

단일 센서 한계 극복을 위한 센서 신뢰도 기반 확률 융합 구조의 다중 센서 위치 추정 방법론

이 준 행¹⁾ · 김 재 혁¹⁾ · 변 진 규¹⁾ · 유 재 연¹⁾ · 이 동 현¹⁾ · 유 진 우^{*2)}국민대학교 자동차모빌리티대학원¹⁾ · 국민대학교 자동차IT융합학과²⁾

A Multi-Sensor Localization Methodology Based on Sensor Reliability-Driven Probabilistic Fusion Structure for Overcoming Single-Sensor Limitations

Junhaeng Lee¹⁾ · Jaehyeok Kim¹⁾ · Jingyu Byeon¹⁾ · Jaeyeon Yoo¹⁾ · Donghyun Lee¹⁾ · Jinwoo Yoo^{*2)}¹⁾Graduate School of Automobile and Mobility, Kookmin University, Seoul 02707, Korea²⁾Department of Automobile and IT Convergence, Kookmin University, Seoul 02707, Korea

(Received 8 September 2025 / Revised 2 October 2025 / Accepted 18 October 2025)

Abstract : Reliable localization in autonomous driving requires real-time, context-aware reweighting of heterogeneous sensors. This paper proposes a hierarchical fusion architecture that treats the outputs and dynamic covariances of two estimators—MSCKF-based VIO (OpenVINS) and EKF-based GNSS/INS (SBG Ellipse-D)—as observation models and fuses them with an Interacting Multiple Model (IMM) filter. In the dynamics layer, the IMM runs Constant Acceleration and Constant Turn models in parallel. In the observation layer, time-varying measurement covariance is injected into the likelihood to adapt mode probabilities and sensor weights without fixed sensor-priority rules. We employ statistical gating (Mahalanobis), covariance capping/scaling, and a gradual weight handover during GNSS outages to increase robustness to outliers and dropouts. In ROS-based road tests, the method consistently reduced Absolute and Relative Trajectory Errors against VIO-only and GNSS/INS-only baselines. Beyond accuracy, we quantify transition behavior and internal reasoning and yield improvements in Transition Stability Error, Re-convergence Time, and Model Probability Accuracy. Leveraging the dynamic reliability of the constituent estimators without prior shadow maps or fixed priorities, the approach jointly addresses maneuver and sensor uncertainties within a single Bayesian framework.

Key words : Vehicle localization(차량 위치 추정), Interacting multiple model(상호작용 다중 모델), GNSS-inertial navigation(GNSS-관성 항법), Visual-inertial odometry(시각-관성 주행거리측정), Dynamic measurement covariance(동적 측정 공분산), Real-time sensor reweighting(실시간 센서 가중 조정)

1. 서론

자율주행차량이 혼잡한 도심도로 내 안정적으로 주행하기 위해서는, 다양한 주행 환경에서 강인하고 정밀한 위치 추정 기술이 필수적이다.^{1,2)} 자율 주행 분야에서는 차량 위치 추정을 위해 위성의 절대 위치 · 속도로 IMU 적분 예측(자세 · 속도 · 위치)을 보정하는 GNSS/INS와 카메라 특징점 추적으로 얻은 상대 이동을 IMU와 융합하는 시각-관성 주행거리측정(Visual-Inertial Odometry, VIO) 등 다양한 추정 방법들이 사용된다.³⁾

각 추정 방식은 주행 환경과 조건에 따라 서로 다른 취약 구간을 가진다. GNSS/INS는 터널 · 교량 하부 등 위성 가시성이 낮은 구간에서 DOP(Dilution of Precision)가 악화되면서 측위 품질이 저하되고, 유효한 위성 신호가 순간 약해지거나 끊기면, 위치 추정을 보정하는 과정이 멈추거나 시스템이 순간 방향을 잃는 Dropout(신호 끊김 현상)이 발생할 수 있다.^{4,5)} 일반적으로 GNSS/INS는 장기 드리프트 억제에 장점이 있지만 이러한 환경적 변수에 매우 민감하다. VIO는 단기 정밀도와 연속성 확보에

*Corresponding author, E-mail: jwyo@kookmin.ac.kr

¹⁾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.

강점을 보이지만, VIO는 텍스처 결핍, 동적 물체 등에 민감하여 GNSS에 비해 추정 민감도가 높고, 시간이 지날수록 위치 오차가 누적되는(드리프트)에 대해 상대적으로 취약하다.^{6,7)}

실제 주행환경에서는 구간별로 어떤 센서를 신뢰할지 사전에 정하기 어렵고, 센서 신뢰도는 주변 환경과 차량의 기동 상태에 따라 비선형적으로 불규칙하게 변화한다.⁸⁾ 그러므로 고정 임계치나 사전 규칙에 의존한 센서 전환만으로는 실제 주행에서 요구되는 정확한 위치 추정을 보장하기 어렵다.

최근 차량의 상태 추정 방식의 한계성을 극복하기 위해 Tightly coupled 구조의 팩터 그래프 기반 공동 최적화를 중심으로, GNSS의 의사거리와 주파수 변화율 및 VIO의 IMU 사전적분(Preintegration)을 한 백 엔드에서 공동 최적화하여 장기 드리프트와 일시적 신호 손실에 강건하게 대응하는 방향으로 연구가 이뤄지고 있다.⁹⁻¹¹⁾ 또한 적응형 공분산(잡음) 추정을 통해 주행 중 센서 신뢰도 변화를 온라인으로 반영하고, 로버스트 최적화(예: 스위처블 제약, Dynamic covariance scaling)에 의거하여 이상치와 급격한 환경 변화에 대응한 안정성을 강화하는 연구도 진행 중이다.¹²⁻¹⁴⁾

본 연구는 EKF 기반 GNSS/INS와 MSCKF 기반 VIO가 산출한 상태 추정치와 시간 가변 측정 공분산 R_k 을 관측 신호로 사용하고, 상위 단계에서 상호작용 다중 모델(Interacting Multiple Model, IMM)로 융합하는 계층 구조를 제안한다. IMM은 예측 단계에서 등가속도(CA)와 등속회전(CT) 모델을 병렬 운용하고, 관측 단계에서 각 채널의 관측 오차와 공분산으로 계산한 가능도를 이용해 모드 확률을 온라인 갱신한 뒤, 갱신된 확률을 가중치로 하여 다음 단계의 상태와 공분산을 혼합하는 확률적 소프트 스위칭 기법이다. 본 연구에서는 이 가능도 갱신부에 하위 추정기(GNSS/INS, VIO)가 산출하는 R_k 를 기반으로 직접 갱신함으로써, 두 관측 채널의 신뢰도(공분산)가 베이저안 방식으로 자연스럽게 가중되도록 하였다. 즉, 신뢰도가 낮아져 R_k 가 커진 채널의 기여도는 자동으로 감소하고, 반대로 R_k 가 작은 채널의 비중은 증가하여, 실제 환경에서 안정적이고 연속적인 가중 재분배가 이루어진다. 추가로, 관측 공분산에 상한·스케일링을 적용하고, GNSS 신호 상실 시 가중을 시간적으로 점진 이양하는 전환 로직을 구성하여 신호 급변과 이상치에 대한 강건성을 강화하였다.

이와 같은 구조는 사전 규칙에 의존하지 않고 관측 신뢰도를 직접 반영하는 구조로써 환경 변화와 기동 변화 하에서 연속적이고 안정적인 위치 추정을 가능하게 한다.

2. 관련연구

2.1 필터 기반 예측과 다중모델 추정

2.1.1 단일-모델 필터 기반 상태 추정

칼만필터(Kalman Filter, KF)는 과거 상태와 현재 관측을 결합해 대상 상태를 추정하는 단일 모델 필터이다.¹⁵⁾ 본 필터는 자율주행 시스템에서 차량의 위치·자세 등 상태 추정에 실시간성·해석 용이성·계산 효율성의 장점으로 널리 사용된다.

$$x_k = F_{k-1}x_{k-1} + B_{k-1}u_{k-1} + w_{k-1}, \quad (1)$$

$$z_k = H_k x_k + v_k,$$

where x_k : state vector;

F_{k-1} : state transition;

B_{k-1} : control matrix;

u_{k-1} : control input;

w_{k-1} : process noise;

z_k : measurement;

H_k : measurement matrix;

v_k : measurement noise

식 (1)은 칼만 필터의 시스템의 상태가 시간에 따라 어떻게 변하고, 그 상태를 바탕으로 어떻게 관측값이 얻어지는지를 설명하는 모델이다. 첫 번째 식은 상태 예측을 나타내며, 이전 시점의 상태 x_{k-1} 와 외부 입력 u_{k-1} 을 바탕으로 현재 상태 x_k 를 계산한다. 이때, 상태가 시간에 따라 어떻게 변하는지를 나타내는 행렬 F_{k-1} 와, 입력이 상태에 미치는 영향을 나타내는 행렬 B_{k-1} 가 사용된다. 여기에 실제 시스템에서 발생할 수 있는 예측 오차나 불확실성을 반영하기 위해, 프로세스 잡음 w_{k-1} 이 추가된다.

