



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

工學碩士 學位論文

APCW 기반의 라디오맵 생성  
네트워크에 관한 연구

A Study on Radiomap Generation  
Network based on APCW

The seal of Korea Maritime & Ocean University is a circular emblem. It features a central stylized 'M' shape above a book, with the year '1945' below. The outer ring contains the university's name in Korean '한국해양대학교' and English 'KOREA MARITIME & OCEAN UNIVERSITY'.

指導教授 徐 東 煥

2020年 8月

韓國海洋大學校 大學院

電氣電子工學科

太 壽 鎬

本 論文을 太壽鎬 工學碩士 學位論文으로 認准함

委員長：工學博士 金 載 熏 ㉠

委 員：工學博士 徐 東 煥 ㉠

委 員：工學博士 朱 良 翊 ㉠

2020年 7月

韓國海洋大學校 大學院

# 목 차

목 차 .....	i
그림 및 표 목차 .....	ii
Abstract .....	iv
제 1 장 서 론 .....	01
제 2 장 관련이론 .....	04
2.1 Fingerprint .....	04
2.2 Deep Neural Network(DNN) .....	07
2.3 Conditional Generative Adversarial Nets(CGAN) .....	10
제 3 장 제안한 라디오맵 생성 방법 .....	13
3.1 APCW 기반의 RGN .....	13
3.2 AP-Centered Window(APCW) .....	15
3.3 Radiomap Generation Network(RGN) .....	20
제 4 장 실험 및 결과 .....	25
4.1 실험환경 .....	26
4.2 실험결과 .....	28
4.2.1 APCW의 크기에 따른 RGN의 Radiomap 생성 정확도 .....	28
4.2.2 APCW 기반 RGN의 특성분석 .....	31
제 5 장 결 론 .....	40
참 고 문 헌 .....	41

# 그림 및 표 목차

## <그림목차>

그림 2.1	Fingerprint의 흐름도 .....	04
그림 2.2	심층신경망 .....	07
그림 2.3	CGAN의 구조 .....	10
그림 3.1	APCW 기반 Radiomap 생성 Network의 구조도 .....	13
그림 3.2	Localization Domain의 구조 .....	15
그림 3.3	APCW 생성과정과 구조 .....	18
그림 3.4	APCW 기반 Radiomap 생성 Network의 구조 .....	20
그림 3.5	예측된 Radiomap의 구조 .....	22
그림 3.6	Generating Phase의 Radiomap 생성 과정 .....	24
그림 4.1	실험환경 .....	26
그림 4.2	APCW의 크기에 따른 RGN의 Epoch당 학습시간 .....	28
그림 4.3	APCW의 크기에 따른 평균 제공근 오차 .....	29
그림 4.4	모델별 Radiomap 생성 결과 .....	33
그림 4.5	모델의 Weight Vector .....	35
그림 4.6	4층 데이터를 학습한 RGN의 Radiomap 생성 결과 .....	37
그림 4.7	3층과 4층의 데이터를 학습한 RGN의 Radiomap 생성 결과 .....	38

<표 목 차>

표 3.1 장애물의 종류에 따른 Cell의 속성 ..... 16

표 3.2 Radiomap 생성 Network의 Layer 및 입출력 크기 ..... 21

표 4.1 각 모델의 정의 및 세부사항 ..... 31

표 4.2 모델별 Radiomap 생성 정확도 ..... 34



# APCW 기반의 라디오맵 생성 네트워크에 관한 연구

태 수 호

대한민국, 부산  
한국해양대학교 대학원  
전기전자공학과

## 초록

Wi-Fi 기반 실내 위치인식에서 대표적인 기법인 Fingerprint는 AP의 고유정보인 Service Set Identifier(SSID)와 수신기에서 측정된 신호 세기인 Received Signal Strength Indication(RSSI)로 구성된 Radiomap을 기반으로 사용자의 위치를 인식한다. 최근 건물의 대형화로 인해 Location based Service(LBS)를 적용하는 공간이 확장됨에 따라 RSSI를 수집하는 범위가 넓어졌으며, 이로 인해 사람이 직접 측정하는 Radiomap 구축의 비용은 크게 증가하고 있다. 또한 건물 구조가 다양해지기 때문에 기존의 전파모델 기반 Radiomap 생성 기법은 적용하기 어렵다. 따라서 본 논문에서는 Fingerprint의 구축비용을 줄이며 건물 구조로 인한 왜란에 강건한 생성 네트워크를 위해 AP-Centered Window(APCW)와 Conditional Generative Adversarial Nets(CGAN) 기반 Radiomap Generation Network(RGN)를 제안한다. 제안하는 APCW는 건물의 구조를 2차원으로 나타낸 데이터로써, 핵심적인 건물 구조인 벽의 종류를 분류하여 재질적 특성을 고려하고 AP 중심으로 Region of Interest(ROI)를 설정하여 생성에 왜란이 되는 데이터를 제거한다. 또한 RGN은 APCW를 Label로 사용하기 위해 CGAN을 기반으로 설계하고 Non-Line of Sight(NLOS)에서 신호가 전파되는 범위를 특정할 수

없기 때문에 Fully connected network를 통해 생성 및 판별하는 네트워크로 구성된다. 이를 통해 제안하는 네트워크는 생성 시에 외란이 되는 Wi-Fi 신호의 음영지역 데이터를 억제하여 Radiomap 생성의 정확도를 높인다. 그리고 네트워크는 입력하는 공간적 구조의 AP 위치를 고정하며 CGAN을 통해 각 재질적 특성까지 고려함으로써 건물의 일부영역이 변형되어도 RSSI의 재측정 없이 Radiomap을 구축할 수 있다. 그래서 Fingerprint 기반 LBS의 고질적 문제인 구축비용을 줄일 수 있다. 제안하는 네트워크의 타당성 및 우수성을 검증하기 위해 실제 건물의 Wi-Fi 신호를 수집하여 Radiomap을 만들었으며 한 층의 데이터만을 학습하여 학습되지 않은 층의 Radiomap을 예측하였다. Radiomap 생성 결과의 평균 제곱 오차는 4.01 dBm으로 가장 우수한 성능을 보였다.





# A Study on Radiomap Generation Network based on APCW

*by Soo Ho, Tae*

Department of Electrical & Electronics Engineering  
Graduate School of Korea Maritime & Ocean University  
Busan, Republic of Korea

## **Abstract**

Fingerprint, a representative technique in Wi-Fi-based indoor location recognition, recognizes the user's location based on a Radiomap composed of Service Set Identifier (SSID), which is unique information of AP, and Received Signal Strength Indication (RSSI), which is signal strength measured by the receiver. do. As the space for applying Location Based Service (LBS) has expanded due to the recent enlargement of buildings, the range of collecting RSSI has also expanded, and for this reason, the cost of constructing a radiomap directly measured by humans is increasing significantly. In addition, since the structure of the building is diversified, it is difficult to apply the existing radiomap-based radiomap generation technique. Therefore, in this paper, we propose a Radiomap Generation Network (RGN) based on AP-Centered Window (APCW) and Conditional Generative Adversarial Nets (CGAN) for a generation network that reduces the construction cost of fingerprints and is robust against disturbances caused by building structures. The proposed APCW is data showing the structure of a building in two dimensions, and it is data that is disturbed by classifying the type of wall, which is a core building

structure, considering the material characteristics, and setting the Region of Interest (ROI) around the AP. Remove. In addition, RGN is designed based on CGAN in order to use APCW as a label, and it is composed of a network that is created and determined through a fully connected network because the range of signal propagation in Non-Line of Sight (NLOS) cannot be specified. Through this, the proposed network increases the accuracy of radiomap generation by suppressing the shadow area data of the Wi-Fi signal, which becomes disturbing during generation. In addition, the network fixes the location of the AP of the spatial structure to be input, and considers the characteristics of each material through the CGAN, so that even if a partial area of the building is deformed, a Radiomap can be constructed without re-measurement of RSSI. So, it is possible to reduce the construction cost, a chronic problem of fingerprint-based LBS. In order to verify the validity and excellence of the proposed network, a radiomap was created by collecting Wi-Fi signals of an actual building, and the radiomap of an untrained floor was predicted by learning only the data of one floor. The mean square error of the radiomap generation result was 4.01 dBm, showing the best performance.

## 제 1 장 서 론

최근 Wi-Fi, UWB, BLE 등의 무선통신 기술이 실내 위치인식기법에 활용되고 있다[1-3]. 이중 Wi-Fi 기반의 Fingerprint는 다른 무선통신기술에 비해 송신범위가 넓고 보급률이 높아 인프라 구축비용이 적은 장점이 있다[4-6]. 또한 사용자의 위치를 인식하기 위해서 스마트폰을 Wi-Fi 신호의 수신기로 사용할 수 있기 때문에 가장 많이 연구되고 있다.

Fingerprint는 Wi-Fi에서 방사된 신호세기인 Received Signal Strength Indicator(RSSI)를 바탕으로 사용자의 위치를 인식한다. 따라서 Fingerprint는 실내위치인식을 적용하는 서비스 공간에서 RSSI를 수집하고 이를 통해 데이터베이스인 Radiomap을 생성하는 Offline Phase와 스마트폰에서 수집되는 RSSI와 Radiomap의 RSSI를 비교하여 사용자의 위치를 추정하는 Online Phase로 구성된다. Radiomap을 생성하기 위한 Offline Phase에서는 우선 실내공간에서 Reference Point(RP)라 불리는 일정한 간격의 위치들을 설정한다. 이 간격은 신호의 세기가 AP를 중심으로 멀어질수록 감소하기 때문에 각각의 RP에서 측정되는 RSSI를 구분할 수 있도록 설정한다. 일반적으로 Wi-Fi의 신호를 이용하는 Fingerprint에서는 RP의 간격을 2~3m의 간격으로 설정한다[7-9]. 이렇게 구분된 각각의 RP에서 측정되는 Wi-Fi AP들의 RSSI를 수집한 뒤 Radiomap을 생성한다. Online Phase는 Offline Phase에서 생성된 Radiomap과 실시간으로 측정되는 사용자의 RSSI들의 유사도를 기반으로 위치를 추정하기 때문에 확률 또는 결정론적 알고리즘들이 많이 적용된다[9,10].

따라서 Fingerprint에서는 사용자의 위치를 인식하기 위한 Radiomap이 필수적이며 가장 기본적인 Radiomap 구축방법은 모든 RP에서 측정되는 AP들의 RSSI를 일정한 시간동안 수집 회 이상 측정하는 Point-by-Point Calibration이다[11]. 하지만 이러한 방법은 건물의 대형화로 인해 RP의 수가 증가하여 RSSI를 수집

하는 시간 및 인적비용이 크게 증가하고 있다. 이를 해결하기 위해 직접 측정 방법, 비측정 방법, Semi-측정 방법의 Radiomap 생성 방법이 연구되고 있다 [7,12-15].


직접 측정 방법은 설정된 경로를 이동하면서 수집되는 관성센서의 신호를 통해 사용자의 RP를 추정하고 이를 기반으로 RP의 위치 및 Wi-Fi 신호세기를 매칭하여 Radiomap을 생성한다. 하지만 관성센서는 측정시간이 증가함에 따라 신호의 잡음 및 적분 오차로 인해 Drift현상이 일어난다[16]. 따라서 직접 측정 방식은 Radiomap 구축비용을 크게 줄일 수 있지만 실제 사용자의 위치와 관성센서의 신호를 기반으로 추정된 위치의 오차로 인해 위치인식 정확도가 낮아진다. 비측정 방법은 Wi-Fi의 전파 모델을 설계하고 이를 통해 장애물 및 거리에 따른 RSSI를 예측함으로써 Radiomap을 생성한다. 이는 RSSI를 수집하는 과정 없이 Radiomap 구축이 가능하지만 장애물을 구성하는 재질 및 형태에 따라서 전파세기에 미치는 영향력이 다르기 때문에 정확한 전파의 반사 및 흡수 계수 등의 물리 계수에 대한 분석이 필요하다.

Semi-측정 방법은 연산처리장치의 비약적인 발전으로 인해 Neural Network를 이용한 Radiomap 생성 방법이다. Chen의 연구는 적대적 학습기반 네트워크를 이용하여 일부 RP에서만 수집된 RSSI를 통해 전체 RP의 RSSI를 예측하는 RSSI 데이터 증강기를 제안하였다[17]. 하지만 제안하는 증강기는 RSSI를 수집하는 구조 및 공간에 대해 고려하지 않았기 때문에 RSSI를 측정하는 환경에 의존적이다. Seong의 연구는 건물에서 한 층의 RSSI를 수집하고 Autoencoder와 GAN을 이용하여 다른 층의 RSSI를 예측함으로써 층별 구조가 유사한 건물에서 Radiomap을 구축하는 비용을 크게 줄였다[18]. 하지만 장애물의 유무만을 고려한 데이터를 GAN에 입력해 주기 때문에 전파가 장애물의 재질로 인해 발생할 수 있는 왜곡을 예측하기 어렵다. 또한 다른 구조의 건물에서는 학습된 네트워크를 적용할 수 없기 때문에 건물마다 RSSI 데이터의 수집이 필수적이다.

