

측위 안정화를 위한 End to End 기반의 Wi-Fi RTT 네트워크 구조 설계

성 주 현[†]

End-to-end-based Wi-Fi RTT network structure design for positioning stabilization

Ju-Hyeon Seong[†]

ABSTRACT

Wi-Fi Round-trip timing (RTT) based location estimation technology estimates the distance between the user and the AP based on the transmission and reception time of the signal. This is because reception instability and signal distortion are greater than that of a Received Signal Strength Indicator (RSSI) based fingerprint in an indoor NLOS environment, resulting in a large position error due to multipath fading. To solve this problem, in this paper, we propose an end-to-end based WiFi Trilateration Net (WTN) that combines neural network-based RTT correction and trilateral positioning network, respectively. The proposed WTN is composed of an RNN-based correction network to improve the RTT distance accuracy and a neural network-based trilateral positioning network for real-time positioning implemented in an end-to-end structure. The proposed network improves learning efficiency by changing the trilateral positioning algorithm, which cannot be learned through differentiation due to mathematical operations, to a neural network. In addition, in order to increase the stability of the TOA based RTT, a correction network is applied in the scanning step to collect reliable distance estimation values from each RTT AP.

Key words: Wi-Fi, RTT, Trilateration, Neural Network, End-to-End

1. 서 론

최근 건물의 높이 및 구조에 대한 복잡성이 높아지면서 이러한 환경에 맞는 위치 서비스를 제공할 수 있는 기반 기술인 실내 위치측위에 대한 관심이 증대되고 있다. GPS로 대표되는 실외 위치인식 기술은 정밀한 측위를 바탕으로 다양한 위치기반 서비스(Location based Service, LBS)를 제공하고 있으며 생활에 필수적인 기술로 인식되고 있다. 하지만 GPS

신호는 낮은 신호 세기로 인해 터널, 건물 등 측위가 어려운 음영지역이 발생하며 이러한 지역은 다양한 무선 통신 기술들이 개발되었다. 무선 통신기반의 실내 위치인식은 대표적으로 수신신호세기(Received Signal Strength Indicator, RSSI)기반 기술과 도착시간(Time of Arrival, TOA)기반 기술로 구분한다 [1,2].

수신신호세기를 이용한 대표적인 기술인 지문(Fingerprint) 방식은 측정되는 신호의 세기를 기반

* Corresponding Author : Ju-Hyeon Seong, Address: (49112) Taejong-ro 727, Yeongdo-Gu, Busan, Korea, TEL : +82-51-410-5031, FAX : +82-51-410-5031, E-mail : jhseong@kmou.ac.kr

Receipt date : May 24, 2021, Approval date : May 28, 2021

[†] Dept. of Liberal Education, Center for Liberal Education, Korea Maritime and Ocean University

* This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education (2019R111A3A01063290)

으로 위치를 인식하기 때문에 실내 각 위치에서 측정되는 AP와 신호세기를 저장하는 별도의 데이터베이스가 존재하며 이를 활용해 실시간으로 이동하는 사용자의 위치를 추정한다. 이때 사용되는 무선통신은 BLE[3], Wi-Fi[4,5], Zigbee[6] 등이 사용된다. 이러한 통신을 사용하는 지문 방식은 데이터베이스를 구축해야하는 단점이 있지만 각 공간에 대한 왜곡된 무선신호의 세기와 측정 AP를 그대로 저장하여 사용할 수 있기 때문에 장애물이 많은 NLOS(Non-Line of sight) 환경에 강인하다[7,8].

반면에 AP와 단말기의 데이터 송수신 시간을 기반으로 위치를 추정하는 도착시간 방식은 UWB, CSS 등의 무선 통신을 활용하여 수 cm 이내의 정밀한 위치인식이 가능하며 별도의 데이터베이스가 필요없이 쉽게 구축이 가능하다. 하지만 해당 통신을 송수신할 수 있는 AP와 단말기가 별도로 필요하고 NLOS 환경에서 장애물에 의한 전파도착 시간의 왜곡이 심해 측정오차가 많이 발생한다. 삼변측위(Trilateration)은 3개의 AP로부터 측정되는 거리값을 통해 사용자의 위치를 추정하는 방식으로 이러한 도착시간 방식의 대표적인 측위 기법이다[9,10].

