

# 실내 화재 상황에서 머신러닝 기반의 최적 대피 경로 안내 AR 내비게이션 시스템 연구

조용준\*, 박성용\*, 윤성호\*, 최승희\*, 유상조°

## Machine Learning Based Optimal Evacuation Route Guidance AR Navigation System in Indoor Fire Situations

Yong-Jun Cho\*, Seong-Yong Park\*, Seong-Ho Youn\*, Seung-Hee Choi\*, Sang-Jo Yoo°

### 요약

본 논문에서는 머신러닝과 AR을 이용하여 실내 화재 상황에서의 최적 대피 경로 안내 시스템을 제안한다. 사용자 위치 추정을 위해 실제 시스템을 적용할 장소에 BLE 비콘 환경을 조성한 후, 위치에 따른 비콘 신호의 RSSI 데이터를 수집한다. 수집한 데이터를 바탕으로 심층신경망 모델을 학습하여 사용자 위치를 결정한다. 최적 대피 경로 도출에는 Q-learning을 활용하며, 사용자 위치와 화재 위치, 대피 경로의 혼잡 상황 등의 정보를 종합적으로 반영한다. 도출된 대피 경로는 안드로이드 AR 애플리케이션을 통해 직관적으로 제공한다. 실제 수집한 RSSI 데이터를 기반으로 한 성능평가에서 사용자 위치 추정은 높은 정확도를 보였다. 또한, Q-Learning을 통해 위험한 지역을 피하고 최단 시간이 소요되는 경로를 도출하였다. 본 논문에서 제안하는 시스템을 통해 개개인의 신속한 대피를 도와 인명피해를 줄일 수 있을 것으로 보인다.

**Key Words** : Indoor Positioning, Machine Learning, Optimal Evacuation Route, Q-Learning, Deep Learning, AR

### ABSTRACT

In this paper, we propose an optimal evacuation route guidance system for indoor fire emergency environments using machine learning and AR technologies. For user indoor positioning, we have implemented BLE beacon devices, and then collect received signal strength indication (RSSI) data of beacon signals at the user's smartphone according to the locations. Based on the data collected, a deep learning model is trained to determine user locations. Q-learning is utilized to derive optimal evacuation paths for individuals, and comprehensively reflects information such as user location, fire locations, and congestion situations in evacuation routes. Derived evacuation paths are intuitively provided through the Android AR application we implemented. Through performance evaluations based on the RSSI data collected in practice, user location estimation showed high accuracy and the Q-learning based evacuation path can derive the shortest time route without passing risky areas. Through the system proposed in this paper, we can help individuals evacuate quickly and reduce human casualties.

\* 이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2020R1F1A1053006), 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터 육성지원사업의 연구결과로 수행되었음 (IITP-2021-0-02052)

♦ First Author : Inha University Department of Information and Communication Engineering, yacyj22@gmail.com, 학생회원

° Corresponding Author : Inha University Department of Information and Communication Engineering, sjyoo@inha.ac.kr, 종신회원

\* Inha University

논문번호 : 202107-174-C-RN, Received July 20, 2021; Revised August 12, 2021; Accepted August 18, 2021

## 1. 서 론

우리나라에서는 크고 작은 화재 피해가 자주 발생하고 있다. 최근 10년간 연평균 화재 건수는 약 4만 건, 인명피해는 약 2천 명에 이른다. 이중 건축·구조물 화재가 가장 자주 발생했으며, 이는 유형별 화재 중 매년 가장 큰 인명, 재산 피해 규모를 차지한다. 화재 발생 시 인명피해를 줄이기 위해서는 골든타임 이내의 신속한 대피가 무엇보다 중요하다.<sup>[1]</sup> 비상구 표시 등, 피난 유도선과 같은 기존 시스템은 화재 상황을 감지했을 때 모든 사람에게 동일한 대피 경로를 제공하게 된다. 이는 화재 전파와 대피 경로의 혼잡 상황 등을 고려하지 않은 경로이기에 대피 시 소요되는 시간이 늘어날 수 있는 한계가 있다. 따라서 본 논문에서는 실내 건물 환경정보를 기반으로 사용자의 위치를 추정하고 경로 추적 알고리즘을 통해 각 사용자에게 최적의 탈출 경로를 예측하며 증강현실(AR, Augmented Reality) 기술을 통해 탈출 경로를 사용자에게 제공한다.

각 사용자에게 맞춰 최적의 경로를 찾는 알고리즘을 이용하기 위해서는 우선 실내에서 사용자의 위치를 결정해야한다. 일반적으로 위치 결정에는 GPS(Global Positioning System)기술이 많이 활용되나, 실내 및 지하에서 사용하게 되면 신뢰성이 떨어지기 때문에 본 알고리즘으로 이용하기에 부적합하다.<sup>[2,3]</sup> 그래서 실내에서 진행되는 사용자 위치 추정에는 BLE 비콘(Bluetooth Low Energy Beacon) 또는 WiFi로부터 얻은 RSSI(Received Signal Strength Indicator)를 이용한 알고리즘에 대한 연구가 많이 진행되고 있다. 이는 실내에 서로 다른 위치에 있는 비콘으로부터 RSSI 신호를 수신하게 되면 사용자의 위치에 따라 각각의 비콘으로부터 수신되는 신호의 세기가 다른 것을 이용한 방식이다. 하지만 사용자 위치 추정에 수신한 RSSI 값을 그대로 이용하는 경우에는 신호에 섞이는 잡음에 의해 오차가 발생하여 정확도가 떨어지는 문제가 있다. 따라서 이러한 잡음에 의한 문제를 해결하기 위한 연구가 많이 진행되고 있다. G. Li는 블루투스 게이트웨이 기반 RSSI 실시간 보정 방법을 제안했다.<sup>[4]</sup> 이는 오차를 줄이는 RSSI 거리 모델을 찾기 위해 PSO-BPNN에 의해 최적화된 역전파 신경망을 사용한다. 이는 RSSI 값에 따라 매번 적합한 RSSI 거리 모델을 찾아야 한다는 번거로움이 발생한다. O. Chitsobhuk는 실내 내비게이션 시스템을 제안하였는데 이때 실내에서 사용자의 위치를 추정하기 위해 WiFi RSS 핑거프린트 위치 추정 방식을 사용하였

