

멀티모달 센서퓨전 기반 차량 주행 기록 복원

전진환¹⁾ · 황윤진¹⁾ · 최세범^{*1)}한국과학기술원 기계공학과¹⁾

Vehicle Motion Reconstruction via Multi-Modal Sensor Fusion

Jinhwan Jeon¹⁾ · Yoonjin Hwang¹⁾ · Seibum B. Choi^{*1)}¹⁾ Department of Mechanical Engineering, Korea Advanced Institute of Science and Technology,
291 Daehak-ro, Yuseong-gu, Daejeon 34141, Korea

Abstract : Recent explosive interests in autonomous driving have led to the development of various background technologies. Among them, vehicle localization and pose estimation are needed directly or can be used for advanced applications, which is why these topics have been consistently studied from the past. Although a lot of research have been done in this field, most of the studies assumed ideal driving scenarios where all sensor data are available throughout the experiment. However, this is not the case for general driving, where sensor signals can be degraded or even be lost for extreme cases. Thus, this study presents a novel sensor fusion framework to enhance vehicle motion reconstruction, even for challenging scenarios. Other than conventional INS and GNSS, learning-based lane detection system is added to the sensor configuration to enhance estimation accuracy. Robustness and performance of proposed sensor fusion framework was verified through the comparison with State-of-the-Art visual odometry algorithms, by testing on real vehicle driving dataset.

Key words : Autonomous Driving(자율주행), Multi-Modal Sensor Fusion(멀티모달 센서퓨전), INS, GNSS, Nonlinear Least Squares Optimization(비선형 최소제곱 최적화)

Nomenclature

R : SO3 rotation matrix $\in \mathbb{R}^{3 \times 3}$
 \mathbf{v} : velocity vector $\in \mathbb{R}^{3 \times 1}$
 \mathbf{p} : position vector $\in \mathbb{R}^{3 \times 1}$
 \mathbf{b}^a : acceleration bias vector $\in \mathbb{R}^{3 \times 1}$
 \mathbf{b}^g : gyro bias vector $\in \mathbb{R}^{3 \times 1}$
 l : lateral lane distance $\in \mathbb{R}$
 \mathbf{L} : relative lane point vector $\in \mathbb{R}^{3 \times 1}$
 Q : INS covariance $\in \mathbb{R}^{9 \times 9}$
 Σ : measurement covariance
 \mathcal{L} : cost function
 \mathbf{r} : cost function residual vector
 Exp : SO3 exponential mapping from $\mathbb{R}^{3 \times 1}$ to $\mathbb{R}^{3 \times 3}$

$\delta\boldsymbol{\phi}$: rotation perturbation vector $\in \mathbb{R}^{3 \times 1}$
 $\delta\mathbf{v}$: velocity perturbation vector $\in \mathbb{R}^{3 \times 1}$
 $\delta\mathbf{p}$: position perturbation vector $\in \mathbb{R}^{3 \times 1}$

Subscripts

i : state number index
INS : INS cost function residual vector indicator
GNSS : GNSS cost function residual vector indicator
LANE : lane cost function residual vector indicator

Superscripts

j : lane preview number
 $\hat{\cdot}$: hat operator (maps $\mathbb{R}^{3 \times 1}$ vector to $\mathbb{R}^{3 \times 3}$ skew symmetric matrix)

* 최세범, sbchoi@kaist.ac.kr

1. 서론

2016년에 자율주행이 총 6단계로 분류되고, 3단계 이상의 자율주행 차량 관련 연구가 급부상하면서, 자율주행을 위한 기술 또한 주목받기 시작했다. 차량이 안정적으로 자율주행하기 위한 기술에는 여러가지가 있겠지만, 그 중 핵심적으로 중요한 것은 스스로 어디에, 그리고 어떤 자세로 있는지를 정확하게 파악하는 localization과 pose estimation이다. 실시간 자율주행을 위해서 필요하기도 하지만, 비실시간으로도 주행 기록을 누적하여 도로 구간 별 교통량 분석, 차선 정보를 결합하여 차선 지도 구축 등, 다양한 용도로 활용 가능하다.

