

DNN-based LTE Signal Propagation Modelling for Positioning Fingerprint DB Generation

Jae Uk Kwon¹, Seong Yun Cho^{2†}

¹Department of IT Engineering, Kyungil University, Gyeongsan 38428, Korea

²Department of Robotics Engineering, Kyungil University, Gyeongsan 38428, Korea

ABSTRACT

In this paper, we propose a signal propagation modeling technique for generating a positioning fingerprint DB based on Long Term Evolution (LTE) signals. When a DB is created based on the location-based signal information collected in an urban area, gaps in the DB due to uncollected areas occur. The spatial interpolation method for filling the gaps has limitations. In addition, the existing gap filling technique through signal propagation modeling does not reflect the signal attenuation characteristics according to directions occurring in urban areas by considering only the signal attenuation characteristics according to distance. To solve this problem, this paper proposes a Deep Neural Network (DNN)-based signal propagation functionalization technique that considers distance and direction together. To verify the performance of this technique, an experiment was conducted in Seocho-gu, Seoul. Based on the acquired signals, signal propagation characteristics were modeled for each method, and Root Mean Squared Errors (RMSE) was calculated using the verification data to perform comparative analysis. As a result, it was shown that the proposed technique is improved by about 4.284 dBm compared to the existing signal propagation model. Through this, it can be confirmed that the DNN-based signal propagation model proposed in this paper is excellent in performance, and it is expected that the positioning performance will be improved based on the fingerprint DB generated through it.

Keywords: LTE RSRP, positioning fingerprint database, signal propagation model, DNN, deep learning

1. INTRODUCTION

스마트폰의 위치정보는 다양한 위치기반서비스를 위해 필요하며, 위치정보의 정확도 및 가용성은 서비스에 따라 다르게 요구된다. 특히 긴급구조 상황에서 요구조자의 구조활동을 위해서는 높은 정확도와 가용성을 갖는 위치정보를 필요로하며 이를 위한 위치추정 기술 개발이 절실이 요구되고 있다. 만약 요구조자가 실외에 있는 경우에는 Global Positioning System (GPS)/Global Navigation Satellite System (GNSS) 신호를 수신할 수 있으므로 요구조자의 위치정보는 스마트폰 기반으로 정확하게 추

정할 수 있다. 그러나 요구조자가 도심지역, 산속, 터널, 건물 안과 같은 GPS/GNSS 음영지역에 위치하는 경우에는 위치정보를 제공받지 못하거나 큰 오차를 포함하는 위치정보를 추정하게 된다 (Cho & Ji 2019).

이런 문제로 인해 다양한 무선통신/이동통신망 기반의 무선측위 기술이 활용되고 있다. 요구조자가 119/112 긴급구조 신고시스템을 통해 구조요청을 하게 되면 이동 통신사에게 해당 단말기의 위치정보를 요청하게 된다. 이동 통신사는 단말기를 통해 다양한 측정값을 획득한 다음 위치추정 서버를 통해 해당 단말기의 위치정보를 추정하여 긴급구조 신고시스템에 제공하게 된다. 이때 사용될 수 있는 측정값으로는 신호세기 (RSSI: Received Signal Strength Indicator), 전파시간 (ToA: Time of Arrival), 전파시간 차 (TDoA: Time Difference of Arrival), 수신 각 (AoA: Angle of Arrival) 등이 있다. 이 중에서 가장 쉽게 접근할 수 있는 정보가 RSSI이며, 이를 사용하여 삼변측위 (Trilateration), 삼각측위 (Triangulation), Cell-ID, 전자지문법 (Fingerprinting) 등을 통해 스마트폰의 위치를 추정할 수 있다 (Kolodziej & Hjelm 2006, Vo

Received Feb 09, 2021 Revised Feb 19, 2021 Accepted Feb 20, 2021

[†]Corresponding Author

E-mail: sycho@kiu.kr

Tel: +82-53-600-5584 Fax: +82-53-600-5599

Jae Uk Kwon <https://orcid.org/0000-0001-6222-5043>

Seong Yun Cho <https://orcid.org/0000-0002-4284-2156>

& De 2016).

본 연구에서는 Long Term Evolution (LTE) 신호의 Reference Signal Received Power (RSRP) 정보를 사용하여 전자지문법 기반으로 스마트폰의 위치추정을 위한 전자지문 DB 구축을 목적으로 한다. 전자지문법은 위치를 측정하고자 하는 서비스 지역을 격자 형태로 나누고, 각 격자점 (Grid Point)에서 측정가능한 신호를 수신하여 격자점 위치정보와 함께 DB에 저장한 다음 실제 측위 시 획득된 신호를 DB와 비교하여 위치를 추정한다. 따라서 서비스 지역의 전자지문 DB를 사전에 구축해야 한다. 이 때 서비스 지역이 넓은 도심 지역에서는 격자점 상에서 신호 획득이 불가능하기 때문에 신호를 측정할 수 있는 장소에서 획득한 신호정보를 각 격자점 상의 정보로 변환해야 한다. 이 경우, Inverse Distance Weighting (IDW), Kriging 등과 같은 공간보간법이 사용된다 (Cho 2020). 그러나 이 과정에서 한 가지 문제점이 발생한다. 즉 신호를 획득하지 못한 영역이 넓은 경우 공간보간법 만으로는 해당 영역에 위치하는 격자점 상의 신호정보를 생성하지 못할 수 있다. 즉 전자지문 DB에 공백이 발생하게 된다. 만약 요구조자가 이 공백 상에 위치하는 경우에 해당 요구조자의 위치를 정확하게 추정하지 못하게 된다.