다.<sup>[5]</sup> 이는 위치마다 고유의 수신 신호 세기가 존재한다는 것을 이용한 방식으로, 각각의 위치에서 데이터 베이스를 수집하고 새로운 수신 신호를 이와 비교하여 사용자의 위치를 추정하는 방식이다. O. Chitsobhuk는 새로운 수신 신호의 위치를 분류하기 위해 나이브 베이즈 분류기를 이용하였다. 핑거 프린트를 이용한 방식은 데이터베이스에 없는 데이터를 입력으로 받게 되었을 때 원활한 대처를 할 수 없는 문제가 있다. Noh는 딥러닝 기반 Wi-Fi 핑거프린트 실내 측위 기법 동향 및 전망에 대해서 소개하였다.<sup>[6]</sup> 해당 논문에서는 딥러닝 기법 중 합성곱 신경망을 이용한 실내 측위 기법과 순환 신경망을 이용한 실내 측위 기법에 대해 소개하였다. 본 논문에서는 비콘으로부터 얻은 RSSI를 학습된 심층 신경망 모델에 이용해 사용자가 위치한 셀을 출력하는 방식을 사용한다.

얻은 사용자의 위치 정보와 주어진 실내 환경의 출구에 대한 정보를 이용하여 사용자의 위치에서 탈출구로 가는 최적 경로를 찾는다. 일반적으로 최단 경로를 산출하기 위한 알고리즘으로는 Dijkstra 알고리즘이 많이 사용되고 있다. 이는 한 점에서부터 다른 모든 점까지의 거리를 계산하여 최단 경로를 계산하는 방식이다.<sup>[7]</sup> 모든 점간의 최단 거리를 계산할 수 있다는 장점이 있지만 그만큼 시간과 메모리적인 비용이 크게 발생한다는 단점이 있다. Afsana Khan은 A\* 서치 알고리즘을 사용하여 출구까지의 최단 경로를 찾아 피난자를 안내하는 IoT 기반의 지능형 화재 대피 시스템을 제안하였다.<sup>[8]</sup> A\* 서치 알고리즘은 비용함수와 휴리스틱을 이용하여 목적지까지의 경로를 산출하기 때문에 Dijkstra에 비해 비용이 적게 들지만, 재난에 의해 이용할 수 있는 경로가 시시각각 변화하는 상황에서 이용하기엔 여전히 어려움이 존재한다. 따라서 단순히 최단 경로가 아니라 재난 상황을 피한 최적 경로를 산출하기 위해 본 논문에서는 Q-Learning을 이용한다. Q-Learning은 강화학습의 방식 중의 하나로 강화학습은 주어진 상태에서 받게 되는 보상을 최대화하는 행동을 선택하도록 학습하는 것을 목표로 한다.<sup>[9,10]</sup> Q-Learning은 Q-table을 이용해 각 상태에서 최대의 보상을 줄 수 있는 행동에 대해 학습함으로써 최적의 정책을 학습할 수 있다.<sup>[11]</sup> Kong은 Q-Learning을 이용하여 주변 환경을 학습하고 동적 장애물이 존재할 때 이를 회피하는 알고리즘에 대해 제안했다.<sup>[12]</sup> Park은 Deep Q-Network를 이용하여 공장 내부 구조를 촬영한 이미지에서 현재 로봇의 위치에 대한 최적 이동 경로를 도출하는 방법을 제안하였다.<sup>[13]</sup>

마지막으로 이렇게 구한 사용자의 위치와 최적 경로를 AR 애플리케이션을 통해 사용자에게 제공하여 사용자가 최적의 대피 경로를 직관적으로 확인할 수 있도록 한다.

논문의 구성은 다음과 같다. 2장에서는 본 논문이 제안하는 시스템을 크게 사용자의 위치 결정 모델, 최적의 대피로 추정 모델, 증강현실 구현 세 가지로 구분하여 각각의 알고리즘과 기술을 설명한다. 3장에서는 모의실험을 통해 제안된 방식의 성능을 확인하며 마지막으로 4장에서는 결론을 내린다.

## II. 머신러닝 기반의 최적 대피 경로 안내 AR 내비게이션 시스템

본 논문이 제안하는 시스템 구조는 그림 1과 같다. 최적 대피 경로 안내 AR 내비게이션을 위한 시스템은 크게 사용자 위치 결정 모델, 최적 대피 경로 추정 모델, AR 대피 경로 안내로 구분된다. 사용자 위치 결정 모델은 구역별로 수집한 비콘의 RSSI를 이용하여 심층 신경망을 학습시키고 이를 이용하여 사용자의 위치를 예측한다. 서버에서는 학습된 심층 신경망을 통해 수신된 RSSI값만으로도 사용자의 위치를 예측할 수 있다. 사용자의 위치를 결정한 뒤 해당 위치부터 출구까지 최적의 대피 경로를 추정하기 위해서는 Q-Learning 알고리즘을 이용한다. 최적 대피 경로 추정 모델은 화재의 위치, 대피 경로의 혼잡 상황 등을 종합적으로 고려하여 최단 시간 대피 경로를 도출한다. 서버에서는 도출한 최적 대피 경로를 다시 AR 애플리케이션을 통해 사용자에게 제공한다.

