

# AR에 적용 가능한 마커리스 기반의 실내 위치 측정 기법

## Measurement Technique of Indoor location Based on Markerless applicable to AR

김재형\*, 이승호\*

Jae-Hyeong Kim\*, Seung-Ho Lee\*

### Abstract

In this paper, we propose a measurement technique of indoor location based on markerless applicable to AR. The proposed technique has the following originality. The first is to extract feature points and use them to generate local patches to enable faster computation by learning and using only local patches that are more useful than the surroundings without learning the entire image. Second, learning is performed through deep learning using the convolution neural network structure to improve accuracy by reducing the error rate. Third, unlike the existing feature point matching technique, it enables indoor location measurement including left and right movement. Fourth, since the indoor location is newly measured every frame, errors occurring in the front side during movement are prevented from accumulating. Therefore, it has the advantage that the error between the final arrival point and the predicted indoor location does not increase even if the moving distance increases. As a result of the experiment conducted to evaluate the time required and accuracy of the measurement technique of indoor location based on markerless applicable to AR proposed in this paper, the difference between the actual indoor location and the measured indoor location is an average of 12.8cm and a maximum of 21.2cm. As measured, the indoor location measurement accuracy was better than that of the existing IEEE paper. In addition, it was determined that it was possible to measure the user's indoor location in real time by displaying the measured result at 20 frames per second.

### 요약

본 논문에서는 AR에 적용 가능한 마커리스 기반의 실내 위치 측정 기법을 제안한다. 제안한 기법은 다음과 같은 독창성을 갖는다. 첫 번째는 특징점을 추출하고 이를 이용하여 지역 패치를 생성하여 전체 이미지를 학습하지 않고 주변보다 더 유용한 지역 패치만을 학습하고 사용함으로써 더 빠른 연산이 가능하도록 한다. 두 번째는 Convolution Neural Network 구조를 사용한 딥러닝을 통해 학습을 진행하여 오차율을 줄여 정확도를 향상시킨다. 세 번째는 기존의 특징점 매칭 기법과는 다르게 좌우 이동을 포함한 실내 위치 측정이 가능하도록 한다. 네 번째는 매 프레임마다 새롭게 실내 위치를 측정하기 때문에 이동 중 앞쪽에서 발생한 오차가 누적되어 발생하는 것을 방지한다. 따라서 이동 거리가 길어져도 최종 도착점과 예측 실내 위치 간의 오차가 증가하지 않는다는 장점을 갖는다. 본 논문에서 제안하는 AR에 적용 가능한 마커리스 기반의 실내 위치 측정 기법의 소요시간과 정확도를 평가하기 위해 시행한 실험결과, 실제 실내 위치와 측정된 실내 위치의 차이가 평균 12.8cm, 최대 21.2cm로 측정되어서, 기존 IEEE 논문의 결과보다 우수한 실내 위치 측정 정확도를 나타내었다. 또한, 초당 20프레임으로 측정된 결과를 나타내어서 실시간으로 사용자의 실내 위치를 측정하는 것이 가능하다고 판단되었다.

*Key words : Markerless Positioning, Local Patch, AR, Indoor Positioning, Deep learning*

\* Dept. Electronic Engineering, Hanbat National University

★ Corresponding author

E-mail : shlee@cad.hanbat.ac.kr, Tel : +82-42-821-1137

※ Acknowledgment

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korean government (MSIT) (NRF-2019R1F1A1063984).

Manuscript received Apr. 27, 2021, revised Jun. 3, 2021, accepted Jun. 7, 2021.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

## I. 서론

4차 산업혁명이 진행됨에 따라 인공지능 관련 분야의 개발이 급격히 발전하고 있으며, 인공지능의 수준이 높아짐에 따라 카메라로 입력되는 영상을 빠르게 분석하여 이에 대한 정보를 사용자에게 제공할 수 있게 되었다. 이에 따라서 컴퓨터가 제공하는 정보를 현실에 투영시키는 AR(Augment Reality)분야도 높은 관심을 받고 있다[1]. AR은 사용자가 별도의 디스플레이 기기를 사용하지 않고 정보를 사용자가 바라보고 있는 시야에 겹쳐지도록 투영시킴으로써 더욱 직관적으로 정보를 전달받을 수 있도록 한다. AR이 정상적으로 정보를 투영시키기 위해서는 현재 사용자의 위치를 정확하게 파악하는 기술이 필요하다. 이를 위해서 GPS, 마커(Marker), AP(Access Point)/비콘 등을 이용하여 사용자의 위치를 파악하는 기술[2][3]이 개발되어 있다. 그러나 실제 AR이 이용되는 현장에서 사용자의 위치를 파악하기에는 많은 어려움이 있다. 첫째로 GPS는 위성을 이용하여 높은 위치 정확도를 제공하지만, 이는 실외 환경에서만 적용되며 실내 환경에서는 콘크리트 등의 여러 방해 요소가 있어 정확도가 급격히 저하된다. 둘째로 특정 위치에 QR 코드 등의 마커를 이용하는 방식은 마커가 시야에 들어오기 전에는 사용자의 위치를 측정할 수 없고, 마커가 훼손될 경우에도 이를 정상적으로 활용할 수 없다. 셋째로 AP/비콘 등을 사용하여 위치 측정을 하는 경우는 미리 별도의 장비를 설치해야 하며, 기동과 같은 장애물에 의한 전파 방해가 발생하는 문제가 있다.