미수집 영역에 대한 신호정보를 생성하기 위해 해당 영역에서 수신할 수 있는 기지국의 신호전파 모델 (SPM: Signal Propagation Model)을 사용할 수 있다 (Cho 2020). 신호전파 모델은 각 기지국으로부터 송출된 수신 세기와 거리에 따른 감쇄 정보를 사용하여 신호 감쇄 특성을 Log-Distance 형태의 함수로 나타내는 것이다 (Andersen et al. 1995, Cho 2020). 이 때 신호 감쇄 특성은 주변 건물 등에 의한 Long-term Fading은 고려할 수 없으며, 일반적으로 거리에 따른 영향만을 모델링한다. 그러나 도심지역에서는 다양한 크기와 형태의 건물들이 기지국과 수신기 주변에 분포되어 있으며, 기지국을 중심으로 거리뿐만 아니라 방향에 따라 신호 감쇄 특성이 다르게 나타난다. 지금까지 사용된 신호 전파 모델은 거리에 따른 신호 감쇄 특성만을 고려하였으므로 방향에 따라 다른 신호 추정 특성이 나타난다. 따라서 이를 기반으로 생성된 미수집 지역의 DB 정보는 방향에 따라 다른 정확도를 갖게 된다. 이 문제를 해결하기 위해 본 연구에서는 거리와 방향을 함께 고려하여 RSRP 정보를 추정하는 Deep Neural Network (DNN) 기반 신호전파 함수를 생성하고자 한다. 이를 위해 DNN 구조의 Hyper Parameters를 설정하고, 수집된 데이터를 기반으로 이를 학습한다. 그리고 이를 기반으로 신호전파 특성을 함수화 하고 미수집 영역에서의 신호정보를 추정한다. 본 연구에서는 서울 서초구에서 획득된 신호를 기반으로 제안된 DNN 기반의 신호전파 함수화 기법의 성능이 우수함으로 기존의 신호전파 모델을 통해 추정된 신호정보와의 비교를 통해 검증한다.

본 논문의 2장에서는 기존의 전자지문 DB 생성 기법들을 설명하고, 3장에서는 이 논문에서 제안하는 DNN 기반 전자지문 DB 생성 기법을 설명한다. 그리고 4장에서는 실험을 통해 제안된 기법의 성능을 분석하고, 5장에서 결론을 맺는다.

RP Position	BS (1)	BS (2)	...	BS (L)
(x_1, y_1)	$RSRP_{1,BS(1)}$	$RSRP_{1,BS(2)}$	...	$RSRP_{1,BS(L)}$
(x_2, y_2)	$RSRP_{2,BS(1)}$	$RSRP_{2,BS(2)}$	...	$RSRP_{2,BS(L)}$
$\vdots$	$\vdots$	$\vdots$	$\cdot$	$\vdots$
(x_n, y_n)	$RSRP_{n,BS(1)}$	$RSRP_{n,BS(2)}$	...	$RSRP_{n,BS(L)}$




Fig. 1. Conventional fingerprint DB generation method.

2. CONVENTIONAL FINGERPRINT DB GENERATION METHODS

측위용 전자지문 DB는 서비스 대상 지역을 일정한 간격으로 나누고 각 격자점 상의 기준위치 (RP: Reference Point)에서 획득된 신호 정보의 조합을 위치정보와 함께 저장한 것으로 Fig. 1과 같다. 다수의 기지국으로부터 송출된 신호의 조합은 위치에 따라 다른 패턴을 갖는다. 즉 격자점 마다 다른 패턴의 신호 정보를 획득하게 되고 이 정보를 DB로 저장한다. 이 정보는 측위 과정에서 측정된 신호정보와의 상관 (Correlation)을 위해 필요하므로 정확한 DB 구축이 매우 중요하다.

서비스 지역이 좁은 경우에는 기준위치 상에서 신호를 획득하여 DB를 구성할 수 있다. 그러나 도심지역의 넓은 서비스 지역을 대상으로 하는 경우에는 이 방법을 적용할 수 없다. 신호 정보를 차량으로 수집하는 경우 차량에 신호획득 장비를 탑재하고 도로 상에서 신호를 수집한다. 그리고 공간 보간법을 활용하여 기준위치의 신호 정보를 수집된 위치기반 신호 정보를 사용하여 생성한다. 이 장에서는 공간 보간법 기반으로 전자지문 DB를 생성하는 방법과 미수집 지역의 데이터 생성을 위한 신호전파 모델을 활용하는 방법을 설명한다.