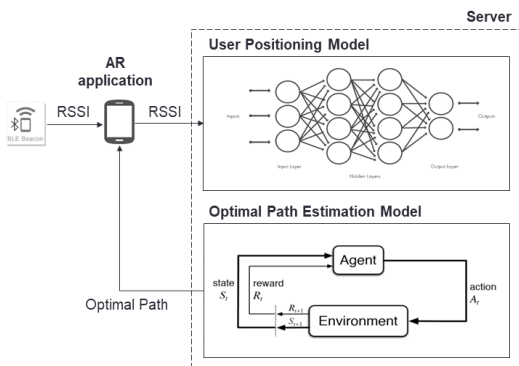


그림 1. 시스템 구조  
Fig. 1. System Architecture

### 2.1 사용자 위치 결정을 위한 심층 신경망 모델

AR 내비게이션 시스템에서 시작점이 되는 사용자 초기 위치를 결정하기 위하여 기계 학습 방식 중 하나인 심층 신경망(DNN, Deep Neural Network)을 사용한다. 심층 신경망은 그림 2와 같이 입력 층과 출력 층 사이에 여러 개의 은닉 층으로 구성된 모델로 최종적으로 원하는 출력을 내기 위해 입력 값에 어떠한 가중치를 곱해야 하는지를 학습하는 모델이다. 가중치는 입력에 대한 정답을 알려주는 지도 학습을 통해 학습되고 학습된 가중치를 통해서 정답을 알 수 없는 새로운 입력에 대해서도 적합한 출력을 낼 수 있다.

본 논문은 공간을  $N_f$ 개의 셀로 구분하고  $N_b$ 개의 비콘을 배치한 실내를 가정한다. 심층 신경망 모델의 입력 값으로는 사용자의 위치에서 비콘으로부터 수신되는 RSSI 값을 이용하며 사용자의 위치가 속한 셀을 출력 값으로 사용한다. 이때, 사용자의 위치에서 수신된 RSSI 값을 그대로 사용하는 경우 잡음에 의해 사용자의 위치 정확도가 감소할 수 있다. 따라서 서버에서는 학습의 정확도를 높이기 위하여 건물 내부의 다양한 요소로 발생한 신호의 잡음을 제거하는 필터링을 수행한다. 본 연구에서는 EWMA(Exponentially Weighted Moving Average) 필터를 사용하였다. EWMA는 현재 수신한 데이터 정보뿐만 아니라 과거에 수신한 데이터에 대한 정보를 이용하여 신호의 변화를 감지하는 방식이다.<sup>[14]</sup> 이는 최근 정보들에 지속적으로 큰 가중치를 부여하여 시스템의 변동에 민감하게 반응하도록 한 것이 특징이며 수식 (1)을 통해 진행된다.

$$y(t) = (1-w)y(t-1) + wx(t) \quad (1)$$

위 수식에서  $x(t)$ 는 현재 측정된 RSSI를 의미한다.  $y(t-1)$ 는 이전시간에 필터링된 RSSI 신호를 의미하며  $y(t)$ 는 새롭게 필터링되어 갱신되는 RSSI 신호가 된다.  $w$ 는 현재와 과거 데이터에 얼마나 가중치




그림 2. 심층신경망 모델 구조  
Fig. 2. DNN model architecture

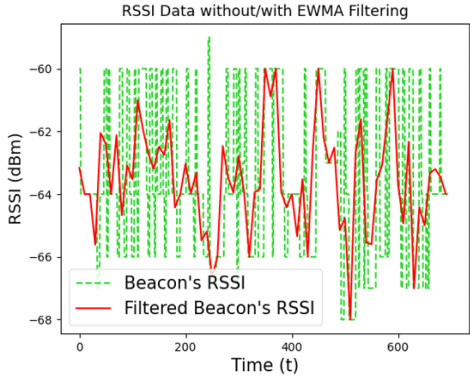


그림 3. EWMA Filtering 수행 전/후 RSSI Data  
Fig. 3. RSSI Data without/with EWMA Filtering

를 부여할지를 나타내는 파라미터로 값이 클수록 현재 데이터의 영향을 많이 받게 된다.

그림 3은 시간에 따른 EWMA 필터를 수행하지 않은 RSSI 값과 EWMA 필터를 수행한 RSSI 값을 비교한 것이다. EWMA 필터 수행한 RSSI의 값이 필터를 수행하지 않은 RSSI값에 비해 변동이 더 적은 것을 알 수 있다. 이는 EWMA 필터를 통해 RSSI에 섞이는 잡음을 완화시킬 수 있다는 것을 의미한다.

### 2.2 최적의 대피로 추정을 위한 Q-러닝 모델

사용자 위치 추정 결과를 기반으로 최적의 대피 경로를 추정하기 위해 강화학습 방법 중 하나인 Q-Learning을 이용한다. 기본적으로 강화학습은 주어진 환경에서 사용자가 행동에 따른 보상을 통해 학습을 진행한다. 실시간으로 바뀌는 실내 화재 위치와 인구수의 변화에 빠르게 대응하여 최적 경로를 산출하기 위해 본 논문은 Q-Learning을 사용한다. Q-Learning은 Q-table을 이용하여 주어진 상태에서 가장 높은 보상을 줄 것으로 기대되는 행동을 선택하게 된다. Q-table은 에피소드가 진행되는 동안 사용자가 행동에 따른 보상에 따라 갱신된다. Q-table을 갱신하기 위한 식은 수식 (2)와 같다.<sup>[15]</sup>

$$Q(S_t, a_t) \leftarrow (1 - \alpha) Q(S_t, a_t) + \alpha \{ R_t + \gamma \max_{a_{t+1}} Q(S_{t+1}, a_{t+1}) \} \quad (2)$$