따라서 본 논문에서는 실내에서 마커나 별도의 위치 측정 장비 없이 AR 디바이스에 장착된 카메라에 입력되는 영상만으로 사용자의 실내 위치를 파악하는 기법을 제안한다.

## II. 본론

### 1. AR에 적용 가능한 마커리스 기반의 실내 위치 측정 기법의 전체 개요도

본 논문에서 제안하는 AR에 적용 가능한 마커리스 기반의 실내 위치 측정 기법의 전체 개요도는 그림 1과 같다.

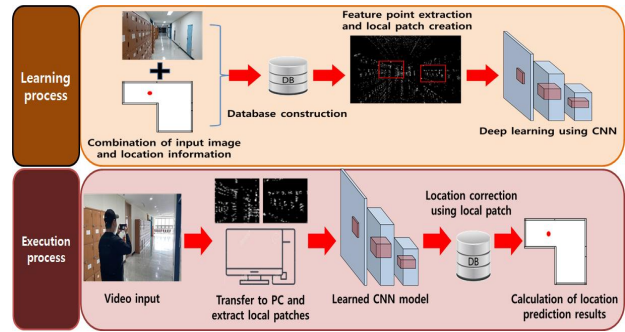


Fig. 1. A complete overview of the proposed method in this paper.

그림 1. 본 논문에서 제안한 기법의 전체 개요도

본 논문에서 제안된 기법은 데이터베이스 구축, 특징점 추출, 지역 패치 생성, Convolution Neural Network 구조를 이용한 딥러닝 학습[4] 등의 4가지 과정으로 이루어져 있으며, 전체 기법의 흐름도는 그림 2와 같다.

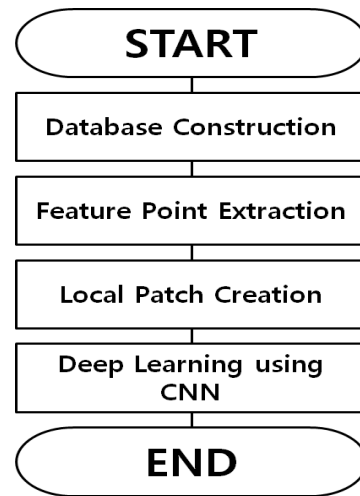


Fig. 2. Full flowchart of the proposed method in this paper.

그림 2. 본 논문에서 제안한 기법의 전체 흐름도

### 2. 데이터베이스 구축

제안된 기법의 정확도를 평가하기 위해서는 영상 정보와 매칭되는 실내 위치 정보를 가진 데이터베이스가 필요하다. 현재로서는 위 두 가지 요건을 충족시키는 증명된 데이터베이스가 존재하지 않기 때문에 직접 데이터베이스를 만들어 사용한다. 교내의 복도에서 촬영을 진행하며, 입력 영상의 사이즈는 1080p(1920×1080 pixel)의 해상도를 사용한다. 학습의 정확도를 높이기 위하여 입력 영상을 회전, 확대, 축소 등을 사용하여 Data Augmentation 기

법[5]을 적용한다. 실내 위치별로 다양한 데이터를 얻기 힘들기 때문에 Data Augmentation 기법을 적용하면 적은 양의 원본 영상 데이터를 다양하게 변이된 많은 양의 영상 데이터의 확보가 가능하다.

