

텔레메트리 자원 최적화를 위한 물리 정보 기반 능동 교통 밀도장 복원 기법

최민준, 김건민, 김경백

전남대학교 인공지능융합학과

stmcskd123@naver.com, geonminkim@jnu.ac.kr, kyungbaekkim@jnu.ac.kr

Physics-Informed Active Sensing for Traffic Density Field Reconstruction with Telemetry Resource Optimization

Minjun Choi, Geonmin Kim, Kyungbaek Kim

Dept. of Artificial Intelligence Convergence, Chonnam National Univ.

요약

본 논문은 무선 통신이 불안정한 구간에서 차량 Probe 관측이 부분적으로 소실되는 환경에서 고정 검지기(Roadside Unit, RSU)정보와 부분 차량 궤적을 결합하여 교통 밀도장을 복원하는 물리 정보 신경망(Physics-Informed Neural Network, PINN) 기반 프레임워크 PITAM을 제안한다. 제안 방법은 LWR 보존식과 Greenshields 속도-밀도 관계를 PINN 손실에 포함하여 부분 관측 하에서도 물리적으로 일관된 밀도장을 추정한다. 실험은 3차선 링 도로에서 사고로 인한 용량 급강하를 유도하고, 터널 구간에서는 Probe 관측만 제거하되 RSU 시계열은 유지하는 비대칭 결측 환경으로 구성하였다. 사고 발생 시각은 관제 신호를 통해 주어진다 가정하며, 이를 기준으로 세 단계의 능동 모니터링을 수행한다. Phase 1에서는 전체 RSU의 1/2, Phase 2에서는 1차 PINN 복원 결과의 PDE 잔차·불확실도 기반 점수 함수로 핵심 위치의 RSU K개를 추가 활성화한다. Phase 3에서는 2차 복원 결과를 바탕으로 동일한 Probe 예산 B를 터널 구간에 배치한다. 제안 방법과의 비교를 위해, 사고 발생 직후 전체 RSU를 즉시 활성화하고 동일한 Probe 예산을 균등 투입하는 비적응형 전략을 Baseline으로 설정한다. 실험 결과, 제안한 모델은 기준 대비 복원 성능을 유지하며 동시에 누적 업링크 17.7% 절감을 달성하여, 제한된 통신 예산 하에서 단계적 PITAM이 효과적인 능동 모니터링 전략임을 정량적으로 입증하였다.

I. 서론

지능형 교통 체계(Intelligent Transportation System, ITS)에서는 실시간 교통 상태를 추정·예측하여 정체 완화, 사고 대응, 경로 안내를 지원하려는 수요가 꾸준히 증가하고 있다[1-2]. 이 가운데 도로 구간별 밀도와 속도 분포를 시공간적으로 복원하는 문제는 혼잡 전파 분석과 운영 전략 설계의 기초가 되는 핵심 과제이다[1, 3-4]. 그러나 도로망 전 구간에 센서를 촘촘히 설치하는 것은 비용과 유지관리 부담이 크기 때문에, 현실의 교통 상태 추정은 제한된 관측 자원에 의존할 수밖에 없다.

대표적인 관측원은 이동체 기반 Probe 차량과 고정형 RSU이다[5]. Probe는 도로 전체를 이동하며 넓은 공간 범위의 정보를 제공할 수 있지만, 침투율이 낮거나 터널·지하 구간처럼 무선 통신이 불안정한 환경에서는 관측 공백이 쉽게 발생한다[6-7]. 반면 RSU는 특정 위치에서 안정적인 시계열 관측을 제공하나, 설치 간격이 넓으면 공간 해상도가 제한된다. 특히 터널 구간에서는 차량 Probe 데이터가 끊기는 반면 유선망 기반 RSU 관측은 유지될 수 있어, 동일 도로 내에서 Probe만 소실되고 RSU는 남은 비대칭 결측 상황이 발생한다. 특히, 사고가 발생한 이후에는 교통류뿐 아니라 통신 자원도 제약이 받기 때문에, 모든 센서를 즉시 최대로 활용하기 보다는 제한된 RSU·Probe 예산의 할당 전략이 중요하다[8]. 그럼에도 기존 연구들은 통신 비용을 명시적으로 다루지 않거나 관측 배치를 정적으로 고정하는 경우가 많아, 사고 이후 단계적·능동적인 관측 전략을 다루는 사례는 드물다[9-10]. 이에 본 논문은 SUMO-TraCI 기반 3차선 링 도로