위의 수식에서  $S_t$ 와  $a_t$ 는 시간  $t$ 에서의 상태와 행동을 나타내고  $R_t$ 는  $a_t$ 에 의해 얻게 되는 보상의 의미이다.<sup>[16]</sup>  $a_{t+1}$ 는 다음 상태  $S_{t+1}$ 에서 Q-값을 최대로 만드는 행동이다. 이렇게 업데이트 된 Q-table을

통해 모델은 미래의 보상을 최대로 하는 행동을 선택할 수 있다.  $\alpha$ 는 Learning rate로 Q-값이 미치는 영향을 조절할 수 있고  $\gamma$ 는 Discount factor로 미래 보상 미치는 영향을 조절할 수 있다.<sup>[17]</sup> Q-Learning 학습에  $\epsilon$ -greedy 알고리즘을 사용한다.  $\epsilon$ -greedy 알고리즘은 사용자가 특정 상태에서  $\epsilon$ 의 확률로 무작위 행동을 수행하고  $(1-\epsilon)$ 의 확률로 현재까지의 경험에 근거하여 보상이 가장 큰 행동을 수행하는 알고리즘이다.<sup>[18]</sup>  $\epsilon$ -greedy 알고리즘을 통해 가보지 않은 상태에 대한 탐색과 알고 있는 최적의 행동에 대한 이용의 균형을 맞출 수 있다.

본 논문에서 제안하는 최적의 대피 경로 도출 시스템은 건물 내부구조와 실내 화재 위치, 구역별 인구수를 기반으로 Q-Learning을 진행한다. 건물 내부 구조에서 복도를 셀로 구분하고 각각의 셀을 상태로 지정한다. 건물 내에 사용자의 현재 상태에서 선택 가능한 행동은 앞, 뒤, 왼쪽, 오른쪽, 아래로 5가지 행동을 선택할 수 있다. 사용자의 최적 탈출 경로 도출은 서버에서 가상 시뮬레이션을 통해 이루어지며, 매 위치가 변화할 때마다 설계된 보상 함수  $R(S_n)$ 에 따라 해당 상태에서 선택한 행동에 대한 보상이 주어진다. 시뮬레이션에서 사용자가 탈출구 혹은 화재를 만나게 되면 하나의 에피소드가 종료된다. 본 논문이 제안하는 보상 함수  $R(S_n)$ 는 수식 (3)과 같다.

$$R(S_n) = \begin{cases} -R_{\min} & (0 \leq n < n_0) \\ -f(n) & (n_0 \leq n < n_1, f'(n) \geq 0) \\ -R_{req} & (n \geq n_1) \end{cases} \quad (3)$$

인구수에 따라 다른 보상이 주어지는 이유는 대피 시 혼잡 구역을 피할 수 있는 최적의 탈출 경로를 제공함으로써 탈출에 필요한 시간을 단축하기 위해서이다. 수식에서  $n$ 은 인구수를 의미하며 인구수가  $n_0$ 명 미만일 경우  $-R_{\min}$ 의 보상을 받고  $n_0$ 이상  $n_1$ 미만일 경우에는  $-f(n)$ 에 따른 보상을 받는다. 이때  $-f(n)$ 는 인구수가 증가함에 따라 값이 감소하는 보상을 부여한다. 인구수가 증가함에 따라 무한히 작아지는 보상을 받지 않도록 하기 위하여 인구수가  $n_1$ 이상일 경우 일정한 값으로 수렴하는 보상  $-R_{req}$ 을 부여한다. 전체적으로  $R(S_n)$ 이 음수의 보상인 이유는 경로를 최소화하기 위해서이다.

### 2.3 AR 내비게이션을 위한 시스템 설계 및 구현

사용자에게 경로 안내 시스템을 직관적으로 제공하

기 위해 증강현실(AR, Augmented Reality)을 이용한다. 증강현실이란 현실에 기반하여 정보를 추가 제공하는 기술로 현실 세계의 이미지나 배경에 가상의 이미지를 추가하기 위해 사용되는 기술이다.<sup>[19]</sup> 정교한 증강현실을 구현하기 위해서는 주변 환경 인식 및 사용자의 위치 추정 등 많은 세부적인 기술들이 필요하다.<sup>[20]</sup> 본 연구에서는 사용자와 3D 객체의 상대적 위치 추정을 위해 Visual SLAM(Simultaneous Localization and Mapping)을 사용하였다.<sup>[21]</sup>

Visual SLAM은 카메라 영상에서 특징점이라는 시각적으로 구별되는 특징을 감지한다. 그리고 이 점을 사용하여 위치 변화를 계산하며, 시각적 정보는 IMU(Inertial Measurement Unit) 센서의 관성 측정과 결합하여 실제 환경에서의 카메라의 위치 및 방향을 추정한다. 따라서 카메라의 시점이 이동되어도 Visual SLAM을 통해 증강현실 객체들의 위치 또한 상대적으로 변하여 실제로 사물이 특정 위치에 고정되어있는 것처럼 동작한다. 2.2절을 통해서 얻은 대피 경로를 스마트폰 애플리케이션에 증강현실을 이용하여 표시하기 위해 소켓 프로그래밍을 이용하여 서버와 사용자를 연결한다. 소켓 프로그래밍으로 전달받은 경로를 유니티(Unity)에 내장된 기술인 Line Rendering에 이용하여 애플리케이션 상에 표현될 수 있도록 한다. 사용자에게 제공하고자 하는 AR 애플리케이션의 UI는 그림 5와 같다. 제공되는 UI는 사용자의 시점으로