이와 같이 Radiomap 구축비용을 줄이기 위한 연구가 진행되고 있으나 RSSI를 예측하기 위한 실내구조와 RSSI 데이터베이스에 대한 표준이 없기 때문에 하나의 건물을 대상으로 Radiomap을 구축하는 방법이 대부분이다. 따라서 향후

에는 건물마다 구축된 전파측정 데이터베이스가 많으면 수집된 데이터베이스를 여러 건물에 활용할 수 있는 연구가 필수적이다.

따라서 본 논문에서는 건물이 달라져도 Radiomap을 생성할 수 있도록 AP 주변의 장애물을 데이터화하여 RSSI를 예측 할 수 있게 설계된 AP-Centered Window(APCW)와 이를 기반으로 Radiomap을 생성하는 Radiomap Generation Network(RGN)을 제안한다. APCW는 AP 주변의 장애물에 따른 RSSI 변화를 고려하기 위해서 실내공간을 데이터화하고 이를 AP를 중심으로 RSSI의 예측에 필요한 영역만을 분할하여 생성된다. 이를 통해 APCW를 사용하여 학습된 RGN은 전파가 도달하지 않는 영역으로 인한 잡음에 강인하며 APCW에 포함되는 건물 구조의 패턴에 따라 변하는 Radiomap을 생성할 수 있다. 또한 본 논문에서 설계된 APCW와 이와 동일한 구조의 RSSI로 구성된 데이터베이스를 구축한다면 향후 건물마다 RSSI를 수집해야하는 비용문제를 해결할 수 있다.



## 제 2 장 관 련 이 론

### 2.1 Fingerprint

그림 2.1은 일반적인 Fingerprint의 흐름도를 나타낸다. Fingerprint 알고리즘은 Radiomap을 생성하는 Offline Phase와 실시간 위치를 인식하는 Online Phase로 구성된다. Offline Phase는 Radiomap을 생성하기 위해 3단계의 과정으로 나누어진다. 첫 번째는 사용자의 위치를 인식하고 위하여 위치인식을 적용하는 공간에서 2~3m의 일정한 간격으로 RP를 설정한다. 두 번째는 설정된 모든 RP에서 AP들의 RSSI를 측정한다[7-9]. 마지막으로 수집된 AP들의 Service Set Identifier(SSID) 및 RSSI를 사용하여 Radiomap을 구축한다.

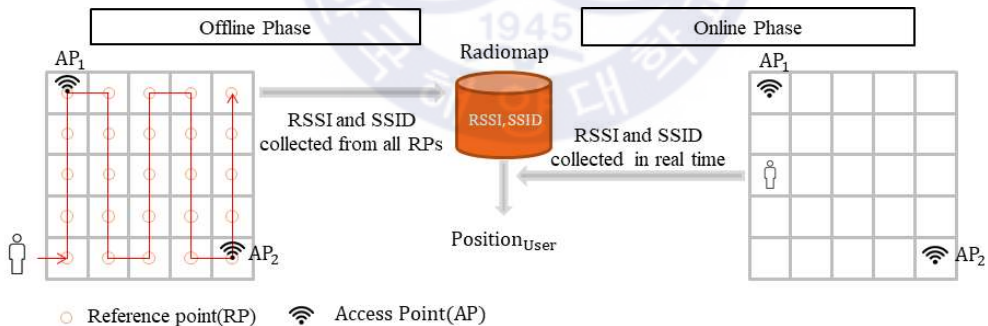


그림 2.1 Fingerprint의 흐름도

Fig 2.1 Flowchart of Fingerprint

이때 AP에서 방사된 전파세기는 수신기와 송신기 사이의 상대적인 거리 및 주변 장애물 등에 의해 잡음이 포함된다. 이러한 잡음을 제거하기 위해 각각의 RP에서 측정되는 RSSI들은 평균 등의 전처리를 통해 Radiomap에 저장된다. 식 (2.1)은 Offline Phase에서 구축된 Radiomap의 구조를 나타낸다. x축은 RP를, y축은 AP를 나타내며  $RSSI_{SSID(i)RP(j)}$ 는  $j$ 번째 RP에서 측정되는  $i$ 번째 AP의 RSSI들의 평균을 의미한다.

$$Radiomap = \begin{bmatrix} RSSI_{SSID1}(RP1) & RSSI_{SSID1}(RP2) & \cdots & RSSI_{SSID1}(RPn) \\ RSSI_{SSID2}(RP1) & RSSI_{SSID2}(RP2) & \cdots & RSSI_{SSID2}(RPn) \\ \vdots & \vdots & \ddots & \vdots \\ RSSI_{SSIDn}(RP1) & RSSI_{SSIDn}(RP2) & \cdots & RSSI_{SSIDn}(RPn) \end{bmatrix} \quad (2.1)$$

Online Phase에서는 Offline Phase에서 구축된 Radiomap과 실시간으로 측정되는 AP 신호를 기반으로 사용자의 위치를 추정한다. 이때 실시간으로 측정된 RSSI와 Radiomap에 저장된 RSSI의 유사도가 가장 높은 RP를 사용자의 위치로 추정한다. 유사도를 기반으로 위치를 추정하기 때문에 Offline Phase에서는 확률 또는 결정론적 알고리즘들이 많이 적용된다[9,10]. 이 중 사용자의 위치를 실시간으로 인식하기 위해서 다른 알고리즘에 비해 연산이 복잡하지 않은 Euclidean Distance(ED) 알고리즘이 많이 사용되며 이는 식 (2.2)와 같다.

$$P_{User} = \min \left( \sqrt{\sum_{j=1}^n (RSSI_j - RSSI_{real})^2} \right) \quad (2.2)$$

여기서  $P_{User}$ 는 예측된 사용자의 위치,  $n$ 은 Radiomap에 저장된 RP의 수를,  $RSSI_{real}$ 은 실시간으로 측정된 RSSI를,  $RSSI_j$ 는 Radiomap의  $j$ 번째 RP에 저장된 RSSI를 의미한다. ED는 실시간으로 측정되는 RSSI와 Radiomap에 저장된 모든 RP의 RSSI의 차를 구하는 알고리즘으로 RSSI들의 분포가 유사할수록 ED의 결과 값이 작아진다. 따라서 각각의 RP에서 계산된 ED 값들 중에 최솟값을 가지



는 RP가 사용자의 위치이다. 이러한 과정을 통해 사용자의 위치를 인식하는 Fingerprint는 오직 RP로만 사용자의 위치를 표현 가능하다. 따라서 RP를 설정한 간격에 따라 위치인식 성능이 결정되기 때문에 RP 사이의 간격이 좁을수록 높은 측위 정확도를 얻을 수 있다. 하지만 RP 사이의 간격이 좁아지면 일정한 공간상에서 설정되는 RP의 수가 증가하기 때문에 Radiomap을 구축하는 시간 및 인적 비용이 크게 증가한다. 이러한 이유로 Radiomap 구축비용을 줄이기 위한 연구가 Fingerprint의 Offline Phase에 집중되어 있으며 Online Phase에 비해 다양하다.





## 2.2 Deep Neural Network(DNN)

인간의 신경망을 모방한 Neural Network는 데이터의 분포 및 경향성을 학습하고 이를 통해 예측 및 판단하는 기능을 수행한다[19,20]. 하지만 Neural Network는 입력된 데이터를 기반으로 하여 수많은 매개 변수와의 연산을 통해 결과를 도출하기 때문에 연산량과 학습시간이 많이 요구된다. 최근 연산처리 장치의 성능이 극대화 되면서 Neural Network를 이용한 연구가 활발히 진행되었다. 그림 2.2는 대표적인 Neural Network인 DNN(Deep Neural Network)를 나타내며 Input Layer, Hidden Layer, Output Layer 순으로 구성된다.

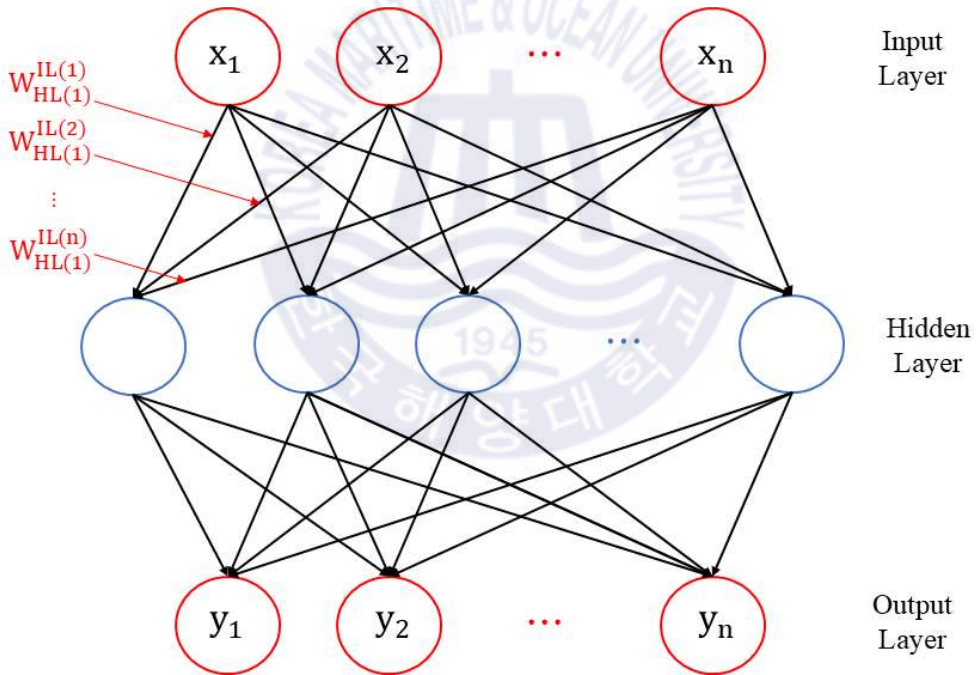


그림 2.2 심층신경망

Fig 2.2 Deep Neural Network

여기서 Input Layer는 데이터가 입력되는 Node, Output Layer는 결과가 출력되는 Node이다. 또한 Hidden Layer는 Input Layer에 입력된 데이터를 기반으로 Output Layer에서 출력되는 결과를 생성하는 Multi-Layer Perceptron이다[21]. 각각의 Layer는 다음 Layer와 가중치로 구성된 Weight Vector로 연결되어 있다. Input Layer에 데이터가 입력되면 Input Layer와 Hidden Layer의 사이에 연결된 가중치를 곱하고 다음 Node로 전달한다. 이후 Hidden Layer를 구성하는 각각의 Node는 Input Layer에서 전달된 수치들을 합하고 활성화 함수를 통해 다음 Layer의 전달여부를 결정한다. Input Layer에 입력된 데이터가 다음 Layer에 전달하는 과정은 식 (2.3)과 같다.

$$Out^k = \sum_{i=1}^n x_i \times w_{HL(k)}^{IL(i)} + b_k \quad (2.3)$$

여기서  $Out^k$ 는 Hidden Layer를 구성하는  $k$ 번째 Node의 출력을 나타내며,  $n$ 는 Input Layer를 구성하는 Node의 수를,  $x_i$ 는 Input Layer의  $i$ 번째 Node에서 입력된 데이터를,  $w_{HL(k)}^{IL(i)}$ 는 Input Layer의  $i$ 번째 Node에서 Hidden Layer의  $k$ 번째 Node와 연결된 가중치를 나타내며  $b_k$ 는 Hidden Layer의  $k$ 번째 Node의 바이어스를 나타낸다. 또한 식 (2.3)의 결과는 활성화 함수를 통해 다음 Layer의 전달여부를 결정된다. 활성화 함수는 XOR와 같은 비선형적인 문제를 해결하기 위해 적용되며 대표적으로 Sigmoid와 Tanh가 있다[22,23]. 하지만 Sigmoid와 Tanh 함수의 출력은 입력 값의 크기와 상관없이 항상 일정한 범위내의 출력을 가지기 때문에 Neural Network를 구성하는 Layer의 층이 많아지면 학습이 되지 않는 Gradient Descent 소실 문제가 있다[24]. 이러한 문제를 해결 위해 연구된 활성화함수인 Rectified Linear Unit(ReLU)는 식 (2.4)와 같다[25].

$$\begin{aligned} ReLU(Out^k) &= Max(0, Out^k) \\ &= \begin{cases} Out^k & (Out^k \geq 0) \\ 0 & (Out^k < 0) \end{cases} \end{aligned} \quad (2.4)$$

여기서  $Out^k$ 는 활성화함수에 입력된 Layer의 출력을 나타내고  $Out^k$ 가 0보다 이상이면  $Out^k$ 가 출력되고  $Out^k$ 가 0보다 작은 경우에는 0의 값이 출력된다. 따라서 3층 이상의 Layer를 가지는 DNN은 입력 값에 비례하여 출력의 크기가 결정되는 ReLU를 활성화 함수로 많이 사용한다. 이러한 과정을 통해 Input Layer에 입력된 데이터는 이러한 과정을 반복하여 Output Layer에서 결과로 출력된다. 또한 일반적으로 DNN은 Gradient Descent 소실문제를 해결하기 위해 Hidden Layer의 활성화 함수로 ReLU를 사용하고 Output Layer에서는 정확도를 높이기 위해 Sigmoid 등의 활성화 함수를 사용한다.