높은 수준의 localization과 pose estimation을 위해 다양한 플랫폼에서 여러 종류의 센서를 장착하고, 센서 정보를 효과적으로 융합하는 연구가 많이 이루어졌는데, 간단한 vision 기반의 방법부터 IMU, GNSS, LiDAR, Radar 등을 활용한 방법까지 제안되었다. 하지만, 대부분의 연구에서는 센서 신호가 정상적으로 들어오는 이상적인 경우에 대해서만 알고리즘 검증은 진행하였는데, 이는 많이 사용되는 확장 칼만 필터(Extended Kalman Filter)¹⁾의 경우 측정값의 형태가 균일해야 하기 때문에, 특정 신호가 들어오지 않는 등의 특수 상황을 고려할 수 없다. 물론 이러한 단점을 극복하고자 SLAM에서는 Nonlinear Least Squares(NLS)²⁾ 방식의 최적화를 도입했지만, 복합적인 악의조건이 있는 주행 시나리오에 대해서는 여전히 충분한 연구가 이루어지지 않았다.

따라서 본 연구에서는 특정 구간에서 센서 신호가 제대로 수신되지 않거나, 센서 측정값 자체가 불안정한 복합적인 악의조건이 포함된 주행 상황에 대해서도 차량의 위치와 자세를 준수한 정확도로 추정할 수 있는 멀티모달 센서퓨전 프레임워크를 제안하고 이를 실제 데이터셋을 통해 성능을 평가한다.

2. 멀티모달 센서퓨전 기반 차량 주행 복원

본 장에서는 악의조건 환경에 대해서도 중저가 센서들을 융합하여 강건하게 차량의 주행 기록을 복원하기 위한 모델과 최적화 방법에 대해서 소개

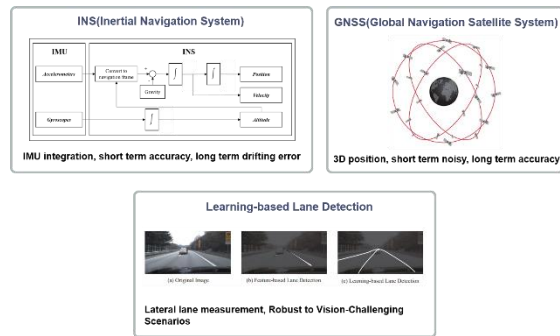


Fig. 2 센서 구성 소개

한다. 또한 소개된 모델을 통한 최적화 방법의 성능을 대전 외곽순환 고속도로를 주행한 데이터를 이용하여 검증하였다.

2.1 센서 구성

멀티모달 센서퓨전 시스템을 구성하는 센서들은 Fig. 2와 같고, 각 센서 별 특징에 대해 간단히 소개한다.

2.1.1 INS (관성 항법 시스템)

관성 항법 시스템은 IMU에서 얻은 가속도, 각속도 정보를 변환하고 적분하여 차량의 states를 얻을 수 있는데, 이러한 특징 때문에 짧은 기간에 대해서만 정확성을 보장할 수 있고, 긴 기간에 대해서는 drift에 취약하다.

2.1.2 GNSS (위성 항법 시스템)

위성 항법 시스템은 지구 상 물체의 위치를 절대 좌표로 알려주는 것이 주된 기능이다. GNSS는 INS와는 반대로, 긴 시간 간격에 대해서도 준수한 정확성을 보장하는 반면, 짧은 시간 간격은 노이즈나 다른 오차원인들로 인해서 높은 수준의 정확성을 보장하기 어렵다. 또한 터널, 지하차도, 높은 건물들이 많은 도심 속 같은 구간에 대해서는 신호가 안정적이지 않거나 완전히 차단될 수도 있다는 한계점도 가지고 있다.

2.1.3 학습기반 차선 인식

학습기반 차선 인식 시스템은 기존의 Feature based detection과는 다르게, 차선이 관측되지 않는 구간에 대해서도 차선을 예측하여 차량에 대한

횡방향 측정값을 반환한다. Feature based detection 대신 학습기반 차선 인식을 사용한 이유는 주변에 차량이 많은 경우, 그리고 터널 진입과 같은 급격한 광량 변화에도 강건하게 측정할 수 있기 때문이다.