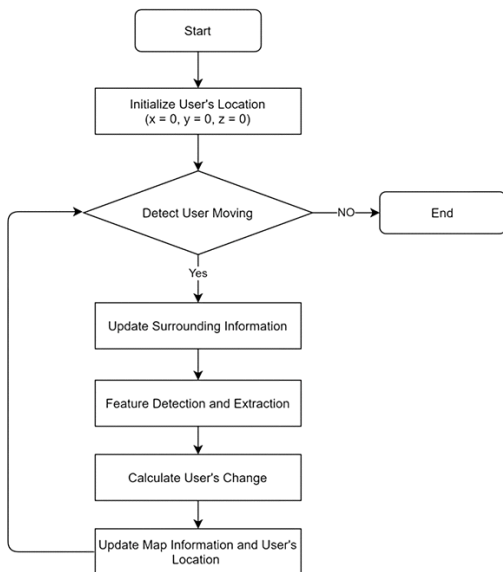


그림 4. Visual SLAM 흐름도  
Fig. 4. Flowchart of Visual SLAM

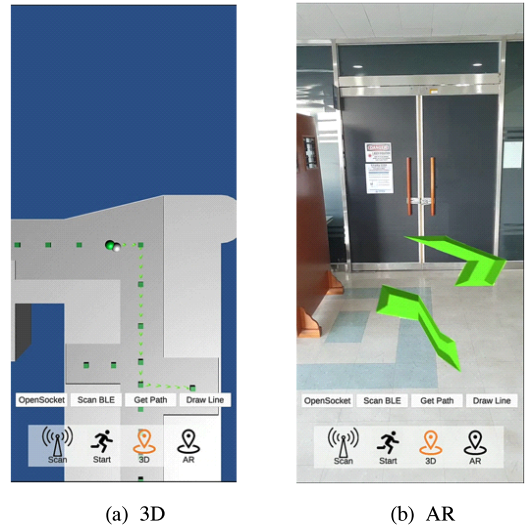


그림 5. 애플리케이션 UI  
Fig. 5. Application UI (a) 3D (b) AR

두 가지 방식을 사용할 수 있도록 구현한다. 그림 5.(a)는 사용자의 위치를 3인칭 관점으로 바라본 방식이다. 현재 위치에서부터 탈출구까지 전체 경로를 볼 수 있다. 그림 5.(b)는 실제에 AR을 적용한 방식으로 사용자의 위치를 1인칭 관점으로 바라본 방식이다. 현재 위치에서 어떠한 방향으로 이동을 해야 하는지에 대한 경로를 볼 수 있다. 표 1은 UI에 사용한 각각의 버튼에 대한 설명이다.

사용자는 ‘OpenSocket’ 버튼을 통해 소켓 프로그래밍을 진행하여 서버와 연결을 할 수 있다. ‘ScanBLE’ 버튼을 통해 비콘의 RSSI 신호를 받을 수 있으며 서버에서는 비콘의 MAC 주소와 RSSI를 받을 수 있다. 서버에서는 수신한 RSSI 신호에 EWMA 필터를 적용하고 미리 학습된 심층신경망 모델에 사용하여 사용자의 위치를 추정한다. 심층신경망 모델을 통해 추정한 사용자의 위치를 시작점으로 하여 Q-Learning 모델을 통해 최적의 대피 경로를 추정한 뒤 다시 소켓 프로그래밍을 이용하여 사용자에게 전

표 1. UI 버튼 설명  
Table 1. Description for UI button

Button	Description
OpenSocket	Open the user's socket and request a connection to the server
ScanBLE	Receive beacons signal
GetPath	Get a optimal escape path from server
DrawLine	Show the escape path as AR

송한다. 'GetPath' 버튼을 통해 사용자의 스마트폰으로 현재 위치부터 탈출구까지 수열 형태로 된 최적 경로가 전송된다. 'DrawLine' 버튼을 통해 유니티 내부의 라인 렌더링의 요소로 수열 형태로 된 셀 번호가 입력되어 최종적으로 AR 경로를 표시하게 된다.

### III. 모의실험 및 결과

본 논문이 제안하는 실내 화재 상황에서 머신러닝 기반의 최적 대피 경로 안내 AR 내비게이션 시스템을 구현하고 실험을 통해 성능을 확인하였다. 사용자 위치 추적을 위한 심층신경망 모델 구현, 최적 대피 경로 산출을 위한 Q-Learning 모델 구현, 사용자에게 최적 경로를 제공하기 위한 AR 애플리케이션 구현을 통해 전체 시스템을 구현하였으며 실제 상황에 동작을 확인하였다. 심층신경망 모델과 Q-Learning 모델은 파이썬(python)을 이용하여 구현하였고 심층신경망 모델의 경우 텐서플로우(tensorflow) 라이브러리를 이용하였다. AR 애플리케이션은 AR 기능과 3D 객체 사용을 위해 유니티를 이용하여 구현하였다. 그리고 블루투스, 진동 등과 같은 안드로이드 네이티브 기능을 사용하기 위해 안드로이드 스튜디오를 이용하여 플러그인을 제작하였다. 사용자의 위치를 추정하기 위해 그림 6과 같은 구조의 실제 환경에서 RSSI 데이터를 수집하였다.

건물의 코너 부분을 10개의 가로 3m, 세로 3m 정사각형 셀로 구역을 나누어 라벨링을 수행하였고 6개의 비콘을 배치하였다. 각각의 셀에서 6개의 비콘으로부터 받은 RSSI 데이터를 수집하였으며 수집한 데이터는  $t=10$ 으로 슬라이딩하여 EWMA 필터에 통과시키고 마지막에 측정된 값을 심층신경망 모델의 입력 데이터로 사용하였다. 각각의 입력 데이터에 대한 출력 값은 RSSI 데이터를 수집한 셀이 되도록 설정하여 심층신경망 모델이 입력된 RSSI 데이터를 통해 사용자가 위치한 셀을 추정할 수 있도록 학습시킨다. 심층

