

무선 센서 네트워크에서 준지도 학습을 이용한 신경망 기반 노드 위치 추정

이 유리*, 김향란*, 김형남^o

Node Localization Based on Neural Network Using Semi-Supervised Learning in Wireless Sensor Networks

Yu-Ri Lee*, Xianglan Jin*, Hyoung-Nam Kim^o

요 약

무선 센서 네트워크에서 효과적인 자원 사용을 위해서 GPS 수신기가 장착되지 않은 저렴한 일반 센서 노드를 사용할 때, 네트워크 관리를 위해 일반 센서 노드의 위치를 정확하게 추정할 필요가 있다. 일반 노드의 위치 추정 방법 중 노드 연결 정보만을 이용하는 방법은 연산량이 적고 추가적인 측정 장치가 필요하지 않다는 장점이 있어 다양한 방식의 알고리즘들이 제안되었다. 최근에는 기계 학습 방식 중 하나인 신경망을 이용한 위치 추정 방법에 대한 연구가 진행되었다. 신경망을 이용하는 방법은 GPS 수신기가 장착된 비콘 노드의 위치 정보를 이용해 모델을 학습하는데, 비콘 노드의 개수가 적은 상황에서 일반 노드의 위치 추정 성능이 저하된다는 문제점이 있다. 본 논문에서는 비콘 노드가 적은 상황에서 일반 노드의 위치 추정 오차를 줄이기 위해 준지도 학습을 적용하는 방법을 제안한다. 모의실험을 통해 비콘 노드가 적은 상황의 무선 센서 네트워크 모델을 정의하고 각 네트워크 모델에서 제안한 방식이 기존의 방식보다 위치 추정 오차가 더 작은 것을 확인한다.

Key Words : neural network, node localization, semi-supervised learning, sensor networks, multi-hop wireless network

ABSTRACT

Accurate node localization of ordinary sensor nodes in wireless sensor networks is very important for effective use of resources when we use an inexpensive ordinary sensor node that does not have a GPS receiver. Among the methods of node localization, the method using only the information of node connections is advantageous in that the calculation amount is small and the additional measuring device is not necessary. For this reason, various algorithms using only the information have been proposed. One useful method is to use neural networks, one of the machine learning applications. In the method of using the neural network, the model is learned using the position information of the beacon node equipped with the GPS receiver. However, in a situation where the number of beacon nodes is small, there is a problem that the localization error of ordinary nodes in situations where there are few beacon nodes. Through simulation experiments, we define wireless sensor network models with fewer beacon nodes and confirm that the proposed method has smaller localization error than the conventional method in each network model.

* 이 성과는 2018년도 과학기술정보통신부의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.2017R1D1A1B04035230)

※ 본 논문은 BK21플러스, IT 기반 융합산업 창의인력양성사업단에 의하여 지원되었음.

♦ First Author : Department of Electronics Engineering, Pusan National University, leeyuri@pusan.ac.kr, 학생회원

o Corresponding Author : Department of Electronics Engineering, Pusan National University, hnkim@psuan.ac.kr, 종신회원

* Department of Electronics Engineering, Pusan National University, jinxl77@gmail.com, 종신회원

논문번호 : 201811-354-B-RN, Received November 2, 2018; Revised December 14, 2018; Accepted December 21, 2018

I. 서 론

최근에 무선 센서 네트워크 (wireless sensor network)는 빠른 속도로 발전되어 왔다. 무선 센서 네트워크는 센서에서 수집된 정보를 기반으로 하여 가정, 도시 및 환경을 모니터링할 수 있는 기능을 제공한다. 이 때 사용되는 센서 노드 (sensor node)는 위치 정보를 알 수 있도록 GPS 수신기가 장착된 비콘 노드 (beacon node)와 GPS 수신기가 장착되지 않은 저렴한 일반 노드 (ordinary node) 크게 두 가지로 나눌 수 있다. 무선 센서 네트워크는 일반적으로 비콘 노드의 지리적 정보를 이용해 주변 상태를 모니터링할 수 있다. 그런데 도시 및 환경과 같이 넓은 범위를 모니터링하는 대규모 센서 네트워크인 경우에는 많은 수의 센서가 필요하므로 제한적인 재원을 효과적으로 사용하기 위해 일반 노드를 함께 사용하는 경우가 많다¹⁾. 센서 노드의 지리적 정보는 네트워크 관리, 이벤트 감지, 지리 기반 쿼리 (query) 처리 및 라우팅 (routing) 등과 같은 센서 네트워크의 많은 작업에 필수적으로 사용되기 때문에^{2,3)} 일반 노드의 위치를 파악해야 한다.

일반 노드의 위치를 파악하는 방법은 크게 범위 기반 (range-based) 방식과 비-범위 기반 (range-free) 방식으로 나뉜다^{4,5)}. 범위 기반 방식은 노드 간의 거리를 측정하는 방식으로 수신 신호 세기 (received signal strength indication), 도착 지연 시간 (time difference of arrival), 도래각 (angle of arrival) 등의 정보를 기반으로 하여 위치를 추정한다. 하지만 이러한 방법은 잡음의 영향을 받기 쉽고, 모든 센서 노드들이 비콘 노드 중 최소한 한 노드와 통신이 가능해야 하며, 정확도에 따라 복잡성 및 비용이 증가한다는 단점이 있어 대규모 센서 네트워크에 적용하는데 어려움이 있다. 이에 반해 비-범위 기반 방식은 위치 정보를 가진 노드와 직접적인 통신이 되지 않는 노드들이 존재하는 시스템인 다중-홉 (multi-hop) 환경에서 사용할 수 있으며, 거리 측정 과정이 없이 노드 연결 정보 (hop 개수)만을 이용하여 연산을 수행하기 때문에 연산량이 적다는 이점이 있다.