수신신호세기 방식의 AP에서 도착시간 방식이 가능하게 구현한 802.11 mc 표준인 Wi-Fi RTT는 Wi-Fi의 보급률과 도착시간 방식의 장점과 맞물려 새로운 측위 기술로써 최근 많은 연구가 진행되고 있다.

Guo et al.[11]은 RTT의 송수신기간의 측위 오차를 분석하여 가우스 모델을 기반으로 범위 오차 모델을 설계하였다. 이는 단순한 AP간의 제한된 거리 측정 연구로써 삼변측위 등 실제 위치적용에 대한 결과를 확인하기 어렵다. 또한, 실내 환경에 대한 영향을 고려하지 않아 신호의 불안정성과 측정오류에 대한 고려가 부족하다.

Cao et al.[12]은 RTT를 이용한 LOS(Line of sight) 환경에서의 삼변측위 알고리즘에 대해 연구하였다. 해당 연구를 통해 일반적으로 벽면과 같은 무선 다중경로 환경에서 측정이 어려운 RTT 특성을 보였다. 이는 실내 환경에서 RTT의 적용에 여전히 제약이 있음을 나타낸다.

이러한 연구들을 살펴보면 실제 환경에서 벽 주변의 멀티패스에 의한 측정 어려 및 미수신 현상의 문제가 많이 발생하고 있다. 이러한 문제를 해결하기 위하여 본 논문에서는 뉴럴 네트워크 기반 RTT 보

정과 삼변측위 네트워크가 각각 결합된 End-to-end 기반의 WiFi Trilateration Net (WTN)을 제안한다. 제안한 네트워크는 RTT 거리 정확도를 향상시키기 위한 순환신경망 (Recurrent Neural Network, RNN) 기반 보정 네트워크와 End-to-end 구조로 구현된 실시간 위치 확인을 신경망 기반 삼변측위 네트워크로 구성된다. 제안한 네트워크는 수학적 연산으로 인해 미분을 통한 학습이 불가능한 삼변측위 알고리즘을 뉴럴 네트워크로 변경하여 학습 효율을 높인다. 또한 멀티패스에 의한 RTT의 수신 안정성을 높이기 위해 스캐닝 단계에서 보정 네트워크를 적용하여 각 RTT AP로부터 신뢰성 있는 거리 추정값을 수집한다.

본 논문의 구성은 다음과 같다. 2장에서 본 논문의 기본 이론이 되는 WiFi RTT기반 삼변측위와 뉴럴 네트워크기반의 측위 알고리즘에 대하여 정의한 다음, 3장에서 제안하는 WTN을 설명한다. 여기에서는 제안한 WTN의 전체적인 흐름도와 알고리즘을 구체적으로 서술한다. 그리고 4장에서는 제안한 WTN의 측위 성능을 검증하기 위해 실험한 결과를 객관적인 평가 지표로 비교하여 성능을 평가하고 5장에서 결론을 맺는다.

2. 이 론

2.1 WiFi RTT기반 삼변측위

2016년에 발표된 IEEE 802.11 mc standard인 WiFi RTT는 구글의 안드로이드를 중심으로 스마트폰기반 새로운 위치측위 방식으로 발표되었다. RTT는 기존의 도착시간 기반 측위 방식으로 전파의 송수신거리를 추정하는 양방향 거리추정(Two-way ranging) 방식을 사용하고 있다. Fig. 1은 WiFi RTT의 거리 추정 방식을 나타낸다. 스마트폰과 WiFi AP간의 FTM(Fine timing measurement) 프로토콜을 전송하여 송수신 시간을 기록하고 계산한다. RTT에 의해 추정된 거리 D 는 다음과 같이 정의된다.

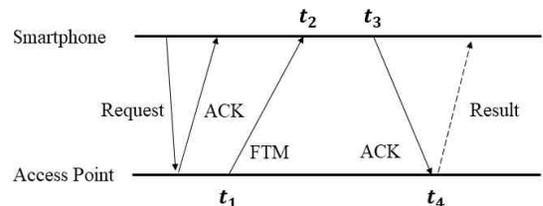


Fig. 1. RTT distance estimation principle.