이에 매칭되는 실내 위치 정보를 얻기 위해 복도 폭 260cm 중 사물함 등의 장애물을 제외한 120cm의 폭에서 학습용 데이터와 실험용 데이터를 나누어 촬영을 진행한다. 학습용 데이터는 30cm 간격으로 실내 위치 정보를 라벨링하여 저장한다. 실험용 데이터는 실제 실내 위치 정보를 cm 단위로 평면도에 x, y 좌표의 형태로 저장하여 최종적으로 실험 결과를 도출할 때 출력된 실내 위치 정보와의 오차를 계산하는데 사용한다. 이미지를 획득하고 실내 위치 정보를 매칭시킨 데이터를 저장하여 데이터베이스를 구축한다. 데이터베이스 구축에 대한 전체적인 개요도는 그림 3과 같다.

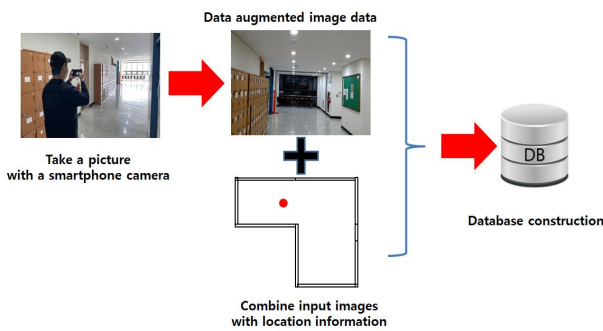


Fig. 3. A complete overview of database construction.  
그림 3. 데이터베이스 구축 전체 개요도

### 3. 특징점 추출

전체 이미지를 학습할 경우 학습 속도와 추후 실내 위치 측정 시 연산량이 증가하여 소요시간이 증가하게 된다. 전체 이미지에서 두드러지는 특징점만을 추출하여 학습을 진행하면 연산량과 소요시간을 감소시키는 효과가 있다. 특징점 추출은 원본 이미지에서 코너를 찾아 추출하는 FAST-9 알고리즘[6]을 사용하여 추출한다. FAST-9 알고리즘은 윈도우 슬라이드 방식으로 전체 이미지를 돌며 임의의 점 p와 p를 중심으로 하는 반지름 3픽셀인 원상의 16개의 픽셀값들을 비교하여 p가 특징점인지 아닌지 판별한다. 임의의 점 p 주변의 픽셀값들이 밝거나 어둡게 n개 이상 연속될 경우 점 p를 특징점으로 판별한다. 이때, n을 9~16 중 하나의 숫자로 지정하여 적용한다. n을 9로 지정할 경우 중심

점 p와 확연히 다른 픽셀값을 가진 점 9개가 연속으로 있을 경우에 p를 특징점으로 판별한다. 주변값과 비교하여 특징점을 추출하면 특징점 주변에 있는 다수의 점들이 같이 추출되는 경우가 많다. 이 경우에 너무 많은 특징점이 추출되기 때문에 인접한 특징점들 중 가장 두드러지는 특징점만을 추려내는 과정이 필요하게 되고, 이를 위해 Non-maximal suppression 과정을 거친다. 검출된 모든 특징점에 대하여 코너성 점수 V를 계산하여 인접한 특징점들끼리 V를 비교하여 인접한 특징점들 중에서 V가 가장 높은 특징점만을 남기게 된다.

특징점이 전부 추출되면 검은색 바탕화면에 하얀색으로 특징점을 표시한 이미지를 획득하여 저장한다. 그림 4는 추출된 특징점을 표시한 결과 이미지이다.



Fig. 4. Result image showing the extracted feature points.  
그림 4. 추출된 특징점이 표시된 결과 이미지

### 4. 지역 패치 생성

추출한 특징점의 군집도를 파악해 지역 패치를 생성한다. 지역 패치를 생성하는 이유는 전체 이미지를 학습과 검출에 사용하지 않고 두드러지는 특징이 포함된 작은 이미지를 사용함으로써 연산량을 줄이기 위함이다. 또한 실내 위치 측정 결과의 정확도를 높게 보정하기 위해 사용한다. AR을 위한 실내 위치 측정은 사람의 걸음 속도를 기준으로 이루어지기 때문에 비슷한 이미지가 연속으로 입력되어 학습 결과가 부정확하게 도출될 확률이 높다. 따라서 지역 패치를 저장할 때, 전체 이미지에서 지역 패치의 위치 좌표를 같이 라벨링하여 저장함으로써 최종 결과 도출시 라벨링 데이터를 이용하여 정확도를 보정한다. 비슷한 지역 패치가 인식될 경우, 저장되어 있는 지역 패치의 위치좌표를 이용하여 인식된 지역 패치들 중 현재 인식된 지역 패치의 위치와 가장 가까운 지역 패치를 선택하게 된다. 그림 5와 같이 파란색 화살표 방향으로 진행되는 윈도우 슬라이드 방식으로 전체 특징점 추출

이미지에서 고정된 크기(256×256 pixel)의 영역 안에 특징점이 20% 이상 존재하는 영역을 지역 패치 후보군을 생성한다. 이미지의 상단 부분은 천장 부분으로 조명 기구에 의해 밝기의 영향을 크게 받으므로, 이미지의 상단 부분은 지역 패치 후보군을 생성하지 않고 제거한다.