노드의 위치 추정을 위하여 다양한 방식의 비-범위 기반 알고리즘이 제안되어 왔는데, 이 중 참고문헌 [6]과 [7]에 제시된 방법들은 최근 각광받고 있는 기계 학습 (machine learning) 중 신경망 (neural network) 알고리즘을 적용한 방법으로 비교적 높은 정확도를 가진다. 여기서 신경망 모델을 학습시키는 방식은 지도 학습 (supervised learning)⁸⁾ 방식으로, 입출력 쌍의 데이터를 기반으로 학습 모델을 훈련하여 입출력

에 해당하는 함수를 유추하는 방식을 사용하고 있다. 비콘 노드의 노드 연결 정보와 GPS 수신기로 측정된 위치 정보를 이용해 신경망 모델을 학습하고, 위치 정보를 알 수 없는 일반 노드의 위치를 추정한다. 이러한 방법은 노드의 위치 추정 정확도를 높이기 위해서 비콘 노드의 개수를 늘리는 것이 좋다. 하지만 앞서 말했듯이 제한적인 재원을 효과적으로 사용하기 위해서는 비콘 노드의 개수를 줄여야 하므로 비콘 노드가 적은 상황에서 노드의 위치 추정 정확도를 높이는 방법이 필요하다. 따라서 본 논문에서는 준지도 학습 (semi-supervised learning)^{9,10)} 방식을 이용해 비콘 노드의 정보뿐만 아니라 일반 노드의 추정된 위치 정보로 신경망 모델의 훈련용 데이터를 늘려 노드의 추정 오차를 줄이는 방법을 제안한다.

본 논문의 구성은 다음과 같다. II장에서는 신경망 모델을 이용하여 센서 노드의 위치를 추정하는 기존의 방식을 살펴보고 기존 방식의 문제점을 확인한다. III장에서는 기존 방식의 문제점을 해결하기 위한 준지도 학습 방식을 적용한 제안하는 노드의 위치 추정 방식에 대해 설명하고, IV장의 모의실험을 통해 등방성 (isotropic) 및 비등방성 (anisotropic)을 가지는 센서 네트워크 환경을 구성하고 이러한 환경에서 제안한 방식의 위치 추정 성능을 확인한다. 마지막으로 V장에서 본 논문의 결론을 맺는다.

II. 신경망 모델을 이용한 노드의 위치 추정

2.1 신경망(Neural network) 모델

신경망 모델은 뇌의 생물학적 구조에서 착안된 방법으로 오직 데이터를 이용해 상호 연결된 뉴런들을 학습시켜 입력 값에 따른 원하는 출력 값을 얻는 수학적 모델을 생성하는 알고리즘이다. 신경망은 다중 뉴런에 의해 병렬적으로 데이터를 처리하기 때문에 복잡한 수학적 모델을 추측할 수 있는 장점이 있어 문자 인식, 음성 인식, 영상 처리, 의료 공학, 로봇 공학 등 다양한 분야에서 이용되고 있다. 이러한 수학적 모델을 추측하기 위해서는 수집된 데이터를 이용해 뉴런 사이의 연결 강도를 의미하는 가중치 (weights)를 훈련시켜야 한다.

그림 1은 입력 층 (input layer), 출력 층 (output layer) 및 하나의 숨은 층 (hidden layer)을 가지는 경우이며, 피드백 (feedback) 연결에 의한 루프 (loop)가 존재하지 않는 피드포워드 (feedforward) 신경망 모델을 나타낸다. 숨은 층의 j 번째 뉴런은 입력 값 h_i 와




그림 1. 피드포워드 신경망 모델
Fig. 1. Feedforward neural network model.

연결 가중치 $w_{i,j}^{(1)}$ 를 곱하고 모두 합한 후 활성화 함수 f 를 통과한다. 숨은 층의 각 뉴런의 출력 v_j 는 다음과 같이 나타낼 수 있다.

$$v_j = f\left(\sum_i w_{i,j}^{(1)} h_i\right) \quad (1)$$

여기서 활성화 함수는 선형 함수 (linear function), 간단한 임계값을 이용한 계단 함수 (step function), 시그모이드 함수 (sigmoid function) 또는 쌍곡선 탄젠트 함수 (hyperbolic tangent function) 등을 사용할 수 있다^[11]. 출력 층의 k 번째 뉴런은 입력 값 v_j 와 연결 가중치 $w_{j,k}^{(2)}$ 를 곱하고 합한 후 활성화 함수 g 를 통과한다. 따라서 최종 출력 값 z_k 는 다음과 같이 나타낼 수 있다.

$$z_k = g\left(\sum_j w_{j,k}^{(2)} v_j\right) \quad (2)$$

연결 가중치는 모든 학습 데이터에 대한 출력 값과 원하는 출력 값의 오차를 줄이도록 갱신된다. 신경망으로부터 얻은 출력 값과 원하는 출력 값의 오차 E 는 일반적으로 다음과 같이 차의 제곱의 합으로 정의한다.

$$E = \frac{1}{2} \sum_k (z_{dk} - z_k)^2, \quad (3)$$




그림 2. 무선 센서 네트워크 모델의 예시
Fig. 2. An example of wireless sensor network model.

여기서 z_{dk} 는 k 번째의 원하는 출력 값이고, z_k 는 신경망으로부터 얻은 k 번째 출력 값을 나타낸다. 각 가중치 $w_{i,j}^{(1)}$ 와 $w_{j,k}^{(2)}$ 는 주로 역전파 (backpropagation)^[12]라 불리는 지도 학습 기법을 이용해 E 를 최소화하도록 조정된다. 그러나 역전파 방식은 수렴 속도가 느리거나 오차 함수의 전역 최소값 (global minimum)을 찾을 수 없다는 제약이 있기 때문에 Levenberg-Marquardt (LM)^[13]에 기반한 역전파 알고리즘들이 사용된다.

2.2 무선 센서 네트워크 모델

본 논문에서는 그림 2와 같이 지리학적으로 2차원 영역의 무선 센서 네트워크 모델을 고려한다. 무선 네트워크는 GPS 수신기가 있어 위치를 알 수 있는 M 개의 비콘 노드 $\mathcal{S}_B = \{S_1, S_2, \dots, S_M\}$ 와 개별적으로는 위치 정보를 알 수 없는 N 개의 일반 노드 $\mathcal{S}_O = \{S_{M+1}, S_{M+2}, \dots, S_{M+N}\}$ 로 이루어져 있어, 총 $M+N$ 개의 센서 노드 $\mathcal{S}_T = \{\mathcal{S}_B, \mathcal{S}_O\}$ 의 배치에 의해 형성된다. 각 노드의 통신이 가능한 범위 (communication range)는 모두 동일하다 가정하였고, 센서 노드의 종류와 관계없이 두 센서 노드가 통신 범위 내에 있으면 통신이 연결되고 이러한 연결을 홉 (hop)이라 할 때, 다중-홉 (multi-hop) 경로를 사용하여 통신 범위 밖의 노드들과의 통신도 가능하다. 그림 2의 빨간 점선은 A 노드에서 B 노드까지의 다중-홉 경로를 의미하며, 두 노드간의 홉 거리 (hop count) $h(S_A, S_B)$ 는 최소 경로를 의미하며 4의 값을 가진다.