시뮬레이션에서 비대칭 결측 환경을 명시적으로 모델링하고, 사고 시각이 관제 또는 신호로 주어진다 가정 하에 3단계 능동 관측 전략 PITAM(Physics-Informed Traffic Active Monitoring)을 제안한다. 핵심 기여는 다음과 같다:

1. 비대칭 결측 모델링: 터널 구간에서 Probe만 소실되고 RSU는 유지되는 환경을 PINN 학습에 명시적으로 반영한다.
 2. PINN 가이드 RSU 선택: 1차 복원 결과의 PDE 잔차·밀도 기울기·충격과 근접도 등 다중 점수 함수로 비활성 RSU 중 정보 가치가 높은 위치를 선별적으로 활성화한다.
 3. 단계적 Probe 배치: 2차 복원 결과를 기반으로 동일한 예산의 Probe를 터널 구간에 배치하며, 배치 전략(균등·무작위·점수 기반)을 비교한다.
 4. 복원 성능 - 통신 비용 동시 평가: 순간 및 누적 업링크를 통해 능동 전략과 비적응형 기준의 통신 효율 차이를 정량적으로 분석한다.
- 실험 결과는 점수 기반 적응형 제안모델 PITAM이 Baseline 대비 성능 지표를 유지하며 업링크를 절감함을 보인다.

본 연구의 실무적 의의는 “정확도 향상” 그 자체보다, 사고 이후 제한된 텔레메트리 자원을 시간 순서에 따라 재배치하는 운영 정책을 제시한다는 점에 있다. 기존의 즉시 전면 활성화 방식은 초기 구간에서 통신 부하를 급격히 증가시키는 반면, PITAM은 사고 전·직후·후속 구간을 분리하여 RSU 활성화와 Probe 투입 시점을 단계적으로 결정한다. 이는 관제 시스템 관점에서 “언제·어디에 관측 자원을 우선 배치할 것인가”를 정량적 지표와 함께 제시하는 의사결정 프레임워크로 해석될 수 있다.




그림 1. PITAM 파이프라인 아키텍처

II. 관련 연구

1. PINN과 교통류

PINN은 PDE 잔차를 신경망 출력에 대해 자동 미분으로 계산하여 손실 함수에 포함함으로써, 관측 데이터와 물리 제약을 동시에 만족하는 해를 학습한다[11]. 초기에는 유체역학·열전달 분야에서 주로 연구되었으며 [12], 최근에는 교통류와 같이 보존식과 속도-밀도 관계로 기술 가능한 시스템에도 적용이 확산되고 있다[13]. 교통 분야에서는 LWR 보존식을 PINN 손실에 포함하여 부분 관측 하에서 밀도장·속도장을 복원하거나, 거시 모형의 파라미터를 식별하는 연구들이 보고되었다[14]. 이들 연구는 관측이 제한된 영역에서도 PDE가 정규화 역할을 수행하여, 순수 데이터 기반 회귀 대비 물리적으로 더 일관된 장을 복원할 수 있음을 보인다.

2. RSU-Probe 통합과 통신비용

RSU와 Probe를 동시에 활용하는 연구들은 두 관측원의 상호보완성을 이용하여 상태 추정 정확도를 높이는 데 초점을 맞춘다[6, 15-16]. 그러나 대부분의 연구는 RSU와 Probe가 항상 사용 가능한 것으로 가정하고, 통신 비용이나 센서 활성화 시점을 명시적으로 모델링하지 않는다. 특히 터널 내에서 Probe만 소실되고 RSU는 유지되는 비대칭 결측 구조, 그리고 사고 이후 제한된 통신 예산을 시간에 따라 어떻게 분배할 것인지를 하나의 프레임워크에서 다루는 사례는 부족하다.