2.1 공간보간법 기반 측위용 전자지문 DB 생성

획득된 측정 데이터를 기반으로 DB를 생성하기 위해 IDW 기반의 K-Nearest Neighbors (KNN) 기법을 사용한다. 이 방법은 기준위치 인근에 있는 측정 데이터들의 가중합 (Weighted Sum)을 통해 해당 기준위치 상의 신호 정보를 추정하는 방법으로 식 (1)과 같이 나타낼 수 있다 (Ismail et al. 2016).

$$\hat{Y}(x_R) = \sum_{i=1}^n \lambda_i Y(x_i) \quad (1)$$

여기서 $\hat{Y}(x_R)$ 는 기준위치 x_R 에서 추정된 값이며, $Y(x_i)$ 는 기준위치 인근 지점 x_i 에서 측정된 신호 정보, 그리고 n 은 측정 데이터들의 수를 나타낸 것이다. λ_i 는 $Y(x_i)$ 에 대한 가중치로 모든 가중치들의 합은 1이 되는 특성을 갖는다. 따라서 각 측정 데이터




Fig. 2. Comparison of fingerprint DB creation results of PCI-144 according to method. (a) Location of measurements on the map, (b) Service area and grid points for fingerprint DB, (c) Measurements-based generated DB, (d) Measurements and SPM-based generated DB, (e) Measurements and DNN-based generated DB

에 대한 가중치 λ_i 는 추정하고자 하는 기준위치와 측정 데이터 획득 위치 사이의 거리 정보만을 이용하여 식 (2)와 같이 계산될 수 있다.

$$\lambda_i = r_i^{-1} / \sum_{j=1}^n r_j^{-1} \quad (2)$$

여기서 r_i 는 x_R 와 x_i 사이의 거리이다.

Fig. 2a는 실험을 통해 획득된 측정데이터 중 Physical Cell identity (PCI)-144번에 해당하는 데이터가 수신된 지역을 나타낸 것으로 초록색 'x'로 표시한 곳이 기지국의 위치이며, 빨간색 점들이 측정데이터의 획득 위치이다. 서비스 지역에서 전자지문 DB를 생성하기 위해 먼저 Fig. 2b와 같이 서비스 대상 지역을 격

자구조로 나뉜다. 이 때 격자 사이의 간격은 30 m로 설정하였으며, 각 격자점 상의 기준위치에서 격자 사이에 위치한 측정치들의 신호 정보를 공간보간법을 사용하여 생성한 다음 DB를 갱신한다. Fig. 2c는 Fig. 2a에서 나타낸 지도상의 측정 데이터 4,127개를 사용하여 공간보간법 기반으로 생성된 DB의 결과이다. 이때 기준위치에서 먼 거리에서 획득된 신호 정보는 사용하지 않으며 일정 거리 이내에서 획득된 신호 정보만 사용한다. 따라서 Fig. 2c를 보면 기준위치 인근에서 획득된 측정치가 없어서 DB 상의 공백이 발생하게 된다. 이로 인해 측위 단계에서 요구조자가 미수집 영역 안에 위치하고 있는 경우에는 측위 오차가 증가할 수 있는 문제가 존재한다.

2.2 신호전파 모델 기반 미수집 영역 Gap Filling

측정 데이터가 없는 미수집 영역에서 수신 가능한 신호정보를 생성하기 위해 신호 전파 모델을 사용하여 Gap Filling을 수행할 수 있다. 기지국에서 송출되는 신호의 세기는 거리에 따라 점차 감쇄 (Attenuation)하는 특성을 가지며, 건물과 같은 구조물을 통과하게 되면 추가적으로 신호 세기가 감쇄된다. 만약 정확한 3D 지도가 있는 경우 전파전파 (Ray Tracing) 기법을 통해 비교적 정확한 신호정보를 생성할 수 있다. 그러나 신호세기 정보를 사용한 무선측위에서는 일반적으로 거리에 따른 신호감쇄 특성만을 고려한 다음과 같이 간략화된 식을 사용한다 (Cho & Park 2014, Saez de Adana et al. 2000).

$$S(d_k) = S(d_0) - 10\alpha \log_{10} \left(\frac{d_k}{d_0} \right) + w(\sigma) \quad (3)$$

여기서 $S(d_k)$ 와 $S(d_0)$ 는 기지국으로부터 거리 d_k 와 기준거리 d_0 (1 m)인 곳에서 측정되는 RSRP (dBm) 정보이며, α 는 전파 감쇄율, 그리고 $w(\sigma)$ 는 표준편차가 σ 인 노이즈를 나타낸 것이다.

만약 측정 데이터의 수가 N 개인 경우 식 (3)은 식 (4)와 같이 행렬형태로 나타낼 수 있다.

$$\begin{bmatrix} S(d_1) \\ \vdots \\ S(d_N) \end{bmatrix} = \begin{bmatrix} 1 & -10\log_{10}(d_1/d_0) \\ \vdots & \vdots \\ 1 & -10\log_{10}(d_N/d_0) \end{bmatrix} \begin{bmatrix} S(d_0) \\ \alpha \end{bmatrix} + \begin{bmatrix} w_1 \\ \vdots \\ w_N \end{bmatrix} \quad (4)$$

$$\Leftrightarrow Y = MX + W$$

식 (4)에서 $S(d_0)$ 와 α 는 최소자승법을 사용하여 식 (5)와 같이 추정할 수 있다.

$$\begin{bmatrix} \hat{S}(d_0) \\ \hat{\alpha} \end{bmatrix} = \hat{X} = (M^T M)^{-1} M^T Y \quad (5)$$

측정 데이터를 사용하여 식 (5)와 같이 추정된 계수를 사용하여 식 (6)과 같이 신호 정보 생성 함수를 구성할 수 있다.

$$\hat{S}_{RP-k} = S(d_0) - 10\hat{\alpha} \log_{10} \left(\frac{d_{RP-k}}{d_0} \right) \quad (6)$$

여기서 $\hat{S}_{RP-k}$ 는 기준위치 k 에서 추정된 RSRP 정보이며, d_{RP-k} 는 기지국과 기준위치 k 사이의 거리값이다.