2.2 멀티모달 센서퓨전 프레임워크

제2장에서 최종적으로 도달하고자 하는 목표는 차량의 state들을 한 번에 오프라인으로 최적화하는 것이다. 즉, 다양하게 주어진 센서 측정값들로부터 최적의 state를 구하는 Maximum a Posteriori(MAP) Problem인데, 이를 정리하면 Nonlinear Least Squares(NLS)와 동치라는 것을 보일 수 있다³⁾. 일반적인 NLS은 아래와 같은 식으로 표현할 수 있다.

$$\mathbf{X}^{\text{MAP}} = \underset{\mathbf{X}}{\operatorname{argmin}} \sum_i \|h_j(x_j) - z_j\|_R^2 \quad (1)$$

이때, $\|\cdot\|_R^2$ 의 표현은 Squared Mahalanobis Distance로, 아래와 같이 표현된다.

$$\|\theta - \mu\|_{\Sigma}^2 \triangleq (\theta - \mu)^T \Sigma^{-1} (\theta - \mu) \quad (2)$$

본 연구에서 NLS를 구성할 때 사용한 state variable은 차량의 3D kinematics를 나타내는데 필요한 차량 states들 $\mathbf{X} = (R, \mathbf{v}, \mathbf{p}, \mathbf{b}^a, \mathbf{b}^g)$ 과 차량 body frame에 대한 차선까지의 횡방향 거리(l)를 변수로 두었다. 해당 변수들을 이용하여 각 센서 시스템 별 구축한 NLS 모델을 소개한다.

2.2.1 INS NLS 모델

INS의 경우에는 mobile robotics 분야에서 많이 사용하는 IMU Preintegration⁴⁾ 방식을 도입하여 GNSS 신호와 IMU 신호의 비동기성을 해결하였고, 최적화 시 연산량을 줄였다.

INS NLS 모델은 아래의 식과 같고, INS의 residual vector의 구체적인 형태는 기존 연구⁸⁾에 소개되어 있다.

$$\mathcal{L}_{\text{INS}} = \sum \|r_{\text{INS}}(\mathbf{X}_i)\|_{Q_i}^2 \quad (3)$$

2.2.2 GNSS NLS 모델

GNSS의 경우에는 GNSS 신호가 존재하거나 정확한 경우에만 모델을 적용하였고, GNSS 음영구역에

대해서는 최종 비용함수에서 제외하였다. GNSS NLS 모델과 residual vector의 형태는 아래의 식과 같다. GNSS 신호가 들어오지 않는 구간에 대해서는 GNSS 신호가 들어오는 양 옆이 anchor point로 작용하여 위치 추정의 정확도를 높인다.

$$\mathcal{L}_{\text{GNSS}} = \sum \|r_{\text{GNSS}}(\mathbf{X}_i)\|_{\Sigma_{\text{GNSS}}}^2 \quad (4)$$

$$r_{\text{GNSS}}(\mathbf{X}_i) = \mathbf{p}_i - \mathbf{p}_i^{\text{GNSS}}$$

2.2.3 Lane NLS 모델

Lane 모델의 경우에는 i 번째와 $i+1$ 번째 timestep의 차선 측정값과 차량 states를 이용하여 구축할 수 있는데, Fig 3처럼 나타낼 수 있다. i 번째 timestep의 차선 포인트들을 $i+1$ 번째 timestep의 차량 위치를 이용하여 적당히 내분한다면, $i+1$ 번째 timestep의 차선 포인트와 같아야 하는 resample 포인트를 구할 수 있다. $i+1$ 번째 timestep의 차선 포인트와 resample 포인트의 차이를 최소화하도록 residual을 구성하였다.

각 timestep별 차량 states 마다 존재하는 preview distance에 따른 차선 횡방향 거리에 대한 변수는 preview step j 를 이용하여 l_i^j 로 표기하는데, 3차원 상의 차선 점군 데이터를 나타내기 위해 l_i^j 를 3차원으로 확장하여 \mathbf{L}_i^j 로 표기한다. Lane NLS 모델과 residual vector의 형태는 아래의 식과 같다.

$$\mathcal{L}_{\text{Lane}} = \sum \|r_{\text{Lane}}(\mathbf{X}_i, \mathbf{X}_{i+1}, \mathbf{L}_i^j, \mathbf{L}_i^{j+1}, \mathbf{L}_{i+1}^j)\|_{\Sigma_{\text{Lane}}}^2 \quad (5)$$

$$\begin{aligned} r_{\text{Lane}}(\mathbf{X}_i, \mathbf{X}_{i+1}, \mathbf{L}_i^j, \mathbf{L}_i^{j+1}, \mathbf{L}_{i+1}^j) &= \lambda R_{i+1}^T (\mathbf{p}_i + R_i \mathbf{L}_i^j - \mathbf{p}_{i+1}) + (1 - \lambda) R_{i+1}^T (\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1}) - \mathbf{L}_{i+1}^j \\ &= R_{i+1}^T (\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1}) + \lambda R_{i+1}^T R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1}) - \mathbf{L}_{i+1}^j \end{aligned}$$