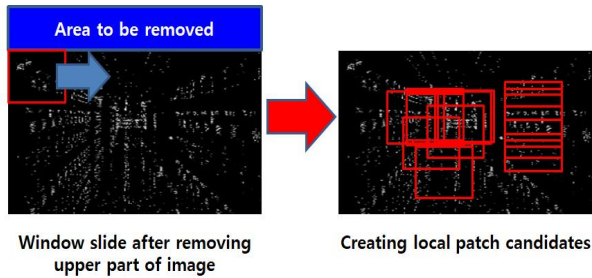


Fig. 5. Process for creating local patch candidate groups.  
그림 5. 지역 패치 후보군 생성 과정

지역 패치 후보군을 생성한 후, 겹치는 지역 패치를 제거하는 알고리즘을 적용한다. 특징점이 한곳에 몰려있는 경우에 주변의 윈도우 대부분이 기준치 이상의 특징점 비율을 가지게 되어 지역 패치가 중첩될 수 있다. 지역 패치가 여러 개 중첩될 경우, 연산량이 증가하여 처리속도에 영향을 끼치기 때문에 이를 방지하는 작업이다. 그림 6과 같이 겹치는 위치에 지역 패치가 생성될 경우 내부 특징점 비율이 더 높은 후보군을 지역 패치로 사용하고 비율이 낮은 후보군은 삭제한다.




Fig. 6. Overview of local patch selection process.  
그림 6. 지역 패치 선택 과정 개요도

생성된 지역 패치는 각각 하나의 객체로 간주하여, 첫 번째에 구축된 데이터베이스에 포함되어 있는 실내 위치 정보를 결합하여 저장한다. 기존의 딥러닝 학습을 이용한 객체 검출 방식은 전체 이미지에서 특정 사물이나 동물 등의 객체를 찾는 것이 목표이므로 사람이 수작업으로 전체 이미지에서

학습할 객체를 지정하고 이에 대한 라벨링을 진행해야 한다. 제안된 기법의 목표는 이미지 내부의 객체를 찾는 것이 아니라 입력된 이미지가 어느 실내 위치에서 촬영된 것인지 찾는 것이므로 지역 패치와 실내 위치 정보를 결합하여 자동으로 라벨링한다. 지역 패치 라벨링 정보는 그림 7과 같이 전체 이미지에서의 지역 패치의 좌상단 x좌표, y좌표와 지역 패치에 자동으로 부여되는 분류 라벨링이 포함되어 있다. 분류 라벨링은 n번 실내 위치에서 촬영한 이미지의 몇 번째 지역 패치인가에 대한 정보가 포함되어 있다. 따라서 그림 7에서 1번 실내 위치에서 촬영한 이미지의 2번째 지역 패치의 경우 (317, 320, 1, 2)로 라벨링이 된다.

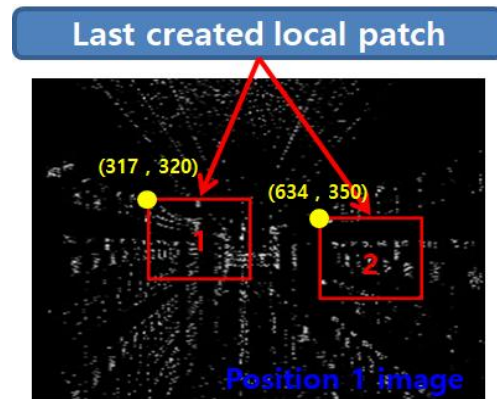


Fig. 7. About x-coordinates, y-coordinates, and classification labeling for local patches.  
그림 7. 지역 패치의 x좌표, y좌표와 분류 라벨링 정보

## 5. Convolution Neural Network 구조를 이용한 딥러닝 학습

Convolution Neural Network는 입력된 이미지를 Convolution 연산을 통해 가장 특징적인 부분만 남기는 네트워크이다. Convolution Neural Network 구조의 가장 큰 특징은 필터를 이용한 Convolution 연산이 진행될수록 이미지 자체의 크기가 줄어든다는 점이다. 이미지 안에서 가장 큰 특징점들만 추려서 추출하기 때문에 이미지 안의 객체 위치가 변하더라도 객체를 식별 할 수 있다는 장점을 가지고 있다. 본 논문에서는 Gradient vanishing/exploding을 방지하기 위하여 Batch Normalization 기법[7]을 사용하였다. 마지막 레이어에는 Average Pooling 레이어를 추가하였다. 그림 8은 본 논문에 적용한 CNN의 구조이다.