식 (6)을 기반으로 전자지문 DB에서 미수집 영역에 위치하는 기준위치 상의 신호정보를 추정하여 Gap Filling을 할 수 있다.

Fig. 2d는 신호전파 모델 기반으로 Gap Filling을 한 후 전자지문 DB를 생성한 결과이다. 이 때 추정된 정보를 보면 기지국을 중심으로 거리가 멀어질수록 신호가 감쇄하게 된다. 기지국에서 멀어질수록 신호의 분산이 증가하는 현상이 발생하기 때문에 신호전파 모델 기반으로 추정된 정보의 오차는 증가할 가능성이 커지게 된다. 또한 거리에 따른 신호 감쇄만을 반영한 신호전파 모델의 특성상 도심 지역에서 방향에 따른 다른 신호 감쇄 특성은 반영하지 못하기 때문에 방향에 따라 부정확한 신호 정보를 생성할 수 있게 된다. 이 때 Gap Filling 가능한 범위는 LTE 신호의 도달 거리를 고려하여 기지국으로부터 500 m 이내로 한정하여 나타내었다.

3. DNN-BASED FINGERPRINT DB GENERATION METHOD

도심 지역에서는 건물과 같은 구조물이 밀집되어 있어 신호 감쇄가 많이 발생하며, 기지국을 중심으로 방향에 따라 다른 구조물에 의한 신호 감쇄 특성이 다르게 나타난다. 2.2절에서 설명한 신호전파 모델은 거리에 대한 신호 감쇄 특성만을 고려하기 때문에 도심 지역에서 방향에 따른 다른 구조물에 의한 신호 특성은 반영하지 못한다. 이로 인해 방향에 따라 부정확한 신호정보를 생성하게 되는 문제점이 발생한다. 이 문제를 해결하기 위해 본 장에서는 거리와 방향정보를 함께 입력신호로 사용하여 RSRP 정보를 생성하는 DNN 모델을 구성하고, 생성된 DNN 모델 기반 신호전파 함수를 사용하여 Gap Filling 된 전자지문 DB를 생성하는 기법을 제안한다.

Artificial Neural Network (ANN)는 인간의 신경망 원리와 구조를 모방하여 수학적으로 모델링하여 지도/비지도 학습을 기반으로 정보를 처리하는 기계학습 알고리즘 중 하나이다. 이에 따라 ANN은 인간의 뇌가 대량의 데이터를 효율적, 병렬적으로 처리 및 학습할 수 있다는 사실에 근거하여, 인간의 신경체계와 유사한 특성을 가지게 된다.

DNN은 기존의 ANN과 구조가 같으며, 은닉층 (Hidden layer)의 수가 2개 이상의 복잡한 신경망으로 이루어져 있는 모델이다. DNN은 각 은닉층마다 다른 함수를 생성하도록 학습할 수 있으며, 가장 큰 특징은 입력과 출력변수 사이의 비선형적 관계를 함수화할 수 있다는 것이다. 따라서 본 논문에서는 측정 데이터의 신호 노이즈가 큰 다량의 데이터를 학습하고, 복잡한 비선형 함수로 구성된 문제를 효과적으로 해결하기 위해 DNN 모델을 사용하고자 한다. DNN 모델은 입력층 (Input layer), 은닉층, 출력층 (Output layer)으로 구성되어 있으며 각 층마다 노드의 수를 결정하여야 한다. 입력층의 노드 수는 입력 변수의 수와 같으며, 출력층의 노드 수는 회귀 (Regression) 문제인 경우 1개, 분류 (Classification) 문제인 경우 분류할 개수로 구성할 수 있다. 본 연구에서는 입력 데이터에 기초하여 필요로 하는 규칙성을 찾을




Fig. 3. Deep neural network structure.

수 있도록 지도 학습 (Supervised Learning)을 갖추고, 연속성이 있는 출력값을 예측할 수 있도록 회귀를 사용한다. 따라서 Fig. 3과 같이 입력층에서는 거리와 방향정보를 포함하는 2개의 노드, 출력층에는 RSRP 신호를 생성하도록 1개의 노드로 구성하였다. 이 때 은닉층의 수는 3개로 설정하였고, 노드의 수는 10개로 레이어 전부 동일하게 할당하였다 (Li et al. 2018).

DNN 모델의 입력에 사용되는 방향 정보는 식 (7)과 같이 계산하였다.

$$\theta_k = \tan^{-1} \{ (Lon_{BS} - Lon_{M-k}) / (Lat_{BS} - Lat_{M-k}) \} \quad (7)$$

여기서 $[Lat_{BS} \ Lon_{BS}]^T$ 와 $[Lat_{M-k} \ Lon_{M-k}]^T$ 는 각각 기지국과 측정지 k 가 획득된 수평 위치 벡터이며 는 기지국과 측정지 사이의 방향 정보이다. 이 때 계산된 방향 정보는 기지국에서 북쪽 방향을 기준으로 각 측정지에 대한 각도를 의미한다.

학습 데이터의 표준편차가 크면 모델의 학습속도가 저하되거나 Local Minimum현상이 발생하여 학습 정확도에 문제를 초래할 수 있다. 이 문제를 해결하기 위해서는 각 데이터에 대한 전처리 (Pre-processing) 과정이 필요하다. 이 때 모든 데이터 값을 일정 범위 내로 변환하기 위해 데이터의 최소/최대값을 이용하여 정규화를 수행하는 Min-Max Normalization을 식 (8)과 같이 사용할 수 있다.

$$x'_k = \frac{x_k - \min(x)}{\max(x) - \min(x)} \quad (8)$$

여기서 x_k 와 x'_k 는 각각 k 번째 측정 데이터와 변환된 데이터를 나타낸 것이며, $\min(x)$ 와 $\max(x)$ 는 각각 데이터의 최소값과 최대값을 의미한다.