Fig. 3 Lane NLS 모델

$$\text{이때, } \lambda = \frac{10(j-1) - [1,0,0] R_{i+1}^T (\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1})}{[1,0,0] R_{i+1}^T R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1})}$$



Fig. 4 멀티모달 센서퓨전 모델 검증 시나리오 (좌) 곡선 구간 (우) 터널 구간(3개)



Fig. 5 VO 대조군 (좌) VINS Stereo (우) Direct Sparse Odometry(DSO)

정확한 최적화를 위해서는 residual에 대한 jacobian도 계산해야 하는데, INS와 GNSS에 대한 jacobian은 기존 연구들에서 계산된 바가 있기 때문에 생략하였고, 본 연구에서 새롭게 제안하는 Lane 모델에 대한 대수적인 jacobian 식은 부록에 유도하였다.

2.3 NLS 최적화

앞서 2.2에서 유도한 NLS 모델을 기반으로 전체 비용함수를 구성할 수 있는데, 이를 최소화하기 위한 방법으로는 Gauss-Newton, Levenberg-Marquardt, Trust Region처럼 크게 3가지 방법이 있다. 이 중 Local Optima로의 수렴성이 보장된 Trust Region 방법을 기존 연구⁵⁾에서 소개한 Indefinite Gauss-Newton-Powell Dog-Leg 방식으로 구현하여 전체 최적화를 진행하였다.

3. 데이터 기반 검증

본 장에서는 앞서 소개한 3가지 모델을 모두 결합하여 최적화를 진행했을 때, 차량의 주행 기록이 효과적으로 복원되는지 실제 데이터셋을 기반으로 검증해본다. 이때, 본 연구에서 제안한 방법의 악의조건에 대한 강건성을 검증하기 위해 복잡한 악의조건이 있는 시나리오에서 평가하였고, 실내나 도심 구역에서 좋은 위치 추정 성능을 보

이는 Vision Odometry (VO) 기법과도 성능을 비교 분석한다.

3.1 실험 구성

실험은 대전 남부순환고속도로에서 진행했는데, Fig. 4와 같이 총 2가지 시나리오를 구성하였다. 첫 번째는 도로 곡률이 높은 구간, 그리고 두 번째는 연속된 터널 3개를 지나는 구간이다. 고속도로 특성상 도심 지역과는 다르게 특징적인 feature가 없고, 오히려 대부분의 특징들이 이미지마다 유사하게 나타나서 기존 VO나 Vision 기반의 SLAM에서 치명적으로 작용한다. 뿐만 아니라, Vision 기반의 방법들은 터널 내부처럼 광량이 충분하지 않거나, 터널 진입 시와 같이 광량이 급격히 변화하는 경우에도 failure가 많이 발생한다. 이러한 악의조건이 다양하게 존재하는 시나리오에 대해서 본 연구의 성능을 평가하고자 한다.

실험차량 구성은 Genesis G80 차량에 Xsens MTi-670g IMU와 FLIR Blackfly 단안 카메라를 두 개 장착하여 Stereo 비전 시스템을 구축하였다. 또한 고정밀 INS인 OxTS RT3100를 장착하여 reference 데이터를 얻었고, 나머지 데이터는 INS Calibration⁶⁾과 Stereo Camera Calibration⁷⁾을 완료한 후에 누적하였다.

본 연구에서 활용한 VO 대조군은 VINS Mono + IMU, VINS Stereo, VINS Stereo + IMU⁽⁸⁻⁹⁾, DSO¹⁰⁾이다. VINS는 feature 기반의 VO로, Fig. 5의 좌측 그림과 같