두 번째 식은 관측 모델로, 예측된 상태 x_k 를 바탕으로 센서나 측정 장치를 통해 관측값 z_k 를 얻는 과정을 설명한다. 상태를 실제 관측값으로 변환하는 데 측정 행렬 H_k 가 사용되며, 이 과정 또한 센서의 오차나 외부 요인으로 인한 측정 잡음 v_k 가 함께 포함된다.

실제 주행 환경의 상태 추정은 비선형 요소가 크므로 KF의 확장형 필터가 필요하다. 대표적으로 EKF(Extended Kalman Filter)는 비선형 함수 $f(\cdot)$, $h(\cdot)$ 를 1차 테일러 근사로 선형화 하여 사용한다.¹⁶⁾

$$x_k = f(x_{k-1}, u_{k-1}) + w_{k-1}, \quad (2)$$

$$z_k = h(x_k) + v_k$$

where $f(\cdot)$: nonlinear state transition function;

$h(\cdot)$: nonlinear measurement function

식 (2)는 EKF에서 가정하는 비선형 상태·관측 시스템을 표현한 수식이며, 이전 상태와 제어 입력이 비선형 동역학 $f(\cdot)$ 을 통해 현재 상태를 예측하며, 비선형 측정 함수 $h(\cdot)$ 로 관측값을 생성하는 과정을 설명한다. EKF는 각 시점에서 1차 테일러 전개를 통해 선형화한 뒤, 식 (3) 표현처럼 상태 야코비안 F_{k-1} 와 관측 야코비안 H_k 을 계산한 뒤 선형 칼만 필터와 동일한 예측-보정 절차를 적용한다.

$$F_{k-1} = \left. \frac{\partial f}{\partial x} \right|_{\text{current estimate}}, H_k = \left. \frac{\partial h}{\partial x} \right|_{\text{current estimate}} \quad (3)$$

그 외, 확률 분포를 시그마 포인트로 근사하여 비선형성에 보다 강점을 보이는 UKF(Unscented Kalman Filter), 상태 오차 추정 기반으로 계산 안정성을 높인 ESKF (Error-State Kalman Filter)가 있다. 최근 연구에서는 상태 (자세, 위치 등)를 Lie 군(SE(3)) 불변성 기반의 IEKF (Invariant EKF)등 비선형성 상태 추정을 위한 KF 기반의 다양한 구조들이 연구되고 있다.^{17,18)}

2.1.2 모델 통합 프레임 워크

단일-모델 필터는 관측-예측 통합에는 강하지만, 고정된 동역학 모델만으로는 시간에 따라 섞여 나타나는 직선 주행·가감속·선회 등 다양한 기동과 환경 변화에 따라 오동치는 센서 신뢰도를 유연하게 반영하기 어렵다. 이 한계를 보완하고자, 최근에는 복수의 추정기를 상위 계층에서 통합해 각 출력과 신뢰도를 함께 고려하는 모델 통합 프레임 워크가 활발히 연구되고 있다.¹⁹⁾

모델 통합 프레임워크는 복수의 상태 추정기를 병렬 또는 계층적으로 운용하며, 각 필터의 출력 및 신뢰도를 종합하여 최종상태를 결정하는 구조를 갖는다. 대표적인 구현 방식은 다음과 같이 분류될 수 있다.

- 선택 기반 구조(Selector-based): 여러 필터 중 신뢰도가 가장 높은 하나를 선택
- 가중 평균 기반 구조(Weighted average): 각 추정 결과에 확률 기반 가중치를 부여해 최종 상태를 산출^{20,21)}
- 메타 필터 구조(Meta-filter): 상위 계층에서 하위 필터의 출력을 입력으로 받아 또 다른 필터링 수행
이러한 접근은 차량의 기동이 급격히 변하거나 관측 데이터가 부족한 상황에서도 상위 계층에서의 적응 능력을 통해 안정적인 추정을 가능하게 한다는 점에서 강점을 가진다.

2.1.3 Interacting Multiple Model (IMM)

단일-모델 필터 기반 상태추정은 비 선형적인 움직임을 가지고 있는 실제 차량 상태를 예측하기에는 한계가 있다. 이의 한계를 극복하기 위해 서로 다른 동역학 다중 모델을 동시에 운용하며, 각 시점마다 현재 차량의 상태와 운용하고 있는 다중 모델의 적합성(확률기반)을 바탕으로 차량 상태 예측을 진행하는 IMM 필터를 사용한다.^{22,23)}

IMM은 Fig. 1에서와 같이 다음 세 단계의 절차로 구성된다:

1. 개별 필터링 단계:

사전에 정의된 복수의 동역학 모델에 따라 각 하위 필터들이 독립적으로 예측-보정을 진행하고, 모델별 상태 추정치와 공분산을 출력한다.

2. 상호작용 단계(Interaction/Mixing):

전이 확률 행렬을 기준으로 각 하위 필터의 초기 상태 공분산을 혼합하여, 시간에 따른 모델 전환 가능성을 반영한다.

3. 출력 통합 단계(Fusion):

하위 필터에서 산출된 적합도를 관측 가능도(Likelihood) 기반으로 판별하여, 각 하위 필터에서 산출된 상태 공분산 값을 가중 평균해 최종 결과를 산출한다.

IMM은 매 시점의 관측 및 예측 정합도(혁신과 그 공분산으로 계산한 우도)를 이용해 모드 확률을 갱신하고, 이를 가중으로 상태와 공분산을 확률적으로 혼합하므로, 시간에 따라 변하는 기동 조건에 능동적으로 적응한다. 이때 하위 추정기가 보고하는 시간 가변 측정 공분산 R_k 이 신뢰도 신호로 작용하여, R_k 가 커진(신뢰도 저하) 채널의 기여도는 자동으로 감소하고 R_k 가(신뢰도 높음) 채널의 비중은 증가하여 연속적 가중 재분배가 이루어

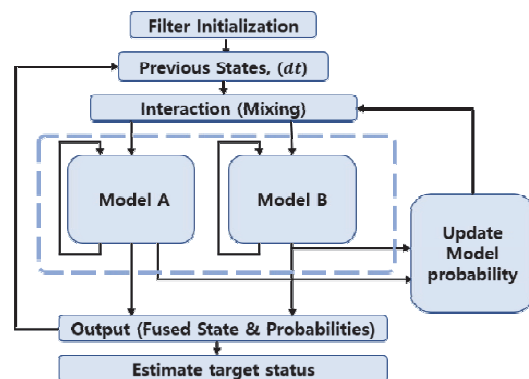


Fig. 1 IMM filter process

진다. 이러한 특성으로 IMM은 단일-모델 필터 대비 예측 안정성과 추정 안정성에서 우수한 성능을 보인다.²⁴⁻²⁶⁾

IMM의 상위 융합은 모드 확률 기반 가중 평균 구조이기 때문에, 실제 센서 관측에서 발생하는 이상치·신호 급변에 대해 마할라노비스 게이팅, 공분산 상한·스케일링, 가중 보정 등을 일관되게 적용하기 용이하다. 본 연구는 이 장점을 활용하여 GNSS/INS-EKF와 VIO-MSCKF가 보고하는 시간 가변 R_k 을 정합도 계산부에 직접 주입함으로써, 휴리스틱 스위칭 없이 센서 신뢰도 변화를 베이직안하게 반영하는 상위 통합을 구현하였다.