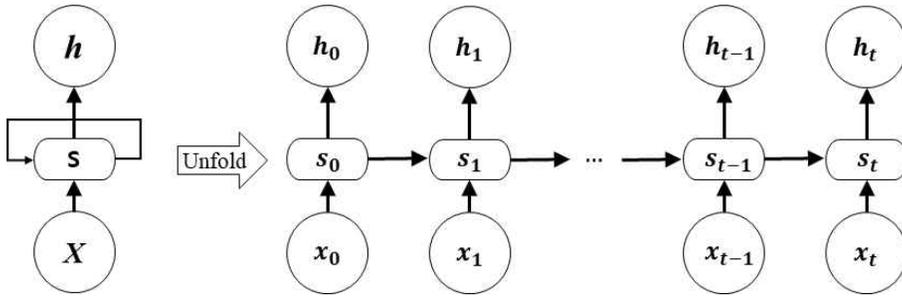


Fig. 2. Structure of Recurrent Neural Network.

$$D = C \times \frac{(t_4 - t_1) - (t_3 - t_2)}{2} \quad (1)$$

여기서, C 는 빛의 속도를 의미한다. AP와 스마트폰의 패킷 전송을 통해 송수신 시간을 계산하면 단일 측정의 경우 오차가 크게 발생할 수 있다. 따라서 수회 해당 알고리즘을 반복해 오차를 최소화하는 방식이 적용된다. 특히, 실내 환경은 이러한 오차 발생이 크기 때문에 이를 보정하기 위한 연구가 많이 되고 있다[13,14].

2.2 뉴럴네트워크 기반의 측위 알고리즘

인공 신경망을 의미하는 뉴럴 네트워크는 뉴럴이 연결된 형태를 모방한 컴퓨팅 모델로써 학습, 인지, 예측 등 데이터를 기반한 다양한 연구 분야에 적용되고 있다.

위치측위 시스템에서는 도착시간 방식과 지문 방식에 따라 알고리즘의 적용 방향이 차별화되어 있다. 도착시간 방식의 경우 실제 위치와 측정되는 위치 사이의 오차를 개선하기 위한 실시간 보정 네트워크가 많이 연구되고 있다. 시계열 측정 거리값에 의해 위치가 추정되어야 하는 도착시간 방식의 특성상 실시간으로 추정되는 거리값에 대한 보정이 필수적이며 이는 순환신경망을 적용한 알고리즘이 많이 적용되고 있다.

반면에 지문 방식의 경우, 데이터를 저장하고 이를 활용하여 실시간으로 분석하기 때문에 데이터베이스의 보정 또는 예측 생성, 측위 보정으로 나누어 연구되고 있다.

두 방식 모두 측위 보정 연구는 실시간 네트워크가 적용되어야 하므로 순환신경망이 사용된다[15, 16]. Fig. 2는 순환신경망의 기본 구조를 나타낸다. 여기서, X 는 입력 데이터, S 는 은닉층을 의미하는

가중치 노드, h 는 출력을 의미한다. 이를 시간 t 에 따른 실시간 처리를 위해 가중치 노드 S 를 연결하면 과거 입력인 x 가 고려되어 결과를 출력할 수 있다. 이는 이전 입력값에 대한 의존성을 가진 실시간 데이터 처리가 가능하다. 이러한 특성은 사용자의 이전 위치 또는 이전 거리값을 고려해 다음 결과에 반영되기 때문에 선형적 결과가 나타나는 사용자의 위치 또는 거리 결과에 적용하면 높은 보정 결과를 기대할 수 있다.

3. 제안하는 위치 측위 네트워크

3.1 제안한 알고리즘의 개요

본 논문에서 제안하는 WTN은 RTT 보정 네트워크와 삼변 측위 네트워크로 구성된다. Fig. 3은 제안하는 WTN의 학습과정과 측위과정을 나타낸다. 제안하는 네트워크는 RTT로부터 측정된 N 개 거리값

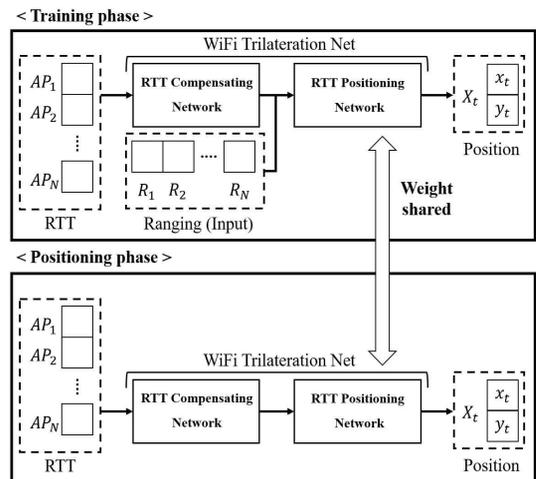


Fig. 3. Flowchart for WTN.

