# Machine Learning-based UWB Error Correction Experiment in an Indoor Environment

Jiseon Moon, Sunwoo Kim<sup>†</sup>

Department of Electronic Engineering, Hanyang University, Seoul 04763, Korea

# ABSTRACT

In this paper, we propose a method for estimating the error of the Ultra-Wideband (UWB) distance measurement using the channel impulse response (CIR) of the UWB signal based on machine learning. Due to the recent demand for indoor locationbased services, wireless signal-based localization technologies are being studied, such as UWB, Wi-Fi, and Bluetooth. The constructive obstacles constituting the indoor environment make the distance measurement of UWB inaccurate, which lowers the indoor localization accuracy. Therefore, we apply machine learning to learn the characteristics of UWB signals and estimate the error of UWB distance measurements. In addition, the performance of the proposed algorithm is analyzed through experiments in an indoor environment composed of various walls.

Keywords: Ultra-wideband (UWB), machine learning

# **1. INTRODUCTION**

최근 위치 기반 서비스의 수요가 증가하면서 실내외 측위 기 술 개발이 활발히 진행되고 있다. 실외에서는 보편적으로 global positioning system (GPS) 기반 측위 기술을 이용하지만, GPS 음 영 지역인 실내에서는 Ultra-Wideband (UWB), Wireless Fidelity (Wi-Fi), 블루투스 등의 무선 신호 기반 측위 기술이 적용된다 (Laoudias et al. 2018). UWB는 time difference of arrival (TDOA) 또는 two-way ranging (TWR)을 이용하여 태그와 앵커 간의 거 리를 추정하며, 넓은 주파수 대역의 활용을 통해 cm 단위의 고 정밀 측위를 가능하게 한다 (Win & Scholtz 1998, Bocus et al. 2020). 하지만 실내 환경을 구성하는 다양한 벽체는 UWB의 거리 측정치를 부정확하게 하며, 이는 실내 측위 정확도를 저하시킨다 (Chen et al. 2020). 따라서, UWB 신호의 거리 측정치를 활용하 기 위해서는 UWB 신호의 오차를 감지하고 보상하는 기술이 필 수적이다.

UWB 신호의 채널 임펄스 응답 (channel impulse response,

Received Feb 24, 2022 Revised Mar 03, 2022 Accepted Mar 04, 2022 <sup>†</sup>Corresponding Author

E-mail: remero@hanyang.ac.kr

Tel: +82-2-2220-4823 Fax: +82-2-2220-3129

Jiseon Moon https://orcid.org/0000-0002-1451-8535 Sunwoo Kim https://orcid.org/0000-0002-7055-6587 CIR)을 활용한 오차 보상 연구는 고차원 데이터에 의한 많은 전 처리 과정을 요구한다. 이러한 문제를 해결하기 위해, 최근 머신 러닝 기반의 UWB line of sight (LoS)와 non-LoS(NLoS) 신호를 분류하는 연구가 진행되고 있다 (Jiang et al. 2020, Stahlke et al. 2020). 본 연구는 머신러닝을 활용하여 UWB 신호의 CIR을 통 해 UWB 거리 측정치의 오차를 추정하고, 오차 추정치를 이용하 여 UWB 거리 측정치를 보정하는 알고리즘을 제안한다. 또한, 다 양한 벽체로 구성된 실내 환경에서의 실제 실험을 통해 제안하는 알고리즘의 성능을 분석한다.

# 2. MACHINE LEARNING-BASED UWB ERROR CORRECTION

#### 2.1 UWB CIR의 Feature 추출

UWB는 나노 또는 피코 초 단위의 좁은 펄스를 발생시키고, 이 에 대한 CIR을 수신함으로써 단말 간의 거리를 추정한다. UWB 의 LoS 신호는 수신단에 첫 번째로 도달하는 신호의 세기가 가 장 강하고, 짧은 상승 시간 (rise time)을 가진다. 이에 반해, 실 내 구조물 및 벽에 의한 NLoS 신호는 신호 세기가 가장 강한 신 호가 수신되기 이전에 신호 세기가 약한 신호가 다중 경로를 통 해 먼저 수신되어, 상승 시간이 길어지게 되는 경향이 있다. 또 한, NLoS 환경에서는 다중 경로에 의해 신호가 확산되기 때문

