

실내 환경에서 이동체의 경로 추정을 위한 딥러닝 기법

*백기환 **인정환 ***장석진

서울시립대학교 전자전기컴퓨터공학부

**in5kim@uos.ac.kr

A Deep Learning Technique for Path Estimation of Mobile Objects in Indoor Environments

*Baek, Ki-Whan **In, Jung-Whan ***Chang, Sekchin

School of Electrical and Computer Engineering, University of Seoul

요약

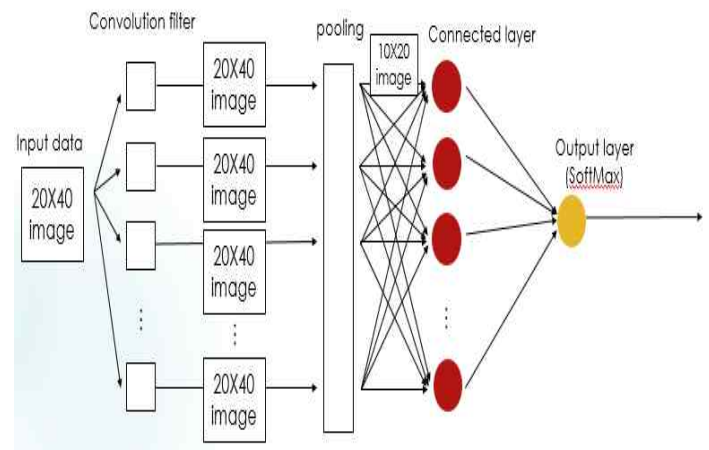
자율 주행 차량의 상용화를 위해서는 차량의 정교한 위치 추정이 필수적이다 특히 실내공간의 경우 다중 경로 등 복잡한 경로를 주행 중인 차량의 위치를 추적해야 한다. 이 경우 정밀한 위치 추정을 위해 이동체가 주행하는 경로를 정확히 판별하는 것이 필수적이다. 본 논문에서는 다중 경로가 존재하는 복잡한 실내공간을 주행하는 이동체의 경로 추정을 위해 딥러닝 기법을 이용한다. 특히 딥러닝 기법이 주행 차량의 영상 정보를 활용하는 방식을 기술한다. 본 논문에서 딥러닝 방식은 주행 차량의 영상 정보를 이용하여 이동체가 주행하게 될 경로를 예측한다. 모의실험은 적용된 딥러닝 방식이 이동체의 주행 경로를 정확하게 예측함을 보인다.

1. 서론

최근 자율주행 차량의 실용화가 구체화되고 있는 상황이다. 그러나 자율주행 차량의 상용화를 위해서는 정교한 위치 추정이 필수적이다. 실외 환경에서 주행 중인 이동 차량의 위치 추정을 위해 5G, WiFi 기술 등이 고려되고 있다. 또한 고속 이동체의 정밀한 위치 추정을 위해 UWB 기술이 적용되었다 [1]. 이들 기법들은 전자기파의 특성을 이용하고 있다. 전자기파가 허용되지 않은 상황에서의 위치 추정을 위해 IMU(Inertial Measurement Unit) 기반의 추정 기법이 제안되었다 [2, 3]. 그러나 이러한 기법들은 실외환경에서 주행 중인 차량에 적용되는 방식들이다. 실내 환경에서 주행 중인 차량의 위치 추정을 위해 엔코더와 영상정보가 융합된 방식이 제안되었다 [4]. 이 방식은 단일 경로의 실내 공간에서는 비교적 우수한 위치추정 성능을 보였다. 그러나 다중 경로를 포함한 복잡한 실내공간에 적용하기에는 위치추정 성능이 부족하다.

본 논문에서는 이러한 단점을 극복하기 위하여 딥러닝 기법을 이용한다. 사용되는 딥러닝 기법은 주행 차량의 영상정보를 이용한다. 따라서 딥러닝 기법으로 영상정보에 적합한 CNN(Convolutional Neural Network) [5]을 이용한다. 영상정보는 다중경로가 시작되는 장소에 설치된 CCTV 등을 이용하여 획득할 수 있다고 가정한다. 실내공간에서 CCTV는 사고가 빈번한 지점에 설치된다 [4]. 따라서 사고 확률이 높은 다중경로 시작 지점은 CCTV가 설치될 수 있는 환경이다. 본 논문에서 이용되는 CNN은 획득한 주행 이동체의 영상정보를 이용하여 이동체가 주행하게 될 경로를 추정한다. 모의실험은 적용된 CNN 기법이 이동체의 주행 경로를 정확하게 예측함을 보인다.