전처리된 데이터는 DNN 모델의 학습 데이터로 사용되며, 모델 훈련 과정에서 총 두 단계로 나누어 진행된다. 첫번째 단계는 순전파 (Forward Propagation) 단계이다. 이 단계는 입력층에서 출력층까지 연결된 가중치 (weight)와 편향 (bias)을 통해 현재 네트워크의 출력 값을 계산해주는 과정이다. 각 레이어의 노드들은 가중치를 통해 연결되어 있는 구조이기 때문에 뉴런의 선형 결합과 활성화 함수 (Activation Function)를 통해 복잡한 함수를 비선형으로 근사화 할 수 있으며, 일반적으로 식 (9)와 같은 방정식으로 계산된다 (Lee et al. 2018).

$$y_j = f \left(\sum_{i=1}^N \sum_{j=1}^M (W_{ij} x_i + b_j) \right) \quad (9)$$

여기서 N 과 M 은 각각 이전 레이어와 다음 레이어의 노드 수, y_j 는 출력값, f 는 활성화 함수, x_i 는 입력값, W_{ij} 는 입력과 출력 사이의 연결 가중치, 그리고 b_j 는 편향을 나타낸 것이다.

순전파를 통해 계산된 예측값은 실제 데이터와 차이가 존재한다. 이 때 비용 함수 (Cost Function)는 식 (10)과 같이 Mean Squared Error (MSE)를 사용하였다.

$$CF = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2 \quad (10)$$

여기서 y_i 와 t_i 는 각각 i 번째 데이터의 최종 출력값과 측정값을 나타내며, n 은 전체 측정 데이터의 수를 의미한다.

비용 함수는 최소지점에 가까울수록 모델의 예측 정확도가 상승하게 된다. 이로 인해 비용 함수를 최소화시키는 가중치와 편향을 찾아 특정 값에 수렴 및 최소점을 찾을 때까지 반복하여 학습을 진행하여야 한다. 이를 위해 두번째 단계로 역전파 (Back Propagation) 과정이 진행된다. 역전파는 순전파를 통해 계산된 예측값과 측정값의 차이인 비용 함수가 최소가 되도록 하기 위해 출력층에서부터 입력층까지 역방향으로 모든 가중치와 바이어스를 갱신하는 과정이다. 이 때 업데이트를 위해 사용되는 알고리즘은 일반적으로 경사하강법 (Gradient Descent Method)을 사용할 수 있다. 경사하강법은 모델 함수의 최소값 위치를 찾기 위해 학습률 (Learning Rate)과 비용 함수의 편미분의 곱만큼 가중치와 편향을 수정하여 최적화된 값을 찾는 방법으로 식 (11)과 같이 나타낼 수 있다.

$$\begin{aligned} W &= W - \alpha \frac{\partial}{\partial W} CF(W, b) \\ b &= b - \alpha \frac{\partial}{\partial b} CF(W, b) \end{aligned} \quad (11)$$

여기서 $\frac{\partial}{\partial W} CF(W, b)$ 와 $\frac{\partial}{\partial b} CF(W, b)$ 는 비용함수를 가중치와 편향에 대해 편미분한 것이며, α 는 학습률을 나타낸 것이다.

기존의 ANN에서 많이 사용하던 활성화 함수는 sigmoid와 tanh 함수 등이 있고, 이를 DNN에 적용하면 기울기가 하강이 반복될수록 오차가 사라지는 Gradient Vanishing 문제가 발생한다. 따라서 기존 sigmoid 함수에 비해 식이 간단하고, 비교적 빠르고 효과적으로 학습이 가능한 ReLU 함수를 사용하였다. 그러나 ReLU 함수는 만약 입력 값이 음수로 들어오게 되면 기울기가 0으로 소멸하게 되고, 그 결과로 모델 업데이트가 되지 않는 Dying ReLU 문제가 존재한다. 이 문제를 해결하기 위해 이 논문에서는 식 (10)에서 나타낸 것처럼 Leaky-ReLU 함수를 사용하였다.


$$f(x) = \max(0.01x, x) \quad (12)$$

Leaky-ReLU 함수는 입력 값이 양수일 경우 기울기가 항상 1이 되고, 음수일 경우 0.01의 가중치를 주어 낮은 기울기 값을 갖도록 하는 함수이다. 이 함수를 사용함으로써 기존 DNN 학습시 활성화 함수의 영향이 감소하는 Gradient Vanishing 문제와 Dying ReLU의 문제를 모두 극복할 수 있게 된다 (Cho et al. 2016).

앞에서 설계한 DNN 모델을 이용하여 학습을 진행하였다.

Table 1. Hyperparameters of the DNN model.

Hyper parameter	Value
Number of input layer nodes	2
Number of hidden layer	3
Number of hidden layer nodes	10, 10, 10
Number of output layer nodes	1
Normalization	Min-max normalization
Weight initialization	He initialization
Activation function	Leaky-ReLU
Optimizer	Adam
Cost function	MSE
Learning rate	0.0001
Batch size	1
Epoch	2000
Early stopping	True

**Fig. 4.** MSE by number of learning.

이 때 전체 데이터 중 90%를 훈련 데이터 (Training Data)로 나머지 10%는 조기 종료 (Early Stopping)를 위한 검증 데이터 (Validation Data)로 활용하였다.