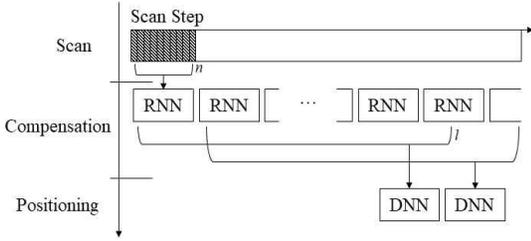


Fig. 4. Network processing structure of WTN.

AP를 입력으로 보상하는 RTT 보정 네트워크를 통해 거리값을 우선적으로 보정한다. 이어서 보정된 거리값과 실제 거리값 R 을 비교 입력값으로 측위 네트워크에 입력받아 최종 사용자의 위치 좌표를 추정한다.

제안하는 네트워크의 처리 구조는 Fig. 4와 같이 학습 효율성을 높이기 위해 혼련 단계에서는 측정된 RTT 데이터를 보정 네트워크에 대한 입력으로 사용하여 측위 네트워크까지 End-to-end 구조로 구성된다.

제안하는 네트워크는 측정되는 거리값에 대한 오차를 우선적으로 보정하기 위하여 Scan step을 거친다. RTT에서는 멀티패스에 의한 미수신률이 매우 크기 때문에 이를 해결하기 위한 Scan step은 10개의 측정 거리를 획득하여 평균 거리값으로 반환한다. 이 거리값은 오류값만을 제외하고 분석한 결과이기 때문에 불안정하다. 따라서 시간에 따른 거리값을 분석하여 안정화시킬 필요가 있다. 반환된 거리값은 삼변 측위를 위해 최소 3개 이상의 AP를 통해 거리값을 입력 받아야한다. 모든 AP로부터 수신받은 거리값은 이러한 Scan step을 통해 Fig. 3의 AP로 정의된다. RTT 신호는 한 Step당 500 ms 이내로 측정되기 때문에 사용자가 움직이는 경우에도 충분히 신뢰성을 확보할 수 있다. 각각의 보정 거리값 AP는 RTT 보정 네트워크인 순환신경망을 통해 시간에 따른 변화를 학습하고 실제 측위 단계에서는 안정적인 거리값이 도출된다. 다음 수식 (2)는 보정 네트워크의 손실함수를 나타낸다.

$$L_{Compensation} = \frac{1}{T} \sum_{t=1}^T \|\hat{R}_t - \bar{R}_t\|_2 \quad (2)$$

이 식은 10개의 Scan step에 해당하는 RMSE (Root mean square error)값을 기반으로 연산된다. \hat{R}_t 과 \bar{R}_t 는 각각 예측되는 거리와 실제 거리를 나타내며, 각 Scan step의 데이터 수인 T 로 나누어 오차를

최소화한다.

일반적으로 딥러닝을 기반한 측위 과정은 순환신경망을 통해 근접 위치 정보를 이용하여 위치 추정 정확도를 향상시킨다. 하지만 이러한 방식은 에러로 인해 신호가 불안정한 RTT에서 앞선 시간대역의 추정이 실패할 경우 치명적이다. 따라서, 제안하는 측위 단계는 시간에 독립적으로 순환신경망의 결과인 범위값을 입력받아 사용함으로써 미수신으로 인한 에러 누적을 최소화한다. 입력 데이터는 모두 동일한 RTT 신호로써 특정한 구조적 연결이 불필요하다. 제안하는 측위 단계는 모든 입력을 연결한 Dense 레이어를 2층으로 구성하여 최종적인 좌표를 추정한다. 다음 수식 (3)은 측위 네트워크의 손실함수 L 을 나타낸다.

$$L_{Positioning} = \frac{1}{T} \sum_{t=1}^T \|\hat{X}_t - \bar{X}_t\|_2 \quad (3)$$

여기서, \hat{X}_t 과 \bar{X}_t 는 각각 예측되는 좌표와 실제 좌표를 나타내며 수식 (2)와 같은 형태로 좌표값을 도출시킨다. 따라서 전체 손실함수는 다음 수식 (4)로 표현된다.

$$L_{Total} = L_{Compensation} + L_{Positioning} \quad (4)$$

각 손실함수를 합산하여 최종 시스템의 손실함수를 도출하고 이를 통해 End-to-end 학습이 가능한 시스템 구조를 설계할 수 있다.

