추정하고, 이를 삼변측량하여 위치를 계산한다. ToA 방식은 앵커와 태그 간 시간 동기를 필요로 하고, TDoA 방식은 앵커들 사이의 동기를 전제로 한다. 이에 비해 TWR 방식은 신호의 왕복 시간을 측정하므로 별도의 시간 동기 없이 거리를 추정할 수 있어 실내 측위에서 널리 사용된다[3]. UWB는 수 나노초 이하의 짧은 펄스를 사용하여 시간 분해능이 높고, 이에 따라 다중 경로 성분을 세밀하게 구분할 수 있어 가시경로(LOS; Line-of-Sight) 환경에서 cm급 정확도를 달성할 수 있다. 그러나 실내 환경에서는 벽, 가구, 사람 등 장애물로 인해 NLOS 전파가 빈번하게 발생한다. NLOS 상황에서는 직선 경로 신호가 차단되거나 크게 감쇠되어 반사·회절을 거친 더 긴 경로의 신호가 최초 도달 신호로 검출되므로, 측정 거리가 실제 거리보다 길게 나타나는 양의 편향이 발생한다. 이러한 편향은 평균이 0이 아닌 체계적 오차로서 삼변측량 과정에서 위치 오차로 그대로 전파되며, 여러 앵커가 동시에 NLOS의 영향을 받을 경우 오차가 더욱 증폭된다. 실제로 한 선행 연구에서는 태그와 앵커로 구성된 UWB 네트워크를 실제 현장에 구축하여 실시간으로 실내 객체를 측위하고, 그 위치 정확도를 정량적으로 검증하는 방법을 제시한 바 있다[5]. 또한 제조 공정의 공구 추적을 위해 칼만 필터를 적용한 UWB 삼변측량 기반 실시간 위치추적 시스템이 개발되어, 측정 잡음 완화를 통한 측위 정밀도 향상이 보고되었다[6].

2-2 머신러닝 기반 거리 보정

NLOS로 인한 오차를 완화하기 위해 머신러닝을 활용한

연구가 활발히 진행되어 왔다[7]. 초기 연구에서는 실측 UWB 수신 파형의 채널 임펄스 응답(CIR; Channel Impulse Response)에서 추출한 첨도, 평균 초과 지연, 지연 확산 등의 통계적 특징을 입력으로 LOS/NLOS를 분류하고 거리 오차를 완화하는 기법이 제안되었다[4]. 이후 LOS/NLOS의 명시적 분류 없이 수신 파형으로부터 비모수 회귀(non-parametric regression)를 통해 거리 오차를 직접 추정·보상하는 기법으로 발전하였다[8]. 또한 강건 최소제곱으로 NLOS 잔여 거리 오차를 억제하는 기법[9]이나, CIR과 그 시간-주파수 정보를 입력으로 하는 딥러닝 기반 NLOS 식별 기법[10]도 제안되었다. 최근에는 그래디언트 부스팅 계열 모델이 빠른 학습 속도와 해석 용이성, 임베디드 환경 적합성을 바탕으로 거리 보정에 적용되고 있으며, [11]에서는 XGBoost를 이용해 NLOS를 분류·필터링하고 UWB 거리 측정값을 보정하는 기법을 제시하였다. 본 연구는 이러한 XGBoost 기반 거리 보정 접근을 계승하되, 다음과 같은 점에서 차이가 있다. 첫째, 실측 데이터에 의존하지 않고 공간 크기·앵커 배치·측정 잡음·NLOS 발생 확률을 자유롭게 설정할 수 있는 시뮬레이터 환경에서 거리 보정 알고리즘을 검증함으로써, 하드웨어 구축이나 현장 실험 없이 다양한 조건에서의 성능을 체계적으로 분석한다. 둘째, 1차 삼변측량으로 추정한 위치 정보와 측정 거리·기대 거리의 차이값을 보정 모델의 입력 특징으로 재사용하여, 위치 정보를 거리 보정에 반영함으로써 보정 성능과 최종 측위 정확도를 함께 향상시킨다.

Ⅲ. 제안하는 RTLS 시뮬레이터와 거리 보정

3-1 전체 구조

그림 1은 제안하는 시뮬레이터의 전체 파이프라인을 나타낸다. 공간 모델링, XGBoost 학습, 1차 삼변측량, XGBoost 거리 보정, 2차 삼변측량의 순서로 수행되며, 1차 삼변측량에서 추정된 위치 정보를 거리 보정 모델에 반영함으로써 보정 성능과 최종 위치 추정 정확도를 향상시킨다. 시뮬레이터는 시각화와 사용자 입력을 담당하는 Unity 모듈과 데이터 생성·학습·추론을 담당하는 Python 모듈로 구성되며, 두 모듈은 UDP 통신으로 연동된다. 이를 통해 실측 위치, 보정 전 추정 위치, 보정 후 추정 위치를 동일한 좌표계에서 실시간으로 비교할 수 있다.