2.3 노드의 위치 추정

본 논문에서는 참고문헌 [14]에서 사용된 것과 유사한 통신 프로토콜을 사용하여 구현하였다. 여기서 하나의 비콘 노드가 전체 네트워크를 제어하는 헤드

비콘 (head beacon)으로 선택되며 신경망에 대한 훈련을 실행한다. 훈련 단계에서 각 비콘 노드는 전체 센서 네트워크에 HELLO 메시지를 전송하여 비콘 노드 간의 홉 거리에 대한 정보를 얻고, 자신의 정확한 위치와 함께 비콘 노드 쌍의 홉 거리에 관한 정보를 헤드 비콘에 전송한다. 이러한 정보를 이용하여 신경망을 훈련한 뒤, 헤드 비콘은 훈련된 신경망 모델의 가중치 및 바이어스 (bias)를 네트워크 내의 모든 센서 노드에 전달한다. 다음으로 시험 단계에서 각 비콘 노드는 전체 네트워크에 HELLO 메시지를 전송하는데, 이를 통해 각 일반 노드는 모든 비콘 노드들로부터의 홉 거리에 관한 정보를 획득할 수 있도록 한다. 그런 다음 위치 추정 단계에서 각 센서 노드는 신경망 모델과 홉 거리에 관한 정보를 이용해 자체적으로 위치를 추정한다. 이러한 메시지 교환은 유니캐스트 라우팅 프로토콜 (unicast routing protocol)^[14]를 따른다. 신경망 모델을 사용한 노드의 위치 추정에서 훈련 단계와 시험 단계에 관한 자세한 방법은 다음과 같다.

먼저 훈련 단계에서는 비콘 노드의 정확한 위치와 함께 비콘 노드 쌍의 홉 거리에 관한 정보를 이용한다. 신경망 모델의 훈련을 위한 입력은 고정된 i 번째 비콘 노드 S_i 에서 다른 비콘 노드 S_j ($j = 1, 2, \dots, M$) 와의 홉 거리 $h(S_i, S_j)$ 를 가지는 벡터이고, 그에 해당하는 원하는 출력 z_{di} 는 i 번째 비콘 노드의 x 축과 y 축의 위치를 나타내는 벡터 $(x_{true,i}, y_{true,i})$ 이다. 훈련 단계에서 사용할 수 있는 모든 입력 \mathbf{H} 와 출력 \mathbf{Z}_d 를 행렬로 나타내면 식 (4) 와 같다.

$$\mathbf{H} = \begin{bmatrix} h(S_1, S_1) & h(S_1, S_2) & \dots & h(S_1, S_M) \\ h(S_2, S_1) & h(S_2, S_2) & \dots & h(S_2, S_M) \\ \vdots & \vdots & \ddots & \vdots \\ h(S_M, S_1) & h(S_M, S_2) & \dots & h(S_M, S_M) \end{bmatrix}, \quad (4)$$

$$\mathbf{Z}_d = \begin{bmatrix} x_{true,1} & y_{true,1} \\ x_{true,2} & y_{true,2} \\ \vdots & \vdots \\ x_{true,M} & y_{true,M} \end{bmatrix}$$

이러한 식 (4)의 각 행은 신경망 모델을 훈련하기 위한 하나의 데이터 샘플이 된다. 따라서 신경망 모델은 입력 벡터의 차원에 따라 M -입력, 출력의 차원에 따라 2-출력 시스템이 되고, 사용할 수 있는 데이터 샘플의 개수는 M 개가 된다. 입력 층의 뉴런에서 사용되는 전달 함수 f 는 식 (5)와 같은 쌍곡선 탄젠트 함수이고,

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

출력 층의 뉴런에서 사용되는 전달 함수 g 는 선형 함수이다. 또한 입력 층과 출력 층 모두 바이어스가 있는 모델을 사용하여 신경망 모델을 학습시킨다^[14].

다음으로 시험 단계에서는 훈련된 신경망 모델에 일반 노드와 비콘 노드 쌍의 홉 거리에 관한 정보를 입력하여 일반 노드의 위치를 추정한다. 신경망 모델의 입력은 고정된 i 번째 비콘 노드 S_i 에서 일반 노드 S_j ($j = M+1, M+2, \dots, M+N$) 와의 홉 거리 $h(S_i, S_j)$ 를 가지는 벡터이고, 그에 해당하는 출력은 i 번째 일반 노드의 x 축과 y 축의 추정된 위치를 나타내는 벡터 $(x_{est,i}, y_{est,i})$ 이다. 시험 단계에서 사용되는 모든 입력 \mathbf{H} 와 추정된 출력 $\hat{\mathbf{Z}}$ 을 행렬로 나타내면 식 (6)과 같다.

$$\mathbf{H} = \begin{bmatrix} h(S_{M+1}, S_1) & h(S_{M+1}, S_2) & \dots & h(S_{M+1}, S_M) \\ h(S_{M+2}, S_1) & h(S_{M+2}, S_2) & \dots & h(S_{M+2}, S_M) \\ \vdots & \vdots & \ddots & \vdots \\ h(S_{M+N}, S_1) & h(S_{M+N}, S_2) & \dots & h(S_{M+N}, S_M) \end{bmatrix}, \quad (6)$$

$$\hat{\mathbf{Z}} = \begin{bmatrix} x_{est,M+1} & y_{est,M+1} \\ x_{est,M+2} & y_{est,M+2} \\ \vdots & \vdots \\ x_{est,M+N} & y_{est,M+N} \end{bmatrix}$$

이러한 식 (6)의 각 행은 신경망 모델의 하나의 입력 데이터와 그에 대한 추정된 일반 노드의 위치를 나타낸다.


2.4 비콘 노드 개수에 따른 위치 추정 성능

기존의 노드 위치 추정 방법은 비콘 노드의 홉 거리와 위치 정보를 이용하여 신경망 모델을 훈련시키기 때문에 전체 센서 노드 중 비콘 노드의 비율, $R_B = M/(M+N)$, 에 영향을 받는다. 그림 3은 전체 센서 노드의 개수 $M+N$ 이 고정됐을 때 R_B 에 따른 일반 노드의 위치 추정 성능을 나타낸다. 여기서 평균 오차 \bar{E} , 최대 오차 E_{max} , 표준 편차 오차 E_σ 는 식 (7)과 같다.