3. 선택적 통신·능동 관측

분산 센싱 및 다중 에이전트 제어 분야에서는 통신 비용을 줄이기 위해, 정보 가치에 따라 통신 여부를 선택하는 선택적 통신 기법이 제안되어 왔다[17-19]. 대표적으로 TD-error나 불확실도를 기반으로 통신 필요성을 판단하고, 통신 비용을 낮추면서도 제어 성능을 유지하는 접근이 연구되고 있다[11, 21]. 그러나 대부분은 상태를 PDE 기반 연속장으로 복원하기 보다는 신호 제어나 국지적 의사결정에 초점을 두며, RSU-Probe와 같은 이질적 관측원을 동시에 고려하거나, 사고 이후 특정 구간에서만 Probe가 소실되는 교통류 복원 문제에 직접 적용된 사례는 제한적이다.

4. 본 연구의 위치

본 논문은 RSU 시계열과 Probe 궤적을 명시적으로 분리하고, 터널 구간에서만 Probe가 소실되는 비대칭 결측 환경을 PINN 학습에 직접 반영한다. 나아가 사고 발생 이후 RSU 추가 활성화와 Probe 배치를 PINN 복원 결과에 기반한 점수 함수로 결정하는 3단계 능동 관측 절차를 설계하여, RSU-Probe 통합 복원과 통신 예산 제약을 동시에 고려한다. 이를 통해 기존의 정적 관측 배치·단일 관측원 중심 연구와 달리, 사고 이후 단계적 센서 활성화 정책과 통신 비용-복원 성능 간 트레이드오프를 정량적

으로 분석하는 것이 본 연구의 차별점이다.

III. 실험 설정 및 제안 방법 PITAM

1. 시뮬레이션 환경 및 관측 채널

본 연구는 표 1과 같이 SUMO-TraCI 기반 3차선 링 도로(길이 $L = 1,000m$)에서 교통류를 시뮬레이션한다. 전체 차량의 시공간 위치

<표 1> 주요 실험 파라미터

항목	값
도로 형태	3차선 링 도로, 1km
시뮬레이션 시간	3,600s $\Delta t = 1s$
RSU 간격 / 총 수	25m / 40기
터널 구간	$x \in [350, 650]m$
총 차량 수 / Probe 비율	200대 / 10%
추가 투입 Probe 예산 B	60대
PINN 백본	Fourier Feature FNN [64, 64, 64, 64], tanh
손실 가중치 $\lambda_{pde}, \lambda_{data}$	0.92, 1.06
최적화	Adam + L-BFGS
평가 격자 크기	160*120 (공간 * 시간)

로부터 셀 단위 밀도를 계산하여 Ground Truth 밀도장 $\rho(t, x)$ 를 구성하며, 차량 중 약 10%는 Probe 차량으로 지정하여 시각 t , 위치 x , 속도 v 관측을 수집한다. RSU는 도로 전 구간에 $\Delta x_{RSU} = 25m$ 간격, 총 40기가 설치된 고정 감지기로 모델링하며, 각 시각에 해당 위치의 밀도를 기록한다. 터널 구간 ($x \in [350, 650]m$)에서는 무선 통신 단절을 가정하여 Probe 관측만 제거하고 RSU 관측은 유지한다. 이에 따라 Probe는 공간적 hole을 가지는 반면 RSU는 연속적인 시계열을 제공하는 비대칭 결측 환경이 형성된다. 사고는 $t_{inc} = 1,200s$ 에 터널 내부 예지의 제한 속도를 급강하하여 유도하며, 사고 발생 시각은 관제 시스템 또는 외부 신호를 통해 주어진다고 가정한다.

2. 3단계 능동 모니터링 시나리오

제안 방법 PITAM은 그림 1과 같이 사고 시각 기준 세 단계 순차 의사 결정으로 동작한다.

Phase 1 ($t < t_{inc}$): 전체 40기의 RSU 중 짝수 번째 20기만 활성화하여 사고 전/초기 흐름의 기준 패턴을 수집한다. 이 RSU 시계열과 터널 외부 Probe 관측을 결합해 1차 PINN 복원(Stage 1)을 수행한다. Stage 1의 출력은 밀도장 예측값 $\hat{\rho}(t, x)$ 와 점수 산출용 중간량(PDE 잔차, 기울기 등)이다.