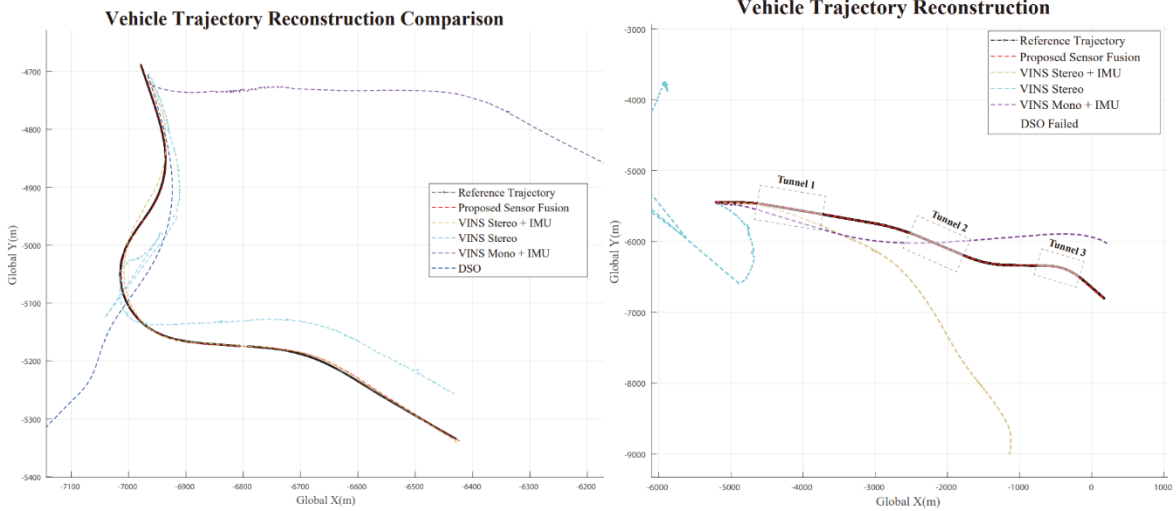


Fig. 6 각 시나리오 별 최적화 결과 비교 (좌) 곡선 구간 (1.077km) (우) 터널 3개 구간 (5.29km)

이 주변의 특징점을 매칭하여 역으로 ego motion을 추정한다. 이와 다르게 DSO는 Fig. 5의 우측 그림과 같이 연속된 이미지 간의 photometric error를 추적하여 역으로 ego motion을 추정한다. 두 방법은 각각 취약점과 강점이 명백히 다르기 때문에 제안하는 센서퓨전 방법의 대조군으로 선정하여 비교하고자 하였다.

3.2 검증 결과

시나리오 1과 2를 총 4개의 VO 대조군, 간단한 INS + GNSS 센서퓨전, 그리고 본 연구에서 제안하는 INS + GNSS + Lane 센서퓨전에 대해서 최적화를 진행하고, 결과를 비교 분석한다.

3.2.1 시나리오 1 (곡선 구간)

시나리오 1에 대한 결과는 Fig. 6의 좌측 그림과 같다. 그림에서 볼 수 있듯이, VINS Stereo + IMU의 경우를 제외한 VO 방법들은 좋지 못한 성능을 보였다. 정량적으로 결과를 비교해보면, Table 1에서 VINS Stereo + IMU도 오차가 많이 크음을 확인할 수 있다. 이처럼 VO 방법들이 큰 오차를 보이는 이유에 대해서는 3.2.3에서 소개하겠다. 마지막으로 단순한 INS + GNSS 센서퓨전은 Fig. 6에서는 본 연구에서 제안한 방법과 큰 차이가 없어 보이기 때문에 Table 1에서만 정량적으로 비교하였다. INS + GNSS는 VO에 비해 좋은 성능을 보이지만, 제안한

INS + GNSS + Lane 모델 기반의 방법이 가장 뛰어난 성능을 보이는 것을 확인할 수 있다.

Table 1 시나리오 1 정량적 오차 비교

구분	RMSE(m)	Max Error(m)
DSO	285	715
VINS Stereo + IMU	17.3	38.8
VINS Stereo	45.6	231
VINS Mono + IMU	385	542
INS + GNSS	4.24	9.05
INS + GNSS + Lane	2.41	3.31

3.2.2 시나리오 2 (터널 구간)

시나리오 2에 대한 결과는 Fig. 6의 우측 그림과 같다. 연속된 터널 3개를 지나는 구간이기 때문에 Vision 기반의 방법들이 오차가 큰 것을 확인할 수 있고, DSO는 알고리즘이 완전히 발산하여 중단되었다. 시나리오 1에서도 제안한 방식이 가장 좋은 성능을 보였지만, 시나리오 2에서 더욱 부각되었다.