Table 1은 데이터 학습을 위해 사용한 인공신경망의 구조와 파라미터를 나타낸 것이다. 학습률은 0.0001로 설정하였고, 배치 (Batch) 크기는 1, 비용함수를 최소화하고 과적합을 방지하기 위해 Adam-Optimizer (Kingma & Ba 2015)와 정규화를 적용한 Early-stopping을 사용하였다.

학습 과정의 궁극적인 목표는 훈련 데이터를 이용하여 학습한 모델을 가지고 테스트 데이터에 대한 새로운 결과를 추측하는 것이다. 이 때 테스트 데이터는 학습 과정에 참조할 수 없기 때문에 훈련 데이터만을 가지고 테스트 데이터를 잘 예측하도록 학습되어야 한다. 따라서 학습을 통해 모델의 언더피팅 (Underfitting)된 부분을 제거해나가면서 오버피팅 (Overfitting)이 발생하기 직전에 학습을 멈추어야 구조나 패턴을 일반화하는 모델이 구성될 수 있다.

Fig. 4는 각각 훈련 데이터와 검증 데이터의 학습 수에 따른 MSE 오차를 나타낸 것이다. 여기서 훈련 데이터로 학습을 진행하기 때문에 오차는 계속 감소하는 것을 볼 수 있지만 학습된 모델을 새로운 검증데이터로 평가하면 약 85 epoch에서부터 오차 곡선이 감소하지 않는 것을 확인할 수 있다. 이 때 학습을 하면서 검증데이터의 성능 개선이 없거나 이전 epoch보다 오차가 증가하게 되면 오버피팅 되었다고 간주하여 학습을 종료하도록 설정하고 이를 통해 생성된 모델 기반으로 미수집 영역에 대한 신호

정보를 추정하여 전자지문 DB의 Gap Filling을 수행하도록 한다.

본 연구에서는 거리에 대한 신호 감쇄 특성만을 고려하는 기존의 신호전파 모델의 한계를 보완하기 위해 거리뿐 아니라 방향을 함께 고려한 신호 감쇄 특성을 반영한 DNN 모델 기반 신호전파 함수를 제안하였다. Fig. 2e는 제안한 DNN 모델 기반으로 미수집 영역의 신호 정보를 추정하여 Gap Filling된 전자지문 DB의 결과를 나타낸 것이다. 이 때 거리와 방향정보에 대한 신호 특성을 함께 모델링하여 미수집 영역의 신호 정보를 추정하였기 때문에 거리뿐 아니라 방향에 따라서도 신호 감쇄 특성이 다르게 나타나는 것을 볼 수 있다. Fig. 2d의 신호전파 모델 기반으로 추정된 결과와 비교하면 다음과 같다. 우선 Fig. 2c를 보면 도로 방향으로 멀리까지 신호가 전파되며 파워의 감쇄가 다른 방향보다 작은 것을 볼 수 있다. 그 이유는 도로 방향을 기준으로 측면 방향으로 큰 건물 등으로 인해 신호 감쇄가 상대적으로 더 많이 발생한다. 그러나 거리만을 고려한 신호전파 모델은 이런 특성을 고려하지 못함으로써 방향에 따라 달라지는 신호 감쇄 특성을 반영하지 못하여 특정 방향으로만 추정된 값과 근처의 측정치가 큰 차이를 보이는 것을 Fig. 2d에서 확인할 수 있다. 그러나 Fig. 2e에서는 거리와 방향을 함께 고려하여 학습된 DNN 모델 기반으로 신호를 추정함으로써 도로 방향으로만 신호 감쇄가 크지 않으나 도로 이외의 일부 방향으로만 신호가 크게 떨어지는 특성을 함께 반영하고 있음을 확인할 수 있다. 즉 추정된 값과 이웃하는 측정치와의 차이가 상대적으로 크지 않은 것을 볼 수 있다.

4. EXPERIMENTAL ANALYSIS

3장에서 제안한 DNN 모델 기반 신호전파 함수의 성능을 분석하기 위하여 실시함을 수행하였다. 시험 장소는 서울시 서초구 서초 1, 2동이며 GPS 기반 위치정보와 LTE 신호를 시각동기화 하여 측정 및 저장할 수 있는 장치를 차량에 탑재하고 이동하면서 도로상에서 획득한 측정치를 사용하였다.

측정 데이터는 DB 생성을 위해 획득된 것으로, 통계적인 특성이 나타나도록 성능 분석을 하기 위해 획득된 측정치의 10%를 제외하고 DB를 생성한 다음 제외한 측정치를 사용하여 생성된 DB의 성능을 분석하도록 하였다. 이 때 제외하는 10%의 측정치는 전체 측정 데이터 중에서 랜덤으로 추출한 것이며, 추정된 값과 임의로 추출한 10%의 데이터를 비교하여 Root Mean Squared Errors (RMSE) 오차를 계산하도록 하였다.

수집된 다수의 기지국 데이터 중에서 획득된 측정치의 수가 많고, 전파 거리에 따라 신호 감쇄가 이루어지는 기지국 8개를 선정하였다. 선정된 기지국을 PCI 순서로 배열하면 8, 12, 109, 144, 174, 188, 298, 398과 같다.