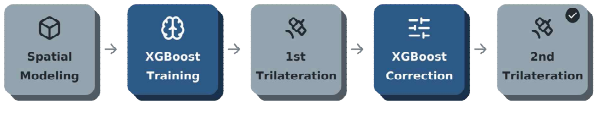


그림 1. 제안 시뮬레이터의 전체 파이프라인
Fig. 1. Full pipeline of the proposed simulator

3-2 측정 모델과 데이터 구성

제안 시뮬레이터는 공간 크기와 앵커 위치를 정의하고, 각 앵커-태그 거리에 잡음과 NLOS 편향을 적용하여 실제와 유사한 거리값을 생성한다. 앵커 i와 태그 위치 p 사이의 측정 거리 ri는 식 (1)과 같이 모델링된다.

$$r_i = \|a_i - p\| + n_i + b_i \tag{1}$$

여기서 ai는 앵커 i의 좌표, ni ~ $N(0,\sigma^2)$는 표준편차 σ = 10 cm의 가우시안 측정 잡음이다. bi는 NLOS 편향으로, 기본 10%의 확률로 U(50, 200) cm 범위에서 발생하고 그 외에는 0이다. 표준편차 10 cm는 상용 UWB 칩셋이 LOS 환경에서 보고하는 거리 측정 분포를 반영한 값이다. 또한 NLOS 편향이 항상 양의 방향인 것은 장애물 투과와 다중 경로로 인한 거리 과대측정 특성을 반영한 것이며, 분포는 사전 정보가 없을 때 UWB NLOS 모델링에 통상 사용되는 균등분포를 채택하였다[12]. 크기 범위는 DW1000을 포함한 상용 UWB 시스템의 산업형 실내 실측에서 보고된 수 cm~1-2 m 수준의 양의 초과 오차[13]와 벽 투과 전파 모델[14]의 예측(콘크리트 벽 1장 약 0.5 m, 다중 벽·경사 입사 시 약 2 m)을 함께 고려하여, 단일 벽에서 다중 벽 차폐에 이르는 실측 오차 수준을 포괄하도록 설정하였다. 한편 NLOS 발생 여부는 장애물과의 기하학적 가시성 판정 대신 발생 확률을 파라미터로 부여하여 모사하며, 이는 NLOS 발생 정도를 통제 변수로 두고 보정 성능을 분석하기 위한 설계이다.

이 측정 모델로 생성한 학습 데이터를 세 종류로 구성하였다. 수동 데이터는 사용자가 직접 실측 궤적을 입력해 수집한 것으로 1차 검증에 사용하며, 자동 데이터는 공간 전체를 균등하게 커버하도록 수집하여 경로 편향과 누락을 보완한 주 학습 데이터이다. 합성 데이터는 자동 궤적에서 NLOS 발생 확률을 기본값보다 높은 15%와 20%로 높여 생성한 것으로 학습 데이터 증강에 사용한다.

3-3 2단계 삼변측량

제안 파이프라인은 두 단계의 삼변측량을 사용한다. 1차 삼변측량은 두 앵커 거리식의 차분을 통해 구성한 선형 시스템을 최소제곱(LSQ)으로 풀어 해석적 해를 구한다. 이 해는 계산이 빠르고 초기값으로 적합하지만 측정 오차에 민감하다. 2차 삼변측량은 식 (2)의 비선형 최소제곱 문제를 신뢰영역 기반 알고리즘(TRF; Trust Region Reflective, SciPy least_squares의 기본 알고리즘)으로 풀며, 1차 결과를 초기값으로 사용하여 안정적인 수렴을 보장한다.

$$(\hat{x}, \hat{y}) = \mathrm{argmin}_{(x,y)} \ \Sigma_i (\ \|a_i - (x,y)\| - r_i^{\mathrm{corr}})^2 \tag{2}$$

여기서 r_i^{corr}는 보정된 거리이다. 본 연구의 핵심은 1차 삼변측량 결과를 단순히 정밀화의 초기값으로만 쓰는 것이 아니라, 거리 보정 모델의 입력 특징으로도 재사용한다는 점이다.

즉, 1차 위치 추정 → 거리 보정 → 2차 위치 추정으로 이어지는 2단계 구조에서, 1차 추정 위치를 거리 보정 단계의 입력으로 사용함으로써 위치 정보를 거리 보정에 반영한다.

3-4 거리 보정 모델

거리 보정 모델은 앵커별로 독립적으로 학습되며, 입력 특징은 표 1의 5개로 구성된다. 측정 거리 r, 1차 삼변측량 추정 좌표($\hat{x}$, $\hat{y}$), 앵커와 추정 좌표 사이의 기대 거리 d_geom, 그리고 측정 거리와 기대 거리의 차이값 residual이다. 특히 잔차(residual)는 측정 거리가 기대되는 거리에서 얼마나 벗어났는지를 나타내므로 NLOS 의심 신호로 작용한다.

표 1. 거리 보정 모델의 입력 특징
Table 1. Input features of the range-correction model

Feature	Description
r	Measured distance
$\hat{x}$, $\hat{y}$	Estimated coordinates from the 1st trilateration
d_geom = $\|a - (\hat{x}, \hat{y})\|$	Expected distance between the anchor and the estimated position
residual = r − d_geom	Residual (indicator of suspected NLOS)

거리 보정에는 그래디언트 부스팅 결정 트리 모델인 XGBoost를 사용한다[15]. XGBoost는 빠른 학습 속도와 정규화 기반의 과적합 억제, 임베디드 환경에서의 효율적 추론이 가능하여 실시간 측위 응용에 적합하다. 학습된 모델이 예측한 거리 오차를 측정 거리에서 제거하여 보정 거리 r_i^corr를 산출하고, 이를 이용한 2차 삼변측량으로 최종 위치를 추정한다. 과적합을 완화하기 위해 트리 최대 깊이 제한, 표본 및 특징의 무작위 추출, 검증 오차 기반 조기 종료를 적용하였다. 주요 하이퍼파라미터는 표 2와 같다.

표 2. XGBoost 하이퍼파라미터
Table 2. XGBoost hyperparameters.