Table 2 시나리오 2 정량적 오차 비교

구분	RMSE(m)	Max Error(m)
DSO	X	X
VINS Stereo + IMU	1190	2560
VINS Stereo	3810	6740

VINS Mono + IMU	1610	2660
INS + GNSS	4.93	14.8
INS + GNSS + Lane	2.78	7.42

3.2.3 결과 분석

시나리오 1과 2 모두 전체적으로 VO 기법들이 좋지 않은 성능을 보였는데, VINS와 DSO로 나누어서 더 자세히 분석한다

1) VINS

앞서 소개한 것과 같이 VINS는 feature 매칭 기반의 알고리즘이기 때문에, feature를 정확하게 잡아내는 것이 매우 중요하다. 하지만 Fig. 5의 좌측 그림에서도 확인할 수 있듯이, 고속도로 시나리오에서는 특징적인 feature가 없어서 주변의 움직이는 차량에 꽤 많은 feature를 두었는데, 주변 차량은 ego 차량에 대해서 상대적인 움직임이 있기 때문에, ego motion 추정에 큰 오차를 불러 일으킨다. 따라서 VINS 기반의 대조군들은 두 시나리오 모두에 대해서 큰 오차를 보인다.

2) DSO

DSO는 이미지 간의 photometric error를 기반으로 ego motion을 추정하기 때문에, 너무 어둡거나, 카메라로 들어오는 광량이 급격히 변화하는 시나리오에 취약하다. 시나리오 1 중반부에는 고가도로 밑을 지나갔고, 시나리오 2는 연속된 터널 3개를 지나면서 급격한 광량 변화 및 터널 내부 광량 부족 등으로 인해서 알고리즘이 좋지 않은 성능을 보였다. 이미지 내 feature에 의존적이지 않다는 점에서 VINS의 대안으로 제안되었지만, 여러 악의 조건이 포함된 일반적인 주행에 대해서는 그 취약점이 오히려 더 부각되었다.

3) INS + GNSS + Lane (제안한 방법)

본 연구에서 제안한 방법은 부정확한 GNSS 신호가 있는 경우에는 제거하고, GNSS 신호가 있는 구간이 anchor처럼 작용하여 GNSS 신호가 부정확하거나 단절된 구간의 정확성을 끌어올릴 수 있었다. 뿐만 아니라, 학습기반의 차선 인식 시스템을 활용하여 다양한 악의조건 상황에 대해서도 강건하게 차선 측정값을 획득할 수 있었고, INS + GNSS에 추가되어 차량의 횡방향 위치 추정 정확도를 향상할 수 있었다.

4. 결론

본 연구에서는 INS, GNSS, 학습기반 차선 인식 시스템을 융합하여 여러 악의조건이 포함된 시나리오에 대해서 차량의 주행 기록을 준수한 정확도로 복원하는 방법이 제안되었다. 특히 횡방향 차선 측정값을 활용하는 NLS 모델을 새롭게 구축하여 차량의 위치 추정 정확도를 추가적으로 향상하는데 기여했다. 제안한 모델의 성능을 검증하기 위해 다양한 악의조건이 포함된 고속도로 시나리오를 구성하였고, 기존 실내나 도심지에서 좋은 성능을 보이는 비전 기반의 알고리즘들과의 비교, 분석을 통해 검증하였다.

5. 부록

본 장에서는 2.2.3에서 다루었던 Lane NLS 모델의 대수적인 jacobian을 기존 IMU Preintegration⁴⁾의 방법을 활용하여 유도한 과정에 대해 소개한다.

5.1 Perturbation for R_i

$$\begin{aligned}
& \mathbf{r}_{\text{Lane}}(R_i \text{Exp}(\delta\phi_i)) \\
& \cong R_{i+1}^T (\mathbf{p}_i + R_i(1 + \delta\phi_i^\wedge) \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1}) \\
& + \lambda R_{i+1}^T R_i (1 + \delta\phi_i^\wedge) (\mathbf{L}_i^j - \mathbf{L}_i^{j+1}) - \mathbf{L}_{i+1}^j \\
& = \mathbf{r}_{\text{Lane}}(R_i) + R_{i+1}^T R_i \delta\phi_i^\wedge \mathbf{L}_i^{j+1} + \lambda R_{i+1}^T R_i \delta\phi_i^\wedge (\mathbf{L}_i^j - \mathbf{L}_i^{j+1}) \\
& = \mathbf{r}_{\text{Lane}}(R_i) - R_{i+1}^T R_i (\mathbf{L}_i^{j+1})^\wedge \delta\phi_i - \lambda R_{i+1}^T R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1})^\wedge \delta\phi_i \\
& = \mathbf{r}_{\text{Lane}}(R_i) - R_{i+1}^T R_i \{ (\mathbf{L}_i^{j+1})^\wedge + \lambda (\mathbf{L}_i^j - \mathbf{L}_i^{j+1})^\wedge \} \delta\phi_i \\
& \therefore \frac{\partial \mathbf{r}_{\text{Lane}}}{\partial \delta\phi_i} = -R_{i+1}^T R_i \{ (\mathbf{L}_i^{j+1})^\wedge + \lambda (\mathbf{L}_i^j - \mathbf{L}_i^{j+1})^\wedge \}
\end{aligned}$$