Fig. 5a는 앞에서 사용된 기지국의 위치를 지도상에 나타낸 것이다. 지도상에서 파란색 점들은 측정치를 획득한 위치로 차량시행을 통해 도로상에서만 획득된 것을 알 수 있다. Fig. 5b는 각 기지국으로부터 획득된 측정치를 기반으로 DB를 생성한 다음 미수집된 공간을 신호전파 모델과 제안한 DNN 모델 기반으로 각각 Gap Filling하여 갯신된 DB를 나타낸 것이다. 각 기법을 통해 생성된 DB의 결과를 비교해보면 먼저 신호전파 모델 기




Fig. 5. Comparative analysis of DB generated after gap filling by method. (a) Location of base stations on the map, (b) (left) DB generated based on SPM, (right) DB generated based on DNN





Fig. 5. Continued



(b)

Fig. 5. Continued




Fig. 6. Comparative analysis of RMSE values by method.

Table 2. Summary of evaluation tests.

PCI	Mean of RMSE values w.r.t modeling method (dBm)	
	SPM-based	DNN-based
8	11.991	6.332
12	8.535	5.547
109	9.405	6.049
144	10.234	5.650
174	11.690	6.125
188	9.510	6.141
298	11.828	7.038
358	9.954	6.887
Mean	10.393	6.221

반으로 추정된 결과는 기지국을 중심으로 거리에 따라 신호 감쇄가 이루어지지만 그 정도가 약하기 때문에 거리가 멀어질수록 오차가 증가하게 되며, 또한 모든 방향에서 동일하게 신호가 감쇄되는 것을 볼 수 있다. 이로 인해 도심 지역에서 방향에 따라 다른 구조물에 의한 신호 감쇄가 전부 다르게 나타나는 측정 데이터의 영향을 반영하지 못하여 측정치 기반으로 생성된 신호 정보와 잘 융화가 되지 않게 된다. 반면에 DNN 모델 기반으로 추정된 결과는 각 기지국을 중심으로 획득된 측정치의 거리 뿐 아니라 방향에 따른 신호 감쇄 특성을 포함하여 모델링 하였기 때문에 추정된 정보가 방향에 따라서도 다른 신호 특성을 포함하게 된다. 이에 따라 DNN 모델 기반으로 추정된 결과는 측정치 기반으로 생성된 신호 정보와 잘 융화되면서 DB가 생성됨을 확인할 수 있다.

각 기지국별로 획득된 측정 데이터를 사용하여 비교분석을 위해 계산한 RMSE를 Fig. 6에서 나타내고 있다. 즉 랜덤으로 추출한 10%의 테스트 측정치를 제외하고 나머지 데이터를 사용하여 각 기법별로 모델링을 수행한 다음 테스트 측정치와 모델링을 통해 생성된 추정치와의 차이를 통해 RMSE를 계산하였다. 이 과정을 100개의 랜덤 측정치 세트를 사용하여 각각 수행하여 계산된 RMSE 결과를 Boxplot 형태로 Fig. 6에 나타내고 있으며, 100번 계산된 RMSE의 평균값을 Table 2에 나타내고 있다. RMSE 평균 값을 비교하여 보면 신호전파 모델 기법은 약 10.393 dBm, 그리고 DNN 모델 기반 신호전파 함수는 약 6.221 dBm의 오차로 계산된다. 이 시험 결과를 다음과 같이 정리할 수 있다. 먼저 신호전파 모델은 거리에 대한 신호 세기가 감쇄되는 상관관계를 가지기 때문에 획득된 모든 측정치에 대하여 방향에 따른 신호 감쇄 특성을 전부 포함할 수 없게 된다. 이러한 문제로 인하여 상대적으로 큰 오차 경향성을 나타내게 되며, 이로 인해 신호전파 모델 기반으로 생성된 DB의 성능이 떨어지는 것으로 분석된다. 이에 반해 DNN 모델 기반 신호전파 함수는 측정치의 거리에 대한 영향과 방향에 대한 특성을 모두 포함하여 모델링 하였기 때문에 기존의 신호전파 모델과 비교하여 낮은 오차특성을 보이며, 이를 통해 생성된 DB의 성능이 상대적으로 향상되는 것으로 분석된다. 따라서 이 논문에서 제안한 DNN 모델 기반 신호전파 함수를 통해 도심지역에서 미수집 영역의 신호 정보를 정확하게 생성하고 이를 기반으로 생성된 전자지문 DB는 요구구조자의 위치를 정확하게 추정하는데 유용하게 사용될 수 있을 것으로 기대된다.

5. CONCLUSIONS

본 논문에서는 도심 지역에서 LTE 신호 기반의 측위를 위한 전자지문 DB 생성을 목적으로 한다. 측정치가 획득된 영역에서는 이를 활용하여 DB를 생성할 수 있으나 미수집된 영역에서는 일반적으로 공간보간법을 통해 Gap Filling을 할 수 있다. 그러나 미수집된 영역이 넓거나 도심지역과 같이 신호의 분산이 큰 경우에는 공간보간법 만으로는 제대로된 Gap Filling을 수행하기 어려울 수 있다. 이런 문제를 해결하기 위해 신호전파 모델링을 사용하는 방법이 연구되었다. 그러나 방향에 따른 건물 분포가 다른 도심지역에서는 거리에 따른 신호전파 모델만으로는 정확한 신호전파 특성을 모델에 반영하기 어렵다. 이런 문제점들을 토대로 이 논문에서는 DNN 모델 기반으로 거리와 방향을 모두 고려한 신호전파 함수화하는 방법을 제안하였다. 서울시 서초구에서 수행된 실험을 통해 각 기법에 대한 RMSE 오차를 계산하여 비교 분석하였다. 분석 결과 DNN 기반으로 추정된 신호 정보의 결과가 신호전파 모델로 추정한 결과보다 RMSE가 약 4.172 dBm 이상 향상되는 것을 확인할 수 있었다. 본 논문에서 제안된 기법을 기반으로 측정치 미수집 영역에서 획득가능한 신호 정보를 추정함으로써 향상된 측위용 전자지문 DB를 생성할 수 있게 되었으며, 이에 따라 LTE 신호 기반 위치추정의 정확성과 가용성이 모두 향상될 수 있을 것으로 기대된다.