Parameter	Value
max_depth	5
learning_rate	0.05
n_estimators	2000
subsample	0.8
colsample_bytree	0.8
min_child_weight	20
reg_lambda	2.0
early_stopping_rounds	50

표 2의 하이퍼파라미터는 과적합 억제와 일반화 성능을 함께 고려하여 설정하였다. 부스팅 단계 수(n_estimators)는 2,000으로 충분히 크게 두되, 학습률(learning_rate)을 0.05로 낮게 설정하여 각 트리가 잔차를 조금씩 보정하도록 함으로써 안정적이고 세밀한 학습을 유도하였다. 다만 트리 수가 많을수록 과적합 위험이 커지므로, 검증 오차가 50 라운드(early_stopping_rounds) 동안 개선되지 않으면 학습을 조기 종료하여 실제로 사용되는 트리 수를 데이터에 맞게 제한하였다. 개별 트리의 복잡도는 최대 깊이(max_depth)를 5로 제한하고, 한 리프 노드가 갖는 표본 가중치의 합(min_child_weight)을 20 이상으로 요구하여 소수 표본에 의한 과적합과 잡음 학습을 억제하였다. 또한 각 트리를 학습할 때 표본의 80%(subsample)와 특징의 80%(colsample_bytree)만 무작위로 사용하여 트리 간 상관성을 낮추고 일반화 성능을 높였다. 끝으로 리프 가중치에 대한 L2 정규화 계수(reg_lambda)를 2.0으로 적용하여 모델 복잡도에 추가적인 제약을 두었다. 이러한 설정은 NLOS로 인한 큰 편향값을 일부 표본에 과도하게 맞추지 않으면서, 앵커별 거리 오차의 전반적인 경향을 학습하도록 하기 위한 것이다. 한편, 학습 데이터는 좌표 (x, y)를 25cm 격자의 셀로 양자화한 뒤 셀 단위로 train/validation/test=70/15/15%로 분할하였다. 이는 인접한 샘플이 학습과 평가에 동시에 포함되어 발생하는 공간적 정보 누출(spatial leakage)을 방지하고, 학습에 사용되지 않은 위치에 대한 일반화 성능을 검증하기 위함이다.

Ⅳ. 실험 및 성능 평가

4-1 공간모델링

측위 대상 실내 공간은 바닥 평면과 외벽, 내부 장애물(벽·기둥 등)로 구성되며, 이들은 실측과 유사한 환경 구성과 이동 궤적 정의, 그리고 위치 추정 결과의 실시간 시각화에 사용된다. 사용자는 공간의 크기, 앵커의 좌표, 태그의 이동 궤적을 직접 정의할 수 있다. 모든 좌표는 cm 단위의 2차원 평면 좌표계로 표현하며, 앵커는 고정된 점으로, 태그는 시간에 따라 이동하는 점으로 나타낸다. 본 실험에서는 면적이 4배 차이 나는 두 공간(20×10m, 40×20m)을 구성하고, 각 공간에 3개의 앵커를 배치하였다. 실행 시 Unity 모듈은 태그의 실측 위치를 5 Hz(초당 5회)로 Python 모듈에 전송하고, Python 모듈은 이를 입력으로 거리값 생성, 거리 보정, 위치 추정을 차례로 수행한 뒤 결과를 다시 Unity 모듈로 회신한다. 이때 실제 현장 배치에서는 무선 전송과 처리 과정에서 지연이 불가피하므로, 이를 고려하여 송신부터 회신까지 약 1초의 종단 간(end-to-end) 지연을 적용하였다. 회신된 보정 전·후 추정 위치는 실측 위치와 함께 동일 화면에 실시간으로 렌더링되어, 보정에 따른 궤적 변화를 직관적으로 비교할 수 있다.

4-2 실험 설정 및 평가 지표

제안 기법을 4-1절에서 정의한 두 공간에서 평가하였다. 20×10m 공간은 앵커를 (0, 700), (2000, 300), (1000,

1000)cm에, 40×20m 공간은 (0, 1500), (4000, 500), (2100, 2000)cm에 배치하였다. 두 공간 모두 3-4절의 셀 단위 분할(70/15/15%)을 적용하였으며, 평가 시 표준편차 10cm의 가우시안 잡음과 10% 확률의 NLOS 편향 조건을 사용하였다. 학습 데이터는 25 cm 간격의 정사각 격자 위 위치들을 50Hz 주기로 수집한 뒤 3-2절의 절차에 따라 합성 데이터로 증강하여 구성하였으며, 규모는 40×20m 공간 약 20만 프레임, 20×10m 공간 약 4만 프레임이다. 셀 단위 분할에 따라 40×20m 기준 약 14만 프레임을 학습에, 약 3만 프레임씩을 검증과 시험에 사용하였다. 한편 특징 수가 2개인 2-feat 구성에서는 colsample_bytree=0.8 적용 시 트리당 사용 특징이 1개로 절사되어 두 특징 간 상호작용 분할이 불가능하므로, 이 구성에 한해 colsample_bytree를 1.0으로 설정하였다. 성능 평가는 추정 위치와 실제 위치 사이의 유클리드 거리 오차를 기준으로 한다. 평균 위치 오차(MAE)는 전체 표본에 대한 평균 거리 오차로 전반적인 정확도를 나타내고, 평균 제곱근 오차(RMSE)는 오차를 제곱하여 평균하므로 큰 오차에 더 큰 가중치를 부여하여 오차 분포의 폭을 반영한다. 95백분위수 오차(p95)는 거리 오차 분포의 상위 5% 지점에 해당하는 값으로, 최악에 가까운 큰 오차의 정도를 나타낸다. RTLS 응용에서는 평균적인 정확도뿐 아니라 최악의 경우 오차가 중요하므로 세 지표를 함께 보고한다. 또한 결과의 통계적 신뢰도를 확보하기 위해 난수 시드(seed)를 달리하여 각 실험을 독립적으로 5회 반복 수행하였으며, 이하 모든 성능 지표는 그 평균±표준편차로 제시한다. 한편 본 평가는 합성 데이터와 단순화된 NLOS 통계 모델에 기반하며 단일 태그와 3개 앵커의 고정 배치를 가정하므로, 앵커 수와 기하 배치에 따른 성능 민감도는 분석 범위에 포함하지 않았다. 따라서 본 결과는 실측 환경에서의 절대 성능이 아니라 실측 문헌에 근거한 오차 모델 하에서 제안 보정 파이프라인 설계의 유효성을 검증한 것이다.