### 2.3 Conditional Generative Adversarial Nets(CGAN)

적대적 학습 기반 Neural Network는 모델링 기법만으로 예측하기 어려운 실제 데이터의 분포를 학습하고 이를 모방한 데이터를 생성하는 네트워크이다 [26,27]. Conditional Generative Adversarial Nets(CGAN)은 실제데이터의 분포를 학습하기 위한 Training Phase와 학습된 네트워크를 이용하여 데이터를 생성하는 Generating Phase로 나누어진다. 그림 2.3은 데이터를 생성하는 Generator와 Generator의 성능을 평가하기 위한 Discriminator로 구성되는 CGAN의 구조를 나타낸다. 여기서 Real Data는 Generator가 모방하여 생성하고자 하는 실제 데이터인 Ground truth로 실측을 통해 얻은 데이터이다.

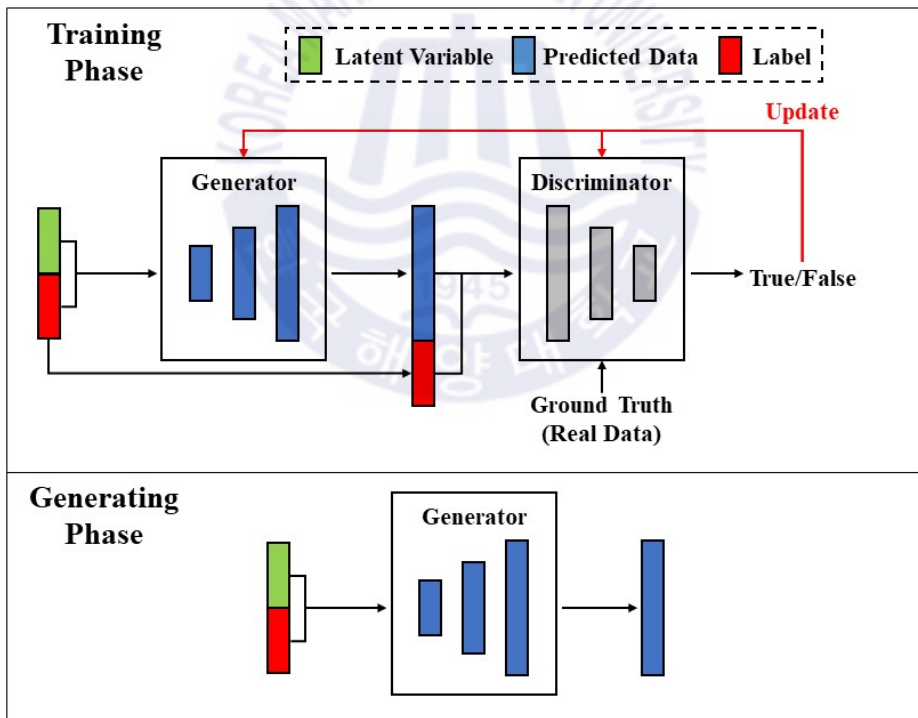


그림 2.3 CGAN의 구조

Fig 2.3 The Architecture of CGAN

Generator가 Real Data와 유사한 데이터를 생성하기 위해서는 우선 Real Data의 분포를 학습해야 한다. Training Phase에서 Generator의 학습 과정은 3단계로 구성되며 다음과 같다. 첫 번째, Generator는 Latent Variable과 Label을 입력 받아 Real Data를 모방한 데이터를 생성한다. 이때 Generator에서 출력된 데이터는 Predicted Data라고 부를 수 있다. Latent Variable은 평균이 0이고 표준편차가 1인 정규분포를 따르는 랜덤 변수로써 Real Data의 분포를 학습하기 위해 사용된다. 또한 Label은 Predicted Data를 생성하기 위한 조건으로 Real Data의 클래스와 같은 보조정보를 나타낸다. 두 번째, Discriminator는 Predicted Data가 Real Data와 유사한지 판별한다. 이때 Discriminator는 유사하다고 판별하면 참을, 유사하지 않다고 판별하면 거짓을 출력한다. 따라서 Discriminator에서 참이 출력되면 Generator의 생성 성능이 Discriminator의 판별 성능보다 높은 것을, 거짓이 출력되면 Generator의 생성 성능이 Discriminator의 판별 성능보다 성능이 낮은 것을 의미한다. 마지막으로 Discriminator의 판별 결과에 따라 Generator와 Discriminator를 학습을 진행하며 학습을 위한 각각의 손실함수는 식 (2.5), 식 (2.6)과 같다.

$$L_G(z, y) = E[\log(D(G(z)|y))] \quad (2.5)$$

$$L_D(z, y, x) = E[\log(D(x|y))] + E[\log(1 - D(G(z)|y))] \quad (2.6)$$

여기서  $z$ 는 Latent Variable을,  $G$ 와  $D$ 는 각각 Generator와 Discriminator의 출력,  $x$ 는 Real Data를,  $y$ 는 Label을 나타낸다. CGAN의 목적은 실제와 구별이 불가능한 수준의 Predicted Data를 생성하는 것이기 때문에 Generator의 손실함수  $L_G$ 를 최소화하며 Discriminator의 손실함수  $L_D$ 를 최대화하는 방향으로 학습을 진행한다. Generating Phase에서 CGAN은 Real Data의 분포와 유사한 Predicted Data를 생성하는 것이 목적이기 때문에 Generator의 성능을 평가하는 Discriminator가 필요 없다. 따라서 CGAN에서 Discriminator는 제거되고

Generator만을 사용하여 Predicted Data를 생성한다. 이때 Generator에 입력되는 Label을 조작함으로써 원하는 클래스의 Predicted Data를 생성할 수 있다.



## 제 3 장 제안한 Radiomap 생성 방법

### 3.1 APCW 기반의 RGN

제안한 AP-Centered Window(APCW) 기반의 Radiomap Generation Network(RGN)은 CGAN과 동일하게 Training Phase와 Generating Phase로 구성되며 그림 3.1과 같다.

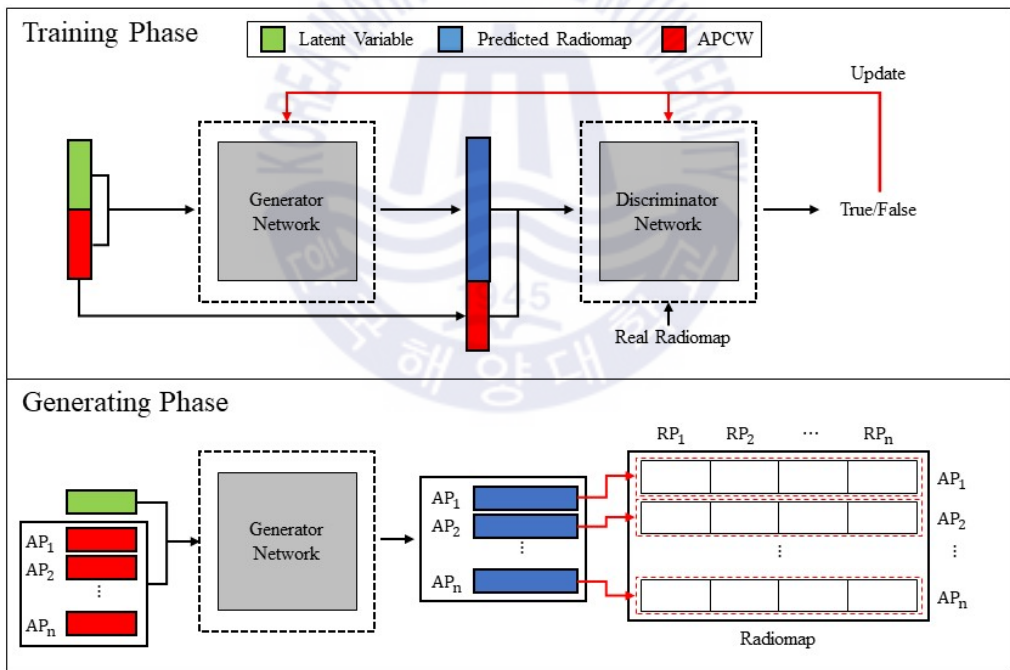


그림 3.1 APCW 기반 Radiomap 생성 Network의 구조도

Fig 3.1 The Architecture of APCW based Radiomap Generation Network

Training phase에서는 평균이 0이고 표준편차가 1인 정규분포를 따르는 랜덤 변수인 Latent Variable과 Label로서 제안한 APCW가 Generator에 입력된다. Generator에서는 Predicted Data인 Predicted Radiomap이 생성되며 이는 APCW와 결합하여 Discriminator의 입력으로 사용된다. 이러한 과정을 통해 손실함수인 식 (2.5)와 식 (2.6)의 반복 연산으로 Generator의 학습이 이루어진다. 마지막으로 Generating Phase는 학습된 Generator를 통해 AP의 RSSI를 예측하고 이를 통해 Radiomap을 생성한다. 이때 Generator는 한 번의 동작으로 한 AP의 Radiomap을 생성할 수 있기 때문에  $L$ 에 존재하는 AP의 개수만큼 동작하여 전체 Radiomap을 구축한다. 다음 장에서는 실내 환경을 고려한 APCW와 RSSI를 예측할 수 있는 RGN 구조에 대하여 자세히 설명한다.





### 3.2 AP-Centered Window(APCW)

Radiomap을 생성하기 위해서는 실내 구조, 수신 거리 등과 같은 물리적 환경과 학습을 위한 RGN의 입력구조에 대한 고려가 필수적이다. 이를 위해 우리는 실내 공간을 데이터화하고 AP를 중심으로 분할된 정방형 데이터인 APCW를 제안한다. 그림 3.2는 실내 공간 전체를 2차원 데이터화한 Localization Domain을 나타낸다.

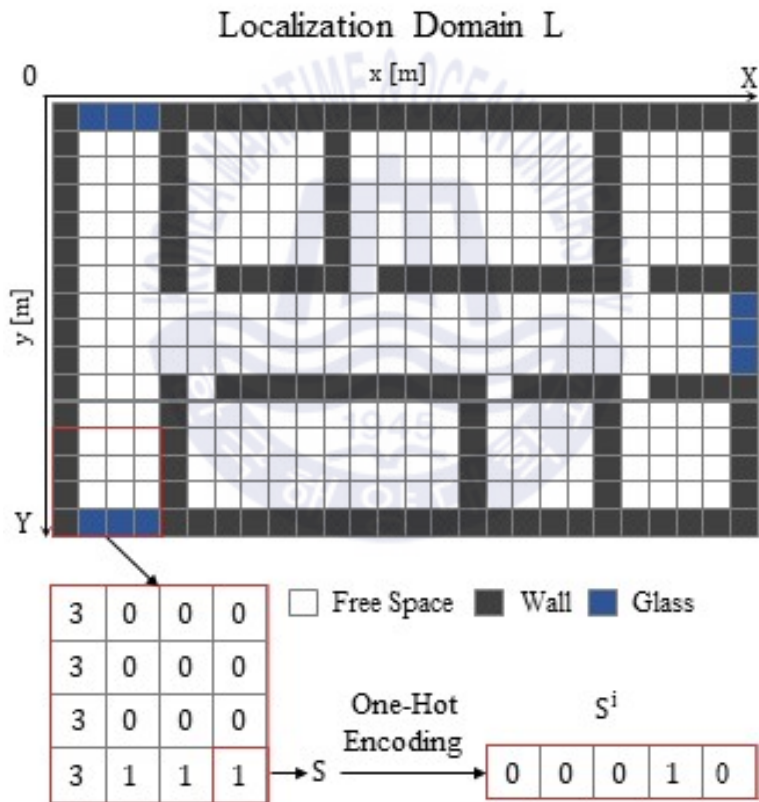


그림 3.2 Localization Domain의 구조

Fig 3.2 The Structure of Localization Domain

여기서  $X$ ,  $Y$ 축은 공간적 거리를 나타내며 Localization Domain  $L$ 은 일정한 공간을 나타내는 Cell들의 집합으로 구성된다. 각 Cell은 Wi-Fi RP의 간격인  $3m \times 3m$ 이내에서 RSSI에 영향을 줄 수 있는 장애물 크기와 실험에 사용한 연산처리장치의 컴퓨팅 파워를 고려하여  $1m \times 1m$ 로 설정하였다. 따라서 하나의 Cell에는 하나의 공간 정보  $S$ 만을 포함하며  $L$ 은 식 (3.1) 같이 표현할 수 있다.

$$L = \{S_{(1,1)}, S_{(2,1)}, \dots, S_{(X,Y)}\} \quad (3.1)$$

여기서, 공간정보  $S$ 는  $L$ 의 임의의  $X$ ,  $Y$ 좌표에 존재하는 장애물에 따라 하나의 Index값을 가진다. 표 3.1은 이러한 장애물의 종류에 따른  $S$ 의 인덱스 값을 나타낸다. 여기서 Index 0은 AP의 신호를 측정하지 못하거나 건물 밖의 공간을 표현하기 위해 설정하였다. 이러한  $L$ 을 생성함으로써 2차원 실내 공간을 연산 처리가 가능한 데이터로 변환할 수 있다. 하지만 이러한 생성방법은 하나의 Cell에 2개 이상의 Index가 포함 될 수 있다. 이는 Neural Network 기반 학습 알고리즘은 분류된 각 Index들의 전파의 물리계수들을 명확하게 분류하고 학습하기 어렵다. 따라서 이러한 문제를 해결하기 위해  $L$ 을 One-Hot Encoding을 통해 벡터화 함으로써 하나의 Index가 Input Layer의 Node에 입력되게 설계한다.