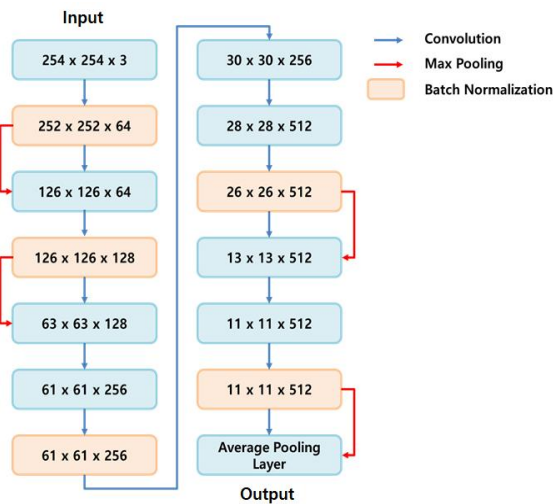


Fig. 8. CNN structure applied to this paper.  
그림 8. 본 논문에 적용한 CNN 구조

학습 과정 중 입력된 지역 패치의 분류 라벨링과 출력으로 나온 예측된 분류 라벨링이 다를 경우 그림 9와 같이 다음 학습 과정에서 적용되는 가중치를 수정하는 Backpropagation 과정[8]을 진행하여 오차를 줄이는 과정을 반복한다.

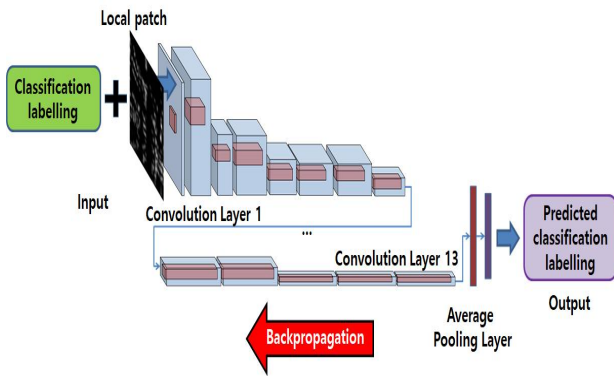


Fig. 9. Overview of backpropagation processing.  
그림 9. Bacpropagation 과정의 진행 개요도

총 73,412개의 Training Sets에 대하여 학습을 수행하며, 1개 Training Sets에 대한 학습이 완료된 것을 뜻하는 Epoch를 2,000번 이내로 제한하여 그 중 가장 적은 Loss를 도출한 가중치를 선택하여 CNN 모델에 적용한다. Epoch를 2,000번 이내로 제한을 둔 이유는 너무 많은 Epoch를 진행하면 Overfitting이 발생하여 Loss는 더 줄어들지만, 학습에 사용된 데이터에만 적합한 가중치로 변하기 때문이다. 그림 10은 Epoch에 따른 Loss의 변화 그래프이다.

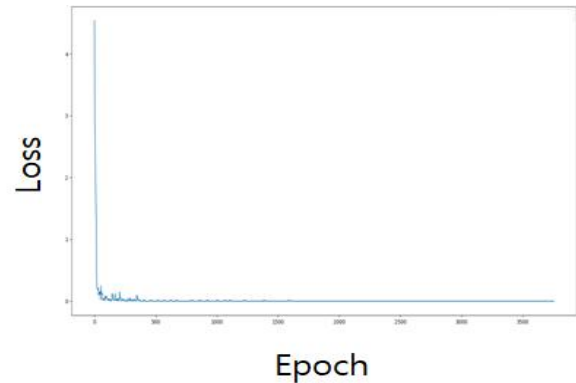


Fig. 10. Graph of loss changes with epoch.  
그림 10. Epoch에 따른 Loss의 변화 그래프

학습이 완료된 CNN 모델에 검출된 지역 패치를 입력하여 출력된 결과 값과 Confidence Score, 데이터베이스에 입력된 지역 패치의 위치 좌표를 이용한 실내 위치 예측 결과 보정 알고리즘을 적용한다. 그림 11과 같이 검출된 지역 패치를 학습된 CNN 모델에 입력하여 출력된 Confidence Score가 2개 이상 비슷한 경우에만 적용한다. 데이터베이스에 입력된 지역 패치의 위치 좌표와 검출된 지역 패치의 위치 좌표를 비교하여 더 가까운 위치에 있는 지역 패치를 선택하여 선택된 지역 패치의 실내 위치 정보를 반환한다.