#### Table 1. UWB CIR feature.

Feature	Equation	
Energy	$\mathcal{E}_{r} = \int_{T}  r(t) ^{2} dt$	
Maximum amplitude	$r_{max} = max_t  r(t) $	
Rise time	$t_{rise} = t_H - t_L$	
Mean excess delay	$\tau_m = \int_T t  \psi(t)  dt$	
RMS delay spread	$\tau_{RMS} = \int_T (t  -  \tau_m)^2  \psi(t)  dt$	
Kurtosis	$\kappa = \frac{1}{\sigma_{ r }^4 T} \int_T ( \mathbf{r}(t)  - \mu_{ r })^4 dt$	
Estimated distance	â	



Fig. 1. CIR features according to the indoor environment.

에 root-mean square (RMS) 지연 확산 (delay spread), 평균 초 과 지연 (mean excess delay)이 LoS에 비해 큰 값을 가지게 된다 (Maranò et al. 2010). LoS와 NLoS 환경에서 수신한 UWB 신호의 CIR은 수집 환경에 따라 그 특성이 달라지게 되며, CIR의 특성을 수치화한 특성 (feature)은 머신러닝 기반 UWB 오차 추정에 활용 된다. CIR의 특성으로 CIR 신호의 에너지, 최대 진폭, 상승 시간, 평균 초과 지연, RMS 지연 확산, 첨도 (Kurtosis), UWB 거리 추정 치가 활용되며, 시간 T 동안 수신한 CIR 신호 r(t)로부터 추출한 특 성은 Table 1과 같다. 신호의 상승 시간은 신호가 최대 진폭의 일정 비율까지 도달하는 데에 소요되는 시간이며, t<sub>t</sub>=min{t: r(t) ≥ ασ<sub>t</sub>},  $t_{H}=\min\{t: r(t) \ge \alpha \sigma_{n}\}$ 에 의해 계산된다.  $\sigma_{n}$ 는 열 잡음의 표준편차, α>0, 0<β≤1이다. 신호의 평균 초과 지연은 다중 경로에 의한 채</p> 널의 시간 분산 성질이며, RMS 지연 확산은 전력 지연 프로파일 의 분산으로써, ψ(t)=r(t)²/Er에 의해 계산된다. 또한, 신호의 첨도 는  $\mu_{|\mathbf{r}|} = \frac{1}{r} \int_{\mathbf{T}} |\mathbf{r}(t)| dt$ ,  $\sigma_{|\mathbf{r}|}^2 = \frac{1}{r} \int_{\mathbf{T}} (|\mathbf{r}(t)| - \mu_{|\mathbf{r}|})^2 dt$  에 의해 계산되 며, CIR의 뾰족한 정도를 수치화한 것이다. Fig. 1은 자유공간, 유 리벽, 콘크리트의 벽체가 존재하는 실내환경에서 수집된 CIR의 특성을 나타낸 것이다.

#### 2.2 SVM Regression 기반 UWB 오차 추정

서포트 벡터 머신 (support vector machine, SVM)은 데이터의 분류 (classification) 및 회귀 (regression) 분석에 활용되는 지도 학습 (supervised learning)의 일종이다. SVM은 회귀 분석은 관 측된 입력 *x* ∈ ℝ<sup>n</sup>으로부터 스칼라 출력 *y* ∈ ℝ을 추정하기 위한 초 평면 (hyperplane)을 찾는 기법으로, 회귀 분석의 입력과 출력 관



Fig. 2. Deep neural network structure.