2.2 GNSS-INS 절대위치 추정 및 통합

2.2.1 Global Navigation Satellite System (GNSS)

GNSS는 위성으로부터 도달한 신호의 코드 기반 의사 거리와 반송파 위상 관측을 결합하여 수신기의 위치와 시각 오차를 추정하며, 차량에 절대 좌표를 낮은 샘플링으로 제공한다.^{27,28)} 추정 정확도는 수신 가능한 위성 수와 위성 배치의 기하적 구조에 크게 영향을 받는다. 이러한 영향은 DOP지표를 통해 정량화 할 수 있다. 수신 정확도를 높이기 위해, 고정된 기지국(Reference station)의 관측 데이터를 활용해 오차를 보정하고, 위성 신호 간의 세밀한 위상 차이를 정밀하게 계산하는 RTK(Real-Time Kinematic) 보정 기법을 적용하면, 수 센티미터(cm) 수준의 고정밀 위치 추정이 가능하다.²⁹⁾

그러나 GNSS는 위성 신호에 본질적으로 의존하는 특성을 가지므로, 터널, 교량하부, 도심 협곡과 같은 환경에서는 신호 가시성 저하 및 다중경로 오차로 인해 정확도 저하 및 위치 추정이 중단되는 현상이 발생할 수 있다.

또한, 위성 신호의 방송 주기와 수신기의 내부 처리 지연(RF 파이프라인) 등의 구조적 제약으로 인해, 단독 GNSS 운용 시에는 위치 정보의 갱신 주기가 낮다는 한계도 존재한다.

2.2.2 Inertial Navigation System (INS)

INS는 IMU로부터 얻는 가속도와 각속도 데이터를 이용하여, 연속적인 운동 방정식을 이산화 및 적분함으로써 자세, 속도, 위치 정보를 높은 샘플링으로 산출하는 항법 체계이다.

일반적으로 사용되는 고정형 INS 구조(Strapdown)에서는, 차량 좌표계 기준으로 측정된 가속도를 자세 정보로 이용하여 지도 좌표계로 변환한 후, 중력 보정을 거쳐 속도를 적분하고, 이를 다시 적분하여 위치를 계산한다.³⁰⁾ 또한, 자이로스코프는 각속도를 적분하여 자세를

지속적으로 갱신한다. 이처럼 높은 연산 주기는 단기 기동 상황에 대한 연속 추정에 강점을 가진다.

한편 INS 오차는 바이어스, 스케일 팩터, 정렬 오차(Misalignment) 및 측정 잡음이 적분되며 시간에 따라 누적된다. 전형적으로 속도 오차는 선형적으로, 위치 오차는 이차적으로 성장하여 절대 위치 앵커가 없는 단독 운용에서는 장기 정확도가 제한된다. 결과적으로 INS는 높은 샘플링의 연속 예측 채널로서 단기적인 기동 추정에는 강점을 가지지만, 장기적인 드리프트를 억제하기 위해서는 외부관측을 통한 주기적 보정이 필수적이라는 한계를 지닌다.

2.2.3 GNSS-INS EKF 통합

이러한 상호 보완 관계를 활용하는 표준적 접근이 GNSS-INS 통합이며, 일반적으로 EKF로 구현된다.^{31,32)} EKF는 예측 단계에서 IMU 동역학을 이용해 상태와 예측 불확실성 공분산을 높은 샘플링으로 전파하고, 보정 단계에서 GNSS(또는 RTK-GNSS)의 낮은 샘플링의 절대 위치/속도를 관측으로 반영해 상태를 갱신한다. 이 구조에서는 GNSS 신호가 일시적으로 끊기거나 낮은 샘플링으로만 제공되는 구간에서도, INS의 연속적인 예측을 통해 차량 궤적을 끊임없이 이어갈 수 있다. 또한 GNSS 신호가 다시 정상적으로 수신된다면, 절대 위치 정보와 보정하여 누적된 드리프트 오차를 보정한다.

EKF는 상태 추정치와 그에 대응하는 공분산 행렬 $P_{(k|k)}$ 을 함께 산출해 추정의 불확실도를 정량화 한다.^{33,34)} 공분산 행렬의 대각 성분(분산)은 각 상태 성분의 불확실성을 나타내며, 비 대각 성분(공분산)은 변수 간 상관성을 의미한다.

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (4)$$

where K_k : Kalman gain;
 $P_{k|k-1}$: predict error covariance

식 (4)에서 보듯 K_k 는 예측 불확실도 $P_{k|k-1}$ 와 관측 잡음 공분산 R_k 의 상대적인 크기에 의해 자동으로 조정되므로, 관측 불확실도가 크면 이득이 작아져 해당 관측의 영향이 줄고, 반대로 예측 불확실도가 크면 관측에 더 크게 의존하게 한다.

공분산이 안정적으로 수렴하면 모델과 관측이 잘 부합함을 의미하며, 반대로 증가하거나 발산할 경우에는 센서 성능 저하나 모델 불일치를 의미한다.

따라서 EKF 기반 GNSS-INS 통합은 GNSS의 절대 위치 정보와 INS의 높은 샘플링 기반 연속 예측을 상호 보

완적으로 결합할 뿐만 아니라, 공분산 행렬을 통해 추정 결과의 신뢰도까지 함께 제공한다는 장점을 가진다.

2.3 Visual Inertial Odometry (VIO)

VIO³⁵⁾는 카메라와 IMU의 상호 보완적 결합을 통해 이동체의 자세, 속도, 상대 위치를 추정한다. 카메라는 장면의 특징점이나 패턴을 이용해 기하학적 제약을 제공하지만, 환경 요인(조명 변화, 텍스처 부족, 동적 물체)에 따라 특징점 추출 및 추적의 신뢰도가 저하되는 한계를 가진다.

IMU는 높은 샘플링 기반 단기 기동을 안정적으로 추적할 수 있으나, 적분 과정에서 드리프트가 누적되는 한계를 가진다. 두 센서를 결합한 VIO는 이러한 한계를 상호 보완함으로써, GNSS/GPS 성능이 저하되거나 가용하지 않은 구간에서도 연속적인 추정과 일정 수준의 강건성을 제공한다.

VIO 알고리즘은 크게 최적화 기반과 필터링 기반으로 나눌 수 있다. 최적화 기반 접근은 VINS-Fusion, ORB-SLAM3^{36,37)} 등에서 볼 수 있듯, 시간 윈도우(또는 그래프)에 누적된 관측을 통합 최소화하여 상태를 추정한다. 충분한 관측이 축적되면 재최적화를 통해 누적 오차를 줄일 수 있으며, 특히 SLAM 계열은 루프 클로저를 통해 장기 드리프트를 효과적으로 억제한다.^{38,39)}

반면 필터링 기반 접근은 MSCKF 계열(OpenVINS 등)⁴⁰⁾처럼 관측이 도착할 때마다 예측-보정을 순차적으로 수행한다. 이 방식은 상태 추정과 함께 공분산을 동시에 산출하여 불확실도 관리가 내재화 되어 있으며, 계산 비용이 상대적으로 적어 실시간성 확보에 유리하다. 그러나 두 계열 모두 근본적으로 상대 위치 추정(odometry)에 의존하기 때문에, 장기 운용에서는 드리프트 누적을 피하기 어렵다.

3. 제안하는 위치 추정 방법론

3.1 센서 신뢰도 반영을 위한 융합 아키텍처

본 논문에서 제안하는 시스템은 다양한 주행 환경에서 연속적이고 강건한 위치 추정을 달성하기 위해, GNSS/INS와 VIO의 두 관측을 융합한다. 핵심은 특정 상황에서 어떤 센서를 규칙기반 전환에 의존하지 않고, 각 관측이 시점별로 제공하는 시간 가변 측정 공분산 $R_k^{(s)}$ 을 신뢰도 신호로 사용하여 확률적으로 가중치를 조정하며, 직선·가감속·선회 등 다양한 기동 및 불확실한 센서 상태 변화에 유기적으로 대응하는 것이다.

본 아키텍처는 예측(동역학) 모델 그룹과 관측 모델 그룹으로 구성되며, Fig. 2에 제시한 구조와 같이 단일 IMM 필터로 유기적으로 결합된다. IMM은 각 시점의 관

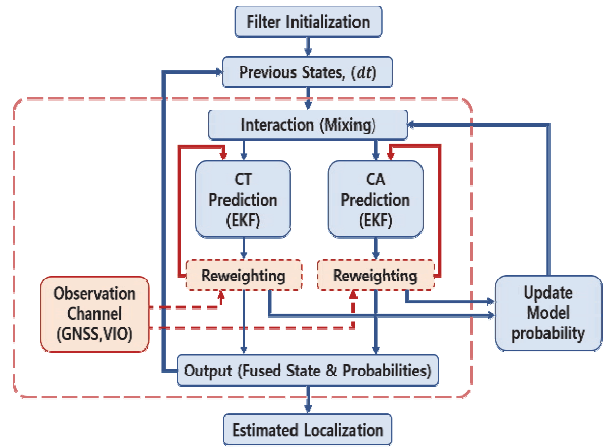


Fig. 2 Proposed system architecture

측 가능도로부터 모델 가중치를 갱신하고, 동역학 (CA/CT)과 관측(GNSS/INS, VIO)을 확률적으로 결합하여 최종 상태 추정을 산출한다.