2. 경로 추정을 위한 CNN의 구조



[그림 1] 경로 추정을 위해 사용되는 CNN의 구조

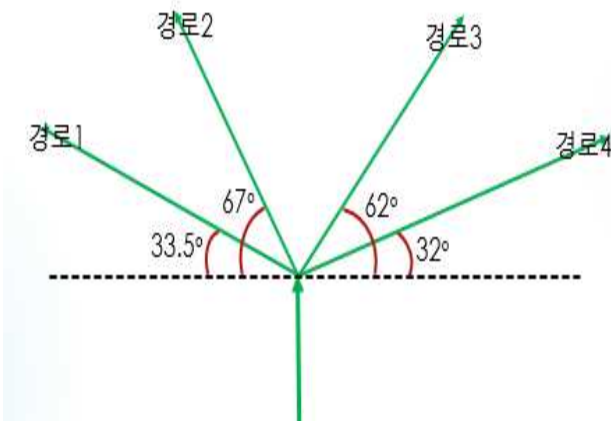
그림 1은 이동체의 경로 추정을 위해 사용되는 CNN의 구조를 보여준다. 원 영상 정보는 20x40의 이미지 데이터이다. 원 영상 정보는 16개의 컨볼루션 필터(convolution filter)를 통과한 후 풀링(pooling) 계층을 거쳐 16개의 10x20 영상 정보로 변환된다. 이 16개의 10x20 영상 정보가 결합 계층(connected layer)의 입력으로 이용된다. CNN의 출력 계층(output layer)에서 주행 경로가 선택된다. 그림 1의 CNN 학습을 위하여 각 경로 당 400개의 학습 데이터가 이용되며 경로 선택 테스트를 위하여 각 경로 당 190개의 테스트 데이터가 이용된다.

3. 모의 실험




[그림 2] 모의 실험에서 이용된 이동체와 주행 경로

그림 2는 모의 실험에서 이용된 이동체와 주행 경로를 보여준다. 4개의 경로로 이루어진 다중 경로를 이용하였다. 따라서 본 실험에서는 총 1600개의 학습 데이터 (각 경로 당 400개)와 총 760개의 테스트 데이터 (각 경로 당 190개)가 이용된다. 그림 2의 경로들은 각각의 각도가 균일하도록 배치되었다. 그림 3은 그림 2 경로들의 각도를 보여준다.



[그림 3] 모의 실험에서 이용된 주행 경로들의 각도

그림 4는 CNN의 입력으로 이용되는 각 경로 당 주행 이동체의 영상정보를 보여준다. 그림 4의 영상정보는 그림 2 이동체의 위타마크를 이용하여 획득하였다 [4].



[그림 4] CNN의 입력으로 이용되는 각 경로 당 주행 이동체의 영상 정보

학습된 CNN을 이용한 주행 이동체의 경로 추정은 모든 테스트 데이터에 100% 성공률을 보였다.

감사의 말: 본 연구는 한국연구재단에서 지원한 중견연구 [2017R1A2B4005105]과제의 성과입니다.

4. 참고문헌

- [1] M. Kim and S. Chang, "A real-time locating system for localization of high-speed mobile objects," *International Journal of Distributed Sensor Networks*, pp. 1-12, vol. 4, no. 5, May 2018.
- [2] E. Choi and S. Chang, "A consumer tracking estimator for vehicles in GPS-free environments," *IEEE Trans. Consumer Electron.*, vol. 63, no. 4, Nov. 2017.
- [3] E. Choi and S. Chang, "An adaptive tracking estimator for robust vehicular localization in shadowing areas," *IEEE Access*, vol. 7, pp. 4236 - 4244, Mar. 2019.
- [4] K. Baek, J. Bae, and S. Chang, "Collaboration of Image Information and Encoder Information for Localization of Mobile Objects in Indoor Environments," *Image Processing and Image Understanding (IPIU) 2019*, Feb. 2019.
- [5] J. Lemley, S. Bazrafkan, and P. Corcoran, "Deep learning for consumer devices and services: pushing the limits for machine learning, artificial intelligence, and computer vision," *IEEE Consumer Electron. Mag.*, vol. 6, no. 2, pp. 48 - 56, April 2017.