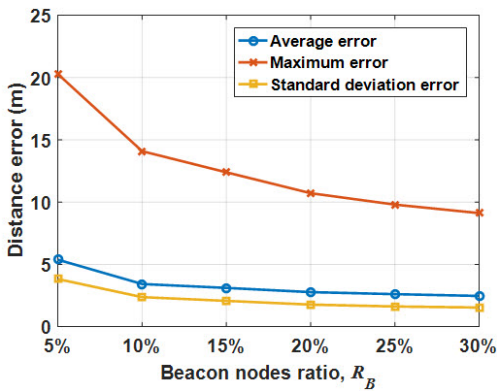
$$\bar{E} = \frac{1}{L} \sum_{i=1}^L |z_{di} - \hat{z}_i|$$

$$E_{max} = \max(|z_{di} - \hat{z}_i|)$$

$$E_\sigma = \sqrt{\frac{1}{L} \sum_{i=1}^L (|z_{di} - \hat{z}_i| - \bar{E})^2} \quad (7)$$



(a)



(b)

그림 3. 비콘 노드의 비율에 따른 일반 노드의 위치 추정 오차; (a) $M+N=160$, (b) $M+N=320$
 Fig. 3. Errors of ordinary node localization based on beacon node ratio; (a) $M+N=160$, (b) $M+N=320$.

여기서 z_{di} 는 i 번째 일반 노드의 실제 위치 좌표이고, \hat{z}_i 는 식 (6)과 같이 신경망으로부터 얻은 i 번째 일반 노드의 위치 추정 값을 나타낸다. 그림 3의 결과로 전체 노드의 개수와 관계없이 R_B 가 낮아지면 위치 추정 오차가 증가하는 경향을 확인할 수 있다. 또한, 그림 3의 (a)와 (b)에서 평균 오차의 기울기를 확인하면, (a)에서는 R_B 가 약 40% 이상일 때 평균 오차가 수렴되고, (b)에서는 약 25% 이상일 때 평균 오차가 수렴된다.

대규모 센서 네트워크는 센서의 비용을 절감하기 위해 GPS 수신기가 장착된 비콘 노드와 GPS 수신기가 없는 일반 노드가 함께 사용된다. 그러므로 전체 센서의 개수에서 R_B 를 낮추는 것이 비용 절감에도움이 되는데, 기존의 위치 추정 방법은 위의 실험 결과와 같이 R_B 를 줄이게 되면 일반 노드의 위치 추정 오차가 증가하는 문제점이 있다.

III. 준지도 학습을 이용한 노드의 위치 추정 방법

지도 학습⁸⁾은 입력에 대한 출력 레이블 (label)이 존재하는 데이터 쌍을 이용해 학습 모델을 훈련시키는 방식으로, 모든 훈련용 데이터가 입력에 대한 출력 레이블이 존재하는 경우에 사용하는 방식이다. 지도 학습 방식은 정확한 출력 값을 이용해 학습 모델을 훈련시키기 때문에 충분한 입력력 데이터 쌍이 있다면 비교적 정확한 학습 모델을 얻을 수 있다. 하지만 실제로 대량의 데이터가 모든 출력 레이블을 가지기 위해서는 많은 시간과 비용이 드는 것이 일반적이다. 따라서 소량의 입력력 데이터 쌍으로도 더 정확한 학습 모델을 얻기 위한 방식으로 준지도 학습을 사용할 수 있다.

준지도 학습^{9,10)}은 출력 레이블이 있는 데이터와 없는 데이터를 동시에 사용하여 더 정확한 학습 모델을 만드는 방식이다. 이 방식을 무선 센서 네트워크의 노드의 위치 추정 방법에 사용하면 앞서 II.4절에서 설명한 비콘 노드가 줄어든 상황에서도 좀 더 정확한 노드의 위치 추정이 가능할 수 있다. 하지만 준지도 학습이 모든 경우에 성능 향상을 보장하는 것은 아니기 때문에 본 논문에서는 모의실험을 통해 이를 확인하고자 한다.

준지도 학습 방식은 대부분 2-단계로 이루어진다¹⁰⁾. 첫 번째 단계에서는 출력 레이블이 존재하는 데이터 쌍을 이용해 학습 모델을 훈련시키고, 학습된 모델은 출력 레이블이 없는 데이터를 입력시켜 추정된 결과 값을 레이블로 제공한다. 두 번째 단계에서는 출력 레이블이 존재하는 데이터 쌍과 추정된 결과 값으로 레이블이 제공된 데이터 쌍이 학습 모델을 훈련시키는 데 함께 사용된다. 이 때 첫 번째 단계에서 하나의 학습 모델을 만들어 그 결과를 두 번째 단계에서 사용하는 방식을 자기학습 (self-training)이라고 하고, 두 개의 독립적인 학습 모델을 만들어 각각의 결과를 종합하여 두 번째 단계에서 사용하는 방식을 협동학습 (co-training)이라고 한다. 본 논문에서는 비교적 간단한 방식인 자기학습 방식을 선택하였고, 첫 번째 단계에서 추정 오차를 가지는 레이블에 의한 영향을 최소화하기 위해 두 번째 단계에서 결과 값의 정확도를 나타내는 척도를 비교해 선택된 일반 노드 S_s 의 데이터 쌍만 사용하는 방식과 반복적인 학습 방식을 사용하였다.

준지도 학습을 이용한 제안하는 노드의 위치 추정을 위한 알고리즘 순서는 아래와 같다.

(1) 첫 번째 단계에서 기존 방법과 같이 비콘 노드의 홉 거리와 위치 정보를 이용해 신경망 모델을 학습한다.

(2) 두 번째 단계에서 신경망 모델의 학습에 사용되지 않은 일반 노드의 홉 거리를 입력시켜 위치를 추정하여 추정된 위치의 정확도를 나타내는 척도를 구한다. 이 척도를 비교해 일반 노드 중 정확도가 높은 K 개의 일반 노드를 선택 비율 $R_S = K/N$ 에 따라 선택하고, 선택된 노드와 전체 비콘 노드와의 홉 거리가 1 보다 큰 노드를 최종적으로 선택된 일반 노드 S_S 로 설정한다.

(3) 비콘 노드 S_B 의 홉 거리 및 위치 정보와 선택된 일반 노드 S_S 의 홉 거리 및 추정된 위치 정보를 이용해 신경망 모델을 학습한다.

