

향상된 딥러닝 기반 주행기록 측정을 위한 유사 OBD 생성 및 적용에 관한 연구

*임진욱, 김찬영, 설상훈
고려대학교 전기전자공학부

e-mail : jwlim@mpeg.korea.ac.kr, cykim@mpeg.korea.ac.kr, sull@korea.ac.kr

A Study on Generation and Application of Pseudo OBD for Improved Deep Learning Based Odometry

*Jinwook Lim, Chan Young Kim, Sang-Hoon Sull
School of Electrical Engineering
Korea University

Abstract

Proposed improved odometry by adding pseudo OBD(On-Board Diagnostics) data to visual odometry using deep learning. The method of creating pseudo OBD data for the proposed method uses the dynamic model of the vehicle. We propose a data input structure that combines pseudo OBD and sequential images for the proposed method.

I. 서론

차량의 주행기록 측정(Odometry)은 바퀴 회전을 이용하거나 GPS를 측정하여 시간의 경과에 따른 차량의 egomotion을 기록한다. 하지만 위와 같은 방법들은 도로의 상태나 통신 상태에 따라서 오차가 발생하는 문제가 있다. 반면에 순차적인 카메라 영상을 활용하는 영상 주행기록 측정(Visual Odometry)은 영상을 이용하여 이동 거리를 측정하므로 앞에서 말한 문제점들을 극복할 수 있다. 대표적으로 영상 주행기록 측정을 활용하는 방법에는 SLAM(Simultaneous Localization And Map building)을 활용한 Visual SLAM[1]이 있다. 또한 최근에는 딥러닝을 활용한 Kendall[2]이 있고,

비지도학습 방법을 사용한 Zhou[3], Yin[4]가 있다.

현대의 자동차에서는 제동계통, 조향계통의 계측과 제어를 위해 센서를 탑재하고 있으며, 이러한 장치들은 ECU(Electronic Control Unit)에 의하여 제어된다 [5]. 따라서 위 계측에 대한 전자적인 진단 시스템인 OBD(On-Board Diagnostics)를 활용하여 차량에 대한 정보를 전자적으로 받을 수 있다. 이렇게 획득한 제동 및 조향 정보는 차량의 동력학적 모델로 근사적 설명이 가능하다[6].

본 논문에서는 기존의 영상 주행기록 측정의 딥러닝 방법과 차량의 동력학적 모델로 만든 pseudo OBD 데이터를 활용함으로써 실제와 유사한 환경에서의 성능 향상을 알아보고자 한다.

II. 본론

2.1 동력학 모델을 이용한 pseudo OBD 생성

입력영상에 대응하는 egomotion에서 차량의 앞뒤 이동 변화량(t_z)와 좌우이동 변화량(t_x) 그리고 좌우 회전 변화량(θ)를 이용하여 차량의 근사적인 이동거리를 구했다. 이와 차량의 동력학 모델[6]을 바탕으로 실제 OBD와 유사한 차량 바퀴회전 횟수와 차량 스티어링의 회전 각도를 구함으로써 pseudo OBD를 생성하였다. 이를 위해 사용한 식들은 다음과 같다.

$$\text{차량 이동거리 } (S) = \frac{\theta}{2 \sin \frac{\theta}{2}} \sqrt{t_x^2 + t_z^2} \quad (1)$$

$$\text{차량 회전각도 } (a) = \theta \times \frac{\text{차체의 길이}}{S} \quad (2)$$

$$\text{차량 바퀴회전 횟수} = \frac{S}{\alpha}, \text{ where } \alpha = \frac{1}{3.6 \times FPS} \quad (3)$$

$$\text{차량 스티어링 회전각도} = \frac{a}{\pi} \times 180 \times \text{Angle Scale} \quad (4)$$

$$\text{where Angle Scale} = \frac{540}{35}$$

2.2 딥러닝을 이용한 주행기록 추정 모델

최근의 방법들인 Zhou[3], Yin[4]은 공통적으로 단안 카메라를 사용하여, 영상에서의 깊이 추정 및 egomotion을 추정한다. 일반적으로 이러한 방법들의 네트워크 구성은 연속된 단일 이미지들을 입력으로 받아서 영상의 깊이를 추정하는 네트워크와 egomotion을 추정하는 네트워크를 가진다.

본 논문에서는 Yin[4]에서 사용하는 egomotion 추정 네트워크를 기본 구조 [그림 1]로 채택하고자 한다.




그림 1. egomotion 추정을 위한 모델의 구조

III. 실험 및 결과

본 논문의 구현에서 egomotion 추정 네트워크 부분은 영상과 pseudo OBD를 입력으로 받기 위해 수정된 데이터 결합 구조 [그림 2]를 사용하였다. 이 구조는 pseudo OBD 데이터를 채널축으로 쌓고 영상크기와 같게 복제하여 영상의 채널축과 결합한 것이다.