ACKNOWLEDGMENTS

This work was supported by Institute of Information & Communications Technology Planning & Evaluation (IITP) grant funded by the Korea government (MSIT) (No. 2019-0-01401, Multi-source based 3D emergency LOCalization using machine learning techniques.)

AUTHOR CONTRIBUTIONS

Jae Uk Kwon contributed to the design and implementation of the algorithm and to the writing of the manuscript. Seong Yun Cho supervised the research and reviewed the manuscript as a project administrator. All authors discussed the proposed approach and results.

CONFLICTS OF INTEREST

The authors declare no conflict of interest.

REFERENCES

Andersen, J. B., Rappaport, T. S., & Yoshida, S. 1995,

Propagation measurements and models for wireless communications channels, *IEEE Communications Magazine*, 33, 42-49. <https://doi.org/10.1109/35.339880>

Cho, S. Y. 2020, LTE Signal propagation model-based fingerprint DB generation for positioning in emergency rescue situation, *JPNT*, 9, 157-167. <https://doi.org/10.11003/JPNT.2020.9.3.157>

Cho, S. Y. & Park, J. G. 2014, Radio propagation model and spatial correlation method-based efficient database construction for positioning fingerprints, *ICROS*, 20, 774-781. <https://doi.org/10.5302/J.ICROS.2014.14.0010>

Cho, Y. H., Seo, Y. D., Park, D. J., & Jeong, J. C. 2016, Study on the activation functions for efficient learning in DNN, *IEIE*, 11, 800-803. <https://repository.hanyang.ac.kr/handle/20.500.11754/100831>

Cho, Y. S. & Ji, M. I. 2019, Feasibility analysis on LTE RSRP fingerprint DB estimation using sparse war-driving collecting data for emergency location, *ISGNSS 2019 proceedings*, 29 Oct - 1 Nov 2019, Jeju, Korea, pp.51-58. <http://ipnt.or.kr/2019proc/6>

Ismail, A. H., Kitagawa, H., Tasaki, R., & Terashima, K. 2016, WiFi RSS Fingerprint Database Construction for Moblie Robot Indoor Positioning System, 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 9-12 Oct. 2016, Budapest, Hungary, pp.1561-1566. <https://doi.org/10.1109/SMC.2016.7844461>

Kingma, D. P. & Ba, J. L. 2015, Adam: A Method for Stochastic Optimization, *ICLR*, San Diego, pp.1-15. <https://arxiv.org/abs/1412.6980>

Kolodziej, K. W. & Hjelm, J. 2006, Local positioning systems: LBS applications and Services (Boca Raton, FL: Taylor & Francis Group). <https://doi.org/10.1201/9781420005004>

Lee, J. Y., Eom, C., Kwak, Y., Kang, H. G., & Lee, C. 2018, DNN-based wireless positioning in an outdoor environment, *ICASSP*, 15-20 April 2018, Calgary, AB, Canada, pp.3799-3803. <https://doi.org/10.1109/ICASSP.2018.8462098>

Li, G., Geng, E., Ye, Z., Xu, Y., Lin, J., et al. 2018, Indoor positioning algorithm based on the improved RSSI distance model, *Sensors*, 18, 2820-2834. <https://doi.org/10.3390/s18092820>

Saez de Adana, F., Blance, O. G., Diego, I. G., Arriaga, J. P., & Catedra, M. F. 2000, Propagation model based on ray tracing for the design of personal communication systems in indoor environments, *IEEE Transactions on Vehicular Technology*, 49, 2105-2112. <https://doi.org/10.1109/25.901882>

Vo, Q. D. & De, P. 2016, A survey of fingerprint-based outdoor localization, *IEEE Communications Surveys*

& Tutorials, 18, 491-506. <https://doi.org/10.1109/COMST.2015.2448632>



Jae Uk Kwon received the B.S. degrees in Mechanical and Automotive Engineering from Kyungil University in 2020. He is currently studying for a master's degree in IT Engineering at Kyungil University. His current research topics include LTE-based fingerprinting for positioning, UWB-based wireless positioning, and navigation for autonomous vehicle.



Seong Yun Cho received the B.S., M.S., and Ph.D. degrees in Control and Instrumentation Engineering from Kwangwoon University in 1998, 2000, and 2004, respectively. From 2004 to 2013, he was with Electronics and Telecommunications Research Institute as a senior researcher. In 2013, he joined the faculty of the Department of Robotics Engineering at Kyungil University, where he is currently an associate professor. His current research topics include positioning and navigation systems, filtering theory for linear/nonlinear systems, sensors-based motion detection, and LBS application systems.