표 3.1 장애물의 종류에 따른 Cell의 속성

Table 3.1 Cell Properties According to Obstacle Material

Index $i$	Object	Material	One-Hot Vector $S^i$
0	Inaccessible Space	-	{0,0,0,0,0,1}
1	Free Space	Vacuum	{0,0,0,0,1,0}
2	Glass Wall	Glass	{0,0,0,1,0,0}
3	Concrete Wall with Window	Concrete, Glass	{0,0,1,0,0,0}
4	Concrete Wall	Concrete	{0,1,0,0,0,0}
5	Concrete Wall with Iron Door	Concrete, Iron	{1,0,0,0,0,0}

식 (3.2)은  $L$ 을 벡터화한  $L_{one-hot}$ 을 나타낸다.

$$L_{one-hot} = \{S_{(1,1)}^i, S_{(2,1)}^i, \dots, S_{(X,Y)}^i\}$$

$$S_{(X,Y)}^i = \begin{cases} 0,0,0,0,0,1 & \text{if } i = 0 \\ 0,0,0,0,1,0 & \text{if } i = 1 \\ 0,0,0,1,0,0 & \text{if } i = 2 \\ 0,0,1,0,0,0 & \text{if } i = 3 \\ 0,1,0,0,0,0 & \text{if } i = 4 \\ 1,0,0,0,0,0 & \text{if } i = 5 \end{cases} \quad (3.2)$$

여기서, 벡터정보  $S_{X,Y}^i$ 는  $L$ 의 임의의  $X, Y$ 좌표에 존재하는  $S$ 의 Index  $i$ 에 따른 One-Hot Vector 값을 가진다. 이를 통해 이를 통해 RSSI에 영향을 주는 건물의 구조 및 위치 정보를 포함하는 Label의 기본 구조를 생성할 수 있다. 하지만 이러한 구조는 건물의 전체를 2차원화 시킨  $L$ 이기 때문에 부분적으로  $L$ 을 분할하여 사용하기 어렵다. 이는 동일한 구조와 장애물 특성을 가진 건물에서만 Radiomap을 생성할 수 있으며, AP의 RSSI가 측정되지 않는 음영지역도 함께 학습 Network에 입력으로 사용되기 때문에 불필요한 Network의 연산과 높은 RSSI의 예측 오차가 발생한다. 따라서 건물의 크기와 형태의 변화에 강건하며 음영지역으로 인한 잡음문제를 해결하기 위하여 APCW를 제안한다. 제안한 APCW는  $L_{one-hot}$ 에서 실제 학습이 필요한 RSSI가 측정되는 AP 위치를 중심으로 정방형의 Window를 Label로 분할되어 재생성된다. 여기서, 분할된 Label의 수는  $L$  내의 AP 수에 따라 Window의 개수가 결정된다. 일반적으로 AP를 중심으로 RSSI가 측정되는 수신거리가 결정되기 때문에 Window의 중심은 AP의 위치로 설정하였으며, AP를 중심으로 분할되는 거리는 APCW의 크기에 따른 Generator에서 생성된 Radiomap과 실제 Radiomap의 유사도 실험을 바탕으로 실내 환경에 최적화된 정방형의 크기를 결정한다. 그림 3.3은  $L_{one-hot}$ 에서 서로 다른 두 위치의 AP를 중심으로 생성된 APCW들을 나타낸다.

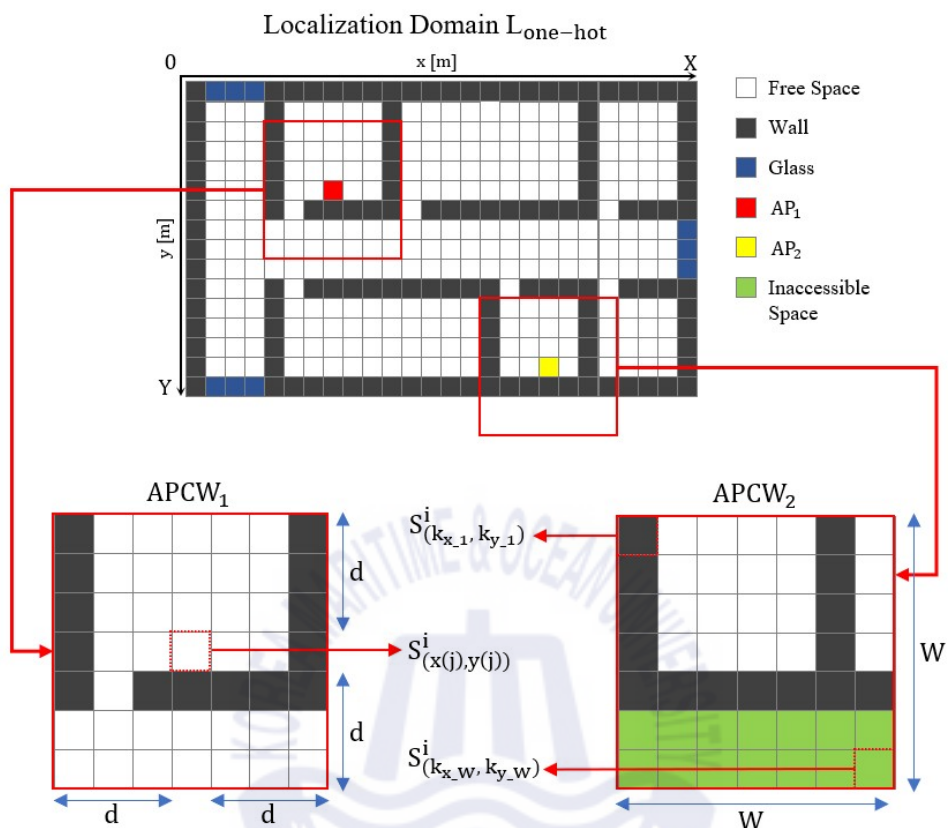


그림 3.3 APCW 생성과정과 구조

Fig 3.3 APCW Generation Process and Structure of APCW

이때, 하나의 AP에서는 하나의 APCW가 생성되고 한 AP를 중심으로 분할된 APCW는 식 (3.3)로 표현된다.

$$APCW_j = \{S_{(k_{x_1}, k_{y_1})}^i, S_{(k_{x_1}+1, k_{y_1})}^i, \dots, S_{(k_{x_W}, k_{y_W})}^i\}$$

$$k_{x_1} = x(j) - d, k_{y_1} = y(j) - d, k_{x_W} = x(j) + d, k_{y_W} = y(j) + d \quad (3.3)$$

여기서,  $x(j)$ 는  $j$ 번째 AP의 X축 좌표를,  $y(j)$ 도 동일한 AP의 Y축 좌표를,  $d$ 는 AP를 중심으로 분할되는 거리를,  $k_{x_1}$ ,  $k_{y_1}$ 는 각각 X, Y축의 첫 좌표를,

$k_{x_w}$ ,  $k_{y_w}$ 는 각각 X, Y축의 끝 좌표를 나타낸다. 따라서 생성된  $APCW_j$ 는  $W \times W$ 개의 Cell로 구성되며 하나의 AP를 중심으로 주변  $d$ 만큼 떨어진 공간의 장애물 정보를 획득할 수 있다. 이때  $APCW_j$ 는 AP를 기준으로 생성되기 때문에 AP의 위치에 대한 정보를 별도로 입력하지 않는다. 따라서 APCW의 중심에는 Free Space를 나타내는 Index정보를 입력할 수 있다. 이는 AP의 위치 정보를 나타내기 위한 Index를 추가하지 않아도 되기 때문에 Network의 연산을 줄일 수 있다.  $APCW_j$ 는 이를 통해 Network는 장애물의 재질과 구조적 특징을 고려한 Label을 입력 받을 수 있으며, AP 중심으로 관심영역을 생성함으로써 건물의 전체 구조에 대한 과적합을 막을 수 있다.



### 3.3 Radiomap Generation Network(RGN)

제안하는 RGN는 CGAN 기반으로 Generator 및 Discriminator를 설계하였으며 Generator는 Radiomap을 생성하기 위한 Label로써 APCW 기반 입출력 구조를 사용한다. 그림 3.4는 Fully Connected(FC) Layer 기반의 Generator와 Discriminator로 구성되는 RGN의 구조를 나타낸다.

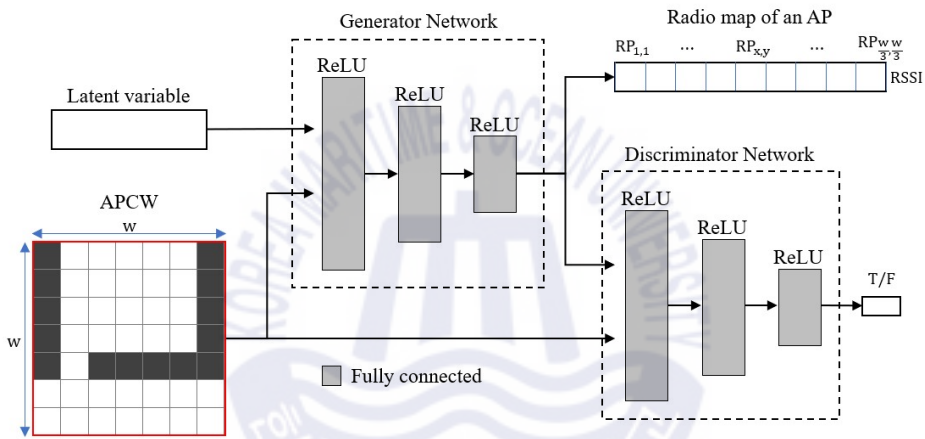


그림 3.4 APCW 기반 Radiomap 생성 Network의 구조

Fig 3.4 The Structure of APCW based Radiomap Generation Network

Generator의 입력은 실제 Radiomap의 분포를 학습하기 위한 Latent Variable  $z$  와 APCW이다. 일반적으로 CGAN의 Generator는 고정된 Size의 Convolution 또는 Transposed Convolution을 사용한다. 하지만  $L$ 에 있는 모든 AP들을 중심으로 주변 장애물들에 의해 왜곡되는 RSSI의 측정 가능한 거리가 불규칙하기 때문에 동일한 Size를 적용하기 어렵다. 따라서 APCW를 구성하는 모든 성분을 Generator의 Input Layer에 연결하기 위해서  $z$ 와 APCW가 결합된 입력은 ReLU를 활성화함수로 가지는 3개의 Fully Connected Network로 처리된다. FC는

Convolution Layer에 비해 특징을 추출하는 성능이 떨어지기 때문에 Generator의 첫 번째 Layer의 Size는 APCW의 구조적 특징을 많이 추출하기 얻기 위해 APCW보다 크게 설정하였다. 또한 첫 번째 Layer에서 추출된 특징을 바탕으로 RSSI를 예측하기 위해서 두 번째, 세 번째 Layer의 Size는 점차 작아지게 설정하였다. 동일한 이유로 Discriminator도 3개의 Fully Connected Network로 구성되며 Discriminator의 경우에는 판별에 목적을 두기 때문에 별도의 특징 추출을 위한 Layer의 확장이 필요 없다. 따라서 Discriminator의 Layer는 점차 작아지게 설정하였다. 표 3.2는 설계된 Generator와 Discriminator의 Layer 종류와 활성화 함수 그리고 입출력 Size를 나타낸다.