4. 실험 결과 및 고찰

4.1 실험 환경 구성

제안한 WTN의 측위 정확성과 안정성을 검증하기 위하여 실험 공간 및 환경은 Fig. 5와 같이 구성하였다. 학습과 검증을 위한 데이터 수집은 한국해양대학교 공과대학 1호관 487호에서 진행하였다. (a)에서 데이터 송수신을 위해 사용된 RTT AP는 Compublab사에서 제작한 WILD를 사용하였다. WILD는 Intel AC8260 Wi-Fi module이 탑재되어는 IEEE 802.11 mc의 RTT를 구현한 측위 연구용 WiFi 모델이다. (b)는 데이터를 수집한 위치를 나타낸다. 0.5 m 간격으로 총 1170 개의 위치를 설정하였으며 위치 당 200 회씩 측정하여 데이터를 수집하였다.

이 RTT 데이터 수집 프로세스를 통해 구축된 데이터베이스를 기반으로 하는 데이터 세트는 각각 6.4

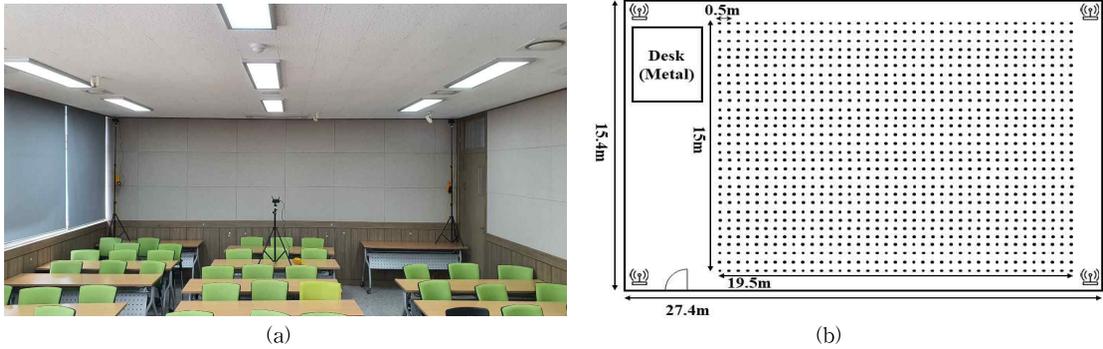


Fig. 5. Experiment environment, (a) Measurement configuration, (b) Data collection location,

: 1.6 : 2의 일반 비율로 학습, 셀, 실험 데이터로 나뉩니다. 데이터는 최소 1 m에서 최대 20 m의 거리로 정규화하였다. 실제 송신기와 수신기 사이의 최대 및 최소 거리 오차를 고려한 데이터 값으로 모든 측정 데이터는 100~2000 cm의 정수값을 갖는다. 또한 네트워크 훈련 과정에서 사전에 훈련 데이터와 검증 데이터를 분리하여 과적합을 방지했습니다.

4.2 실험 결과 및 고찰

제한된 네트워크는 두 단계로 구분된 학습 구조이기 때문에 두 개의 손실함수를 가진다. Fig. 6는 각 Epoch에 따른 각 단계와 전체 손실을 나타낸다. 여기서, x축은 한 데이터 세트를 전체 순환 횟수를 의미하는 Epoch이고 본 실험에서는 3000 회를 진행하였다. y축은 Mean square error로 계산된 손실로써, 학습 초기 단계의 그래프 가독성을 위해 로그 스케일로 표기하였다. 제한한 네트워크에서 모든 손실은 750

회를 기준으로 완만하게 수렴하는 것을 확인할 수 있다. 세부적으로는, RTT 신호를 보정하는 네트워크인 Compensation 단계가 비교적 낮은 학습 난이도를 가지므로 가장 낮은 값을 가지며, 삼변측위 네트워크인 Positioning 단계가 비교적 큰 손실을 가진다. 특히, 학습 초기 단계에 Compensation 단계와 Positioning 단계가 경쟁하기 때문에 적색의 Positioning 손실이 수렴하기 전인 125회 이하에서 불안정한 패턴을 보인다. 이후, positioning 단계가 완전히 안정되면 Compensation 단계도 동일하게 안정된다.