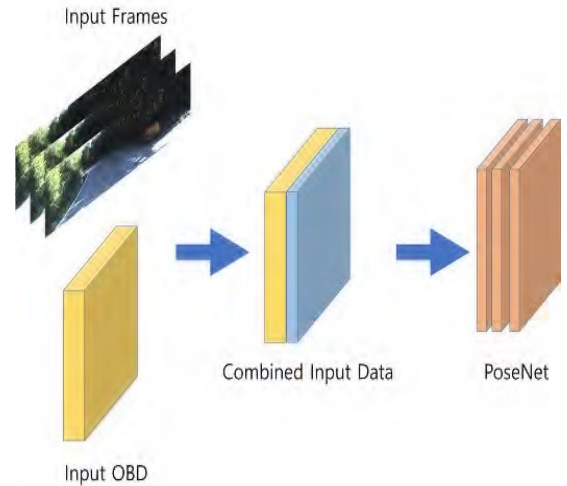


그림 2. OBD입력을 위해 수정한 데이터 결합 구조

전처리 영상 및 pseudo OBD 데이터 생성을 위한 데이터셋으로는 KITTI odometry dataset[7]을 사용하였다. 본 논문의 모델을 위한 학습 데이터는 전체 데이터셋의 Sequence 1부터 8까지를 사용하였으며, 테스트 데이터는 Sequence 9, 10을 사용하였다. 또한 하이퍼파라미터는 Yin[4]의 방법을 사용하였다.

본 논문의 제시 방법과 기존의 방법들의 테스트 데이터에 대한 성능 결과는 하기 표 1.과 같다. 이때 사용한 측정방식은 ATE(Absolute Trajectory Error)를 이용하였다. 성능의 비교 결과는 순수 영상만을 사용한 Zhou[3], Yin[4], ORB-SLAM[8] 보다 좋은 성능을 보인다. 이는 차량의 제동 및 조향에 관련된 pseudo OBD 데이터를 사용하는 것이 영상만을 사용했을 때 보다 좋은 주행기록 추정 결과를 얻을 수 있음을 말해준다.

Method	Seq.09	Seq.10
ORB-SLAM(full) [8]	0.014 ± 0.008	0.012 ± 0.011
ORB-SLAM(short) [8]	0.064 ± 0.141	0.064 ± 0.130
Zhou[3]	0.021 ± 0.017	0.020 ± 0.015
Zhou updated[3]	0.016 ± 0.009	0.013 ± 0.009
Yin[4]	0.012 ± 0.007	0.012 ± 0.009
Ours	0.009 ± 0.006	0.008 ± 0.007

표 1. 제안한 방법과 기존 방법들의 결과 비교

IV. 결론 및 향후 연구 방향

주행기록 측정 분야에서 양안 영상, 레이더 등의 데이터를 복합적으로 이용 가능한 딥러닝을 사용하는 것이 요즘의 추세이다. 이를 위해 본 논문에서는 pseudo OBD 데이터를 근사적으로 만드는 방법을 제시하였다. 또한 딥러닝에 영상과 pseudo OBD를 같이 적용시킬 수 있는 데이터 결합 구조를 제시하였다. 본 논문의 구현 결과에서 제안한 방법이 기존의 영상만을 사용한 방법보다 성능 향상을 유도하는 것을 확인하였다. 이는 본 논문의 차량의 제동 및 주행에 관한 데이터를 근사적으로 만드는 방법이 적절하며 영상 주행기록 추정 모델이 보다 좋은 성능을 내는 방향으로 학습되게 돕는 것으로 판단된다. 따라서 이후에는 실제 OBD 데이터를 사용하여 추가적인 연구를 진행할 예정이다.

Acknowledgement

이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원(No.2016-0-00152, Deep Learning 기반의 보행자 안전 지원 스마트카 비전 기술의 개발)과 2018년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임(IITP-2018-2016-0-00464, 대학ICT연구센터육성지원사업)

참고문헌

- [1] Engel et al, "LSD-SLAM: Large-scale direct monocular SLAM." European Conference on Computer Vision. Springer, Cham, 2014. p. 834-849.
- [2] Kendall et al, "Posenet: A convolutional network for real-time 6-dof camera relocalization." Proceedings of the IEEE international conference on computer vision. 2015. p. 2938-2946.
- [3] Zhou, et al, "Unsupervised learning of depth and ego-motion from video." CVPR. Vol. 2. No. 6. 2017.
- [4] Yin, et al, "GeoNet: Unsupervised Learning of Dense Depth, Optical Flow and Camera Pose." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Vol. 2. 2018.
- [5] Hu, et al, "Developing PC-based automobile diagnostic system based on OBD system." Power

and Energy Engineering Conference (APPEEC), 2010 Asia-Pacific. IEEE, 2010. p. 1-5.

- [6] Gillespie et al, "Vehicle dynamics." Warren dale (1997).
- [7] Geiger et al, "Are we ready for autonomous driving? the kitti vision benchmark suite." Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on. IEEE, 2012. p. 3354-3361.
- [8] Mur-Artal et al, "ORB-SLAM: a versatile and accurate monocular SLAM system." IEEE Transactions on Robotics, 2015, 31.5: 1147-1163.