계는 식 (1)과 같다.

$$y(\chi) = w^{T} \varphi(\chi) \tag{1}$$

 $\varphi(\cdot)$ 는 선형 회귀 함수, w는 SVM 훈련 데이터셋  $\{\chi_j, y_j\}_{j=1}^N$ 에 의 해 결정되는 회귀 함수의 매개변수이다. SVM 회귀 분석은 결정 경계 간의 거리  $\mathbf{d} = 2\epsilon/\sqrt{\|\mathbf{w}\|_2^2 + 1}$ 를 최대화하는 w를 찾는 최적 화 문제로 식 (2)와 같다 (Vapnik 2000).

minimize 
$$\|w\|_2^2 + \gamma \sum_{j=1}^N L\left(y_j - w^T \varphi(\chi_j)\right)$$
, s.t.  $|y_j - y(\chi_j)| \le \epsilon$  (2)

y는 훈련 데이터셋의 오차에 관여하는 매개변수,  $L(\cdot)$ 는 손실 함 수,  $\epsilon > 0$ 이다. 본 연구에서는 UWB CIR로부터 추출한 특성을 벡 터화한  $\chi = [\mathcal{E}_r, r_{max}, t_{rise}, \tau_{MED}, \tau_{RMS}, \kappa, d]^T$ 를 SVM regression (SVR)의 입력으로 하여 UWB 거리 측정치의 오차 y를 예측한다.

#### 2.3 DNN Regression 기반 UWB 오차 추정

Fig. 2와 같이 심층 신경망 (deep neural network, DNN)은 입 력층 (input layer), 복수 개의 은닉층 (hidden layer), 출력층 (output layer)으로 이루어진 인공 신경망 (artificial neural network, ANN)으로써, 복잡한 데이터의 특징을 스스로 학습하여 비선형 관계를 모델링한다 (Goodfellow et al. 2016). 심층 신경망의 학습 은 은닉층에 의해 구성되는 가중치 w의 함수로 나타내어지는 손 실 함수 *L*을 최소화하는 방향으로 진행되며 식 (3)과 같다.

$$min_{w} \frac{1}{N} \sum_{j=1}^{N} L(w, \chi_{j}, y_{j})$$
(3)

심층 신경망의 손실 함수를 최소화하는 가중치 w를 얻기 위해 다양한 최적화 알고리즘 (optimizer)이 사용된다. 전체 훈련 데 이터에 대한 손실 함수의 경사 (gradient)가 감소하는 방향으로 가중치를 조정하는 경사 하강법 (gradient descent)이 대표적이 며, 최근에는 훈련 과정에서의 학습률 (learning rate)과 학습 방 향 (momentum)을 조절할 수 있는 adaptive moment estimation (Adam)이 활용된다.



(a) Free space (FTC 5th floor)



(c) Iron fire door (FTC 5th floor)



(d) Concrete (IT·BT 3rd floor)

Fig. 3. Experiment environment.

# 3. EXPERIMENTAL ANALYSIS

### 3.1 실험 환경

본 실험은 한양대학교 퓨전테크센터 (FTC)와 IT·BT관에서 진 행했으며, Fig. 3의 다양한 벽체로 구성된 실내 환경에서 UWB CIR 신호가 수집되었다. 실험에 사용된 UWB는 Pozyx DWM 1000으로, 6240 MHz의 중심 주파수와 499.2 MHz 대역폭을 이용 하며 UWB의 앵커와 태그 간 거리는 TWR 알고리즘을 통해 측정 된다. UWB 앵커와 태그는 3 m, 5 m, 8 m, 10 m로 거리를 변화시 키며, 실험 환경 및 UWB 모듈 간의 거리에 따라 각 500개의 CIR 샘플을 수집하였다. 실내 환경은 복수개의 벽체로 이루어져 있기 때문에, 단일 벽체에 대한 UWB CIR 샘플을 수집하기 위하여 두 UWB 앵커와 태그는 실험 벽체의 법선 방향으로 위치시켰다.

### 3.2 머신러닝 기반 UWB 오차 추정 결과

수집한 데이터의 80%은 학습, 20%는 성능 검증에 사용되 었다. SVR의 파라미터 C는 1000, y는 0.1이며, DNN에 활용 된 모델 구조는 32×128×64, 최적화 알고리즘은 Adam, 손실 함 수는 평균 절대 오차 (mean absolute error, MAE)로 계산되 었다. Fig. 4는 DNN 학습을 500번 반복함에 따라 감소하는 손 실 함수를 나타낸 것이다. 400번 이상 학습이 진행되었을 때, 테 스트 데이터셋의 손실 함수가 수렴하는 것을 확인할 수 있다. N 개의 테스트 데이터에 대해 실제 UWB 거리 측정치 오차 *e와* DNN으로 추정한 오차 *ê<sub>DNN</sub>* 및 SVR로 추정한 오차 *ê<sub>DNN</sub>*의 MAE



Fig. 4. Loss function versus the DNN training epoch.