예측(동역학) 모델 그룹은 차량의 실제 기동을 반영하기 위해 등가속도(Constant Acceleration, CA)와 등속선회(Constant Turn, CT)의 두 모델을 사용하며, IMM이 두 모델을 병렬 운용하고 시점별로 관측과 예측의 부합 정도를 바탕으로 모델 확률을 갱신한 뒤, 갱신된 확률을 가중치로 하여 두 모델의 상태와 공분산을 단일 추정으로 통합한다.

관측 모델 그룹의 핵심은 Observation channel의 설계이다. 본 시스템은 Raw 센서 값을 직접 사용하는 대신, 각 센서 전용의 하위 추정기(GNSS/INS의 EKF, VIO의 MSCKF)가 산출한 Odometry 추정치와 대응되는 공분산 값을 상위 IMM의 의사 관측으로 사용한다. 구체적으로, 하위 추정기의 결과를 정렬 행렬 $S^{(s)}$ 로 상위 상태에 맞춘 의사 관측 $z_k^{(s)}$ 와 그 측정 공분산 $R_k^{(s)}$ 로 정의한다(식 (5)). 상위 필터의 관측 모델은 식 (6)으로 표현된다.

$$z_k^{(s)} := S^{(s)} \hat{x}_{k|k}^{(s)}, \quad R_k^{(s)} := S^{(s)} P_{k|k}^{(s)} S^{(s)T} \quad (5)$$

where $S^{(s)}$: state alignment matrix;
 $z_k^{(s)}$: pseudo-measurement;
 $R_k^{(s)}$: measurement covariance

$$z_k^{(s)} = H_k^{(s)} x_k + v_k^{(s)}, \quad v_k^{(s)} \sim N(0, R_k^{(s)}) \quad (6)$$

where $H_k^{(s)}$: measurement Jacobian;
 $v_k^{(s)}$: measurement noise

식 (5), (6)에 따라, IMM은 상위 추정기로서 하위 추정기의 결과를 입력으로 받아, 센서 신뢰도의 시변적 변화를 가중치-보정 루프에 직접 반영한다. 이를 통해 특정 상황에서 센서 품질이 저하되더라도, IMM은 하드 스위치 없이 자연스럽게 가중치를 조정하며 연속적이고 안정적인 상태 추정을 유지한다.

3.2 확률적 IMM 기반 추정 프레임워크

본 시스템은 Fig. 3과 같이, 예측 모듈과 관측 모듈을 단일 확률적 추정 루프로 결합하고, 관측의 시간 가변 측정 공분산 R_k 을 동시 추정하도록 구성하였다. 본 시스템의 구성은 매 시점의 R_k 변화가 동일 루프에서 칼만 이득 K_k 및 동역학 모듈 가중치에 즉시 반영되어, 환경 변화에 따른 가중 조정 지연을 최소화한다.

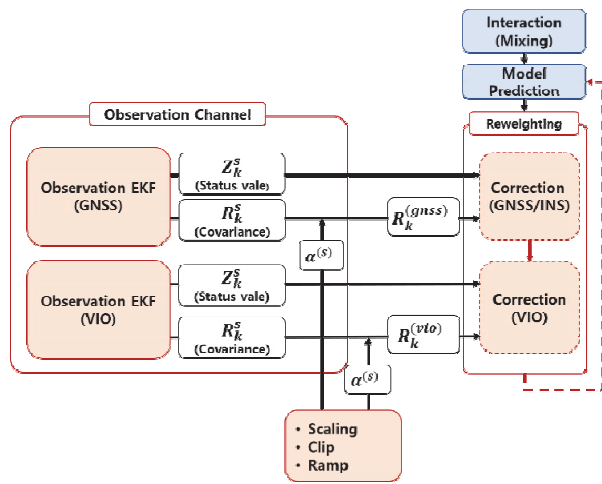


Fig. 3 IMM filtering with adaptive observation reweighting

3.2.1 동적 모델 혼합(Interaction/Mixing) 절차

동적 모델 혼합 단계의 목적은 예측 시각 k 에서 사전에 정의한 다중 예측 모델(등가속도, 등속선회)의 초기 상태와 초기 공분산을 일관되게 구성하는 데 있다. 본 단계에서는 직전 시각의 모델 비율과 전이 확률을 함께 고려하여, 각 하위 필터의 초기 조건을 인접 모델의 추정치와 가중 결합으로 설정한다. 즉, 각 예측 모델은 자신의 직전 결과를 주로 반영하되, 다른 모델로의 전환 가능성에 비례하는 비중을 소량 포함하도록 초기값을 구성한다. 이 절차는 실제 주행에서 모델 전환 구간의 불연속을 억제하고 응답성을 개선하며, 이후 보정 및 가중 갱신 단계의 수렴 안정성을 높이는 효과를 갖는다.

3.2.2 신뢰도 기반 적응형 보정 및 가중 업데이트

본 단계에서는 예측된 상태를 두 관측(GNSS/INS,

VIO)에 대해 순차 보정한다. 보정 순서는 GNSS/INS를 먼저 적용해 절대 위치 기준을 확보한 뒤, VIO로 세밀한 보정을 수행하는 방식이다. 각 보정 시, 전단 추정기가 추정하는 시점 별 측정 오차 공분산을 신뢰도 지표로 사용하며, 잔차를 정규화해 보정 이득과 IMM 모델 비중을 즉시 갱신한다.

관측 값이 비정상적으로 크게 벗어난 경우에는 마할라노비스 거리(정규화 잔차 제곱)에 기반한 임계 값 검증을 적용해 해당 관측을 배제한다. 이는 일종의 통계적 필터링(Gating) 절차로, 센서 품질의 급변, 노이즈 스파이크, 점프 현상과 같은 상황에서도 수렴성과 강건성을 유지하도록 한다.

1. 스케일링:

센서 별 추정 모듈(EKF, MSCKF 등)이 산출한 공분산은 일관성 검증 절차를 통해 센서 신뢰도를 점검하고, 그 결과에 따라 보정 계수 $\alpha^{(s)}$ 를 적용하였다. 이에 따라 GNSS는 공분산이 축소 ($\alpha^{(GNSS)} < 1$), VIO는 확대 ($\alpha^{(VIO)} \geq 1$)되는 방향으로 조정된다. GNSS 부재 시에는 $\alpha^{(VIO)}$ 를 시간 함수로 점진적으로 변화시켜 VIO의 비중을 늘린다

2. 상 · 하한(Clip) :

요소별 R_{min}, R_{max} 를 적용해 이상치 급변으로 인한 과도 반응을 억제한다.

3. 램프 전이

GNSS 드롭 아웃 이후 경과시간에 따라 $\alpha_k^{(VIO)}$ 를 선형 램프로 변화시켜 VIO 영향력을 부드럽게 이양하고, 복귀 시 역방향 램프로 복원한다.

이러한 구성에 의해 가중은 규칙 기반 스위치 없이 연속적으로 이동하며, 관측 품질 변동과 기동 변화에 능동적으로 적응한다.

위 정책에 의해 가중은 규칙 기반 스위치 없이 연속적으로 이동하며, 관측 품질 변동과 기동 변화에 동시에 적응한다.

3.2.3 가중 통합을 통한 최종 상태 추정

순차 보정 및 가중 갱신이 완료되면, IMM은 두가지 동역학 모델을 병렬로 유지하여, 이전 시점에서의 비율을 전이 확률로 갱신한 뒤, 잔차와 그 분산을 통해 이번 관측과 더 유사한 모델 예측에 비율을 더 크게 부여한다. 이렇게 얻은 모델 비율 $\mu_i(k)$ 을 가중치로 하여 최종 상태 추정을 통합한다(식 (7)).

$$\hat{x}_{k|k} = \sum_{i \in \{CA, CT\}} \mu_i(k) \hat{x}_{i,k|k} \quad (7)$$

where $\hat{x}_{i,k|k}$: state estimate of the i_{th} model;

$\mu_i(k)$: model probability at time

최종 상태는 각 모델 추정치를 가중 평균한 값으로 계산된다.