딥러닝 기반 네트워크는 가중치 노드의 수에 따라 특징 패턴을 분석할 수 있는 능력이 결정된다. 하지만 노드가 많아질수록 학습 시간이 오래 걸리므로 네트워크의 상황에 따라 적절한 노드 선택이 필요하다. 따라서, 본 논문에서는 64에서 1024 개까지 확장해가며 최적의 노드 수를 확인하였다. Fig. 7은 순환

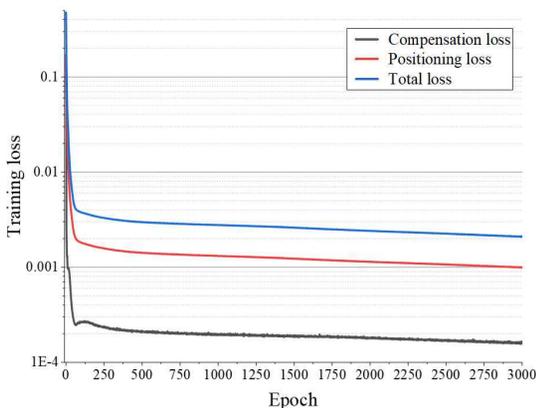


Fig. 6. Training loss analysis according to epoch,

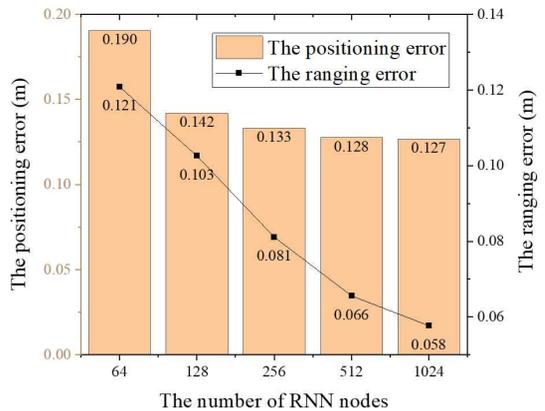


Fig. 7. Ranging and positioning performance analysis according to the number of nodes,

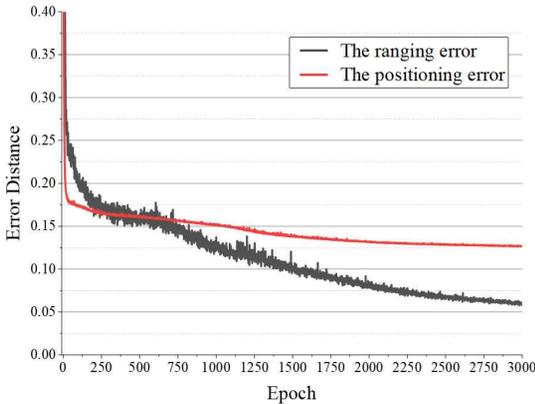


Fig. 8. Ranging and positioning performance analysis according to the number of nodes.

신경망 노드 수에 따른 Compensation과 Positioning 단계의 네트워크 성능을 나타낸다. 여기서, x축은 2의 배수로 설정된 순환신경망의 가중치 노드 수를 의미하며, 좌측 y축은 Positioning 단계의 위치 RMSE (Root mean square error), 우측 y축은 Compensation 단계의 Ranging RMSE를 나타낸다. 막대로 표기된 Positioning 오차는 노드 수가 커짐에 따라 0.127 m로 수렴하고 실선으로 표기된 Ranging 오차는 동일하게 0.058 m로 수렴한다. 네트워크는 규모가 커짐에 따라 성능이 향상되나 큰 연산량을 요구하기 때문에 적절한 크기가 필요하며 본 논문에서는 수렴하는 1024 개의 노드로 결정하였다.