표 3.2 Radiomap 생성 Network의 Layer 및 입출력 크기

Table 3.2 Layer and Input/output Size of Radiomap Generation Network

Network	Layer	Activation Function	Input Size	Output Size
Generator	FC	ReLU	$z_n + W^2 \times i_n$	$2 \times W^2$
	FC	ReLU	$2 \times W^2$	$W^2 \div 3$
	FC	ReLU	$W^2 \div 3$	$W^2 \div 9$
Discriminator	FC	ReLU	$W^2 \div 9 + W^2 \times i_n$	$W^2 \div 9$
	FC	ReLU	$W^2 \div 9$	$W^2 \div 27$
	FC	ReLU	$W^2 \div 27$	1

여기서  $z_n$ 는 Latent Variable의 크기를,  $W^2$ 은 APCW의 크기를,  $i_n$ 은 APCW를 생성하는 Index의 개수를 나타낸다. RGN이 동작하기 위해서는 Generator와 Discriminator의 입출력 크기를 정확하게 설정하는 것이 중요하다. 따라서 Generator의 입력 크기는  $z$ 와 APCW의 크기를 더한  $z_n + W^2 \times i_n$ 로 설정하였다. 또한 Discriminator의 목적은 Generator에서 생성된 Radiomap이 실제 Radiomap과 유사한지 판별하는 것이기 때문에 Discriminator의 출력크기는 참 또는 거짓이 출력되도록 1로 설정하였다. Generator에서 출력되는 각각의 성분은 일반적으로 Fingerprint에서 RSSI를 측정하는 간격이  $3m \times 3m$ 인 것과 동일하게 설정하였다.



따라서 APCW를 구성하는 각 성분이  $1m \times 1m$  공간을 나타내기 때문에 APCW와 Generator에서 출력되는 Radiomap의 가로 및 세로의 크기는 3대 1의 비율을 갖는다. 따라서 APCW의 가로 및 세로의 크기는 최소  $3m$  이상으로 설정해야 한다. 이때 Generator가  $APCW_j$ 를 생성조건으로 입력받아 출력한 Radiomap을  $Predicted Radiomap_j$ 으로 정의한다. 그림 3.5는 Generator가  $APCW_j$ 와  $z$ 를 입력으로 사용하여 출력한  $Predicted Radiomap_j$ 의 구조를 나타낸다.

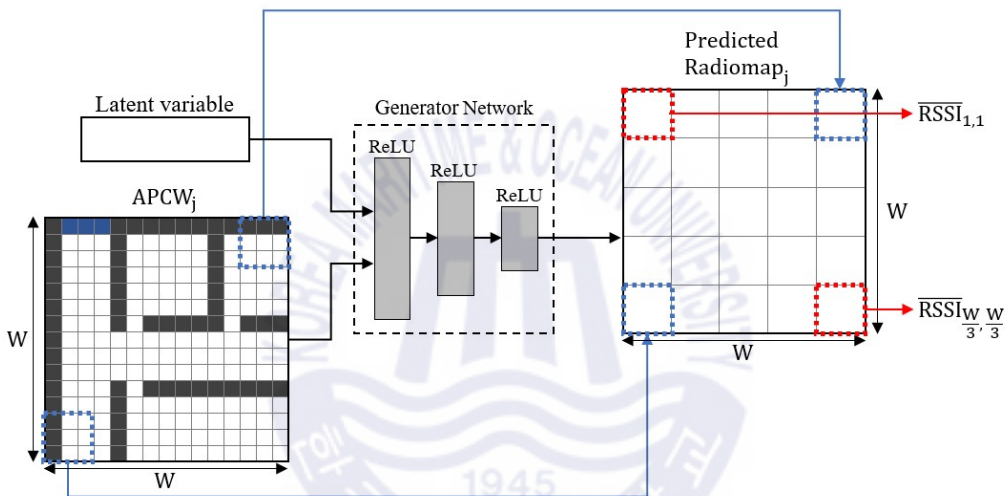


그림 3.5 예측된 Radiomap의 구조

Fig 3.5 The Structure of Predicted Radiomap

여기서  $W$ 는 정방행렬인 APCW의 대각성분의 크기를 나타낸다.  $Predicted Radiomap_j$ 를 구성하는 각각의 Cell은 Generator에 입력된  $APCW_j$ 에서  $3m \times 3m$  영역에 대한 RSSI를 예측한다. 따라서  $Predicted Radiomap_j$ 은  $\frac{W}{3} \times \frac{W}{3}$ 개의 Cell로 구성된다. Generator는 APCW를 입력으로 사용하여 실제 수집된 RSSI와 유사한 결과를 출력되게 학습을 해야 한다. 따라서 학습을 위한 Real Data인  $Real Radiomap_j$ 은 Generator가 정확한  $Predicted Radiomap_j$ 를 생성하기 위해 매우 중요하다. 정확한 RSSI의 비교를 위해서  $Real Radiomap_j$ 의 형태는  $Predicted$



$Radiomap_j$ 와 동일하게 설정하였고  $Real Radiomap_j$ 에서 해당 AP의 RSSI가 측정되지 않는 RP는 연산을 위해  $-100\text{dBm}$ 으로 설정한다. 또한 이렇게 생성된  $Real Radiomap_j$ 은 Network의 학습속도를 높이기 위해  $0\sim 1$  사이의 값으로 정규화된다. 이 정규화 과정은 식 (3.4)와 같다.

$$\overline{RSSI}_{(x,y)} = \begin{cases} RSSI_{(x,y)} - RSSI_{\min} \\ RSSI_{\max} - RSSI_{\min} \end{cases} \quad (3.4)$$

여기서  $\overline{RSSI}_{(x,y)}$ 는 임의의  $x, y$ 에서 측정된 RSSI인  $RSSI_{(x,y)}$ 가 정규화를 통해 변환된 수치를 나타낸다.  $RSSI_{\min}$ 은  $Real Radiomap_j$ 에서 RSSI의 최솟값인  $-100\text{dBm}$ 을,  $RSSI_{\max}$ 은 수집된 RSSI의 최댓값을 나타내며 정규화 값이 점점 작아질수록 신호세기는 크다. 따라서 Generator는 정규화된  $\overline{RSSI}$  데이터셋을 통해 학습하기 때문에  $0\sim 1$ 의 값의 출력을 가진다. 제안한 RGN은 Generator에서 임의의 한 AP의  $Predicted Radiomap_j$ 이 출력되고 Discriminator는 이  $Predicted Radiomap_j$ 과  $Real Radiomap_j$ 의 비교를 통해 두 Radiomap의 유사도가 출력된다. 이러한 CGAN 기반 Network는 적대적 학습을 위해 Generator와 Discriminator에 각각 다른 손실함수를 적용하며 이는 식 (3.5)와 식 (3.6)과 같다.

$$L_G(z, L^j) = E[\log(D(G(z)|L^j))] \quad (3.5)$$

$$L_D(z, L^j, R^j) = E[\log(D(R^j|L^j))] + E[\log(1 - D(G(z)|L^j))] \quad (3.6)$$

여기서  $z$ 는 Latent Variable를,  $G$ 와  $D$ 는 각각 Generator와 Discriminator의 출력을,  $R^j$ 는  $j$ 번째 AP의 실제 Radiomap을 나타낸다.  $L^j$ 는  $j$ 번째 AP의 APCW를 말한다. 제안하는 RGN는 실제와 구별이 불가능한 수준의 정확도를 가지는 Radiomap을 생성하는 것이기 때문에 Generator의 손실함수  $L_G$ 를 최소화하며 Discriminator의 손실함수  $L_D$ 를 최대화되게 학습한다. 이러한 학습 과정의 반복

을 통해 Generator의 출력인  $PredictedRadiomap_j$ 는 점차  $RealRadiomap_j$ 와 유사해진다. 학습이 끝나고 Generating Phase에서는 Generator는 한 번의 동작으로 한 AP의 Radiomap을 생성할 수 있다. 따라서 Generating Phase에서는 AP 각각의 Radiomap을 생성하고 이를 결합하여 하나의 Radiomap으로 구축한다. 그림 3.6은 Generating Phase에서 Radiomap을 구축하는 과정을 나타낸다.

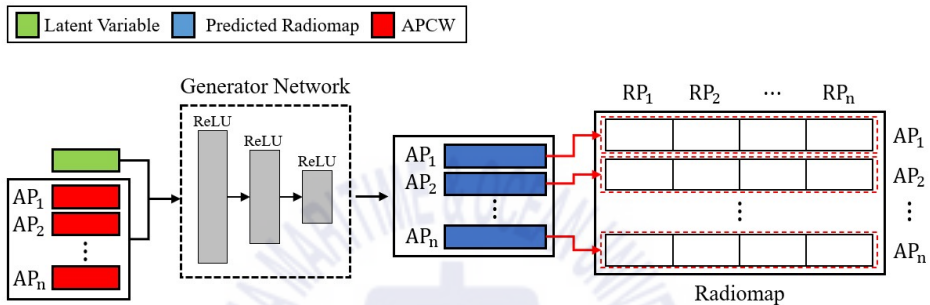


그림 3.6 Generating Phase의 Radiomap 생성 과정

Fig 3.6 Radiomap Construction Process in the Generating Phase

여기서  $AP_n$ 은 AP의 수를,  $RP_n$ 는 RP의 수를 나타낸다. 이때 Generator의 출력은 0~1의 값이기 때문에 역 정규화를 통해 스케일을 맞추고 Radiomap에 입력된다.

## 4. 실험 및 결과

본 논문에서는 제안하는 APCW 기반의 RGN의 Network를 분석하기 위해 2가지 실험을 진행하였다. 첫 번째 실험에서는 우선, APCW의 크기에 따라 변하는 RGN의 Radiomap 생성 정확도를 확인하기 위해 동일한 AP의 위치에서 서로 다른 크기로 설정된 APCW들을 생성한다. 이 APCW들을 RGN에 입력하여 Radiomap들을 생성한다. 마지막으로, 생성된 Radiomap들과 실제 Radiomap들 각각의 RMSE를 계산하고 APCW의 크기에 따른 RMSE들을 비교한다. 두 번째 실험은 APCW를 생성할 때, 장애물의 종류를 고려하는 방법과 이를 AP를 중심으로 분할하는 방법에 따라 변하는 RGN의 Radiomap 생성 정확도를 확인하기 위해 서로 다른 4개의 모델을 설계하고 각 모델의 Radiomap 생성 정확도들을 비교하였다. RGN의 Radiomap 생성 정확도를 평가하기 위한 지표는 Root Mean Square Error(RMSE)와 Histogram을 사용하였다[28,29]. RMSE는 서로 다른 두 데이터의 유사도를 평가하기 위해 데이터를 구성하는 각 성분들의 거리의 평균을 구한다. 이때 두 데이터의 분포가 유사하다면 RMSE의 값이 작아진다. 따라서 RGN에서 생성된 Radiomap과 실제 Radiomap의 RMSE의 값이 작을수록 RGN의 Radiomap 생성 정확도가 높다. 또한 Histogram은 데이터를 구성하는 성분의 크기와 크기에 빈도수로 나타내는데 이는 데이터의 분포를 직관적으로 확인할 수 있다. 실험에 사용된 AP 및 RP의 수가 많아 모든 결과를 확인하기 어렵기 때문에 이러한 결과를 통계적으로 분석하기 위해 Histogram을 사용하였다.

#### 4.1. 실험환경

실험은 그림 4.1과 같이  $82m \times 32m$  크기의 한국해양대학교 미음 캠퍼스 2, 3, 4층에서 실험을 진행하였으며, 실내공간에는 RSSI에 영향을 주는 장애물(예: 콘크리트벽, 창문 있는 콘크리트벽 등)이 있어 다양한 NLOS환경에 대한 실험을 진행할 수 있다.

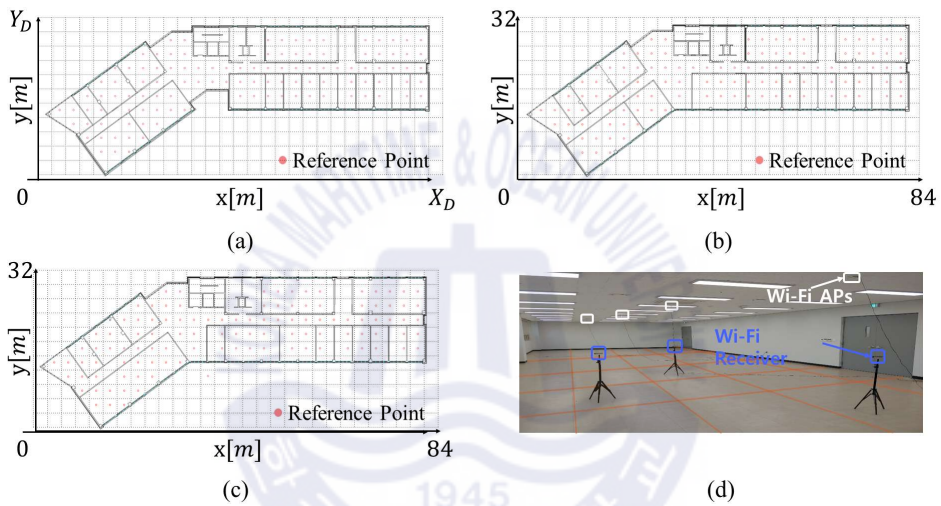


그림 4.1 실험환경

(a)2층의 구조 (b)3층의 구조 (c)4층의 구조 (d)AP 및 수신기

Fig 4.1 Experiment Environment

(a)Structure of 2nd Floor (b)Structure of 3rd Floor (c)Structure of 4th Floor (d)AP and Receiver

또한 각 층은 건물의 중심부에서 구조적으로 차이를 보이며 좌측과 우측의 경우 동일한 구조를 나타낸다. AP가 설치된 위치에 따라서 변하는 RSSI를 수집하기 위해 RP는 3m간격으로 설정하였고 각각의 RP에 AP를 설치한 뒤 SSID 및 RSSI를 수집하였다. 측정방법은 임의의 RP에 AP를 설치하고 모든 RP에서 측정되는 RSSI 신호를 수집하였다. 또한 2, 3, 4층의 경우, 각각 111, 112, 110

개의 AP를 설치하였고 LG-V20 스마트폰 3대를 이용하여 Wi-Fi 신호를 수집하였다. 실험은 1주일간 진행하였으며, 하나의 RP에 3분 동안 200회의 신호를 수집하였다. 또한 검증에 위한 연산처리 장치(PC)는 Inter(R) Core(TM) CPU i5-9400F, 32GB Memory, Geforce RTX 2070, 500GB SSD and 2TB HD를 사용한다.