4-3 보정 성능

그림 2와 표 3은 두 공간에서 보정 전(raw)과 보정 후(corrected)의 위치 정확도를 난수 시드를 달리한 5회 반복 실험의 평균±표준편차로 나타낸 것이다. 20×10m 공간에서 MAE는 57.7±2.2cm에서 28.0±1.8cm로 약 52%, 40×20m 공간에서는 62.0±1.1cm에서 35.5±0.5cm로 약 43% 감소하였다. RMSE는 각각 약 47%, 45% 감소하였고, p95는 각각 약 60%, 56% 감소하여, 평균 오차뿐 아니라 오차 분포의 폭과 큰 오차가 모두 효과적으로 완화됨을 확인하였다. 또한 모든 지표에서 보정 전후의 성능 격차가 5회 반복의 표준편차를 크게 상회하여, 개선 효과가 시드 선택과 무관하게 안정적으로 재현됨을 보여준다. 특히 면적이 4배 차이 나는 두 공간에서 유사한 수준의 개선율이 관측되어, 제안 보정 기법의 효과가 공간 크기에 크게 의존하지 않음을 알 수 있다.

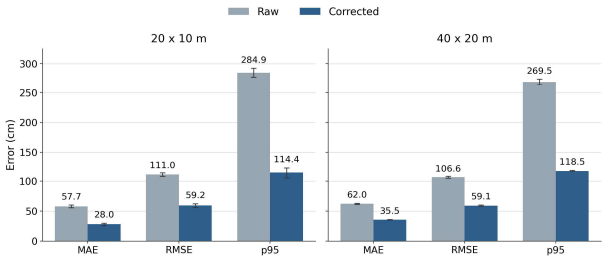


그림 2. 두 공간에서의 보정 전후 위치 정확도(raw vs corrected)

Fig. 2. Positioning accuracy before and after correction in the two spaces

표 3. 두 공간에서의 보정 전후 위치 정확도(단위: cm, 5회 반복 평균±표준편차)

Table 3. Positioning accuracy before and after correction in the two spaces (cm, mean±std over 5 seeds).

Space	Config	MAE	RMSE	p95
20×10m	Raw	57.7±2.2	111.0±2.9	284.9±7.6
	Corrected	28.0±1.8	59.2±3.2	114.4±9.1
40×20m	Raw	62.0±1.1	106.6±1.6	269.5±4.5
	Corrected	35.5±0.5	59.1±0.9	118.5±1.3

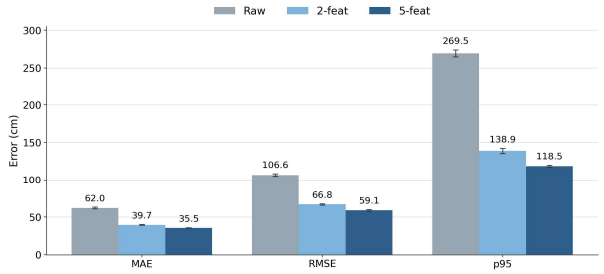


그림 3. 입력 특징 구성에 따른 보정 성능 비교

Fig. 3. Ablation of input features on correction performance

표 4. 입력 특징 구성에 따른 보정 성능(40×20m, 단위: cm, 5회 반복 평균±표준편차)

Table 4. Ablation of input features on correction performance (40×20m, cm, mean±std over 5 seeds)

Config	MAE	RMSE	p95
Raw (LSQ only)	62.0±1.1	106.6±1.6	269.5±4.5
2-feat	39.7±0.6	66.8±0.9	138.9±3.5
5-feat	35.5±0.5	59.1±0.9	118.5±1.3

제안 기법의 핵심인 1차 삼변측량 추정 좌표를 명시적인 입력 특징으로 추가하는 설계가 보정 성능에 기여하는 정도를 확인하기 위해, 40×20m 공간에서 입력 특징 구성을 달리한 ablation 실험을 수행하였다(그림 3, 표 4). 비교 대상은 보정을 적용하지 않은 raw, 1차 추정 좌표($\hat{x}$, $\hat{y}$)와 기대 거리 d_geom을 제외하고 측정 거리 r과 잔차 residual의 2개 특징만 사용한 모델(2-feat), 그리고 이들을 모두 포함한 5개 특징의 제안 모델(5-feat)이다. 다만 잔차가 1차 추정 위치로부터 계산되는 만큼 2-feat 모델도 위치 정보를 간접적으로는 활용하며, 본 실험은 추정 좌표와 기대 거리를 명시적 특

징으로 추가할 때의 효과를 비교한 것이다. 2-feat 모델은 raw 대비 MAE를 62.0±1.1cm에서 39.7±0.6cm로 약 36% 감소시켜, XGBoost 기반 거리 오차 회귀 자체가 보정에 효과적임을 보였다. 여기에 1차 삼변측량 추정 좌표와 기대 거리를 입력 특징으로 추가한 5-feat 모델은 MAE를 35.5±0.5cm로 더욱 낮추어, raw 대비 약 43%, 2-feat 대비 약 10%의 추가 감소를 달성하였다. RMSE(106.6 → 66.8 → 59.1 cm)와 p95(269.5 → 138.9 → 118.5cm)에서도 동일한 경향이 관측되었으며, 특히 2-feat와 5-feat 간 MAE 차이(약 4.1cm)가 두 구성의 반복 표준편차(0.5cm 수준)의 7배를 넘어, 1차 추정 좌표를 명시적인 입력 특징으로 재사용하는 설계가 시드 변동에 따른 우연이 아니라 일관된 정확도 향상 요인임을 정량적으로 확인하였다.