5.2 Perturbation for \mathbf{p}_i

$$\begin{aligned}
& \mathbf{r}_{\text{Lane}}(\mathbf{p}_i + R_i \delta\mathbf{p}_i) \\
& = R_{i+1}^T (\mathbf{p}_i + R_i \delta\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1}) \\
& + \lambda R_{i+1}^T R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1}) - \mathbf{L}_{i+1}^j \\
& = \mathbf{r}_{\text{Lane}}(\mathbf{p}_i) + R_{i+1}^T R_i \delta\mathbf{p}_i \\
& \therefore \frac{\partial \mathbf{r}_{\text{Lane}}}{\partial \delta\mathbf{p}_i} = R_{i+1}^T R_i
\end{aligned}$$

5.3 Perturbation for R_{i+1}

$$\begin{aligned}
& \mathbf{r}_{\text{Lane}}(R_{i+1} \text{Exp}(\delta\phi_{i+1})) \\
& \cong (1 - \delta\phi_{i+1}^\wedge) R_{i+1}^T (\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1}) \\
& + \lambda (1 - \delta\phi_{i+1}^\wedge) R_{i+1}^T R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1}) - \mathbf{L}_{i+1}^j \\
& = \mathbf{r}_{\text{Lane}}(R_{i+1}) - \delta\phi_{i+1}^\wedge R_{i+1}^T (\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1})
\end{aligned}$$

$$\begin{aligned}
& -\lambda \delta \phi_{i+1}^\top R_{i+1}^\top R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1}) \\
& = \mathbf{r}_{\text{Lane}}(R_{i+1}) + \left(R_{i+1}^\top (\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1}) \right)^\top \delta \phi_i \\
& + \lambda \left(R_{i+1}^\top R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1}) \right)^\top \delta \phi_i \\
& \therefore \frac{\partial \mathbf{r}_{\text{Lane}}}{\partial \delta \phi_i} = \left(R_{i+1}^\top (\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1}) \right)^\top \\
& \quad + \lambda \left(R_{i+1}^\top R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1}) \right)^\top
\end{aligned}$$

5.4 Perturbation for \mathbf{p}_{i+1}

$$\begin{aligned}
& \mathbf{r}_{\text{Lane}}(\mathbf{p}_{i+1} + R_{i+1} \delta \mathbf{p}_{i+1}) \\
& = R_{i+1}^\top (\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1} - R_{i+1} \delta \mathbf{p}_{i+1}) \\
& + \lambda R_{i+1}^\top R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1}) - \mathbf{L}_{i+1}^j \\
& = \mathbf{r}_{\text{Lane}}(\mathbf{p}_i) - \mathbf{I} \delta \mathbf{p}_{i+1} \\
& \therefore \frac{\partial \mathbf{r}_{\text{Lane}}}{\partial \delta \mathbf{p}_i} = -\mathbf{I}
\end{aligned}$$

5.5 Perturbation for \mathbf{L}_i^j

$$\begin{aligned}
& \mathbf{r}_{\text{Lane}}(\mathbf{L}_i^j + \delta \mathbf{L}_i^j) \\
& = R_{i+1}^\top (\mathbf{p}_i + R_i \mathbf{L}_i^{j+1} - \mathbf{p}_{i+1}) \\
& + \lambda R_{i+1}^\top R_i (\mathbf{L}_i^j + \delta \mathbf{L}_i^j - \mathbf{L}_i^{j+1}) - \mathbf{L}_{i+1}^j \\
& = \mathbf{r}_{\text{Lane}}(\mathbf{L}_i^j) + \lambda R_{i+1}^\top R_i \delta \mathbf{L}_i^j \\
& \therefore \frac{\partial \mathbf{r}_{\text{Lane}}}{\partial \delta \mathbf{L}_i^j} = \lambda R_{i+1}^\top R_i
\end{aligned}$$