Fig. 11. Overview of correction algorithm for indoor location prediction results.  
그림 11. 실내 위치 예측 결과 보정 알고리즘 개요도

## 6. 성능 실험

### 가. 실험 환경

본 논문의 실험에 사용된 운영체제 및 하드웨어는 Windows 10 Pro 64비트 운영체제를 기반으로 Intel(R) Core(TM) i7-8700k 3.7GHz CPU, RAM 16GB, NVIDIA GeForce GTX 1080 Ti (VRAM 11GB) GPU로 구성되어 있다. 스마트폰 카메라는 Samsung galaxy A90 모델을 사용하였다. 개발도구

는 JetBrains Pycharm Community Edition 2020.2.4. 버전을 사용하였으며 Pytorch 1.7.1, CUDA 10.1, CuDNN 6.0 라이브러리를 사용하였다. 본 논문에서는 자체적으로 구축한 교내의 복도를 촬영한 이미지와 실내 위치 정보가 결합된 데이터베이스를 사용한다. 그림 12는 본 논문에서 실험에 사용한 데이터베이스의 예시 이미지와 라벨링 데이터를 나타낸다. 사진 아래 4개의 숫자는 지역 패치의 x 좌표, y 좌표, 위치 정보, 지역 패치 번호를 나타낸다. 데이터베이스에 저장된 사용자의 실제 실내 위치를 표시하고 실제 실내 위치와 예측된 실내 위치의 오차를 계산한다. 이 과정의 시간을 측정하여 총 5,000장의 Test Sets를 실험하는데 걸리는 평균 시간을 계산한다.




Fig. 12. Database description constructed for the experiment. 그림 12. 실험을 위해 구축한 데이터베이스 설명도

나. 실험 결과

본 논문에서 제안하는 AR에 적용 가능한 마커리스 기반의 실내 위치 측정 기법의 정확도와 소요 시간을 평가하기 위해 2020년에 Songxiang Yang 외 3명이 IEEE Access에서 발표한 “An Improved Vision-Based Indoor Positioning Method”[9]와 유사한 방법으로 실험결과를 산출한다. 그림 13과 같이 빨간색 화살표 방향으로 이동하며 기존의 특징점 매칭 기법과는 다르게 좌우 이동을 포함한 실내 위치 측정 방식을 사용한다.

또한, 그림 14와 같이 매 프레임마다 새롭게 실내 위치를 측정하여 이동 중 앞쪽에서 발생한 오차가 누적되어 발생되지 않게 한다. 따라서 이동 거리가 길어져도 최종 도착점과 예측 실내 위치간의 오차가 증가하지 않는다는 장점이 있다.




Fig. 13. Indoor location measurement methods including left and right movement.

그림 13. 좌우 이동을 포함한 실내 위치 측정 방식




Fig. 14. Measure the new indoor location in each frame.

그림 14. 매 프레임마다 새롭게 실내 위치를 측정

한편, 현재 실내 위치와 측정 실내 위치의 차이의 에러 값은 그림 15와 같이 산출한다.

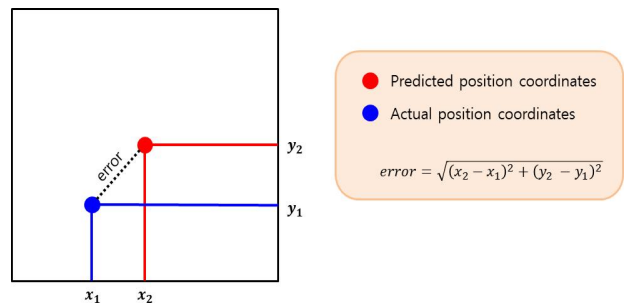


Fig. 15. Process for calculating indoor location measurement error.