(4) (2)-(3)의 준지도 학습 과정을 반복하는데, (2)에서 최종적으로 선택되는 노드 S_S 가 없을 시에 반복을 중단하고 그 때의 신경망 모델을 최종적인 학습 모델로 설정한다.

(2)에서 S_S 의 선택에 필요한 추정된 위치의 정확도를 나타내는 척도는 다양한 방법으로 설정할 수 있는데, 실제 노드의 위치 추정 상황에서는 주로 통계적 정보를 이용한 확률 값을 사용할 수 있다¹⁰⁾. 하지만 본 논문에서는 추정 오차가 발생한 위치 정보를 훈련용 데이터로 이용했을 때 준지도 학습 방식의 적용이 가능한지 확인하는 것이 목적이기 때문에, 일반 노드가 선택되는 과정은 이상적인 상황을 가정한다. 즉, (2)에서의 추정된 위치의 정확도를 나타내는 척도는 일반 노드의 실제 위치와 추정된 위치의 차로 설정하였다.

IV. 모의실험 환경 및 결과

본 논문에서는 신경망의 가중치를 훈련시키기 위한 최적화 알고리즘으로 Levenberg-Marquardt 알고리즘¹³⁾을 사용하였다. 그리고 표 1과 같이 랜덤하게 분포되는 센서 네트워크 환경을 설정하였다. 현재 고려하고 있는 상황은 도시 환경과 같이 넓은 범위를 모니터링하는 대규모 센서 네트워크로서, 비콘 노드의 물리적 위치는 고정된다고 가정한다. 위치 추정 성능은 센서의 위치에 따라 성능의 차이가 나타날 수 있기 때문에 정확한 성능 분석을 위해 각 센서 네트워크 환경에서 100번의 반복 실험을 진행하였다. 한 실험 내에서

표 1. 무선 센서 네트워크 환경 설정 파라미터
Table 1. Parameters for configuration of wireless sensor network.

Distribution type of nodes	Uniform distribution
Total number of nodes, $M+N$	160/320
Length and breadth of the field, D	50 m
Communication range of each node	6 m

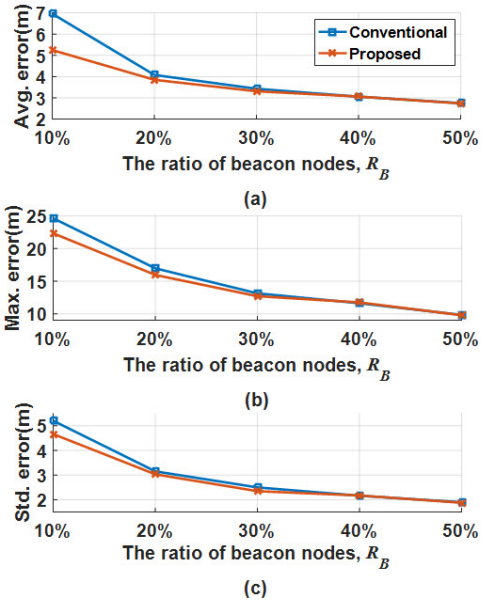


그림 4. 비콘 노드 비율에 따른 일반 노드의 위치 추정 오차 ($M+N=160$, $R_S=20\%$); (a) 평균 오차, (b) 최대 오차, (c) 표준 편차 오차
Fig. 4. (a) Average error, (b) Maximum error, (c) Standard deviation error of node localization according to the beacon node ratio ($M+N=160$, $R_S=20\%$).

고정된 비콘 노드에 의해 학습된 신경망 모델이 사용되고 실험이 바뀔 때마다 센서 위치는 무작위로 선택되어 신경망 모델은 새로운 학습을 한다. 최종적으로 노드 좌표에 영향을 받는 정도를 확인하기 위해 평균 오차뿐만 아니라 최대 오차, 표준 편차 오차를 각각 비교하여 결과를 도출하였다.

그림 4, 5는 전체 노드가 각각 160, 320 개일 때 비콘 노드 비율 R_B 에 따른 기존 방법과 준지도 학습을 적용한 방법을 비교한 그래프이며, (a)는 평균오차, (b)는 최대오차, (c)는 표준 편차 오차를 나타낸다. 여기서 선택된 일반 노드 S_S 의 비율 R_S 는 20 %로 고정하였다. 전체 노드 $M+N$ 이 160 개이고 R_B 가 10 %일 때, 제안한 방식이 평균적으로 약 1.8 m의 오차

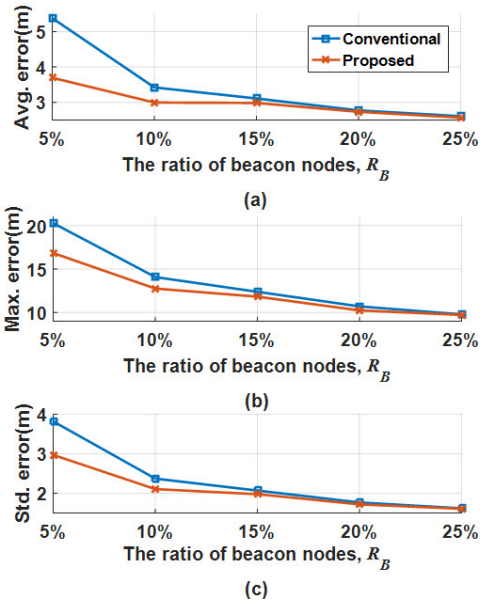


그림 5. 비콘 노드 비율에 따른 일반 노드의 위치 추정 오차 ($M+N=320$, $R_S=20\%$); (a) 평균 오차, (b) 최대 오차, (c) 표준 편차 오차
 Fig. 5. (a) Average error, (b) Maximum error, (c) Standard deviation error of node localization according to the beacon node ratio($M+N=320$, $R_S=20\%$).

감소를 보이며, 전체 노드 $M+N$ 이 320 개이고 R_B 가 5 %일 때, 제안하는 방식이 평균적으로 약 1.5 m 더 작은 오차를 가진다. 제안한 방법이 더 작은 오차를 가지는 이유는, 비콘 노드의 개수가 적으면 훈련용 데이터가 부족하기 때문에 신경망 모델을 충분히 학습할 수 없는데, 부족한 훈련용 데이터를 선택된 일반 노드 S_S 로 추가해 학습할 수 있기 때문이다. 전체 노드의 개수에 상관없이 비콘 노드의 비율이 늘어날수록 제안한 방법과 기존 방법이 유사한 성능을 가지게 되는데, 이는 비콘 노드의 개수가 많아지면서 신경망 모델을 학습하는 데 충분한 훈련 데이터가 존재하기 때문에 제안하는 기법과 기존 기법의 성능이 유사한 결과를 얻게 된다.