4-4 베이스라인 비교

제안 기법을 기존 보정 접근과 비교하기 위해, 학습을 사용하지 않는 강건 추정 기법과 다른 학습 모델을 동일한 실험 조건에서 평가하였다(표 5). 먼저 강건 최소제곱 계열[9]의 대표로, 보정하지 않은 측정 거리에 Huber 손실 기반 비선형 삼변측량을 적용하였다. Huber 임계값 δ는 측정 잡음 표준편차 10cm의 3배인 30cm로 설정하였으며, δ를 30, 50, 80cm로 변화시켜도 MAE 차이가 0.6 cm 이내로 나타나 δ 선택에 강건함을 확인하였다. Huber 삼변측량은 raw 대비 MAE를 62.0±1.1 cm에서 41.9±0.5cm로 약 32% 개선하여 학습 없이도 NLOS 오차를 상당 부분 완화하였으나, p95는 184.5±3.4cm로 제안 기법의 118.5±1.3cm에 크게 미치지 못하였다. 이는 앵커 3개의 최소 구성에서는 측정 중복성이 부족하여 강건 손실만으로는 NLOS 편향을 충분히 분리하기 어렵기 때문으로 판단된다. 다음으로 학습 기반 접근의 대표로, 제안 기법과 동일한 5개 입력 특징을 사용하는 Random Forest 회귀를 학습하였다. 트리 수는 500, 최대 깊이는 20으로 설정하였고, 리프 노드의 최소 표본 수는 XGBoost의 min_child_weight와 같은 의미의 규제가 되도록 동일한 20으로 맞추었다. Random Forest는 MAE 34.2±0.9cm로 제안 기법의 35.5±0.5cm보다 약 1.3cm(4%) 낮은 오차를 보였으나, 4-6절과 동일한 단일 스레드 조건에서 측정한 프레임당 추론 시간은 32.3ms로 XGBoost의 1.09ms 대비 약 30배, 앵커 3개 모델을 합한 직렬화 모델 크기는 535 MB로 약 71배에 달하였다. 이는 5Hz 갱신 주기인 200ms 안에서 동작은 가능하지만 예산의 약 16%를 사용하는 수준으로, 약 0.5%만 사용하는 XGBoost에 비해 다중 태그 확장이나 임베디드 환경에서 불리하다. 요약하면, 학습 없는 강건 추정은 raw 대비 유의한 개선을 제공하지만, 위치 정보를 입력 특징으로 재사용하는 학습 기반 보정이 그 위에 추가적인 정확도 향상을 달성하며, 제안 구성이 비슷한 정확도의 학습 모델 대비 실시간·임베디드 적용에 유리함을 확인하였다.

표 5. 기존 보정 기법과의 성능 비교(40×20 m, 단위: cm, 5회 반복 평균±표준편차)

Table 5. Comparison with baseline correction methods (40×20 m, cm, mean±std over 5 seeds)

Config	MAE	RMSE	p95
Raw (LSQ only)	62.0±1.1	106.6±1.6	269.5±4.5
Huber trilateration	41.9±0.5	79.1±0.6	184.5±3.4
Random Forest (5-feat)	34.2±0.9	57.3±1.7	115.1±1.7
XGB 5-feat	35.5±0.5	59.1±0.9	118.5±1.3

4-5 NLOS 강건성 분석

제안 기법이 NLOS 발생 정도에 얼마나 강건한지 평가하기 위해, 40×20m 공간에서 NLOS 발생 확률을 0%부터 50%까지 변화시키며 보정 전(raw)과 보정 후(corrected)의 MAE를 측정하였다(그림 4). 이때 각 확률 조건의 평가 데이터는 해당 NLOS 확률을 적용하여 독립적으로 재생성한 것으로, 10% 조건의 수치는 평가 데이터 구성 방식의 차이로 인해 4-3절의 결과와 소폭 다르다. NLOS 확률 전 구간에서 보정 모델은 raw 대비 일관된 정확도 개선을 보였으며, 특히 NLOS 확률이 높아질수록 raw의 오차는 가파르게 증가하는 반면 보정 후 오차는 완만하게 증가하여 두 곡선의 격차가 점차 벌어졌다. NLOS가 전혀 없는 0% 환경에서는 MAE가 20.8cm에서 19.5cm로 소폭 감소하는 데 그쳐, 제안 보정의 효과가 주로 NLOS 편향 제거에 기인함을 확인하였다. 기준 조건인 10% NLOS에서는 62.6cm에서 36.2cm로 약 42% 감소하였고, 극단적인 50% NLOS 환경에서도 159.7cm에서 93.7cm로 약 41%의 개선율을 유지하여, 다양한 환경에서 강건하게 동작함을 시사한다. 또한 모든 확률 조건에서 MAE의 5회 반복 표준편차는 보정 전후 모두 0.6cm 이하로 매우 작아, 관측된 개선 추세가 시드 선택에 강건함을 확인하였다. 이처럼 NLOS 발생 확률을 체계적으로 변화시키며 보정 성능을 분석하는 것은 실측 환경에서는 조건을 정밀하게 통제하기 어려워 이러한 분석을 수행하기 까다로운데, 이는 제안 시뮬레이터가 거리 보정 알고리즘의 검증 환경으로서 갖는 효