## 4.2. 실험결과

### 4.2.1 APCW의 크기에 따른 RGN의 Radiomap 생성 정확도

RSSI에 변화를 주는 장애물을 RGN에 입력하기 위한 APCW는  $L_{one-hot}$ 을 AP를 기준으로 일정한 범위까지 분할하여 생성된다. 따라서 APCW의 크기는 AP 주변의  $S^i$ 의 양으로 볼 수 있다. 이는 APCW의 크기가 너무 작으면  $S^i$ 가 부족해 RGN의 Radiomap 생성 정확도가 낮아질 수 있다. 이와 달리 APCW의 크기가 크다면  $S^i$ 가 충분하지만 데이터 크기의 증가로 인해 학습 시간이 증가할 수 있다. 따라서 APCW의 크기에 따른 RGN의 Radiomap 생성 정확도를 분석하기 위해 동일한 AP의 위치에서 서로 다른 크기로 설정된 APCW들을 생성하였다. 이를 RGN의 입력으로 사용하여 APCW의 크기에 따른 각각의 학습시간들을 비교하였다. 또한 각각의 APCW를 입력으로 사용하여 RGN이 생성된 Radiomap과 실제 Radiomap의 RMSE를 계산하여 얻은 APCW의 크기에 따른 RGN의 Radiomap 생성 정확도들을 비교하였다. 그림 4.2는 APCW의 크기를  $9m \times 9m$ 부터  $69m \times 69m$ 까지 증가시키면서 얻은 RGN의 Epoch당 학습시간을 나타낸다.

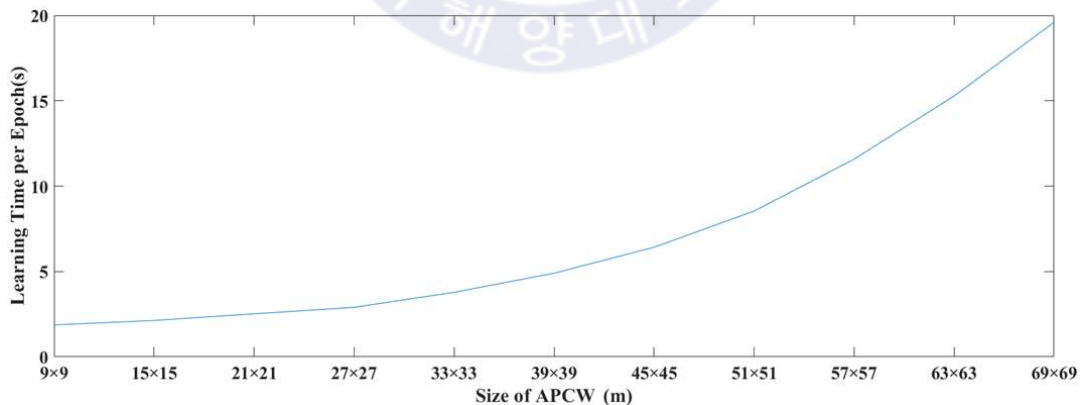


그림 4.2 APCW의 크기에 따른 RGN의 Epoch당 학습시간

Fig 4.2 Learning Time per Epoch According to The Size of APCW

여기서 X축은 APCW의 크기를, Y축은 Epoch 당 소요되는 학습시간을 나타낸다. 실험을 위한 APCW는 3m의 배수의 크기를 가지며 AP를 기준으로 정방형의 데이터이다. 따라서 APCW는  $(1+2n)3m \times (1+2n)3m$ 의 형태로 결정된다. 그림 4.2의 결과를 보면 RGN의 학습 시간은 APCW의 크기가 커질수록 제공의 형태로 증가하는 것을 확인하였다. 향후 여러 건물에서 수집된 데이터베이스가 확보되고 이를 이용하여 학습하는 경우에는 많은 시간이 요구된다. 따라서 APCW의 크기는 작을수록 효율적이다. 하지만 APCW의 크기가 작으면 RGN의 Radiomap 생성 정확도가 낮아질 수 있기 때문에 RGN의 학습 시간과 Radiomap 생성 정확도를 모두 고려해야한다. 그림 4.3은 APCW의 크기를 9m×9m부터 69m×69m까지 증가시키면서 얻은 생성된 Radiomap과 실제 Radiomap의 RMSE들을 나타낸다.

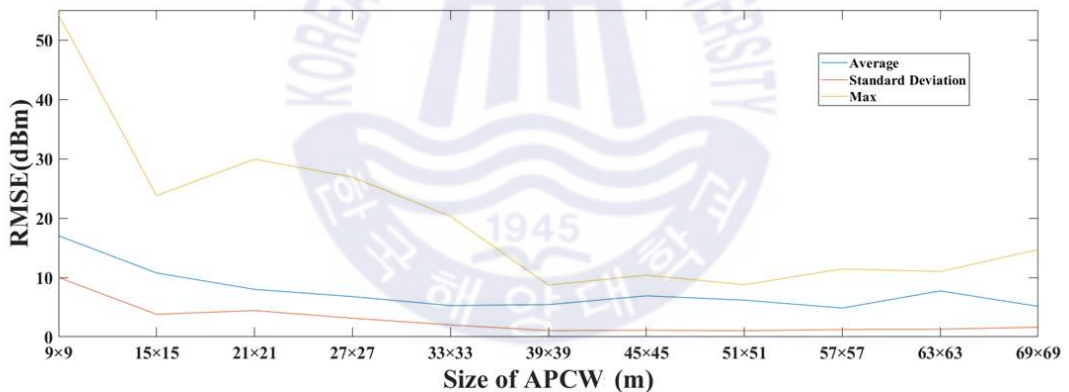


그림 4.3 APCW의 크기에 따른 평균 제공근 오차

Fig 4.3 RMSE According to The Size of APCW

여기서, X축은 APCW의 크기를, Y축은 RMSE를 나타낸다. 이때 Y축의 RMSE는 RGN의 성능을 통계적으로 분석하기 위해서 서로 다른 AP의 위치를 기준으로 얻은 Predicted Radiomap과 Real Radiomap의 RMSE를 계산하고 모든 RMSE들의 평균, 표준편차, 최댓값을 나타낸 것이다. APCW의 크기가 9m×9m에서 33m×33m까지 커질수록, RMSE들의 평균은 작아지는데 33m×33m보다



큰 경우에는 RMSE들의 평균값의 변화가 작다. RMSE의 값이 작을수록 RGN이 생성한 Radiomap이 실제 Radiomap과 유사한 것을 의미하기 때문에 APCW의 크기는  $33m \times 33m$ 에서 최적이다. 하지만 표준편차와 최댓값은 APCW의 크기가  $9m \times 9m$ 에서  $39m \times 39m$ 까지 감소하다가  $39m \times 39m$ 에서 최솟값을 가진다. Fingerprint는 실시간으로 수집된 RSSI 분포와 Radiomap에 저장된 RSSI 분포의 차가 클수록 위치인식 정확도가 낮아진다. 특히 AP 주변의 RSSI 분포 변화는 위치인식 정확도가 크게 감소한다. 따라서 평균값은 APCW의 크기가  $33m \times 33m$ 일 때 가장 작지만 표준편차 및 최댓값을 고려하면 APCW의 크기는  $39m \times 39m$ 가 최적이라 판단된다.





#### 4.2.2 APCW 기반 RGN의 특성분석

우리는 APCW를 생성할 때, 장애물의 형태 및 재질을 고려하는 것과 AP의 위치를 중심으로 생성하는 것을 제안하였다. 따라서 APCW를 생성할 때, 장애물의 종류를 고려하는 방법과 이를 AP를 중심으로 분할하는 방법에 따른 RGN의 Radiomap 생성 정확도들을 비교한다. 이를 위해 서로 다른 4개의 모델들을 설계하였고 표 4.1은 실험을 위해 설계된 모델의 정의, Layer(Activation Function)의 종류와 입출력의 크기를 나타낸다.


표 4.1 각 모델의 정의 및 세부사항

Table 4.1 Definition and Details of Each Model


Model	Defines	Network (Layer)	Input Size	Output Size
1	장애물의 유무를 고려한 Label을 사용하는 RGN	Generator (FC-ReLU)	$z + X_n \times Y_n$	$X_n \times Y_n \div 9$
		Discriminator (FC-ReLU)	$X_n \times Y_n \div 9 + X_n \times Y_n$	1
2	장애물의 재질을 고려한 Label을 사용하는 RGN	Generator (FC-ReLU)	$z + (X_n \times Y_n) \times i_n$	$X_n \times Y_n \div 9$
		Discriminator (FC-ReLU)	$X_n \times Y_n \div 9 + (X_n \times Y_n) \times i_n$	1
3	AP의 중심으로 생성된 Label을 사용하는 RGN	Generator (FC-ReLU)	$z + W^2$	$W^2 \div 9$
		Discriminator (FC-ReLU)	$W^2 + W^2 \div 9$	1
4	APCW를 사용하는 RGN	Generator (FC-ReLU)	$z + W^2 \times i_n$	$W^2 \div 9$
		Discriminator (FC-ReLU)	$W^2 \div 9 + W^2 \times i_n$	1

여기서,  $z$ 는 Latent Variable를,  $X_n$ 는 건물의 X축의 크기를,  $Y_n$ 는 건물의 Y축의 크기를,  $W^2$ 는 APCW의 크기를,  $i_n$ 은 Index의 수를 나타낸다. Generator는  $z$ 와  $1m \times 1m$ 를 기준으로 생성된 Label을 함께 입력 받아  $3m \times 3m$  기준의 Radiomap을 생성한다. 또한 Discriminator는 Generator에서 생성된 Radiomap과 Label을 함께 입력 받아 생성된 Radiomap이 실제 Radiomap과 유사한지 판별한다. 따라서 Generator와 Discriminator의 입력과 출력은 Label의 크기와 형태에 따라 결정된다. Model 1, 2, 3, 4는 각각 표 4.1에 Defines에 정의된 Label을 사용하며 Label은  $L = X_n \times Y_n$ ,  $L_{one-hot} = X_n \times Y_n$ ,  $L = W \times W$ ,  $L_{one-hot} = W \times W$ 이다. 따라서 사용되는 Label의 크기 및 형태에 따른 Generator 및 Discriminator의 입출력은 표 4.1의 Input Size와 Output Size와 같다. 이때 Model 1과 Model 2의 입력으로 사용되는 Label은 건물의 형태 및 크기를 고려하여  $82m \times 32m$ 로 설정하였고 Model 3과 Model 4의 입력으로 사용되는 Label의 크기는 4.2.1장의 실험 결과를 고려하여 가장 안정적인 결과를 보이는  $39m \times 39m$ 로 설정하였다. 또한 학습을 위한 각 모델의 파라미터는 다음과 같이 설정하였다. 또한 학습을 위해 각 모델의 파라미터를 Batch Size는 4000, Training Epoch는 1000, Learning Rate는 0.0001 으로 설정하였다.


그림 4.4는 각 모델이 하나의 AP에서 방사된 전파를 예측한 Radiomap을 나타낸다. (a)는 각 모델의 Radiomap 생성 정확도를 비교하기 위한 예측영역인 Region map이며 동일한 영역에서 모델들의 성능을 비교하기 위해 APCW의 크기와 동일하게 설정하였다. 빨간색 Cell은 AP의 위치를, 하얀색 Cell은 Free Space를, 검은색 Cell은 RSSI를 측정할 수 없는 위치를 나타낸다. (b)~(e)는 Model 1, 2, 3, 4 각각의 Radiomap 생성 결과를 나타낸다.