Phase 2 ($t_{inc} \leq t < t_2$): Stage 1 PINN의 PDE 잔차, 밀도 기울기, 총

격과 근접도, 국소 분산, 시간 변화율을 결합한 점수 함수 $S(t, x)$ 를 계산한다. 점수 함수 S 는 식 (3)과 같이 계산된다. 비활성 홀수 RSU 후보에 대해 시간 구간 $[t_{inc}, t_2)$ 에서 점수를 집계하고 상위 K 개를 선택해 추가 활성화한다. 본 실험에선 8개로 진행하였다. 이후 추가된 RSU 관측을 반영하여 Stage 1 체크포인트에서 warm-start로 재학습한다(Stage 1.5). Phase 3 ($t \geq t_2$): Stage 1.5의 재복원 결과로부터 터널 결측 구간의 시공간 점수 맵을 계산한 뒤, 터널 구간 시공간 후보 중 Probe 예산 B 개를 선택·배치하고 재학습 체크포인트에서 최종 fine-tune한다(Stage 2). Probe 배치 정책으로는 균등(적응형-균등), 무작위(적응형-랜덤), 점수 기반(PITAM), 혼합(적응형-혼합)을 비교한다.

Warm-start란 이전 단계의 PINN 학습 가중치를 폐기하지 않고 초기 값으로 재사용하여 추가 학습을 시작하는 방식이다. 새로운 관측 데이터가 주어졌을 때 처음부터 재학습하는 cold-start 대비, 이미 학습된 물리 패턴을 유지한 채 새 정보만 반영하기 때문에 수렴이 빠르고 이전 지식의 망각을 줄이는 효과가 있다. 본 연구에서는 단계 전환이 있는 적응형 경로(Stage 1→1.5→2)에 warm-start를 적용하고, Baseline의 경우 적응형 경로 Phase2가 없으므로 Stage 1→2에서만 warm-start를 적용하여 동일 데이터 조건에서 재학습하여 비교한다.

3. PINN 기반 밀도장 복원

복원 모델은 LWR 보존식과 Greenshields 속도 - 밀도 관계를 결합한 PINN을 사용한다.

$$\frac{\partial \rho}{\partial t} + \frac{\partial}{\partial x} [\rho v_{\max} (1 - \frac{\rho}{\rho_{\max}})] = 0 \quad (1)$$

신경망은 정규화된 시공간 좌표를 입력으로 받아 정규화 밀도 $\hat{\rho}(t, x)$ 를 출력하며, 백본으로 Fourier Feature FNN (은닉 [64,64,64,64], tanh 랜덤 푸리에 특징 (64차원)을 사용하여 충격파와 같은 고주파 성분을 효과적으로 표현한다. Fourier feature 기반 입력 방법은 사고 및 충격과 전파 구간에서 나타나는 급격한 시공간 변화(고주파 성분)를 보다 안정적으로 표현하기 위해 사용하였다. 일반 MLP는 해당 구간에서 경계 부근이 과도하게 평활화되거나 과현이 흐려지는 경향이 있으나, Fourier feature는 동일 깊이에서 변동 구간의 표현력을 보강하여 밀도장 구조 복원에 유리하다. 총 손실은 다음과 같은 두 MSE의 합으로 정의한다.

$$L = \lambda_{pde} L_{pde} + \lambda_{data} L_{data} \quad (2)$$

L_{pde} : 시공간 콜로케이션 점에서의 PDE 잔차 MSE

L_{data} : RSU 및 Probe 관측점에서의 MSE

손실 가중치 λ_{pde} , λ_{data} 는 물리 일관성과 관측 적합의 균형을 맞추기 위해 설정하였다. λ_{pde} 를 지나치게 크게 두면 초기 학습에서 PDE 잔차는 빠르게 감소하지만 터널 주변 관측 데이터를 충분히 따라가지 못하는 경향이 나타났고, 반대로 λ_{data} 가 너무 크면 회소 관측 인근에서 과적합이 발생하며 미관측 구간에서 비물리적인 밀도 도약이 관찰되었다. 본 연구에서는 학습 초반 수십 스텝 동안 두 손실 항의 기울기 크기가 유사한 수준이 되도록 $\lambda_{pde} = 0.920$, $\lambda_{data} = 1.060$ 으로 설정하였다.