그림 15. 실내 위치 측정 오차 계산 과정

자체적으로 구축한 데이터베이스는 교내의 복도를 촬영한 영상에서 특징점을 추출하고 지역 패치를 생성한 이미지 데이터와 실내 위치 정보 데이터가 결합되어 저장되어 있다. 구축한 데이터베이스에 포함되어 있는 장소에서 스마트폰 카메라로 촬영되는 이미지를 입력으로 실내 위치 측정을 수행하여 걸리는 시간을 측정하였다. 촬영자의 총 이동

거리는 150m이며 5,000장의 이미지를 사용하여 실험하였다. 표 1은 2020년에 Songxiang Yang 외 3명이 IEEE Access에서 발표한 “An Improved Vision-Based Indoor Positioning Method”의 논문에서 발표한 기법들과 비교 평가한 결과를 나타내고 있다. 표 1에서 나타난 바와 같이 본 논문에서 제안하는 측정 결과 실제 실내 위치와 측정된 실내 위치의 차이가 평균 12.8cm, 최대 21.2cm로 측정되어 Songxiang Yang 외 3명이 발표한 기법들보다 높은 정확도를 나타내었다. 또한, 실시간으로 사용자의 실내 위치를 측정하는 것이 가능한 초당 20프레임으로 측정된 결과를 나타내었다.

Table 1. Experimental results.

표 1. 실험 결과

Method	Average error(cm)	Maximum error(cm)	Average processing speed(fps)
Songxiang Yang	17.4 cm	70.3 cm	-
The Proposed Method	12.8 cm	21.2 cm	20 fps

한편, 그림 16은 본 논문에서 제안하는 기법으로 실제 실내 위치와 측정된 실내 위치의 표시 결과를 나타내고 있다. 빨간 선은 측정된 실내 위치 이동 경로이며, 파란색 점은 실제 실내 위치를 표시한다.




Fig. 16. Display Results of Actual and Measured Indoor Locations.

그림 16. 실제 실내 위치와 측정된 실내 위치의 표시 결과

Songxiang Yang 외 3명의 결과는 이동 거리(실내 측정 거리)가 길어질수록 오차가 누적되어 점점 더 큰 오차가 발생한다. 본 논문에서 제안한 실내 측정 기법은 매 프레임마다 실내 위치를 새로 측정하므로 이동 거리가 길어져도 최대 오차가 누적되

어 발생되지 않는다. 그림 17의 (a) 그래프는 본 논문에서 제안한 기법으로 측정된 최대 오차이며, (b) 그래프는 Songxiang Yang 외 3명 논문의 최대 오차 그래프이다. 본 논문에서 제안한 기법은 최대 오차가 일정 수준 이상 증가하지 않는 결과를 볼 수 있다. 또한, 그림 18은 본 논문에서 제안한 기법의 평균 오차 그래프로서 평균 오차 역시 증가하지 않고 일정 값으로 수렴하는 것을 확인 할 수 있다. 따라서 본 논문에서 제안한 기법이 Songxiang Yang 외 3명의 기법보다 우수한 실내 위치 측정 정확도를 나타내었다. 또한, 초당 20프레임으로 측정된 결과를 나타내어서 실시간으로 사용자의 실내 위치를 측정하는 것이 가능하다고 판단되었다.

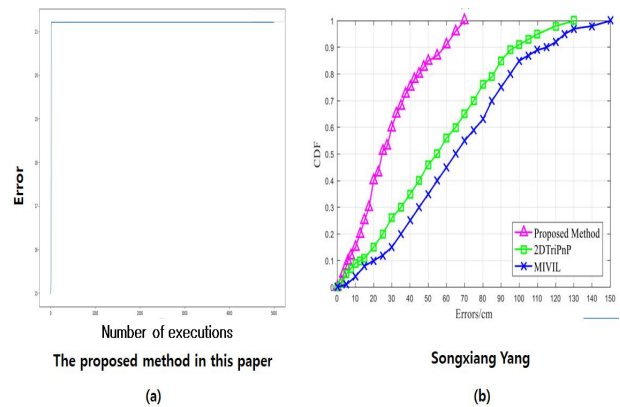


Fig. 17. (a) Maximum error graph of measured by the proposed method in this paper. (b) Maximum error graph of Songxiang Yang and 3 others.

그림 17. (a) 본 논문에서 제안한 기법으로 측정된 최대 오차 그래프 (b) Songxiang Yang 외 3명의 최대 오차 그래프

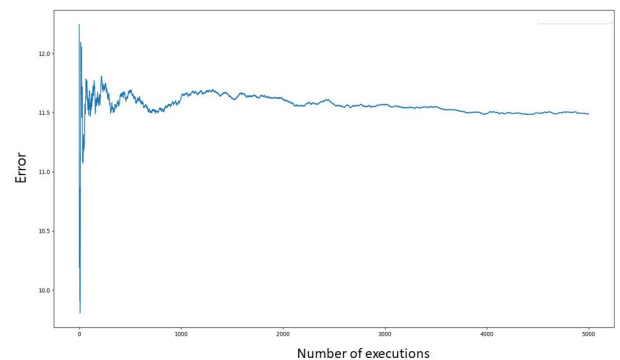


Fig. 18. Mean error graph of measured by the proposed method in this paper.