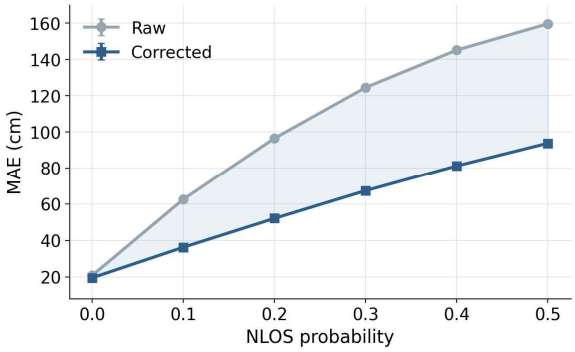


그림 4. NLOS 발생 확률에 따른 MAE 변화(40×20m)

Fig. 4. Change in MAE with NLOS probability (40×20m)

용을 잘 보여준다.

4-6 궤적 시각화 및 처리 시간 분석

그림 5는 단일 궤적에 대해 실측 위치, 보정 전 추정 위치, 보정 후 추정 위치를 동일 좌표계에 시각화한 것이다. 보정 후 궤적이 실측 궤적에 더 근접하며, 특히 NLOS로 인해 크게 튀는 구간에서 보정 효과가 두드러진다. 이는 앞서 정량 지표가 보여준 개선이 실제 이동 궤적 상에서도 재현됨을 시각적으로 확인해 준다.

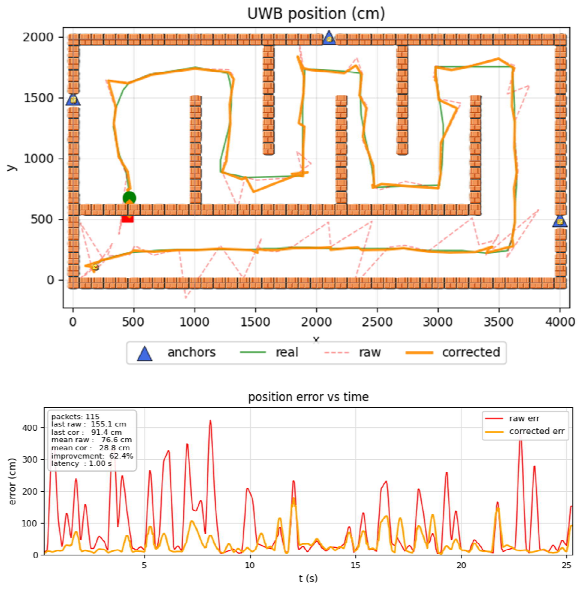


그림 5. 실측·보정 전·보정 후 위치의 실시간 비교
Fig. 5. Real-time comparison of ground-truth, raw, and corrected positions

제안 파이프라인이 실시간 측위에 적용 가능한지 확인하기 위해, 측위 연산 한 사이클의 처리 시간을 측정하였다. 여기서 한 사이클은 XGBoost 거리 보정과 2단계 삼변측량(1차 선형 LSQ, 2차 비선형 TRF)으로 구성되며, 시뮬레이터의 거리값 생성 과정과 무선 전송 모사를 위해 인위적으로 부여한 지연은 측정에서 제외하였다. 측정은 AMD Ryzen 5 9600X(3.90GHz) 환경에서 단일 스레드로 수행하였고, 40×20m 공간의 평가 데이터를 대상으로 초기 워밍업 구간을 제외하고 집계하였다. 측정 결과는 표 6과 같다. 전체 측위 연산 사이클은 평균 2.13ms가 소요되었으며, 최악에 가까운 p95에서도 2.96ms로, 5Hz(프레임당 200ms) 갱신 주기의 1.5%에 불과하였다. 이는 제안 파이프라인이 실시간 측위 환경에서 충분한 연산 여유를 두고 동작할 수 있음을 의미한다. 사이클 내 비중을 보면 XGBoost 추론이 평균 1.09 ms로 전체의 약 51%를 차지하여 가장 컸고, 2차 비선형 삼변측량이 0.98ms로 약 46%를 차지하였으며, 1차 선형 삼변측량은 0.06ms로 비중이 미미하였다. 이러한 연산 분포는 향후 임베디드 측위 시스템 설계 시 XGBoost 트리 추론을 우선적으로 하드웨어 가속 대상으로 삼는 것이 가장 큰 처리 시간 절감을 가져올 수 있음을 시사한다. 또한 반복적 최적화를 수행하는 2차 비선형 삼변측량은 처리할 태그 수가 늘어날수록 누적 연산 비용이 증가하므로, 다중 태그 환경으로의 확장 시 주요한 최적화 지점이 될 것으로 예상된다.