신경망 모델 학습에 사용한 파라미터는 표 2와 같다. 데이터는 모델을 학습시키기 위한 학습 데이터와 모델의 성능을 확인하기 위한 테스트 데이터로 분류하여 사용하였다. 학습 데이터는 4107개, 테스트 데이터는 1028개를 사용하였다. 학습 데이터와 테스트 데이터는 어떤 특정한 환경에서 학습시킨 심층 신경망이 신호에 영향을 주는 건물 내부 환경이 달라졌을 때 예측이 원활하게 이루어지는지에 대해 확인하기 위해서 다른 시간대에 데이터를 추출하였다. 심층신경망 모델에는 5개의 은닉 층을 사용하였고 각각의 노드 수는 64개로 설정하였다. 모델의 손실함수로는 Cross-entropy를 사용하였으며 최종적인 출력을 위해서는 One-hot encoding을 이용하였다. 활성 함수로는 SELU를 이용하였으며 손실함수를 최소화하기 위한 최적화 방법으로는 Adam optimization을 사용하였다.

심층신경망 모델의 입력인 RSSI 데이터에 EWMA 필터를 적용하기 전과 후에 대한 성능을 확인하기 위해서 각각의 경우에 1000번의 학습을 진행했을 때 정확도를 확인하였다. 이때, 정확도는 심층 신경망에 RSSI 신호 값들을 입력했을 때 출력되는 값이 실제 사용자가 위치한 셀과 일치한 비율을 나타낸다. 표 3은 이에 대한 결과이고 그림 7은 EWMA 필터를 사용한 모델의 학습 그래프이다.

EWMA 필터를 적용하기 전에는 테스트 데이터에 대한 결과가 70.37%, 적용한 뒤에는 83.33%로 정확도가 약 13%p 증가한 것을 확인할 수 있다. 이는 EWMA 필터를 이용한 심층신경망 모델이 RSSI 신호의 잡음과 데이터 추출 시간대에 대한 영향을 덜 받고





그림 6. 심층신경망 학습을 위한 환경  
Fig. 6. Environment for DNN learning

표 2. 심층신경망 파라미터  
Table 2. Parameter for DNN

Parameters	value
Number of cells $N_l$	10
Number of beacons $N_b$	6
Training data set	4107
Test data set	1028
Number of hidden layers	5
Number of nodes for each hidden layer	64
Activation Function	SELU
Weight Initializer	Xavier Initialization
Optimizer	Adam
Learning rate	0.0001
Epoch	1000

표 3. 심층신경망 학습 결과  
Table 3. DNN learning results

	Without EWMA Filter	With EWMA Filter
Training data Accuracy	97.95%	98.66%
Test data Accuracy	70.37%	83.33%



(a) Accuracy (b) Cost

그림 7. EWMA Filter 적용 후 심층신경망 학습 결과  
Fig. 7. DNN Learning results after EWMA filtering

사용자의 위치를 더 높은 정확도로 추정할 수 있다는 것을 보여준다.

최적 대피 경로를 산출하는 Q-Learning 모델을 구현하였다. Q-Learning 모델의 환경은 3개의 층을 1층부터 각각 43, 41, 41개의 셀로 구분하였으며 그림 8은 1층과 3층에 대한 환경을 나타낸 것이다.

2층은 3층과 같은 구조를 갖도록 설정하였다. 그림의 하늘색 셀은 길을 나타내며 셀의 채도가 어두워질수록 해당 셀에 인구 밀도가 높은 것을 의미한다. 빨간색 셀은 화재가 발생한 곳을 의미하고 초록색 셀은 계단, 노란색 셀은 탈출구, 보라색 셀은 사용자를 의미한다. Q-Learning에 사용된 파라미터는 표 4와 같다. 심층신경망 모델을 통해 사용자의 위치를 추정하면 해당 셀에서부터 출구까지 최적 경로를 산출하기 위한 Q-Learning 학습이 진행된다.

그림 9는 에피소드를 진행하면서 각 에피소드에서 얻어진 보상의 총합을 그래프로 나타낸 것이다. 보상의 총합을 구하는 수식은 수식 (4)와 같다.




그림 8. Q-Learning 학습을 위한 환경  
Fig. 8. Environment for Q-Learning

표 4. Q-Learning을 위한 파라미터  
Table 4. Parameters for Q-Learning

Parameters		Value
Population( $n$ )	$n_0$	5
	$n_1$	10
Rewards	Escape state	100
	Fire state	-100
	$-R_{min}$	-0.01
	$-f(n)$	$-n$
	$-R_{req}$	-10
Learning rate ( $\alpha$ )		0.3
Discount factor ( $\gamma$ )		0.95
Epsilon( $\epsilon$ )		0.1




그림 9. 에피소드 진행하면서 얻어진 보상의 총합  
Fig. 9. Sum of rewards during episode

$$Q(S_t, a_t) = R_1 + \gamma R_2 + \gamma^2 R_3 + \gamma^3 R_4 + \dots + \gamma^{n-1} R_n \quad (4)$$

수식 (4)는 임의의 시작점  $S_t$ 에서부터 에피소드가 종료될 때까지  $n$  단계를 진행하는 동안 받게 되는 보상의 총합을 의미한다. 보상은 discounted factor  $\gamma$ 에 의해 현재 받게 되는 보상이 높은 가중치를 갖고 미래의 보상은 낮은 가중치를 갖게 되는 것을 알 수 있다. 따라서 학습이 진행되는 초반에는 최단 시간이 소요되는 경로에 대한 학습이 충분히 진행되지 않았기 때문에 우회 경로를 선택하며 최종적으로 출구에서 받는 보상에도 불구하고 discounted factor에 의해 낮은 보상의 총합을 갖게 된다. 학습이 충분히 진행된 이후에도 중간 중간 보상의 총합이 낮아지는 것은 임의의 시작점이 출구와 거리가 멀거나  $\epsilon$ -greedy 알고리즘에 의한 탐험에 의해 출구까지  $n$ 이 커지며 받게 되는 보

상이 작아지기 때문이다.