그림 6은 총 노드의 개수 $M+N$ 이 160 개일 때 제안한 기법에서 훈련용 데이터로 사용되는 일반 노드를 선택하는 비율 R_S 에 따른 노드의 평균적인 위치 추정 오차를 나타내고, (a)는 R_B 가 10 %, (b)는 R_B 가 20 %일 때의 성능을 나타낸다. 그림 7은 총 노드의 개수 $M+N$ 이 320 개일 때 제안한 기법에서 훈련용 데이터로 사용되는 일반 노드를 선택하는 비율에 따른 노드의 평균적인 위치 추정 오차를 나타내

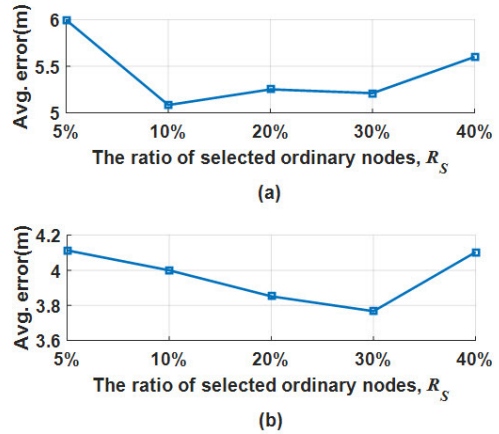


그림 6. 일반 노드를 선택하는 비율 R_S 에 따른 노드의 평균적인 위치 추정 오차 ($M+N=160$); (a) $R_B=10\%$, (b) $R_B=20\%$
 Fig. 6. The average error of node localization according to the ratio of selecting the ordinary node ($M+N=160$); (a) $R_B=10\%$, (b) $R_B=20\%$.

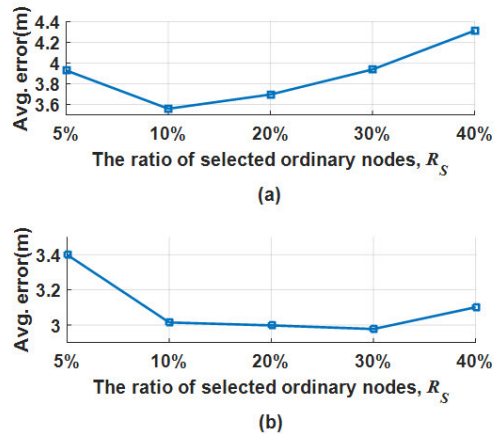


그림 7. 일반 노드를 선택하는 비율 R_S 에 따른 노드의 평균적인 위치 추정 오차 ($M+N=320$); (a) $R_B=5\%$, (b) $R_B=10\%$
 Fig. 7. The average error of node localization according to the ratio of selecting the ordinary node ($M+N=320$); (a) $R_B=5\%$, (b) $R_B=10\%$.

고, (a)는 R_B 가 5 %, (b)는 R_B 가 10 %일 때의 성능을 나타낸다. 그림 6과 7을 살펴보면 모두 ‘V’자 형태의 그래프를 가지는 것을 확인할 수 있다. ‘V’자 형태에서 좌측과 같이 R_S 가 작을 때 오차가 증가하는 이유는 충분한 훈련용 데이터를 가지고 있지 않아 신경망 모델의 학습 정도가 부족하기 때문이다. ‘V’자 형태에서 우측과 같이 R_S 가 클 때 오차가 증가하는

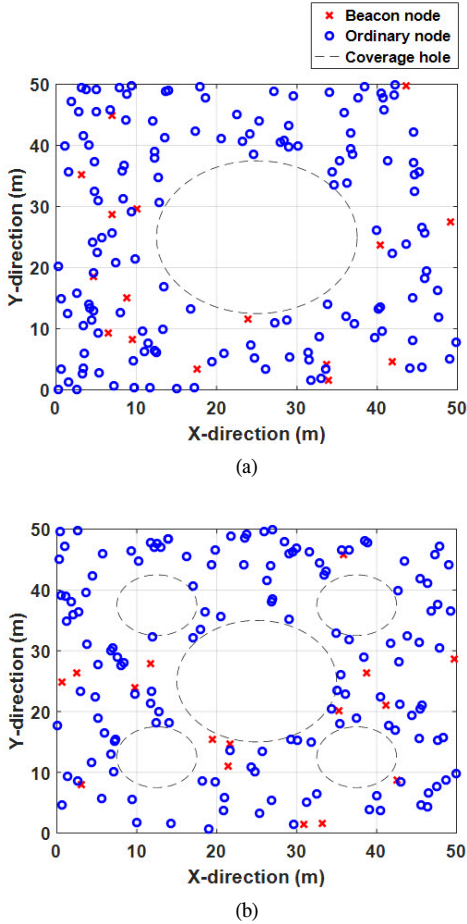


그림 8. 커버리지 홀이 있는 무선 센서 네트워크 모델의 예시; (a) 커버리지 홀이 한 개일 때, (b) 커버리지 홀이 다섯 개일 때
 Fig. 8. Examples of wireless sensor network model with coverage holes; (a) one coverage hole, (b) five coverage holes.

이유는 이미 충분한 훈련 데이터가 존재하는데 오차가 포함된 일반 노드의 위치가 훈련 데이터로 사용되기 때문이다.