각 수치의 개별적인 에러함인 손실과 달리 측위 성능의 비교를 위해선 실질적인 오차인 벡터간의 거리 차이를 분석해야 한다. Fig. 8은 각 Epoch에 따른 두 단계의 유클리드 거리 오차를 나타낸다. 여기서, x축은 Epoch를 나타내며, y축은 유클리드 거리로 환산된 오차 거리를 나타낸다. Compensation 단계의 결과인 range는 4개의 AP로 구성된 벡터이고 Positioning 단계의 결과인 Position은 (x, y)의 벡터이다. 앞선 결과와 달리 벡터의 거리 오차는 손실과 반대로 Positioning 단계의 학습이 빠르다. 이는 벡터의 요소

간 연관성이 낮은 Compensation 단계에 비해 Positioning 단계는 연관성이 높아 근접한 추정 가능성이 때문이다.

Table 1은 측위 알고리즘에 따른 정확도를 나타낸다. 측위 정확도를 검증하기 위해 최근 연구에서 대표적으로 적용한 Least squares[16], Euclidean distance[17], MIMO[19]를 제안한 네트워크와 비교하였다. 도착시간 방식인 Least squares, Euclidean distance 방식은 제안한 네트워크에 비해 성능이 떨어짐을 확인할 수 있다. 또한, 지문 방식인 MIMO가 가장 우수하게 보일 수 있으나 이는 적용방식이 다르고 분해능이 크기 때문에 오차가 상대적으로 나타난다. 따라서 제안한 네트워크를 사용할 경우 0.60 m의 오차가 발생하며 이는 도착시간 방식 비교 결과만 봤을 때 가장 우수함을 확인할 수 있다.

5. 결론

본 논문은 RTT의 멀티패스에 의한 측정 에러 및 미수신 현상의 문제를 보정하고 측위 오차를 개선하기 위하여 뉴럴 네트워크 기반 RTT 보정과 삼변측위 네트워크가 각각 결합된 End-to-end 기반의 WiFi Trilateration Net(WTN)을 제안하였다. 제안한 네트워크는 RTT 거리 정확도를 향상시키기 위한 순환신경망 기반 보정 네트워크와 End-to-end 구조로 구현된 실시간 위치 확인을 신경망 기반 삼변측위 네트워크로 구성하였다. 제안한 네트워크는 수학적 연산으로 인해 미분을 통한 학습이 불가능한 삼변측위 알고리즘을 뉴럴 네트워크로 변경하여 학습 효율을 높인다. 또한 멀티패스에 의한 RTT의 수신 안정성을 높이기 위해 스케닝 단계에서 보정 네트워크를 적용하여 각 RTT AP로부터 신뢰성 있는 거리 추정값을 수집하였다.

실험 결과를 살펴보면 네트워크 최적 노드 설계를 위한 실험 결과를 바탕으로 1024 개의 노드로 설정하여 End-to-end 방식으로 네트워크를 구성하였다.

Table 1. Comparison and analysis of positioning performance according to the algorithm.

The number of nodes	Method			
	Least squares[16]	Euclidean distance[17]	MIMO[18] (Fingerprint)	Proposed Networks
	Distance error[m]			
1024	3.09	0.62	0.43	0.60

또한 도착시간 방식인 최소 제곱, 유클리드와 비교를 통해 높은 성능을 확인할 수 있다.

향후 이 연구를 바탕으로 NLOS 환경에서 정확도 향상을 위한 네트워크 설계를 통해 완전한 실내 환경에 적용 가능한 RTT 네트워크로 확장할 것이다.