표 6. 측위 연산 사이클의 처리 시간 분해(40×20m, ms)
Table 6. Latency breakdown of the positioning computation cycle (40×20m, ms)

Component	Mean	Std. Dev.	p50	p95	Share
1st linear trilateration	0.06	0.02	0.06	0.07	2.8%
XGBoost inference (3 anchors)	1.09	0.52	0.95	1.92	51.0%
2nd nonlinear trilateration	0.98	0.16	0.92	1.20	46.1%
Total cycle	2.13	0.56	2.01	2.96	100%

V. 결 론

본 논문에서는 UWB 통신 환경을 가상으로 모사하는 RTLS 시뮬레이터와 XGBoost 기반 거리 보정 기법을 제안하였다. 제안한 시뮬레이터는 공간 크기와 앵커 배치, 측정 잡음, NLOS 발생 확률을 자유롭게 설정하여 실측과 유사한 거리값을 생성함으로써, 하드웨어 구축이나 현장 실험 없이 거리 보정 알고리즘을 검증할 수 있는 환경을 제공한다. 보정 단계에서는 XGBoost 회귀가 거리 오차를 직접 예측·제거하며, 1차 삼변측량으로 추정한 위치와 측정 거리·기대 거리의 차이값을 입력 특징으로 재사용하여 보정 성능과 위치 추정 정확도를 함께 향상시킨다.

면적이 4배 차이 나는 두 공간에서, 시드를 달리한 5회 반복 실험 기준으로 평균 위치 오차(MAE)는 약 43~52%, 95 백분위수 오차(p95)는 약 56~60% 감소하였으며, NLOS 발생 확률 0~50% 전 구간에서 일관된 정확도 개선과 반복 간 낮은 변동성을 확인하였다. 또한 입력 특징 구성을 달리한 비교를 통해 1차 삼변측량 추정 좌표를 명시적인 입력 특징으로 추가하는 설계가 보정 정확도 향상에 실질적으로 기여함을 정량적으로 검증하였으며, 강건 추정 기법 및 다른 학습 모델과의 비교에서도 제안 구성이 비슷한 정확도의 학습 모델 대비 실시간·임베디드 적용에 유리함을 확인하였다. 처리 시간 측면에서는 측위 연산 한 사이클이 평균 2.13 ms로 5 Hz 갱신 주기에 비해 충분한 여유를 보여, 제안 파이프라인이 실시간 측위에 적용 가능함을 확인하였다. 이를 통해 제안한 시뮬레이터가 UWB 거리 보정 알고리즘의 검증과 개선에 효과적인 평가 환경임을 보였다. 다만 본 연구의 평가는 시뮬레이터

가 생성한 합성 데이터에 기반하며, NLOS 편향을 단순화된 통계 모델로 모사하였으므로 실측 환경에서의 검증이 추가로 필요하다. 또한 단일 태그를 가정하고, 앵커의 위치가 정확히 알려져 있다고 전제하였다는 한계가 있다.

향후 연구에서는 실측 UWB 데이터를 이용해 제안 기법을 검증하고자 한다. 또한 본 연구가 단일 태그를 가정한 것을 넘어, 다수의 앵커와 태그를 동시에 처리할 수 있도록 분산 시스템 구조로 확장할 계획이다. 구체적으로는 앵커 수를 늘려 태그와 가까우면서 신뢰도가 높은 앵커들을 선택적으로 활용하는 측위 구조를 도입하고, 이 과정에서 앵커 수와 배치 조건에 따른 보정 성능의 변화도 함께 평가하며, 다중 태그의 거리 보정과 삼변측량을 병렬적으로 처리하고자 한다. 아울러 실시간 측위를 위한 전용 하드웨어 가속기 설계를 진행하고 있으며, 소프트웨어 구현과 동등한 수준의 측위 정확도를 유지하면서 저지연으로 동작하는 임베디드 측위 시스템을 구현하는 것을 목표로 한다.

감사의 글

본 연구는 산업통상자원부 한국산업기술진흥원 국제공동기술개발사업(과제번호 P0029851)의 연구지원으로 수행되었음.

참고문헌

[1] F. Zafari, A. Gkelias, and K. K. Leung, “A Survey of Indoor Localization Systems and Technologies,” *IEEE Communications Surveys & Tutorials*, Vol. 21, No. 3, pp. 2568-2599, 2019. https://doi.org/10.1109/COMST.2019.2911558

[2] R. Faragher and R. Harle, “Location Fingerprinting with Bluetooth Low Energy Beacons,” *IEEE Journal on Selected Areas in Communications*, Vol. 33, No. 11, pp. 2418-2428, November 2015. https://doi.org/10.1109/JSAC.2015.2430281

[3] B.-J. Jang, “Principles and Trends of UWB Positioning Technology,” *The Journal of Korean Institute of Electromagnetic Engineering and Science*, Vol. 33, No. 1, pp. 1-11, January 2022. https://doi.org/10.5515/KJKIEES.2022.33.1.1

[4] S. Maranò, W. M. Gifford, H. Wymeersch, and M. Z. Win, “NLOS Identification and Mitigation for Localization Based on UWB Experimental Data,” *IEEE Journal on Selected Areas in Communications*, Vol. 28, No. 7, pp. 1026-1035, September 2010. https://doi.org/10.1109/JSAC.2010.100907

[5] I. Jung and B.-J. Jang, “Research on Real-Time Indoor Object Positioning and Quantitative Positional Accuracy Verification Method Using UWB,” *Journal of Korea Academia-Industrial Cooperation Society*, Vol. 24, No. 12, pp. 686-693, December 2023. https://doi.org/10.5762/KAIS.2023.24.12.686

[6] S.-H. Jeong and D.-S. Choi, “Development of a Real-Time Position Tracking System for a Manufacturing Process Based on a UWB Sensor Using a Kalman Filter,” *Journal of the Korea Academia-Industrial Cooperation Society*, Vol. 21, No. 2, pp. 627-633, February 2020. https://doi.org/10.5762/KAIS.2020.21.2.627