그림 18. 본 논문에서 제안한 기법으로 측정된 평균 오차 그래프

### III. 결론

본 논문에서는 AR에 적용 가능한 마커리스 기반의 실내 위치 측정 기법을 제안하였다. 제안한 기법은 다음과 같은 독창성을 갖는다. 첫 번째는 특징점을 추출하고 이를 이용하여 지역 패치를 생성하여 전체 이미지를 학습하지 않고 주변보다 더 유용한 지역 패치만을 학습하고 사용함으로써 더 빠른 연산이 가능하였다. 두 번째는 Convolution Neural Network 구조를 사용한 딥러닝을 통해 학습을 진행하여 오차율을 줄여 정확도를 향상시켰다. 세 번째는 기존의 특징점 매칭 기법과는 다르게 좌우 이동을 포함한 실내 위치 측정이 가능하였다. 네 번째는 매 프레임마다 새롭게 실내 위치를 측정하기 때문에 이동 중 앞쪽에서 발생한 오차가 누적되어 발생되지 않았다. 따라서 이동 거리가 길어져도 최종 도착점과 예측 실내 위치간의 오차가 증가하지 않는다는 장점을 가지게 되었다. 제안하는 기법의 소요시간과 정확도를 평가하기 위해 2020년에 Songxiang Yang 외 3명이 IEEE Access에서 발표한 “An Improved Vision-Based Indoor positioning Method”와 유사한 방법으로 실험결과를 산출하였다. 실험 결과, 실제 실내 위치와 측정된 실내 위치의 차이가 평균 12.8cm, 최대 21.2cm로 측정되어서 기존 IEEE 논문의 결과보다 우수한 실내 위치 측정 정확도를 나타내었다. 또한, 초당 20프레임으로 측정된 결과를 나타내어서 실시간으로 사용자의 실내 위치를 측정하는 것이 가능하다고 판단되었다.

앞으로의 연구에서는 실내 위치 측정 오차를 줄이기 위하여 지역 패치의 생성 기준에 대한 연구와 더 많은 환경에서의 데이터베이스 구축과 테스트에 대한 연구가 필요하다.

### References

- [1] Miyashita, Tsutomu, et al. “An augmented reality museum guide,” *2008 7th IEEE/ACM International Symposium on Mixed and Augmented Reality. IEEE*, 2008.  
DOI: 10.1109/ISMAR.2008.4637334
- [2] M. L. Yuan, S. K. Ong and A. Y. C. Nee, “Registration using natural features for augmented

- reality systems,” in *IEEE Transactions on Visualization and Computer Graphics*, vol.12, no.4, pp.569–580, 2006. DOI: 10.1109/TVCG.2006.79
- [3] X. Yang, Z. Liu, W. Nie, W. He and Q. Pu, “AP Optimization for Wi-Fi Indoor Positioning-Based on RSS Feature Fuzzy Mapping and Clustering,” in *IEEE Access*, vol.8, pp.153599–153609, 2020. DOI: 10.1109/ACCESS.2020.3018147
- [4] Jae-Hyeong Kim, Seung-Ho Lee. “Intelligent face recognition and tracking system to distribute GPU resources using CUDA,” *Journal of IKEEE*, vol.22, no.2, 281–288, 2018.  
DOI: 10.7471/ikeee.2018.22.2.281
- [5] Cubuk, Ekin D., et al. “Autoaugment: Learning augmentation strategies from data,” *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2019.  
DOI: 10.1109/CVPR.2019.00020
- [6] Viswanathan, Deepak Geetha. “Features from accelerated segment test (fast),” *Proceedings of the 10th workshop on Image Analysis for Multimedia Interactive Services*, 2009.
- [7] Ioffe, Sergey, and Christian Szegedy. “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” arXiv preprint arXiv:1502.03167 (2015).  
DOI: 10.5555/3045118.3045167
- [8] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. “Deep learning,” *nature*, Vol.521, pp.436–444, 2015. DOI: 10.1038/nature14539.

### BIOGRAPHY

**Jae-Hyeong Kim** (Member)



2019 : BS degree in Electronic Engineering, Hanbat National University  
2021 : MS degree in Electronic Engineering, Hanbat National University

**Seung-Ho Lee** (Member)

1986 : BS degree in Electronic Engineering, Hanyang University  
1989 : MS degree in Electronic Engineering, Hanyang University  
1994 : Ph. D degree in Electronic Engineering, Hanyang University  
1994~current : Professor, Department of Electronic Engineering, Hanbat National University