마지막으로 사용자의 위치 추정을 위한 심층신경망 모델과 최적 대피 경로 산출을 위한 Q-Learning 모델을 연결하고 AR 내비게이션 시스템을 통해 사용자에게 최적 대피 경로를 제공하는 것을 확인하였다. 그림 10-12는 실제 상황에서 실내에 있는 사용자의 현재 위치를 파악하고 AR 내비게이션을 이용하여 탈출구까지 최적의 경로를 안내하는 과정을 보여준다. 실제로 화재를 발생시킬 수는 없었기 때문에 임의의 지점에서 화재가 발생하였다고 가정하고 시뮬레이션을 진행하였다.

그림 10은 3층에서 사용자가 AR 내비게이션 애플리케이션을 사용했을 때, 사용자의 정확한 위치를 확인하고 AR을 통해 사용자에게 최적의 대피 경로를 안내하는 것을 보여준다. 애플리케이션이 사용자의 현재 위치에서 가장 가까운 계단으로 경로를 안내하는 것을 확인할 수 있다.

그림 11은 3층에서 애플리케이션이 안내한 경로를 통해 2층으로 내려왔을 때의 상황을 보여준다. 사용자에게 가장 가까운 출구는 1층의 위쪽에 있는 출구이고 이를 이용하기 위해서는 가장 가까운 계단을 이용

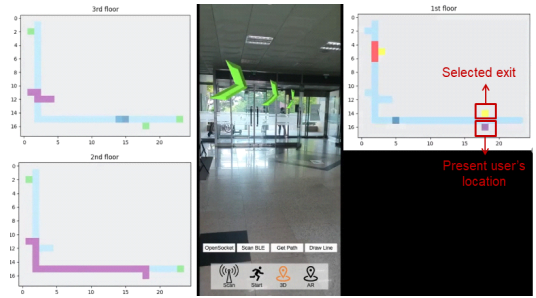


그림 12. 1층에서 강화학습 시뮬레이션과 AR 내비게이션  
Fig. 12. Reinforcement learning simulation and AR navigation on 1F

하여 그대로 내려가면 된다. 하지만 그 위치의 출구는 화재로 인해 막힌 상황이기 때문에 이를 피하기 위해 사용자는 1층 아래쪽에 있는 출구를 이용해야한다. 따라서 1층으로 내려가기 위한 경로 역시 현재 위치에서 가장 가까운 계단이 아니라 이용 가능한 출구에 가까운 계단으로 안내하는 것을 확인할 수 있다.

그림 12를 통해 최종적으로 애플리케이션이 사용자에게 출구를 성공적으로 안내한 모습을 확인할 수 있다.

#### IV. 결 론

본 논문에서는 실내 화재 상황에서의 최적 대피 경로를 안내하는 AR 시스템에 대해 제안하였다. 제안된 시스템은 심층신경망을 이용한 사용자 위치 추정 모델, Q-Learning을 이용한 최적 대피 경로 도출 모델, AR 대피 경로 제공 모델로 구분할 수 있다. 화재가 발생하여 사용자가 제안된 애플리케이션을 실행하면 주변 비콘 신호를 수신하여 RSSI 데이터를 서버로 전송한다. 서버는 이 정보를 미리 학습한 딥러닝 모델에 통과시켜 사용자의 위치를 결정한 후 보유한 환경정보를 반영한 최적 대피 경로를 Q-Learning을 통해 도출한다. 도출된 경로 정보는 다시 애플리케이션으로 전송되어 사용자에게 직관적인 AR 대피 경로로 제공한다. 제안된 시스템을 구현하기 위해 각각의 세부 모델들을 구현하여 최종적으로 전체 시스템의 동작을 확인하였다. 심층신경망 모델이 높은 정확도로 사용자의 위치를 추정하는 것을 확인하였고 Q-Learning 모델의 수렴을 확인하였으며 최종적으로 전체 시스템을 합치고 AR 내비게이션 모델을 통해 실제 상황에서도 제안된 시스템이 정상적으로 동작하여 사용자에게 최적 경로를 제공하는 것을 확인하였다. 향후 해당 시스템을 통해 화재로 인한 인명피해를 크게 줄일 수 있을



그림 10. 3층에서 강화학습 시뮬레이션과 AR 내비게이션  
Fig. 10. Reinforcement learning simulation and AR navigation on 3F



그림 11. 2층에서 강화학습 시뮬레이션과 AR 내비게이션  
Fig. 11. Reinforcement learning simulation and AR navigation on 2F



것으로 기대된다.