해당 상태에 대응하는 공분산은 다음과 같이 주어진다.

$$P_{klk} = \sum_i \mu_i(k) [P_{i,klk} + (\hat{x}_{i,klk} - \hat{x}_{klk})(\hat{x}_{i,klk} - \hat{x}_{klk})^T] \quad (8)$$

where $P_{i,klk}$: model- i th covariance

식 (8)은 개별 모델의 불확실성뿐 아니라 모델 간 불일치까지 함께 고려한 공분산을 산출한다. 따라서 최종 IMM 추정치는 모델 적합도에 따라 가중된 단일 상태로, 신뢰도가 자연스럽게 반영된 결과를 제공한다.

4. 실험

4.1 실험 목적

본 연구의 핵심 목표는 제안하는 IMM기반 융합 필터가 GNSS 신호 가용성이 급변하는 실제 도심 환경에서 각 센서의 신뢰도를 얼마나 효과적으로 판단하고 동적으로 전환하는지를 검증하는 데 있다. 이를 위해, GNSS 신호가 양호한 구간, 미약한 구간, 완전히 차단되는 구간이 연속적으로 나타나는 시나리오에서 실험을 진행하고, 제안하는 방식이 기존 시스템 대비 위치 추정의 정확성과 강건성 측면에서 갖는 우수성을 정성적, 정량적으로 입증하고자 한다.

4.2 실험 환경

실험은 대한민국 서울특별시 성북구에 위치한 국민대학교 주변의 실제 도로환경에서 진행되었다. 실험 플랫폼에는 듀얼 안테나 RTK GNSS/INS 장비인 SBG Ellipse-D와 전방 Razer Kiyo 카메라를 탑재하였다. Ellipse-D는 이중 주파수 GNSS와 다중 위성 항법체계를 통합한 관성항법 장치로, RTK 기준 수평 위치 정확도 약 1 cm + 1 ppm, 롤/피치 0.05°, 헤딩 0.2° 수준의 성능을 제공한다. 본 실험에서의 GNSS 데이터는 제안하는 융합 구조의 성능을 확인하기 위해 듀얼 안테나 및 RTK 기능을 비활성화하고, 단독 GNSS 신호만을 사용하였다. Razer Kiyo는 1080p 30 fps 이미지 데이터를 제공하며, 이는 OpenVINS의 입력 사양을 충족한다. 또한, 모든 센서 데이터는 ROS환경에서 진행되었다.

실험 경로는 제안하는 알고리즘의 강건성을 평가하기 위해 다양한 GNSS 신호 가용성 시나리오를 포함하도록 설계되었다. 실험 경로에는 개방된 도심 구간(신호 안정




Fig. 4 Experiment testbed trajectory

적), 교량 하부와 같은 구조물 환경(다중 경로 및 신호 감쇠로 인한 품질 저하), 그리고 터널 내부(신호 완전 차단)가 모두 포함된다. 실험 경로의 궤적은 Fig. 4에서 확인할 수 있으며, 이러한 조건은 실제 주행환경에서 발생하는 대표적 GPS 열악 상황을 재현하여 제안 기법을 평가하기에 적합한 테스트베드를 제공한다.

4.2.1 데이터 소스

상기 기술된 실험환경에서 수집된 데이터로부터 두 종류의 Odometry를 실시간으로 추출하여 다음 아래 두 가지 비교군을 사용하였다.

1. GNSS/INS Odometry: SBG Ellipse-D의 EKF 출력을 통해 생성된 절대 위치 기반 Odometry.
2. VIO: OpenVINS 알고리즘에 입력하여 생성된 상대 위치 기반 Odometry

4.2.2 데이터 전처리

- Ground truth 생성: 평가의 기준이 되는 Ground truth 궤적은 SBG 장비의 원본 EKF 출력을 기반으로, 위성 지도 상의 명확한 지점을 기준으로 수동 보정하는 후처리 과정을 거쳐 생성되었다.

- 시간 동기화: 서로 다른 샘플링으로 발행되는 모든 센서 데이터는 고주파의 IMU 타임스탬프를 기준으로 공통 마스터 시간 축을 생성하여 동기화 하였다.

- 좌표계 정렬 및 드리프트 보정: 각 Odometry의 상대 좌표계 궤적은 Ground truth의 절대 좌표계와 정합시키기 위해 유사 변환(Similitude transformation)을 적용하여 정렬하였다. 특히 VIO의 경우 장기적인 드리프트가 필터의 초기 성능에 미치는 영향을 배제하고 GPS 신호 단절 시의 융합 성능에 집중하기 위해, Ground truth와의 저

주파 오차 성분을 제거하는 초기 드리프트 보정을 수행하였다.

4.3 실험 평가

제안하는 필터의 다각적인 성능을 입증하기 위해, 다음과 같은 지표를 사용하여 평가를 수행하였다.

- ATE(Absolute Trajectory Error):

추정된 궤적 \hat{p}_k 과 Ground truth p_k^{GT} 간의 전역적인 차이를 식 (9)으로 정의하며, 시스템의 전반적인 정확도를 평가한다.

$$ATE_k = \|\hat{p}_k - p_k^{GT}\|_2, \quad ATE = \frac{1}{N} \sum_{k=1}^N ATE_k \quad (9)$$

where \hat{p}_k : estimated position;

p_k^{GT} : ground-truth position;

$\|\cdot\|_2$: Euclidean norm (m);

N : number of samples

- RPE(Relative Pose Error):

고정 간격 Δt 동안의 상대적인 이동량 오차를 식 (10)로 정의하며, 시간에 따른 드리프트 누적 정도와 국소적 일관성을 평가한다, 또한 RPE의 궤적은 구간별 상대 이동 경로를 의미한다.

$$RPE_{k(\Delta k)} = \|(\hat{p}_{k+\Delta t} - \hat{p}_k) - (p_{k+\Delta t}^{GT} - p_k^{GT})\|_2 \quad (10)$$

$$RPE(\Delta k) = \frac{1}{N - \Delta k} \sum_{k=1}^{N - \Delta k} RPE_k(\Delta k)$$

where Δk : sample stride for RPE

- TSE(Transition Stability Error):

GNSS 신호가 단절되거나 복귀하는 과도기 구간에서 나타나는 최대 오차 피크를 구간별로 뽑아 평균함을 식 (11)과 같이 정의하여, 센서 전환시의 안정성을 평가한다.

$$T = \{\tau_1, \dots, \tau_M\}, \quad TSE = \frac{1}{M} \sum_{i=1}^M \max_{t \in \tau_i} \|\hat{p}_t - p_t^{GT}\|_2 \quad (11)$$

where T : set of GNSS transient intervals;

τ_i : the i_{th} transient interval;

M : number of transient intervals

- RCT(Re-convergence Time):

GNSS 신호가 복귀한 후, 추정 궤적이 기준 궤적에 대해 허용 오차 ε 이하로 다시 수렴하는 데 걸리는 시간을 식 (12)로 정의하며, 시스템의 회복 탄력성과 반응 속도를 평가한다.

$$R = \{r_1, \dots, r_L\} \quad (12)$$

$$t^*(r) = \min \{k \geq : \|\hat{p}_k - p_k^{GT}\|_2 < \varepsilon\}$$

$$RCT(\varepsilon) = \frac{1}{L} \sum_{r \in R} (t^*(r) - r)$$

where R : set of GNSS return indices;

L : number of returns;

ε : re-convergence threshold

- MPA(Model Probability Accuracy):

필터의 내부 IMM이 추정된 차량의 주행 모델(CA, CT)이 실제 주행 레이블과 일치하는 비율을 퍼센트로 측정한다. 이는 식 (13)으로 정의되며, 필터의 내부 판단 정확도 및 지능을 평가한다.

$$d_k = \arg \max_{i \in \{CA, CT\}} \mu_{i,k}, \quad g_k = \begin{cases} CT, & |\psi_k| > \omega_{th}; \\ CA, & otherwise \end{cases} \quad (13)$$

$$MPA = \frac{100}{N} \sum_{k=1}^N 1[d_k = g_k].$$

where d_k : IMM-selected mode at k ;

g_k : ground-truth mode at k ;

$\mu_{i,k}$: IMM mode- i prob. at k ;

ψ_k : ground-truth yaw rate;

ω_{th} : turn threshold;

$1[\cdot]$: indicator;

N : number of evaluated samples

4.3.1 정성적 평가(Qualitative Evaluation)

GNSS/INS(EKF) 기반 ATE 히트맵(Fig. 5)은 개활지 구간에서 전반적으로 낮은 오차 분포(청색 계열)를 나타내며, GNSS 수신 환경이 양호할 경우 안정적인 위치 추정 성능을 확보함을 보여준다. 반면, A구간(터널)에서는 구조물 차폐로 인한 위성 신호의 완전 단절로 인해 GNSS 관측이 불가능해지며, 이에 따라 INS 단독에 기반한 관성 전파만으로 궤적의 연속성이 유지된다. C구간(교량하부)에서는 다중 경로 및 가시 위성 부족, 위성 기하구조의 열화로 인해 GNSS 관측의 품질이 급격히 저하되며, 반복적인 관측 잔차 과다로 인해 EKF의 게이팅

(Gating) 절차, 즉 예측값과 관측값 간 차이가 통계적 임계값을 초과할 경우 관측을 제외하는 메커니즘에 의해, 관측이 지속적으로 배제된다. 그 결과 30초 간의 유효 GNSS 관측 부재 구간이 발생하였다.