[7] F. Wang, H. Tang, and J. Chen, “Survey on NLOS Identification and Error Mitigation for UWB Indoor Positioning,” *Electronics*, Vol. 12, No. 7, 1678, April 2023. https://doi.org/10.3390/electronics12071678

[8] H. Wymeersch, S. Maranò, W. M. Gifford, and M. Z. Win, “A Machine Learning Approach to Ranging Error Mitigation for UWB Localization,” *IEEE Transactions on Communications*, Vol. 60, No. 6, pp. 1719-1728, June 2012. https://doi.org/10.1109/TCOMM.2012.042712.110035

[9] K. Yu, K. Wen, Y. Li, S. Zhang, and K. Zhang, “A Novel NLOS Mitigation Algorithm for UWB Localization in Harsh Indoor Environments,” *IEEE Transactions on Vehicular Technology*, Vol. 68, No. 1, pp. 686-699, January 2019. https://doi.org/10.1109/TVT.2018.2883810

[10] J. Wei, H. Wang, S. Su, Y. Tang, X. Guo, and X. Sun, “NLOS Identification Using Parallel Deep Learning Model and Time-Frequency Information in UWB-Based Positioning System,” *Measurement*, Vol. 195, 111191, May 2022. https://doi.org/10.1016/j.measurement.2022.111191

[11] S. Baek, “A Study on Machine Learning-Based UWB Distance Measurement Correction: An XGBoost Approach for NLOS Classification and Filtering,” *Journal of Internet Computing and Services*, Vol. 26, No. 5, pp. 49-56, October 2025. https://doi.org/10.7472/jksii.2025.26.5.49

[12] S. Xu, Q. Liu, M. Lin, Q. Wang, and K. Chen, “A Novel Non-Line-of-Sight Error Mitigation Algorithm Using Double Extended Kalman Filter for Ultra-Wide Band Ranging Technology,” *Electronics*, Vol. 14, No. 3, 483, January 2025. https://doi.org/10.3390/electronics14030483

[13] A. R. Jiménez Ruiz and F. Seco Granja, “Comparing Ubisense, BeSpoon, and DecaWave UWB Location Systems: Indoor Performance Analysis,” *IEEE Transactions on Instrumentation and Measurement*, Vol. 66, No. 8, pp. 2106-2117, August 2017. https://doi.org/10.1109/TIM.2017.2681398

[14] B. Silva and G. P. Hancke, “Ranging Error Mitigation for Through-the-Wall Non-Line-of-Sight Conditions,” *IEEE*

Transactions on Industrial Informatics, Vol. 16, No. 11, pp. 6903-6911, November 2020. https://doi.org/10.1109/TII.2020.2969886

[15] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*, San Francisco: CA, pp. 785-794, August 2016. https://doi.org/10.1145/2939672.2939785



김하연(Hayeon Kim)

2026년 : 한신대학교 대학원(공학사)

2026년～현 재: 한신대학교 AISW학과 석박사통합과정

※관심분야 : SoC(System on Chip) 설계, AI모델의 하드웨어 가속기(Hardware Accelerator) 설계, 인공지능(AI) 등



정의성(Eu-Sung Jung)

1990년 : 연세대학교 전자공학과(공학사)

1992년 : 연세대학교 대학원 전자공학과(공학석사)

1992년～1998년: 효성T&C 선임연구원

1998년～2000년: DSPD&C 선임연구원

2000년～2004년: 텔슨정보통신 책임연구원

2004년～2005년: 레인콤 책임연구원

2006년～2007년: 맥시안 책임연구원

2007년～2010년: 엠에스웨이 기술이사

2010년～2017년: 셈앤텍 연구소장

2016년～2021년: 제스엔지니어링 연구소장

2022년～현 재: 메타리얼 주식회사 대표

※관심분야 : 메타버스(Metaverse), UWB 측위기술(UWB Positioning Technology), 정보통신(ICT), 사물인터넷(IoT) 등



김명환(MyungHwan Kim)

2003년 : 경상대학교 컴퓨터과학과(이학사)

2003년 : 경상대학교 컴퓨터과학과(이학사)

2007년: 매크로미디어 연구소장

2016년: 솔트웍스 사업기획팀 팀장

2018년～현 재: ㈜심스리얼리티 대표이사

※관심분야 : 메타버스(Metaverse), XR(eXtended Reality), 소프트웨어 아키텍처(Software Architecture), 분산객체(Distributed Objects) 등



백수진(SuJin Baek)

2002년 : 경희대학교 전자전산전파공학부(공학사)

2004년 : 경희대학교 일반대학원 전자계산공학과(공학석사)

2012년 : 경희대학교 일반대학원 컴퓨터공학과(공학박사)

2023년～현 재: 한신대학교 AI시스템반도체학 교수

※관심분야 : 인공지능(AI), 데이터 분석(Data Analysis), 적응형 소프트웨어(Adaptive Software), 센서 모델링(Sensor Modeling), UWB 거리측정 보정 기술(UWB Distance Measurement Correction Technique) 등



정승민(Seungmin Jung)

1990년 : 연세대학교 전자공학과 (공학사)

1992년 : 연세대학교 대학원 전자공학과 (공학석사)

2006년 : 연세대학교 대학원 전기전자공학과 (공학박사)

2006년～현 재: 한신대학교 AI시스템반도체학 교수

※관심분야 : SoC(System on Chip) 설계, AI모델의 하드웨어 가속기(Hardware Accelerator) 설계, 생체인식(Biometrics) 및 이미지처리(Image Processing), VLSI 설계(VLSI Design) 등