실제적인 센서 네트워크 환경은 다양한 장애물로 인한 커버리지 홀 (coverage hole)이 존재한다^[14]. 그러므로 이와 같은 환경에서 제안하는 성능을 확인하기 위해 두 가지의 센서 네트워크 환경을 고려했다. 첫 번째 센서 네트워크 환경은 그림 8의 (a)와 같이 하나의 큰 커버리지 홀이 존재하는 네트워크로, 커버리지 홀의 반경은 12.5 m이고 중심은 (25, 25)로 설정하였다. 두 번째 센서 네트워크 환경은 그림 8의 (b)와 같이 다섯 개의 커버리지 홀이 존재하는 네트워크로, 다섯 개의 홀 중 하나는 반경이 10 m이고 중심은 (25,

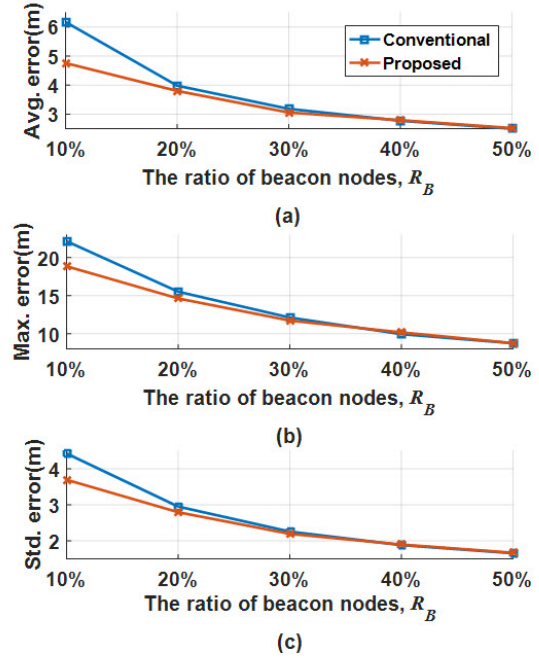


그림 9. 하나의 커버리지 홀이 존재하는 센서 네트워크 환경에서 비콘 노드 비율에 따른 일반 노드의 위치 추정 오차 ($M+N=160$, $R_S=20\%$); (a) 평균 오차, (b) 최대 오차, (c) 표준 편차 오차
 Fig. 9. (a) Average error, (b) Maximum error, (c) Standard deviation error of node localization according to the beacon node ratio in the sensor network with one coverage hole ($M+N=160$, $R_S=20\%$).

25)로 설정하였고 다른 네 개의 홀은 전체 필드의 모서리에 각각 위치하며 반경은 5 m로 설정하였다.

그림 9, 10은 각각 하나와 다섯 개의 커버리지 홀이 존재하는 네트워크 환경에서 전체 노드 $M+N$ 이 160 개일 때 비콘 노드 비율 R_B 에 따른 기존 방법과 준지도 학습을 이용한 제안한 방법에서 R_S 를 20%로 했을 때를 비교한 그래프이다. 이와 같이 커버리지 홀이 존재할 때에도 제안하는 기법을 이용하면 R_B 가 낮을 때 노드의 위치 추정 오차를 줄일 수 있는 것을 확인할 수 있고, R_B 가 늘어날수록 제안한 방법과 기존 방법이 유사한 성능을 가지게 되는 결과도 동일한 것을 알 수 있다.

이와 같이 제안한 노드 위치 추정 방식은 준지도 학습을 이용함으로써 비콘 노드 비율이 낮을 때 기존의 방식에 비해 위치 추정 오차가 작은 이점이 있다. 그런데 준지도 학습은 일반 노드의 위치를 추정하는 연산과 일반 노드 중에서 일부를 선택하여 학습 단계를 반복하기 때문에 기존의 노드 위치 추정 방식에 비

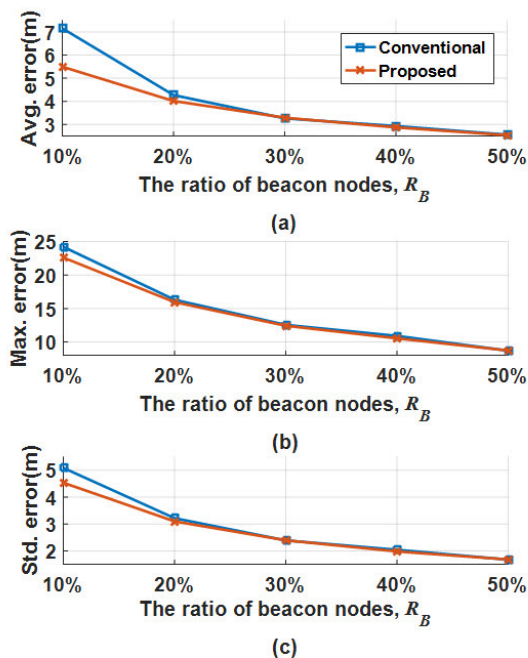


그림 10. 다섯 개의 커버리지 홀이 존재하는 센서 네트워크 환경에서 비콘 노드 비율에 따른 일반 노드의 위치 추정 오차 ($M+N=160$, $R_S=20\%$); (a) 평균 오차, (b) 최대 오차, (c) 표준 편차 오차

Fig. 10. (a) Average error, (b) Maximum error, (c) Standard deviation error of node localization according to the beacon node ratio in the sensor network with five coverage holes($M+N=160$, $R_S=20\%$).

해 학습 단계에서 더 많은 연산을 수행하게 된다. 이를 확인하기 위해 본 논문에서는 학습 단계에서 기존 방식과 제안한 방식의 연산 시간을 비교하였고 그 결과는 표 2와 같다. 이 테스트에 사용된 데스크톱 컴퓨터는 Intel Core i5-8600K CPU, 3.60 GHz 6 코어, 8 GB RAM, Windows 10 Home 64 비트 운영 체제를 갖추고 있고, 전체적인 분석은 MATLAB R2016을 사용하였다. 표 2에서 연산 시간의 증가 비율을 살펴

표 2. 학습 단계에서 기존 방식과 제안한 방식의 연산 시간 비교

Table 2. Comparison of the computational time in a training phase of the conventional and the proposed method.

Algorithm	Running time(sec)	
	$M+N=320$, $R_B=10\%$	$M+N=160$, $R_B=10\%$
Conventional method	0.821	0.164
Proposed method ($R_S=10\%$)	7.915	1.196

보면 제안한 방식의 연산 시간이 기존 방식에 비해 320 개의 노드를 사용했을 때 9.64 배, 160 개의 노드를 사용했을 때 7.29 배가량 증가하였다. 제안하는 방식이 기존의 방법에 비해 많은 연산량을 가지지만 절대적인 시간을 확인해 보면 네트워크 모델이 정해졌을 때 한 번의 학습 과정에서 8 초 이내의 짧은 시간만을 필요로 하므로 실제 무선 센서 네트워크에 적용하는 데에 큰 문제는 없을 것으로 보인다.