 $E_{DNN} = (1/N) \sum_{i=1}^{N} |e_i - \hat{e}_{DNN,i}|$ ,  $E_{SVR} = (1/N) \sum_{i=1}^{N} |e_i - \hat{e}_{SVR,i}|$ 로 오차 추정 성능을 평가한다. UWB 거리 측정치의 오차 추정 실험 을 통해  $E_{SVR}$ 이 55.1 mm,  $E_{DNN}$ 이 33.6 mm으로, DNN 기반 오차 추 정 기법이 SVR와 비교하여 22.1 mm 정확함을 확인할 수 있다.

#### 3.3 UWB 오차 보정 결과

UWB 거리 측정치의 오차 보정은 머신러닝을 통해 추정한 UWB 거리 측정치의 오차 9를 UWB 거리 측정치 d로부터 제하 여 이루어진다. Fig. 5는 자유 공간과 콘크리트 환경에서 100개의 UWB 거리 측정치 오차와 머신러닝을 통해 오차 보정한 결과를 나타낸다. 두 UWB 간의 거리가 증가함에 따라 UWB 거리 측정



Fig. 5. UWB error correction based on machine learning.

 Table 2. Distance error before and after error correction (unit: mm).

	Before error correction	After error correction (SVR)	After error correction (DNN)
Free space	277.68	-1.02	-0.10
Glass	294.91	-8.48	6.88
Concrete	901.01	-27.57	6.03

치 오차가 증가하지만 SVR, DNN을 활용한 UWB 거리 측정치 오 차 보정을 통해 거리 측정 오차가 감소하고, DNN이 SVR보다 우 수한 오차 추정 성능을 가지는 것을 확인하였다. Table 2는 실험 환경에 대한 전체 수집 데이터의 오차 보상 전후 UWB 거리 측 정치 오차를 나타낸 것이다. DNN을 활용한 오차 보상을 통해 콘 크리트 벽체가 존재하는 NLoS 환경에서 평균 거리 측정 오차가 901.01 mm에서 6.03 mm로 크게 감소하는 것을 확인하였다.

# 4. CONCLUSIONS

본 연구는 머신러닝을 활용하여 UWB CIR 특성을 통해 UWB

거리 측정의 오차를 추정하는 방법을 제안한다. 실내 환경에서는 여러 구조물과 장애물에 의해 UWB 거리 측정치의 오차가 발생 하며, 이는 UWB 모듈 측위의 성능을 저하시킨다. 따라서, 본 연 구는 다양한 벽체로 구성된 실내 환경으로부터 UWB의 CIR 신호 를 수집하고, CIR로부터 추출한 특성을 DNN 및 SVR 기반 UWB 거리 측정치 오차 학습에 이용한다. 머신러닝 기반으로 추정된 UWB 거리 측정치의 오차를 활용하여 실제 측정치의 오차를 보 정하며, 시뮬레이션을 통해 머신러닝 기반 UWB 거리 측정치 오 차 보정의 성능을 제시한다. 또한, 자유 공간 및 유리벽, 콘크리 트, 방화 철문으로 구성된 실내 환경에서 실험을 통해 제안한 알 고리즘의 성능을 분석하였다.

### ACKNOWLEDGMENTS

이 논문은 2022년도 정부(소방청)의 재원으로 정보통신기획평 가원의 지원을 받아 수행된 연구임 (No.2019-0-01325, 재난현장 무선통신 추적기반 요구조자 및 소방관 위치정보시스템 개발).