(a)




(b)



(c)



(d)



(e)

그림 4.4 모델별 Radiomap 생성 결과

(a)Region map (b)모델 1 (c)모델 2 (d)모델 3 (e)모델 4

Fig 4.4 Result of Radiomap Generation

(a)Regionmap (b)Model 1 (c)Model 2 (d)Model 3 (e)Model 4

Model 1과 Model 2의 결과와 Model 3와 Model 4의 결과를 보면 장애물의 재질을 고려한 경우가 Radiomap 생성 정확도가 크게 증가하는 것을 볼 수 있다. 또한 AP와의 거리를 고려한 Model 4의 결과를 보면 중심부에서 RSSI 예측 정확도가 높고 중심부에서 거리가 멀어질수록 점차 RSSI 예측 성능이 떨어지는 것을 확인하였다. 표 4.2는 모델의 Radiomap 생성 정확도를 통계적으로 분석하기 위해 서로 다른 110개의 위치에 설치된 AP를 통해 얻은 각 모델의 RMSE들의 평균, 최댓값, 최솟값을 나타낸다.

**표 4.2** 모델별 Radiomap 생성 정확도

**Table 4.2** Accuracy of Radiomap Generation for Each Model

Model	RMSE(dBm)		
	Average	Max	Min
1	28.84	37.84	22.71
2	5.48	7.06	4.1
3	14.98	24.4	6.35
4	4.01	6.43	2.26

Model 1과 Model 3의 결과를 보면 AP의 위치를 고려한 Label을 사용했을 때 RMSE의 평균이 28.84dBm에서 14.98dBm으로 향상되었지만 여전히 높은 오차를 나타내기 때문에 생성된 Radiomap을 이상치에 영향을 많이 받는 Fingerprint에 적용하기 어렵다. 따라서 AP의 위치만을 고려한 Model 3은 Radiomap 생성 네트워크로 적절하지 않다. Model 1과 Model 2의 결과를 보면 장애물의 재질만을 고려한 Label을 사용했을 때 RMSE의 평균이 28.84dBm에서 5.48dBm으로 Radiomap 생성 정확도가 크게 증가한다. 따라서 장애물의 재질만을 고려하더라도 RGN의 Radiomap 생성 정확도를 크게 높일 수 있다. Model 2와 Model 4의 결과를 보면 APCW를 사용했을 때 RMSE의 평균이 5.48dBm에서 4.01dBm으로 Radiomap 생성 정확도가 증가한다. 또한 He의 연구에서 Wi-Fi 신호의 표준편차는 5dBm 이내의 값을 가진다[30]. 따라서 제안하는 APCW 기반의 RGN의 Radiomap 생성 정확도가 4dBm 내외로 안정적인 성능을 보이기 때문에

Radiomap 생성 네트워크로 적절하다고 판단된다.

제안하는 APCW를 기반의 RGN인 Model 4의 Radiomap 생성 정확도가 가장 높게 나왔다. 따라서 AP를 중심으로 Label을 생성하는 방법이 Radiomap 생성 정확도에 미치는 요인을 분석하기 위해 Model 2와 Model 4의 Input Layer의 Weight Vector를 비교하였다. 뉴럴 네트워크의 출력은 식 (2.3)과 같이 입력데이터의 각 성분과 네트워크의 Weight Vector의 곱의 형태이다. 따라서 Input Layer의 Weight Vector는 RGN이 Radiomap을 생성할 때 APCW를 구성하는 각각의  $S^i$ 가 곱해지는 수치를 나타낸다. 이는 Weight Vector를 구성하는 각각의 Weight의 위치와 수치는 해당 위치에 입력된 데이터의 성분이 네트워크의 출력에 미치는 정도를 의미한다. 그림 4.5는 Model 2와 Model 4 각각의 Input Layer의 Weight Vector를 나타낸다. 여기서 (a)의 X, Y축은 각각 Radiomap을 생성하기 위해 Model 2에 입력되는  $L_{one-hot} = 84m \times 32m$ 의 X, Y축 좌표를 나타낸다. 이때 Label의 크기 및 형태는 건물의 크기와 동일하게 설정하였다. 또한 (b)의 (a)의 X, Y축은 각각 Radiomap을 생성하기 위해 Model 4에 입력되는  $L_{one-hot} = 39m \times 39m$ 의 X, Y축 좌표를 나타낸다.

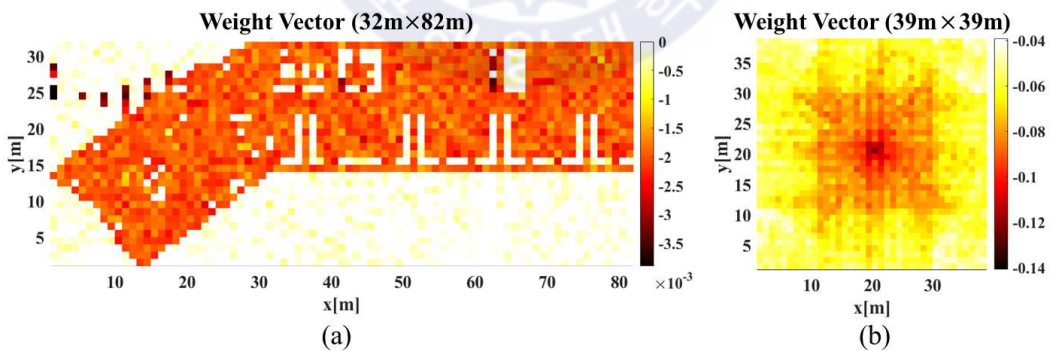


그림 4.5 모델의 Weight Vector

(a)모델 2의 Weight Vector (b)모델 4의 Weight Vector

Fig 4.5 Weight Vector of Model

(a)Weight Vector of Model 2 (b)Weight Vector of Model 4

여기서 Model 2와 Model 4의 Weight Vector는 대부분 음수 값이다. 이는 AP에서 방사된 전파가 벽, 등과 같은 장애물에 의해 점차 감소되기 때문에 Weight Vector는 음수의 값을 가지는 것으로 판단된다. 또한 Weight Vector를 구성하는 Weight의 절댓값은 각각 Radiomap을 생성할 때 사용하는 비율을 의미한다. 따라서 Label에서 임의의 X, Y의 위치가 결과를 생성하기 위해 사용되는 정도를 확인하기 위해선 절댓값을 기준으로 Weight Vector를 분석해야 한다. (a)의 경우에는 입력으로 사용된 건물의 형태와 유사하게 Weight Vector의 형태가 나타났으며 Inaccessible Space를 제외하면 위치와 상관없이 각각의 Weight는 유사한 수치를 가진다. 따라서 Model 2는  $L_{one-hot}$ 에서 임의의 X, Y축에 있는  $S^i$ 를 해당 위치와 AP 사이의 거리와 관계없이 Radiomap을 구성하는 RSSI를 예측하는데 사용하는 것을 의미한다. 하지만 AP 전파는 방사거리가 멀어질수록 반사, 투과 등의 전파현상으로 인해 세기가 감소한다. 따라서 전파가 도달하지 않는 음영지역의 구조물은 Radiomap을 생성할 때 필요가 없고 음영지역으로 인해 생성된 Radiomap에 잡음이 생긴다. 이와 달리 (b)의 경우에는 Weight Vector의 중심부에서 가장 큰 수치를 가지며 중심에서 멀어질수록 점차 작아지는 것을 볼 수 있다. 이는 벽, 창문 등의 구조물이 존재하는 실내 환경이기 때문에 완전한 방사패턴은 아니지만 유사하게 학습한 것으로 보인다. 이는 APCW를 이용하여 학습한 RGN이 Radiomap을 생성할 때 전파세기를 감쇄시키는 장애물과 AP와 거리가 멀수록 해당 위치의 APCW를 사용하는 비율이 작은 것을 의미한다. 이러한 이유로 제안하는 APCW 기반의 RGN은 음영지역으로 인한 잡음문제에 강인하며 Radiomap 생성 정확도가 Model 1, 2, 3보다 높다고 판단된다.

APCW와 RSSI로 구성된 데이터베이스의 활용성을 확인하기 위해서 AP의 위치에 따라서 변하는 RGN의 Radiomap 생성 정확도들을 비교하는 실험을 진행하였다. 그림 4.6은 4층에서 수집된 데이터를 사용하여 학습된 RGN을 통해 3, 4층에서 Radiomap을 생성한 결과를 나타낸다. (a), (c)는 임의의 X, Y좌표에 AP가 위치할 때 RGN에서 생성된 Radiomap과 해당 AP의 실제 Radiomap의 RMSE를 위치별로 나타냈다. 이때 X축과 Y축은 각각의 RSME를 계산한 위치를 나타



낸다. (b), (d)는 (a), (c)가 각각 변환된 히스토그램이다. 이때 X축은 생성된 Radiomap과 실제 Radiomap의 RMSE를, Y축은 빈도수를 나타낸다. 또한 그림 4.7은 3, 4층에서 수집된 데이터를 사용하여 학습된 RGN을 통해 3, 4층에서 Radiomap을 생성한 결과를 나타낸다. 이때 (e), (f), (g), (e) 각각의 X, Y축은 (a), (b), (c), (d)와 동일하다.

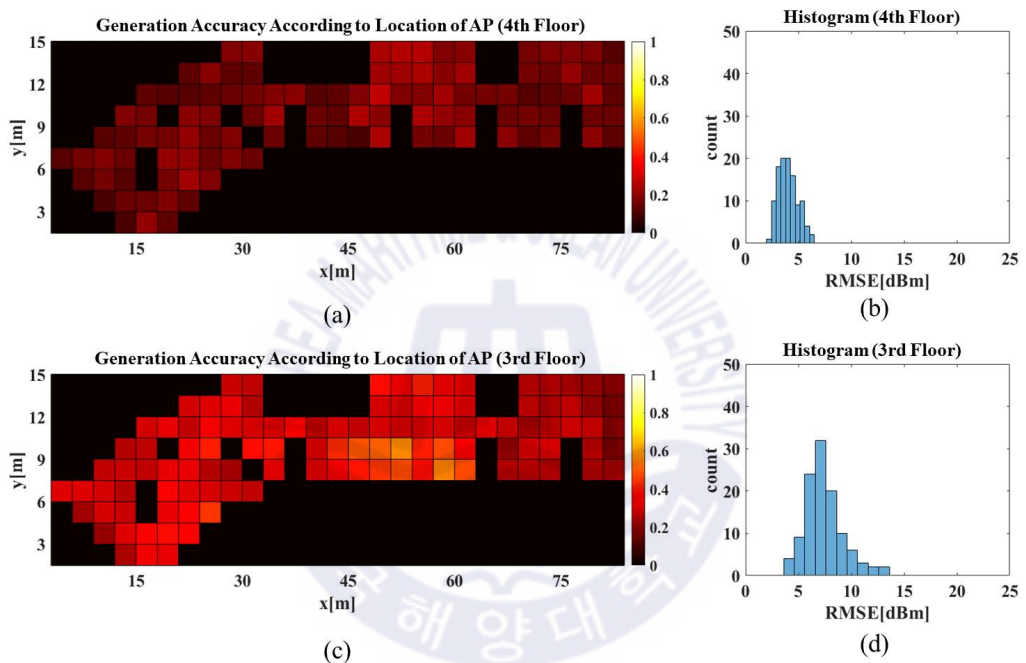


그림 4.6 4층 데이터를 학습한 RGN의 Radiomap 생성 결과  
(a)4층 (b)4층의 히스토그램 (c)3층 (d)3층의 히스토그램

**Fig 4.6** Radiomap Generation Result of RGN Learning the 4th Floor Data  
(a)4th Floor (b)Histogram of 4th Floor (c)3rd Floor (d)Histogram of 3rd Floor

(a), (b)의 결과를 보면 학습된 4층에서 Radiomap을 생성하는 경우, RGN은 AP의 위치와 상관없이 안정적인 Radiomap 생성 정확도를 보였다. 따라서 AP 주변의 건물 구조의 변화에 따른 RSSI 분포를 학습한 것을 확인할 수 있다. (c), (d)의 결과를 보면 3층에서 Radiomap을 생성하는 경우에는 중심부에 AP가

위치한 경우 4층에 비해 성능이 낮아지는 것을 볼 수 있다. 이는 3층과 4층에서 중심부와 좌측 하단부에서의 구조가 다르기 때문인 것으로 판단된다. 하지만 우측부분의 경우는 4층과 3층의 구조적인 차이가 없기 때문에 비교적 안정적인 예측성능을 보였다. 따라서 RGN이 건물 구조에 따른 RSSI 분포를 학습하고 이를 이용해 Radiomap을 생성하는 것으로 볼 수 있다.