REFERENCE

- [1] C. Wu, Z. Yang, and Y. Liu, "Smartphones Based Crowdsourcing for Indoor Localization," *IEEE Transactions on Mobile Computing*, Vol. 14, No. 2, pp. 444-457, 2017.
- [2] J.H. Seong and D.H. Seo, "Wi-Fi Fingerprint Using Radio Map Model Based On MDLP And Euclidean Distance Based on the Chi Squared Test," *Wireless Networks*, Vol. 25, No. 6, pp. 3019-3027, 2019.
- [3] L. Ciabattoni et al, "Real Time Indoor Localization Integrating a Model Based Pedestrian Dead Reckoning on Smartphone and BLE Beacons," *Journal of Ambient Intelligence and Humanized Computing*, Vol. 10, No. 1, pp. 1-12, 2019.
- [4] J.H. Seong and D.H. Seo, "Selective Unsupervised Learning-Based Wi-Fi Fingerprint System Using Autoencoder and GAN," *IEEE Internet of Things Journal*, Vol. 7, No. 3, pp. 1898-1909, 2020.
- [5] Q. Jiang, Y. Ma, K. Liu, and Z. Dou, "A Probabilistic Radio Map Construction Scheme for Crowdsourcing-Based Fingerprinting Localization," *IEEE Sensors Journal*, Vol. 16, No. 10, pp. 3764 - 3774, 2016.
- [6] Z.Y. Dong, W.M. Xu, and H. Zhuang, "Research on ZigBee Indoor Technology Positioning Based on RSSI," *Procedia Computer Science*, Vol. 154, pp. 424-429, 2019.
- [7] J.H. Seong and D.H. Seo, "Environment Adaptive Localization Method Using Wi-Fi and Bluetooth Low Energy," *Wireless Personal Communications*, Vol. 99, No. 2, pp. 765-778, 2018.
- [8] D.J. Kim and J.Y. Son, "A Method to Construct a Cut-off Fingerprint Map to Improve Accuracy in Indoor Positioning Scheme," *Journal of Korea Multimedia Society*, Vol. 20, No. 8, pp. 1330-1337, 2017.
- [9] W.J. Kim and J.H. Kang, "ToA-based Localization Algorithm for Mitigating Positioning Error in NLoS Channel," *Journal of Institute of Control Robotics and Systems*, Vol. 24, No. 11, pp. 1043-1047, 2018.
- [10] P. Wang and Y.J. Morton, "Multipath Estimating Delay Lock Loop for LTE Signal TOA Estimation in Indoor and Urban Environments," *IEEE Transactions on Wireless Communications*, Vol. 19, No. 8, pp. 5518-5530, 2020.
- [11] G. Guo et al., "Indoor Smartphone Localization: A Hybrid WiFi RTT-RSS Ranging Approach," *IEEE Access*, Vol. 7, pp. 176767-176781, 2019.
- [12] H.J. Cao et al., "Indoor Positioning Method Using WiFi RTT Based on LOS Identification and Range Calibration," *ISPRS International Journal of Geo-Information*, Vol. 9, No. 11, pp. 627, 2020.
- [13] J.H. Seong, T.W. Lim, J.S. Kim, S.G. Park and D.H. Seo, "An Improvement Algorithm for Localization Using Adjacent Node and Distance Variation Analysis Techniques in a Ship," *Journal of the Korean Society of Marine Engineering*, Vol. 37, No. 2, pp. 213-219, 2013.
- [14] C.L. Sang et. al., "Numerical and Experimental Evaluation of Error Estimation for Two-Way Ranging Methods," *Sensors*, Vol. 19, No. 3, pp. 616, 2019.
- [15] J.H. Lee, S.H. Lee, S.H. Tae, and D.H. Seo, "Parallel Injection Method for Improving Descriptive Performance of Bi-GRU Image Captions," *Journal of the Korean Society of Marine Engineering*, Vol. 22, No. 11, pp. 1223-1232, 2019.
- [16] C.H. Hsieh, J.Y. Chen, and B.H. Nien, "Deep Learning-Based Indoor Localization Using Received Signal Strength and Channel State Information," *IEEE Access*, Vol. 7, pp. 33256-33267, 2019.

- [17] X. Wang, X. Wang, and S. Mao, "Deep Convolutional Neural Networks for Indoor Localization with CSI Images," *IEEE Transactions on Network Science and Engineering*, Vol. 7, No. 1, pp. 316-327, 2018.
- [18] M.T. Hoang et al., "Recurrent Neural Networks or Accurate RSSI Indoor Localization," *IEEE Internet of Things Journal*, Vol. 6, No. 6, pp. 10639-10651, 2019.



성 주 현

2012년 한국해양대학교 전기전자공학부 공학사
 2014년 한국해양대학교 전기전자공학과 공학석사
 2018년 한국해양대학교 전기전자공학과 공학박사

2018년~2020년 차세대IT선박융합기술연구센터 연구원
 2020년~현재 한국해양대학교 교양교육원 교양교육부 조교수

관심분야 : 신호처리, 인공지능, 위치측위시스템