최적화는 Cosine Annealing 학습률 감쇠를 적용한 Adam 초기 학습 이후 L-BFGS 미세 조정으로 수행하며, Phase 2/3 재학습은 이전 체크포인트에서 warm-start하여 수렴 속도와 복원 품질을 동시에 향상시킨다.

4. PINN 가이드 점수 함수

RSU 추가 선택(Phase 2) 및 Probe 배치(Phase 3)에 사용하는 점수 함수 S 는 다음 다섯 가지 성분의 가중합으로 정의한다.

$$S = \alpha_1 r_{pde} + \alpha_2 g_{\rho} + \alpha_3 s_{shock} + \alpha_4 v_{local} + \alpha_5 d_{temporal} \quad (3)$$

r_{pde} : PDE 잔차 크기 (물리 법칙 불일치 영역)

g_{ρ} : 밀도 기울기 크기 (밀도 급변 영역)

s_{shock} : 충격파 인터페이스 근접도 (가우시안 커널 기반)

v_{local} : 예측값의 국소 분산 (체크포인트 앙상블)

$d_{temporal}$: 시간 방향 밀도 변화율

비활성 RSU의 경우 각 RSU 위치 x 에서 점수를 집계하여 top-K($K=8$)를 선택하고, Probe의 경우 hole 구간 시공간 후보 격자에서 diversity-aware 그리드 선택으로 B 개를 결정한다.

5. 비교 기준 및 통신량 모델

Baseline은 사고 이전에는 제안 방법과 동일하게 20기 RSU만 사용하나, 사고 발생 직후($t \geq t_{inc}$) 즉시 전체 40기 RSU를 활성화하고 동일 예산 B 의 Probe를 균등 배치한다. PINN 복원 결과를 참조하지 않으며 warm-start 없이 재학습한다. 통신 비용은 시간 t 에서의 활성 RSU 수 $n_{rsu}(t)$ 와 Probe 보고 수 $n_{probe}(t)$ 를 이용하여 정의한다.

$$U_{inst}(t) = w_{rsu} n_{rsu}(t) + w_{probe} n_{probe}(t) \quad (4)$$

$$U_{cum}(T) = \sum_{t=0}^T U_{inst}(t) \quad (5)$$

$w_{rsu} = w_{probe} = 1.0$ 으로 설정하며, 두 전략의 통신량 차이는 RSU 활성화 시점과 그 이후 활성 RSU 수(40기 vs 28기)에서 비롯된다.

본 연구의 통신 비용 모델은 메시지 수 기반의 1차 근사 모델이다. 즉, U_{inst} 와 U_{cum} 은 전략 간 상대적 통신 부담을 비교하기 위한 지표로 설계되었으며, 실제 무선 환경에서 발생하는 지연, 패킷 손실, 채널 결합은 포함하지 않는다. 따라서 본 연구의 통신 결과는 절대적 네트워크 성능 예측값이 아니라, 센서 활성화 전략 간 상대 비교 결과로 해석해야 한다.

본 논문에서는 통신 비용을 시간 t 에서 활성 RSU 수 $n_{rsu}(t)$ 와 Probe 보고 수 $n_{probe}(t)$ 에 비례하는 업링크 메시지 수로 단순화하였다. 이는 채널 대역폭과 패킷 크기가 고정되어 있다는 가정 하에서 다양한 프로토콜 세부 요소를 추상화하고, 상위 수준에서 관측 전략 간 트래픽 양을 비교하기 위한 선택이다.