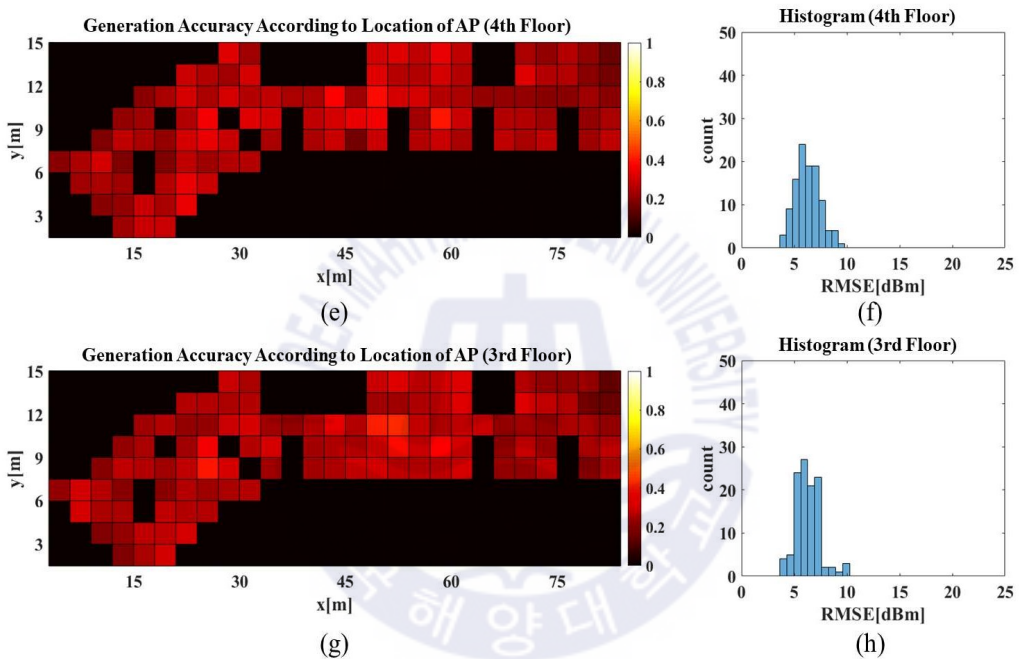


그림 4.7 3층과 4층 데이터를 학습한 RGN의 Radiomap 생성 결과  
(e)4층 (f)4층의 히스토그램 (g)3층 (h)3층의 히스토그램

**Fig 4.7** Radiomap Generation Result of RGN Learning the 3rd Floor Data and 4th Floor Data  
(e)4th Floor (f)Histogram of 4th Floor (g)3rd Floor (h)Histogram of 3rd Floor

또한 3, 4층의 구조를 모두 학습한 RGN을 이용한 (g), (h)의 결과를 보면 3층에서의 Radiomap 생성 정확도가 높아진 것을 볼 수 있다. 이는 APCW 기반의 RGN은 새로운 구조를 학습하고 이를 이용해 Radiomap을 생성하는 것으로 판단된다. 따라서 여러 건물에서 수집된 수준 높은 데이터베이스가 확보된다면



제안하는 APCW 기반의 RGN을 통해 Fingerprint 기법에서 Radiomap을 생성하기 위한 시간 및 인적비용을 크게 줄일 수 있다. 하지만 (e), (f)의 결과를 보면 학습 데이터가 많아지면 RGN이 학습해야 하는 구조적인 패턴이 증가하기 때문에 각층의 Radiomap 생성 정확도가 떨어지는 것을 확인하였다. 이는 RGN을 구성하는 Weight Vector의 전체 파라미터의 수가 동일하기 때문이라고 판단된다. 이러한 문제를 해결하기 위해 데이터베이스가 증가할수록 Network의 크기 설정과 효율적인 학습을 위한 파라미터 설정이 요구된다.



## 제 5 장 결 론

본 논문에서는 Fingerprint에서 Radiomap을 생성하기 위한 시간 및 인적비용을 줄이고 RSSI로 구성된 데이터베이스의 활용성을 높이기 위한 APCW 기반의 RGN을 제안하였다. APCW는 실내공간을 데이터화하고 이를 AP를 중심으로 분할하여 생성되기 때문에 Radiomap를 구성하는 RSSI를 예측하는데 필요한 정보를 포함한다. APCW 기반의 RGN은 RSSI를 예측하여 Radiomap을 생성함으로써 건물마다 Wi-Fi 신호를 수집하는 비용을 크게 줄일 수 있다. APCW 기반의 RGN을 사용하여 Radiomap 생성하는 실험을 진행하였다. 최적의 APCW의 크기는  $39m \times 39m$ 일 때 RGN의 Radiomap 생성 정확도가 4.01dBm이다. 이는 Predicted Radiomap과 Real Radiomap의 RMSE를 나타낸다. APCW의 크기가 보다 작으면 RGN의 Radiomap 생성 정확도가 낮아진다. 반대로 APCW의 크기가 보다 클 때는 RGN의 Radiomap 생성 정확도 차이는 크지 않지만 RGN을 학습하기 위한 시간이 크게 증가한다. 또한 APCW를 사용하여 학습된 RGN이 Radiomap을 생성할 때 전파세기를 감소시키는 장애물이 AP에서 멀어질수록 RSSI를 예측하는데 적게 사용하는 것을 확인하였다. 이는 AP에서 방사된 전파 세기가 거리에 따라 감쇄하고 주변 장애물에 의해 크게 감쇄하는 특성을 학습한 것으로 판단된다. 또한 RGN이 학습하는 구조패턴을 증가시키는 실험을 통해 실내 구조에 대한 패턴을 학습하고 이를 이용하여 Radiomap을 생성할 수 있음을 확인하였다. 하지만 구조패턴의 양이 많아지면 RGN의 Radiomap 생성 정확도가 감소하는 한계가 있다. 향후 연구를 통해 이러한 문제를 해결하고 수준 높은 데이터베이스가 구축된다면 실내 위치인식에서 가장 많이 사용되는 Fingerprint의 Radiomap을 구축하는 비용을 크게 줄일 수 있다.

## 참 고 문 헌

- [1] Anagnostopoulos, V., Havlena, M., Kiefer, P., Giannopoulos, I., Schindler, K., & Raubal, M., “Gaze-Informed location-based services”, *International Journal of Geographical Information Science*, vol 31, no. 9, pp. 1770-1797, 2017.
- [2] Ray, S., Blanco, R., & Goel, A. K., “High performance location-based services in a main-memory database”, *GeoInformatica*, vol. 21 no. 2, pp. 293-322, 2017.
- [3] Zuo, J., Liu, S., Xia, H., & Qiao, Y., “Multi-Phase Fingerprint Map Based on Interpolation for Indoor Localization Using iBeacons”, *IEEE Sensors Journal*, vol. 18, no. 8, pp. 3351-3359, 2018.
- [4] Luo, C., Cheng, L., Chan, M. C., Gu, Y., Li, J., & Ming, Z., “Pallas: Self-bootstrapping fine-grained passive indoor localization using WiFi monitors”, *IEEE Transactions on Mobile Computing*, vol. 16, no. 2, pp. 466-481, 2017.
- [5] Wu, C., Yang, Z., & Xiao, C., “Automatic radio map adaptation for indoor localization using smartphones”, *IEEE Transactions on Mobile Computing*, vol. 17, no. 3, pp. 517-528, 2018.
- [6] Zhuang, Y., Li, Y., Qi, L., Lan, H., Yang, J., & El-Sheimy, N., “A two-filter integration of MEMS sensors and WiFi fingerprinting for indoor positioning”, *IEEE Sensors Journal*, vol. 16, no. 13, pp. 5125-5126, 2016.
- [7] Jung, S. H., Moon, B. C., & Han, D., “Performance evaluation of radio map construction methods for wi-fi positioning systems”, *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, no. 4, pp. 880-889, 2017.
- [8] Lee, S., Kim, J., & Moon, N., “Random forest and WiFi fingerprint-based indoor location recognition system using smart watch”, *Human-centric Computing and Information Sciences*, vol. 9, no. 1, pp. 880-889, 2019.
- [9] Jiang, Q., Ma, Y., Liu, K., & Dou, Z., “A probabilistic radio map construction scheme for crowdsourcing-based fingerprinting localization”, *IEEE Sensors Journal*, vol. 16, no. 10, pp. 3764-3774, 2016.
- [10] Mazlan, M. A. A. A., Khir, M. M., Saad, N. M., & Dass, S. C., “WiFi Fingerprinting Indoor Positioning with Multiple Access Points in a Single Base Station using Probabilistic Method”, *International Journal of Applied Engineering Research*, vol. 12, no. 6, pp. 1102-1113, 2017.

- [11] He, S., & Chan, S. H. G., “Wi-Fi fingerprint-based indoor positioning: Recent advances and comparisons”, *IEEE Communications Survey & Tutorials*, vol. 18, no. 1, pp. 466-490, 2015.
- [12] Wu, C., Yang, Z., & Liu, Y., “Smartphones based crowdsourcing for indoor localization”, *IEEE Transactions on Mobile Computing*, vol. 14, no. 2, pp. 444-457, 2017.
- [13] Zhang, X., Wong, A. K. S., Lea, C. T., & Cheng, R. S. K., “Unambiguous Association of Crowd-sourced Radio Maps to Floor Plans for Indoor Localization”, *IEEE Transactions on Mobile Computing*, vol. 17, no. 2, pp. 488-502, 2018.
- [14] Luo, C., Hong, H., Chan, M. C., Li, J., Zhang, X., & Ming, Z., “MPiLoc: Self-Calibrating Multi-Floor Indoor Localization Exploiting Participatory Sensing”, *IEEE Transactions on Mobile Computing*, vol. 17, no. 1, pp. 141-154, 2018
- [15] Bisio, I., Cerruti, M., Lavagetto, F., Marchese, M., Pastorino, M., Randazzo, A., & Sciarrone, A., “A trainingless wifi fingerprint positioning approach over mobile devices”, *IEEE Antennas and Wireless Propagation Letters*, vol. 13, pp. 832-835, 2014.
- [16] Dissanayake, G., Sukkariéh, S., Nebot, E., & Durrant-Whyte, H., “The aiding of a low-cost strapdown inertial measurement unit using vehicle model constraints for land vehicle applications”, *IEEE transactions on robotics and automation* , vol. 17, no. 5, pp. 731-747, 2001.
- [17] Chen, L., Zhang, S., Tan, H., & LV, B., “Progressive RSS Data Augmenter With Conditional Adversarial Networks”, *IEEE Access*, vol. 8, pp. 26975-26983, 2020.
- [18] Seong, J. H., & Seo, D. H., “Selective Unsupervised Learning-Based Wi-Fi Fingerprint System Using Autoencoder and GAN”, *IEEE Internet of Things Journal*, vol. 7, no. 3, pp. 1898-1909, 2019.
- [19] Hecht-Nielsen, R., “Theory of the backpropagation neural network”, *Nueral networks for perception*, pp. 65-93, 1992.
- [20] Denoeux, T., “A neural network classifier based on Dempster-Shafer theory”, *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and*

- Humans*, vol. 30, no. 2, pp. 131-150. 2000.
- [21] Jain, A. K., Mao, J., & Mohiuddin, K. M., "Artificial Neural Networks: A Tutorial", *Computer*, vol. 29, no. 3, pp. 31-44, 1996.
- [22] Han, J., & Moraga, C., "The Influence of the Sigmoid Function Parameters on the Speed of Backpropagation Learning", *International Workshop on Artificial Neural Networks*, pp. 195-201, 1995.
- [23] Namin, A. H., Leboeuf, K., Muscedere, R., Wu, H., & Ahmadi, M., "Efficient Hardware Implementation of the Hyperbolic Tangent Sigmoid Function", *IEEE International Symposium on Circuits and Systems*, pp. 2117-2120, 2009.
- [24] Hochreiter, S., "The vanishing gradient problem during learning recurrent neural nets and problem solutions", *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, vol. 6, no. 2, pp. 107-116, 1998.
- [25] Nair, V., & Hinton, G. E., "Rectified Linear Units Improve Restricted Boltzmann Machines", *ICME*, 2010.
- [26] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y., "Generative Adversarial Nets", *Advances in neural information processing systems*, pp. 2672-2680, 2014.
- [27] Mirza, M., & Osindero, S., "Conditional Generative Adversarial Nets", arXiv preprint arXiv:1411.1784, 2014.
- [28] Aptula, A. O., Jeliaskova, N. G., Schultz, T. W., & Cronin, M. T., "The Better Predictive Model: High  $q^2$  for the Training Set or Low Root Mean Square Error of Prediction for the Test Set?", *QSAR & Combinatorial Science*, vol. 24, no. 3, pp. 385-396, 2005.
- [29] Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., ... & Zuiderveld, K., "Adaptive Histogram Equalization and Its Variations", *Computer vision, graphics, and image processing*, vol. 39, no. 3, pp. 355-368, 1987.
- [30] Bose, A., & Foh, C. H., "A Practical Path Loss Model For Indoor WiFi Positioning Enhancement", *2007 6th International Conference on information, Communications & Signal Processing*, pp. 1-5. 2007.