## AUTHOR CONTRIBUTIONS

Methodology, Jiseon Moon and Sunwoo Kim; software, Jiseon Moon; validation, Jiseon Moon; writing—original draft preparation, Jiseon Moon; writing—review and editing, Jiseon Moon and Sunwoo Kim; supervision, Sunwoo Kim; project administration, Sunwoo Kim.

# CONFLICTS OF INTEREST

Authors must identify and declare any personal circumstances or interest that may be perceived as inappropriately influencing the representation or interpretation of reported research results. Declare conflicts of interest or state "The authors declare no conflict of interest".

### REFERENCES

- Bocus, M. J., Paulavičius J., McConville, R., Santos-Rodriguez, R., & Piechocki, R. 2020, Low Cost Localisation in Residential Environments using High Resolution CIR Information, IEEE Global Commun. Conf., 7-11 Dec. 2020, Taipei, Taiwan, pp.1-6. https:// doi.org/10.1109/GLOBECOM42002.2020.9322453
- Chen, Y. -Y., Huang, S. -P., Wu, T. -W., Tsai, W. -T., Liou, C. -Y., & Mao, S. -G. 2020, UWB System for Indoor Positioning and Tracking with Arbitrary Target Orientation, Optimal Anchor Location, and Adaptive NLOS Mitigation, IEEE Trans. Veh. Technol., 69, 9304-9314. https://doi. org/10.1109/TVT.2020.2972578
- Goodfellow, I., Bengio, Y., & Courville, A. 2016, Deep learning (Massachusetts: MIT press.)
- Jiang, C., Shen, J., Chen, S., Chen, Y., Liu, D., et al. 2020, UWB NLOS/LOS Classification Using Deep Learning Method, IEEE Commun. Lett., 24, 2226-2230, https:// doi.org/10.1109/LCOMM.2020.2999904
- Laoudias, C., Moreira, A., Kim, S., Lee, S., Wirola, L., et al. 2018, A Survey of Enabling Technologies for Network Localization, Tracking, and Navigation, IEEE Commun. Surveys Tuts., 20, 3607–3644. https://doi.org/10.1109/ COMST.2018.2855063
- Maranò, S., Gifford, W. M., Wymeersch, H., & Win, M. Z. 2010, NLOS identification and mitigation for localization based on UWB experimental data, IEEE J. Sel. Areas in Commun., 28, 1026-1035. https://doi.org/10.1109/JSAC.2010.100907

Stahlke, M., Kram, S., Mutschler, C., & Mahr, T. 2020, NLOS

Detection using UWB Channel Impulse Responses and Convolutional Neural Networks, 2020 Int. Conf. Localization GNSS (ICL-GNSS), 2020, pp. 1-6, https:// doi.org/10.1109/ICL-GNSS49876.2020.9115498

- Vapnik, V. N. 2000, The nature of statistical learning theory, (Berlin: Springer science & business media), pp.181-218
- Win, M. Z. & Scholtz, R. A. 1998, On the robustness of ultra-wide bandwidth signals in dense multipath environments, IEEE Commun. Lett., 2, 51-53. https:// doi.org/10.1109/4234.660801



Jiseon Moon received her B.S. degree in Information Communication Engineering from Inha University of Incheon, South Korea, in 2019. She is currently pursuing the master's degree in the Department of Electronics and Computer Engineering from Hanyang University, Seoul, South

Korea. Her research interests include wireless localization/ positioning systems, multi-target tracking and location-aware communications.



Sunwoo Kim received his B.S degree from Hanyang University, Seoul, Korea in 1999, and his Ph.D. degree, in 2005, from the Department of Electrical and Computer Engineering, University of California, Santa Barbara. Since 2005, he has been working in the Department of Electronic Engineering

at Hanyang University, Seoul, Korea, where he is currently a professor. He is also the director of the 5G/Unmanned Vehicle Research Center, funded by the Ministry of Science and ICT of Korea. He was a visiting scholar to the Laboratory for Information and Decision Systems, Massachusetts Institute of Technology from 2018 to 2019. He is an associate editor of IEEE Transactions on Vehicular Technology. He is a senior member of the IEEE. His research interests include wireless communication/positioning/localization, signal processing, vehicular networks, and location-aware communications.