또한, 시간-ATE의 변화 그래프(Fig. 6)에서도 전반적인 개활지 공간에서는 낮은 ATE값(1이하, 청색)의 값을 보이며, 음영구역의 진입부터 선형적으로 ATE값이 상승 폭을 이루다 다시 양호한 수신 환경으로 복귀하며 ATE 값이 감소하면 정상 수준으로 수렴함을 보인다.

VIO(MSCKF)의 기반 ATE 히트맵(Fig. 7)은 전 구간에서 궤적의 연속성이 유지되었으나, 특정 지점에서 ATE가 순간적으로 상승하는 불안정한 구간이 반복적으로 관찰된다. 이는 크게 두 가지 환경적 요인에 기인한 것으로 분석된다. C구간(교량 하부 구간)과 같이 시작적으로

정적인 구조물로 이루어져 유효한 특징점의 밀도가 낮은 구간에서는 관측 업데이트가 제한되어 일시적인 추정 정확도 저하가 발생한다. B구간(정상 주행 구간)에서의 상·하부 궤적을 비교한 결과, 환경의 특징점은 분포는 유사함에도 불구하고, ATE의 값이 서로 다를 수 있다. 이는 OpenVINS와 같이 특징점 기반 필터 구조는 정합 가능한 시간 정보에 강하게 의존하기 때문에, 시간이 경과함에 따라 누적 오차가 점차 축적되고, 이에 따라 ATE 값이 서서히 증가하는 현상을 확인하였다.

또한 시간-ATE 변화 그래프(Fig. 8)에서도 확인할 수 있듯이 초기 VIO는 정상 궤적으로 감소를 하지만 주행 중 특징점의 초기화 과정에서 업데이트 실패 이후 누적 오차의 영향으로 ATE값이 불안정 상태(1이상 녹색-황색)를 띤다, 또한 이전 GNSS/INS 기반의 ATE-시간 그래

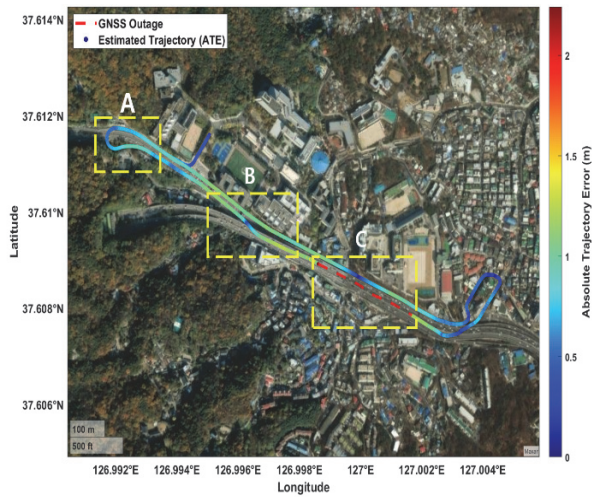


Fig. 5 ATE heatmap of GNSS/INS (EKF)-based trajectory

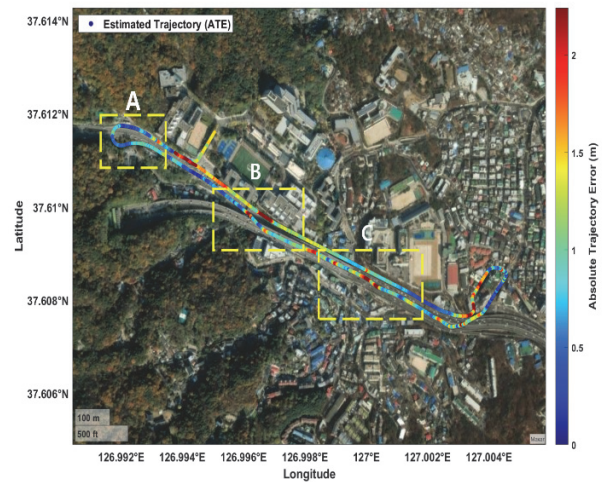


Fig. 7 ATE heatmap of VIO (MSCKF)-based trajectory




Fig. 6 ATE-time profile of GNSS/INS (EKF)-based trajectory




Fig. 8 ATE-time profile of VIO-only trajectory

프와 비교했을 때보다 상대좌표의 업데이트 원리의 한계성으로 인해 절대좌표 기반의 업데이트보다 노이즈가 더욱 큰 제적임을 보인다.

제안된 IMM 융합 방식의 ATE 히트맵(Fig. 9)은 전 구간에 걸쳐 전반적으로 짙은 청색 계열을 나타내며, 이는 기존 GNSS/INS 및 VIO 시스템 대비 우수한 위치 추정 정확도를 달성했음을 시사한다. 특히 GNSS/INS와 VIO의 신뢰도가 모두 높은 구간에서는 두 채널 간 상호 보완이 효과적으로 이루어져, 안정적인 궤적이 형성된다. 한편 C 구간(교량 하부 등 GNSS 수신 환경이 불안정한 구간)에서는 GNSS 품질 저하로 인해 필터가 VIO 기반 궤적에 의존하게 되며, 이에 따라 앞서 분석한 VIO의 오차 특성이 융합 결과에도 일부 반영되는 양상이 관찰된다.

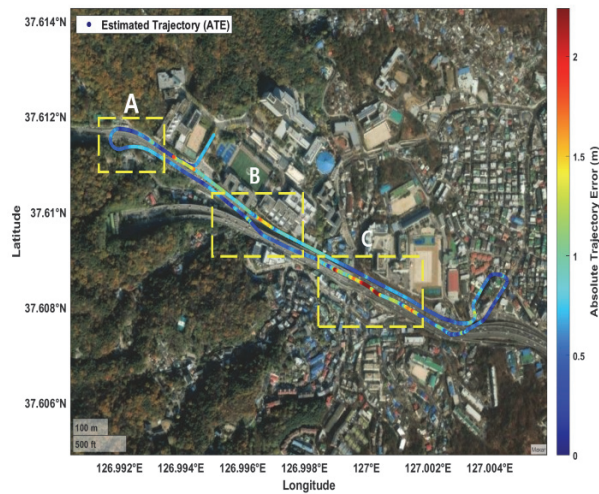


Fig. 9 ATE heatmap of proposed IMM fusion system




Fig. 10 ATE-time profile of the proposed GPS+VIO fusion trajectory

또한, 시각 정보가 불안정하거나 특징점 밀도가 낮은 환경에서는 VIO 오차가 증가하고, 이로 인해 IMM 필터 내 GNSS/INS 모델의 상대 신뢰도에도 영향을 미쳐 가중치 분포가 변화하는 모습이 확인된다.

위와 같은 현상은 ATE-시간 그래프(Fig. 10)에서도 확인할 수 있듯이 전체적으로 단절이 되거나, 비정상적으로 끊기는 궤적이 없다.

이는, 자연스럽게 관측센서의 변환은 이루어졌다고 해석이 된다. 또한 절대 GNSS의 절대 좌표의 융합 영향으로 인해 VIO의 ATE-시간 그래프에 비해 낮은 ATE의 변화를 보이며, 전체적인 ATE의 값의 감소를 확인할 수 있다. 하지만 GNSS/INS 독립 ATE-시간 그래프에 비해 노이즈가 크게 보이는 경향이 보이며, 이는 각 관측 채널이 상호 독립적으로 동작하는 Loosely-coupled 구조 특성상, 하나의 채널에서 발생한 오차가 전체 융합 성능에 영향을 줄 수 있음을 나타낸다.