V. 결론

본 논문에서는 신경망 기반 위치 추정 알고리즘에서 준지도 학습 방식을 적용하는 기법을 제안하였고, 기존의 신경망 기반 위치 추정 알고리즘과 비교하여 노드의 위치 추정 성능을 비교 및 분석하였다. 기존 알고리즘은 비콘 노드 비율이 낮을 때 훈련용 데이터가 적어 신경망 모델의 학습이 충분히 이루어지지 않는 문제점이 있었다. 이를 해결하기 위해 제안한 방식은 추정된 일반 노드의 정보를 훈련용 데이터로 이용하는 준지도 학습 방식을 적용하였다. 제안한 방법은 균일 분포의 센서 배치뿐만 아니라 커버리지 홀이 존재하는 비등방성을 가지는 센서 배치에서도 비콘 노드 비율이 낮을 때 노드의 위치 추정 오차를 줄일 수 있는 것을 확인하였다. 본 논문에서의 결과는 비콘 노드 비율이 낮은 센서 네트워크 환경에서 신경망 알고리즘을 적용할 때 효과적인 센서 위치 추정 방법을 제공할 수 있다. 이를 통해 효율적인 센서 네트워크 관리가 가능할 것으로 기대되며, 향후 준지도 학습을 이용한 방법에서 일반 노드를 선택할 때 오차가 적은 노드를 선택할 수 있는 방법에 관한 다각도의 연구가 필요할 것으로 보인다.

References

- [1] M. L. Sichitiu and V. Ramadurai, "Localization of wireless sensor networks with a mobile beacon," *2004 IEEE Int. Conf. IEEE, Mobile Ad-hoc and Sensor Syst.*, FL, USA, Oct. 2004.
- [2] J. N. Al-Karaki and A. E. Kamal, "Routing techniques in wireless sensor networks: A survey," *IEEE Wireless Commun.*, vol. 11, no. 6, pp. 6-28, Dec. 2004.
- [3] A. Mesmoudi, M. Feham, and N. Labraoui, "Wireless sensor networks localization

algorithms: A comprehensive survey,” *Int. J. Comput. Netw. Commun.*, vol. 5, no. 6, pp. 45-64, Dec. 2013.

[4] Q. Shi, C. He, H. Chen, and L. Jiang, “Distributed wireless sensor network localization via sequential greedy optimization algorithm,” *IEEE Trans. Signal Process.*, vol. 58, no. 6, pp. 3328-3340, Mar. 2010.

[5] S.-W. Lee and C.-W. Lee, “Range-free localization based on residual force-vector with kalman filter in wireless sensor networks,” *J. KICS*, vol. 35, no. 4, pp. 647-658, Apr. 2010.

[6] A. Chatterjee, “A fletcher-reeves conjugate gradient neural-network-based localization algorithm for wireless sensor networks,” *IEEE Trans. Veh. Technol.*, vol. 59, no. 2, pp. 823-830, Oct. 2010.

[7] J. Zheng and A. Dehghani, “Range-free localization in wireless sensor networks with neural network ensembles,” *J. Sensor and Actuator Netw.*, vol. 1, no. 3, pp. 254-271, Nov. 2012.

[8] M. I. Jordan and D. E. Rumelhart, “Forward models—supervised learning with a distal teacher,” *Cognitive Science*, vol. 16, no. 3, pp. 307-354, Sep. 1992.

[9] Q. T. Thai, K.-S. Chung, and C. Keum, “Wifi fingerprint calibration using semi-supervised self organizing map,” *J. KICS*, vol. 42, no. 2, pp. 536-544, Feb. 2017.

[10] X. Zhu, *Semi-supervised learning literature survey*, Technical Report 1530, Univ. of Wisconsin-Madison, 2005.

[11] İ. Güler and E. D. Übeyli, “ECG beat classifier designed by combined neural network model,” *Pattern recognition*, vol. 38, no. 2, pp. 199-208, Feb. 2005.

[12] S.-Y. Lee, “Artificial neural networks for resonant resistance calculation of rectangular, circular MicroStrip antennas,” *J. KICS*, vol. 35, no. 12, pp. 275-278, Dec. 2010.

[13] H. Demuth and M. Beale, *Neural Network Toolbox for Use with MATLAB, User’s Guide*, Natic, MA: MathWorks Inc., 1998.

[14] D. A. Tran and T. Nguyen., “Localization in wireless sensor networks based on support vector machines,” *IEEE Trans. Parall. and Distrib. Syst.*, vol. 19, no. 7, pp. 981-994, May 2008.

이 유 리 (Yu-Ri Lee)



2010년 2월 : 부산대학교 전자
전기공학부 학사 졸업
2012년 2월 : 부산대학교 전자
전기공학과 석사 졸업
2018년 2월 : 부산대학교 전자
전기컴퓨터공학과 박사 졸업
2018년 3월~현재 : 부산대학교

전자공학과 박사 후 연구원

<관심분야> 부채널 공격, 디지털 방송 신호처리, 전
자전 신호처리, 생체 신호처리, 머신러닝

김 향 란 (Xianglan Jin)



1997년 7월 : 북경우전대학교 통
신공학과 학사 졸업
2002년 4월 : 북경우전대학교 통
신공학과 석사 졸업
2008년 8월 : 서울대학교 전기
컴퓨터공학과 박사 졸업
2008년 9월~2010년 2월 : 서울

대학교 전기컴퓨터공학부 박사 후 연구원

2010년 3월~2014년 2월 : 동국대학교 정보통신공학
부 연구교수

2015년 3월~2016년 7월 : University of California,
San Diego, 방문학자

2014년 3월~현재 : 부산대학교 전기컴퓨터공학부 계
약교수

<관심분야> MIMO, 협력통신, 머신러닝, 정보이론

김 형 남 (Hyoung-Nam Kim)



1993년 2월 : 포항공과대학교 전
자전기공학과 학사 졸업

1995년 2월 : 포항공과대학교 전
자전기공학과 석사 졸업

2000년 2월 : 포항공과대학교 전
자전기공학과 박사 졸업

2000년 5월 : 포항공과대학교 전
자컴퓨터공학부 박사 후 연구원

2000년 5월~2003년 2월 : 한국전자통신연구원 무선
방송연구소 선임 연구원

2003년 3월~2007년 2월 : 부산대학교 전자전기통신
공학부 조교수

2007년 3월~2012년 2월 : 부산대학교 전자전기통신
공학부 부교수

2009년 2월~2010년 2월 : Johns Hopkins Univ.
Visiting Scholar

2015년 9월~2016년 8월 : Univ. of Southampton
Visiting Professor

2012년~현재 : 부산대학교 전자공학과 교수

<관심분야> 적응신호처리, 레이더 및 소나 신호처
리, 디지털 방송 신호처리, 생체 신호처리