5.6 Perturbation for \mathbf{L}_i^{j+1}

$$\begin{aligned}
& \mathbf{r}_{\text{Lane}}(\mathbf{L}_i^{j+1} + \delta \mathbf{L}_i^{j+1}) \\
& = R_{i+1}^\top (\mathbf{p}_i + R_i (\mathbf{L}_i^{j+1} + \delta \mathbf{L}_i^{j+1}) - \mathbf{p}_{i+1}) \\
& + \lambda R_{i+1}^\top R_i (\mathbf{L}_i^j - \mathbf{L}_i^{j+1} - \delta \mathbf{L}_i^{j+1}) - \mathbf{L}_{i+1}^j \\
& = \mathbf{r}_{\text{Lane}}(\mathbf{L}_i^j) + (1 - \lambda) R_{i+1}^\top R_i \delta \mathbf{L}_i^{j+1} \\
& \therefore \frac{\partial \mathbf{r}_{\text{Lane}}}{\partial \delta \mathbf{L}_i^{j+1}} = (1 - \lambda) R_{i+1}^\top R_i
\end{aligned}$$

5.7 Perturbation for \mathbf{L}_{i+1}^j

$$\begin{aligned}
& \mathbf{r}_{\text{Lane}}(\mathbf{L}_{i+1}^j + \delta \mathbf{L}_{i+1}^j) = \mathbf{r}_{\text{Lane}}(\mathbf{L}_{i+1}^j) - \mathbf{I} \delta \mathbf{L}_{i+1}^j \\
& \therefore \frac{\partial \mathbf{r}_{\text{Lane}}}{\partial \delta \mathbf{L}_{i+1}^j} = -\mathbf{I}
\end{aligned}$$

후기

이 연구는 교육부 및 한국연구재단의 4단계 두뇌 한국21 사업(4단계 BK21 사업) 연구비 지원, 산업기술혁신사업 캐빈교체형 자율셔틀 공용새시플랫폼 기술 개발 연구비 지원(20014983), 정부(산업통상자원부 및 한국산업기술평가관리원)의 재원으로 자율주행기술개발혁신사업단의 지원(20018181), 산업통상자원부와 한국산업기술진흥원의 미래형 자동차 튜닝부품 기술개발의 지원을 받아 수행된 연구임(P0021036)

References

- 1) T. A. Wenzel, K. J. Burnham, M. V. Blundell & R. A. Williams Dual extended Kalman filter for vehicle state and parameter estimation, *Vehicle System Dynamics*, 44(2), 153–171, 2006
- 2) Thrun S, Montemerlo M. The graph SLAM algorithm with applications to large-scale mapping of urban structures. *The International Journal of Robotics Research*, 25(5–6), 403–429, 2006
- 3) F. Dellaert and M. Kaess, “Factor graphs for robot perception,” *Foundations and Trends in Robotics*, vol. 6, no. 1–2, pp. 1–139, 2017
- 4) C. Forster, L. Carlone, F. Dellaert, and D. Scaramuzza, “Imu preintegration on manifold for efficient visual-inertial maximum-a-posteriori estimation.” *Georgia Institute of Technology*, 2015
- 5) D. M. Rosen, M. Kaess and J. J. Leonard, "RISE: An Incremental Trust-Region Method for Robust Online Sparse Least-Squares Estimation," in *IEEE Transactions on Robotics*, vol. 30, no. 5, pp. 1091–1108, Oct. 2014
- 6) Hwang, Y., Jeong, Y., Kweon, I.S., & Choi, S.B. Online Misalignment Estimation of Strapdown Navigation for Land Vehicle under Dynamic Condition. *International Journal of Automotive Technology*, 22, 1723–1733, 2021
- 7) P. Furgale, J. Rehder and R. Siegwart, "Unified temporal and spatial calibration for multi-sensor systems," *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*,

Tokyo, Japan, pp. 1280–1286, 2013

- 8) T. Qin, P. Li and S. Shen, "VINS–Mono: A Robust and Versatile Monocular Visual–Inertial State Estimator," in IEEE Transactions on Robotics, vol. 34, no. 4, pp. 1004–1020, Aug. 2018
- 9) T. Qin and S. Shen, "Online Temporal Calibration for Monocular Visual–Inertial Systems," 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pp. 3662–3669, 2018
- 10) J. Engel, V. Koltun and D. Cremers, "Direct Sparse Odometry," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 40, no. 3, pp. 611–625, 1 March 2018