4.3.2 정량적 평가(Quantitative Evaluation)

제안하는 방식의 정량적 성능은 먼저 ATE와 RPE 지표를 중심으로 평가하였다. ATE는 추정 궤적과 기준 궤적 간의 전역적 차이를, RPE는 100프레임 간격의 상대적 이동 오차를 기준으로 계산하였다. 이러한 설정은 데이터셋의 평균 샘플링 주기를 고려하여, 단기 센서 노이즈에는 둔감하면서도 주행 중 누적되는 드리프트를 관찰하기 적절한 구간으로 선택된 것이다.

평가 결과, 제안하는 방식은 ATE 0.76 m, RPE 0.19 m로 모든 비교 대상 중 가장 우수한 성능을 보였다(Table 1). 이는 GNSS 음영 구간에서도 안정적인 추정을 유지했을 뿐만 아니라, VIO 단독 시스템(ATE 1.26 m)대비 약 40%의 오차 감소를 달성하여 전반적인 정확도를 크게

Table 1 Localization accuracy comparison ATE/RPE (m) across GNSS/INS, VIO, and proposed fusion

	GNSS /INS	VIO	Proposed fusion
ATE (m)	44.34	1.26	0.76
RPE (m)	9.76	0.33	0.19

Table 2. Robustness and recovery of the proposed IMM fusion TSE (m), RCT (s), and MPA (%)

	TSE (m)	RCT (s)	MPA (%)
Proposed fusion	1.23	0.0025	81.3

향상시켰음을 의미한다. 특히 VIO의 고질적인 약점인 드리프트 역시 RPE 기준으로 약 42% 개선되어 장기 주행에서도 안정성을 확보했음을 확인하였다.

제안하는 방식의 핵심인 동적 신뢰도 판단 능력은 TSE, RCT, MPA 지표를 통해 추가적으로 검증하였다 (Table 2). 먼저, 시스템 안정성은 TSE 1.23 m로 정량화되었으며, 이는 GNSS 전환 구간에서 발생하는 평균 최대 오차가 전체 전역오차(ATE 0.76 m)와 약 0.5 m 차이를 보이는 수준에 그쳐, 제안하는 방식이 센서 전환 충격을 효과적으로 완화됨을 보여준다.

시스템의 회복 탄력성은 0.0025초로, GNSS 신호 복귀 직후 즉시 안정적인 궤도로 재 수렴함을 입증하였다. 본 연구에서는 RCT 임계 값을 평균 ATE의 1.1배로 설정하였다. 이는 오차 규모가 상황에 따라 달라지는 점을 고려하여, 절대값 기준 대신 상대적 기준을 도입함으로써 다양한 조건에서 일관된 수렴 성능 평가를 가능하게 하기 위함이다.

마지막으로, 내부 추정 지능을 평가하는 MPA 결과 또한 제안한 IMM 필터가 실제 주행 모델(직선/회전)을 높은 정확도로 식별함을 보여주었다. 본 MPA는 식 (13)에서 정의한 바 같이 IMM의 시점 별 모델 확률 중 가장 높은 확률 d_k 를 선택하고 기준 궤적의 각속도를 기반으로 정의한 실제 주행 g_k 와 일치하는 비율로 산출하였다. 그 결과, 81.3%의 모델 적합률을 기록하였으며, 이는 단순 무작위 선택(50%)에 비해 높은 모드 적합률을 기록했을 뿐 아니라, 센서 품질이 급변하는 과도기 상황에서도 IMM 필터는 센서 신뢰도에 따라 모델 확률을 연속적으로 조정하기 때문에, 센서의 불확실성이 증가하는 상황에서도 모델 판단이 실제 기동을 안정적으로 반영하고 있음을 보여준다. 따라서 제안한 필터 구조의 내제된 모델 추론 능력과 실시간 판단 신뢰성을 입증하는 근거로 해석된다.

TSE, RCT, MPA 지표는 제안한 Fusion 방식에서만 평가하였다. GNSS/INS 단독이나 VIO 단독 방식은 센서 전환 과정이 존재하지 않으며, IMM 기반의 모델 확률 추정을 수행하지 않기 때문이다. 따라서 해당지표들은 동적 신뢰도 기반 확률 융합 구조를 갖춘 Proposed fusion의 고유 성능을 입증하는 용도로 사용되었다.

5. 결론

본 연구는 IMM 기반 상태 추정 프레임워크에 동적 공분산 조절 기법을 결합하여, GPS 신호가 불안정하거나 완전히 차단되는 음영 구간에서도 높은 강건성과 연속성을 유지할 수 있는 차량 항법 시스템을 제안하였다. 실

제 도심 주행 데이터를 활용한 실험 결과, 제안한 방식은 기존 GNSS/INS 또는 VIO 단일 센서 기반 시스템에 비해 전반적인 위치 정확도 향상을 달성했을 뿐만 아니라, 다음과 같은 세 가지 핵심 성능지표 측면에서도 우수성을 입증하였다.

첫째, 전환 안정성(Transition Stability Evaluation, TSE) 지표를 통해 모델간 상태 전이 시 발생 가능한 불연속성과 오차 증폭을 효과적으로 억제함을 확인하였고,

둘째, 복원 속도 능력(Recovery Time, RCT) 지표 분석을 통해 급격한 센서 품질 저하 이후에도 빠르게 정상상태로 복귀하는 특성을 관찰할 수 있었으며,

셋째, 모델 판단 능력(Model Preference Awareness, MAP)을 통해 센서 신뢰도에 기반한 가중 조절이 자율적으로 이루어져 다양한 주행 시나리오에 유연하게 대응함을 보여주었다.

그러나 현재 융합 구조는 GNSS/INS와 VIO가 독립적으로 계산한 Odometry 결과를 후속 필터에 입력하는 느슨한 결합 방식으로 구현되어 있어, 개별 센서 내 내부 상태 추정에 대한 영향력이 제한적이라는 구조적 한계를 갖는다.

이에 따라, 향후 연구에서는 강한 결합(Tightly-coupled) 구조로의 확장을 통한 성능 고도화가 필요하다. 구체적으로는, VIO가 산출하는 중간 결과(예: 특징점 위치, 잔차 등)를 필터의 측정치로 직접 활용하여, GNSS가 유효한 구간에서 VIO의 내부 파라미터(스케일, 바이어스 등)를 함께 추정 및 보정할 수 있는 구조를 도입할 수 있다 이를 통해 GNSS 수신 가능한 구간에서 VIO의 모델을 선제적으로 교정하고, 이후 음영 구간에서도 보다 안정적이고 정확한 예측이 가능해질 것으로 기대된다.

결론적으로, 본 연구는 실제 환경을 고려한 실증 기반 평가를 통해 GPS 음영 조건에서도 신뢰할 수 있는 차량 위치 추정의 가능성을 제시하였으며, 제안된 융합 전략은 향후 다양한 실내, 도심 항법 시스템으로의 확장성 측면에서도 유의미한 기초를 제공할 수 있을 것으로 판단된다.

후 기

본 연구는 산업통상자원부 ‘자율주행개발혁신사업’의 지원을 받아 수행된 연구 결과입니다(20014476, 혼합 현실기반자율주행부품및시스템평가기술개발).