## References

- [1] R. Vancetti and S. Angelini, "Fire safety engineering: Evacuation management in emergency conditions," *Tema: Technol., Eng., Mater. and Architecture*, vol. 4, no. 1, pp. 127-136, 2018.
- [2] S. Sadowski and P. Spachos, "RSSI-Based indoor localization with the internet of things," *IEEE Access*, vol. 6, pp. 30149-30161, Jun. 2018.
- [3] D. Zhu, B. Zhao, and S. Wang, "Mobile target indoor tracking based on multi-direction weight position kalman filter," *Computer Netw.*, vol. 141, pp. 115-127, Aug. 2018.
- [4] G. Li, E. Geng, Z. Ye, Y. Xu, J. Lin, and Y. Pang, "Indoor positioning algorithm based on the improved RSSI distance model," *Sensors*, vol. 18, no. 9, Aug. 2018.
- [5] O. Chitsobhuk, K. Warunsin, and S. Udomthanapong, "Multidestination indoor navigation using path planning and wifi fingerprint localization," in *2018 3rd ICCCS*, pp. 406-410, Apr. 2018.
- [6] H. M. Noh, Y. J. Oh, N. Y. Lee, and W. J. Shin, "A survey of deep learning-assisted indoor localization with wi-fi fingerprinting: current status and research challenges," *J. KICS*, vol. 46, no. 5, pp. 848-862, May 2021.
- [7] A. Ammar, H. Bennaceur, I. Châari, A. Koubâa, and M. Alajlan, "Relaxed dijkstra and A\* with linear complexity for robot path planning problems in large-scale grid environments," *Soft Computing*, vol. 20, no. 10, pp. 4149-4171, Jul. 2016.
- [8] A. Khan, A. A. Aesha, J. S. Aka, S. F. Rahman, and M. J. U. Rahman, "An IoT based intelligent fire evacuation System," in *2018 21st ICCIT*, pp. 1-6, Dec. 2018.
- [9] Y. J. Choi, J. H. Kwon, H. J. Na, and S. J. Yoo, "Q-Learning based dynamic routing protocol with low latency and high reliability for medical data collection system using body area networks," *J. KICS*, vol. 44, no. 11, pp. 2090-2101, Nov. 2019.
- [10] S. A. Wu, M. H. Kwon, J. Y. Kim, and Y. A. Shin, "Deep reinforcement learning for mode optimization in RF-Powered backscatter cognitive radio networks," *J. KICS*, vol. 46, no. 2, pp. 246-256, Feb. 2021.
- [11] M. Zhao, H. Lu, S. Yang, and F. Guo, "The experience-memory q-learning algorithm for robot path planning in unknown environment," *IEEE Access*, vol. 8, pp. 47824-47844, Mar. 2020.
- [12] Y. H. Kong and W. C. Lee, "Dynamic obstacle avoidance and optimal path finding algorithm for mobile robot using q-learning," *The J. Korean Inst. Inf. Technol.*, vol. 15, no. 9, pp. 57-62, Sep. 2017.
- [13] K. S. Park, J. M. Park, W. K. Yun, and S. J. Yoo, "DQN reinforcement learning: The robot's optimum path navigation in dynamic environments for smart factory," *J. KICS*, vol. 44, no. 12, pp. 2269-2279, Dec. 2019.
- [14] S. J. Choi and M. H. Kim, "A study on efficient rolling stock HBD monitoring method using EWMA technique," *J. Korea Academia-Ind. Cooper. Soc.*, vol. 18, no. 1, pp. 609-617, Jan. 2017.
- [15] M. A. Hossen and S. J. Yoo, "Q-Learning based multi-objective clustering algorithm for cognitive radio ad hoc networks," *IEEE Access*, vol. 7, pp. 181959-181971, Dec. 2019.
- [16] Q. Yang, S. J. Jang, and S. J. Yoo, "Q-learning-based fuzzy logic for multi-objective routing algorithm in flying ad hoc networks," *Wireless Pers. Commun.*, pp. 1-24, Jan. 2020.
- [17] S. H. Choi and S. J. Yoo, "Q-Learning based optimal escape route decision in a disaster environment," *J. KICS*, vol. 46, no. 4, pp. 638-650, Apr. 2021.
- [18] J. Yan, H. He, X. Zhong, and Y. Tang, "Q-Learning-Based vulnerability analysis of smart grid against sequential topology attacks," *IEEE Trans. Inf. Forensics and Secur.*, vol. 12, no. 1, pp. 200-210, Apr. 2016.
- [19] J. E. Park and H. S. Lee, "A case study on

the use of augmented reality for consumer experience marketing in commercial spaces,” *J. Korean Inst. Interior Design*, vol. 30, no. 2, pp. 120-131, Apr. 2021.


- [20] H. S. Kim, J. W. Kam, and S. S. Hwang, “An evaluation system to determine the completeness of a space map obtained by visual SLAM,” *J. Korea Multimedia Soc.*, vol. 22, no. 4, pp. 417-423, Apr. 2019.
- [21] J. Neira, A. J. Davison, and J. J. Leonard, “Guest editorial special issue on visual SLAM,” *IEEE Trans. Robotics*, vol. 24, no. 5, pp. 929-931, Sep. 2008.

**조 용 준 (Yong-Jun Jo)**



2015~현재: 인하대학교 정보통신공학과 (학사 재학)  
 <관심분야> 통신 소프트웨어, 머신러닝

**박 성 용 (Seong-Yong Park)**



2016~현재: 인하대학교 정보통신공학과 (학사 재학)  
 <관심분야> 네트워크, 소프트웨어 개발, AR, 정보보호

**윤 성 호 (Seong-Ho Youn)**



2016~현재: 인하대학교 정보통신공학과 (학사 재학)  
 <관심분야> 네트워크, 통신 인프라, 머신러닝, 소프트웨어 개발

**최 승 희 (Seung-Hee Choi)**



2020년 2월: 인하대학교 정보통신공학과 학사 졸업  
 2019년 2월~현재: 인하대학교 전기컴퓨터공학과 석사  
 <관심분야> 이동통신, IoT, 무선 센서 네트워크, 머신러닝, 강화학습

**유 상 조 (Sang-Jo Yoo)**



1988년 2월: 한양대학교 전자통신학과 (공학사)  
 1990년 2월: 한국과학기술원 전기및전자공학과 (공학석사)  
 2000년 8월: 한국과학기술원 전자전산학과 (공학박사)  
 1990년 3월~2001년 2월: KT 연구 개발 본부

1990년 3월~2000년 11월: NIST(미국 표준기술연구원) 초빙연구원

2001년 3월~현재: 인하대학교 정보통신공학과 교수  
 <관심분야> 무선 네트워킹 프로토콜, Cross-layer 프로토콜 설계, Cognitive Radio Network, 무선센서네트워크, 미래인터넷

[ORCID:0000-0003-1533-0814]