References

- 1) S. Kuutti, S. Fallah, K. Katsaros, M. Dianati, F. McCullough and A. Mouzakitis, "A Survey of the

- State-of-the-Art Localization Techniques and Their Potentials for Autonomous Vehicle Applications,” *IEEE Internet of Things Journal*, Vol.5, No.2, pp.829–846, 2018.
- 2) G. Bresson, Z. Alsayed, L. Yu and S. Glaser, “Simultaneous Localization and Mapping: A Survey of Current Trends in Autonomous Driving,” *IEEE Transactions on Intelligent Vehicles*, Vol.2, No.3, pp.194–220, 2017.
 - 3) J. Laconte, A. Kasmi, R. Aufrère, M. Vaidis and R. Chapuis, “A Survey of Localization Methods for Autonomous Vehicles in Highway Scenarios,” *Sensors*, Vol.22, No.1, Paper No.247, 2022.
 - 4) I. Skog and P. Händel, “In-Car Positioning and Navigation Technologies—A Survey,” *IEEE Transactions on Intelligent Transportation Systems*, Vol.10, No.1, pp.4–21, 2009.
 - 5) J. K. Choi, J. K. Suhr and H. G. Jung, “Landmark Suitability Evaluation of Road Facilities in Highway for Monocular Camera-Based Precise Vehicle Localization System,” *Transactions of KSAE*, Vol.27, No.4, pp.273–290, 2019.
 - 6) R. Yao, G. Lin, S. Xia, J. Zhao and Y. Zhou, “Video Object Segmentation and Tracking: A Survey,” *ACM Transactions on Intelligent Systems and Technology*, Vol.11, No.4, pp.36:1–36:47, 2020.
 - 7) C. Chen, H. Zhu, M. Li and S. You, “A Review of Visual-Inertial Simultaneous Localization and Mapping from Filtering-Based and Optimization-Based Perspectives,” *Robotics*, Vol.7, No.3, Paper No.45, 2018.
 - 8) H. Jing, Y. Gao, S. Shahbeigi and M. Dianati, “Integrity Monitoring of GNSS/INS Based Positioning Systems for Autonomous Vehicles: State-of-the-Art and Open Challenges,” *IEEE Transactions on Intelligent Transportation Systems*, Vol.23, No.9, pp.14166–14187, 2022.
 - 9) C. N. Taylor and J. N. Gross, “Factor Graphs for Navigation Applications: A Tutorial,” *Navigation*, Vol.71, No.3, pp.653–682, 2024.
 - 10) M. M. Karimi and M. R. Mosavi, “GPS/VIO Integrated Navigation System Based on Factor Graph and Fuzzy Logic,” *Scientific Reports*, Vol.14, Paper No.30937, 2024.
 - 11) C. Forster, L. Carlone, F. Dellaert and D. Scaramuzza, “On-Manifold Preintegration for Real-Time Visual-Inertial Odometry,” *The International Journal of Robotics Research*, Vol.36, No.2, pp.191–223, 2017.
 - 12) N. Sünderhauf and P. Protzel, “Switchable Constraints for Robust Pose Graph SLAM,” *Proc. IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS)*, pp.1879–1884, 2012.
 - 13) P. Agarwal, G. D. Tipaldi, L. Spinello, C. Stachniss and W. Burgard, “Robust Map Optimization Using Dynamic Covariance Scaling,” *Proc. IEEE Int. Conf. on Robotics and Automation (ICRA)*, pp.62–69, 2013.
 - 14) D. Solodar, O. Shurin and D. Raviv, “VIO-DualProNet: Visual-Inertial Odometry with Learning-Based Adaptive Noise Covariance Estimation,” *Engineering Applications of Artificial Intelligence*, Vol.132, Paper No.108060, 2024.
 - 15) G. Welch and G. Bishop, *An Introduction to the Kalman Filter*, Technical Report TR 95-041, University of North Carolina at Chapel Hill, Chapel Hill, 1995.
 - 16) A. H. Jazwinski, *Stochastic Processes and Filtering Theory*, Academic Press, New York, 1970.
 - 17) S. Särkkä and L. Svensson, *Bayesian Filtering and Smoothing*, 2nd Edn., Cambridge University Press, Cambridge, 2023.
 - 18) A. Barrau and S. Bonnabel, “The Invariant Extended Kalman Filter as a Stable Observer,” *IEEE Transactions on Automatic Control*, Vol.62, No.4, pp.1797–1812, 2017.
 - 19) X. Li, F. Dunkin and J. Dezert, “Multi-Source Information Fusion: Progress and Future,” *Chinese Journal of Aeronautics*, Vol.37, No.7, pp.24–58, 2024.
 - 20) Z. Zhao and H. Chen, “Multi-Maneuvering Target Tracking Based on a Gaussian Process,” *Sensors*, Vol.24, No.22, Paper No.7270, 2024.
 - 21) M. Qiu and B. Liu, “Multi-Sensor Adaptive Weighted Data Fusion Based on Biased Estimation,” *Sensors*, Vol.24, No.11, Paper No.3275, 2024.
 - 22) H. A. P. Blom and Y. Bar-Shalom, “The Interacting Multiple Model Algorithm for Systems with Markovian Switching Coefficients,” *IEEE Transactions on Automatic Control*, Vol.33, No.8, pp.780–783, 1988.
 - 23) Y. Xu, W. Zhang, W. Tang, C. Liu, R. Yang, L. He and Y. Wang, “Estimation of Vehicle State Based on IMM-AUKF,” *Symmetry*, Vol.14, No.2, Paper No.222, 2022.
 - 24) I. Hwang, C. E. Seah and S. Lee, “A Study on Stability of the Interacting Multiple Model Algorithm,” *IEEE Transactions on Automatic Control*, Vol.62, No.2, pp.901–906, 2017.
 - 25) B. Zhao, C. Guo, H. Xu, J. He and Y. Zhang,

- “Adaptive Integrated Navigation Algorithm Based on Interactive Filter,” *Sensors*, Vol.25, No.15, Paper No.4562, 2025.
- 26) Y. -K. Choi, I. -H. Lee and C. -G. Park, “Robust Adaptive Transition Probability Matrix in IMM with Polynomial Functions and Feedback Structure,” *IJCAS*, Vol.22, pp.3547–3558, 2024.
- 27) SBG Systems, GNSS and Their Error Sources, <https://www.sbg-systems.com/technology/gnss-and-their-error-sources>, accessed on 2025. 10. 21.
- 28) E. Fredeluces, T. Ozeki, N. Kubo and A. El-Mowafy, “Modified RTK-GNSS for Challenging Environments,” *Sensors*, Vol.24, No.9, 2024.
- 29) SBG Systems, RTK – Real Time Kinematic, <https://www.sbg-systems.com/ko/glossary/rtk-real-time-kinematics/>, accessed on 2025. 10. 21.
- 30) SBG Systems, INS, <https://www.sbg-systems.com/ko/glossary/ins-inertial-navigation-systems/>, accessed on 2025. 10. 21.
- 31) H. Qi and J. B. Moore, “Direct Kalman Filtering Approach for GPS/INS Integration,” *IEEE Transactions on Aerospace and Electronic Systems*, Vol.38, No.2, pp.687–693, 2002.
- 32) S. Rezaei and R. Sengupta, “Kalman Filter-Based Integration of DGPS and Vehicle Sensors for Localization,” *IEEE Transactions on Control Systems Technology*, Vol.15, No.6, pp.1080–1088, 2007.
- 33) G. Im, “Notes on Kalman Filter (KF, EKF, ESKF, IEKF, IESKF),” arXiv preprint, arXiv:2406.06427, 2024.
- 34) SBG Systems, EKF, <https://www.sbg-systems.com/ko/glossary/extended-kalman-filter-ekf/>, accessed on 2025. 10. 21.
- 35) D. Nistér, O. Naroditsky and J. R. Bergen, “Visual Odometry,” *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, Vol.1, pp.652–659, 2004.
- 36) T. Qin, S. Cao, J. Pan and S. Shen, “A General Optimization-Based Framework for Global Pose Estimation with Multiple Sensors,” arXiv, <https://arxiv.org/abs/1901.03642>, accessed on 2025. 10. 21.
- 37) C. Campos, R. Elvira, J. J. Gómez Rodríguez, J. M. M. Montiel and J. D. Tardós, “ORB-SLAM3: An Accurate Open-Source Library for Visual, Visual–Inertial, and Multi-Map SLAM,” *IEEE Transactions on Robotics*, Vol.37, No.6, pp.1874–1890, 2021.
- 38) Y. Lee and J. Yoo, “Improved Visual SLAM Framework via Deep Learning-Based Keypoint/Descriptor and Optical Flow-Based Matching,” *Transactions of KSAE*, Vol.31, No.9, pp.707–715, 2023.
- 39) D. Lim and J. Yoo, “Improved Mono-SLAM Algorithm Using Depth Estimation and Segmentation Based on Deep Learning,” *Transactions of KSAE*, Vol.31, No.8, pp.619–627, 2023.
- 40) P. Geneva, K. Eickenhoff, W. Lee, Y. Yang and G. Huang, “OpenVINS: A Research Platform for Visual–Inertial Estimation,” *Proceedings of the 2020 IEEE International Conference on Robotics and Automation (ICRA)*, pp.4666–4672, 2020.