<표 2> 비교 조건(전략) 요약

조건	설명
Baseline	사고 직후 전체 40기 RSU 활성화 + 동일 예산 B 즉시 균등 투입 (stage 1.5 warm-start 없음)
적응형-균등	단계적 RSU 활성화(28기) 후 Probe B 를 균등 배치 + warm-start
적응형-랜덤	단계적 RSU 활성화(28기) 후 Probe B 를 무작위 배치 + warm-start
PITAM	단계적 RSU 활성화(28기) 후 Probe B 를 PINN 점수 기반 배치 + warm-start
적응형-혼합	단계적 RSU 활성화(28기) 후 Probe B 를 혼합(경계 15%+충격파 30%+점수 40%+무작위 15%) 배치 + warm-start

<표 3> 주요 지표별 평가 항목

지표	평가 항목
RMSE_hole	충격파·밀도 급변 구간의 큰 오차를 제곱 패널티로 강조하는 핵심 지표
MAE_hole	오차를 밀도 단위(veh/m)로 직접 해석할 수 있어 물리적 의미 전달에 유리
R^2 _hole	전략별 스케일 불변 비교에 활용
순간 업링크	전략별 업링크 변화를 시각화
누적 업링크	통신 효율의 핵심 지표

적응형-균등-랜덤, PITAM과 적응형-혼합 모두 동일한 3단계 파이프라인을 따르되, Phase 3에서 Probe B개를 배치하는 정책만 다르다. 균등은 감지한 사고 구간을 등간격으로 분할하여 배치하고, 랜덤은 무작위 추출하며, PITAM은 PINN 점수 맵 상위 후보를 선택하고, 혼합은 충격과 근접 및 점수 기반 기준을 중심으로 경계·무작위를 소량 혼합하여 배치한다. 각 전략별 설명은 표 2와 같다.

Baseline과 모든 적응형 전략은 동일한 SUMO 시뮬레이션 트레이스과 동일한 Ground Truth를 사용한다. 차이는 사고 이후 RSU 활성화 방식, Probe 투입 시점, Probe 배치 정책, warm-start 유무에만 있다.

본 실험에서는 복원 품질과 통신 효율이라는 두 가지 관점에서 제안 방법을 평가하며, 각 관점에 적합한 지표를 선정한다. 복원 품질 지표로는 RMSE, MAE, R^2 를 사용하고, 통신 효율 지표로는 순간 업링크와 누적 업링크를 사용한다. 각 지표의 평가 항목은 표 3에 정리하였다.

IV. 실험 결과 및 분석

1. 단계별 복원 성능 변화

표 4는 적응형 전략의 단계별 복원 성능 변화를 보인다. Stage 1에서 Stage 1.5로 전환 시 RMSE_hole이 0.02045에서 0.01429로 30.1% 감소하고 R^2 _hole이 0.5184에서 0.7649로 크게 향상되었다. 이는 PINN 가이드로 선별된 8기의 RSU 추가 활성화가 단순한 센서 수 증가 이상의 효과를 가짐을 보여준다. 비교를 위해 제시한 Baseline(40기 RSU + 60개 Probe)의 RMSE_hole 0.01445와 비교하면, Stage 1.5만으로도 이미 Baseline 수준에 근접한 복원 품질을 달성한다.

<표 4> 터널 구간 단계별 복원 성능

단계	활성 RSU	RMSE_hole	MAE_hole	R^2 _hole
Stage 1	20기	0.02045	0.01537	0.5184
Stage 1.5	28기	0.01429	0.00942	0.7649
Baseline	40기	0.01445	0.00930	0.7597

<표 5> 전략별 최종 복원 성능 비교(터널 구간)

조건	RSU	RMSE	R^2
Baseline	40기	0.01445	0.7597
적응형-균등	28기	0.01438	0.7617
적응형-랜덤		0.01439	0.7613
PITAM		0.01430	0.7645
적응형-혼합		0.01436	0.7624

2. 전략별 최종 복원 성능 비교

표 5와 그림 2는 최종 복원 결과를 비교 및 시각화한다. Baseline 대비 모든 적응형 전략에서 지표가 개선되었으며, 특히 PITAM이 다른 적응형 지표들에 비해 RMSE_hole 0.01430 (-1.0%), R^2 _hole 0.7645 (+0.6%) 으로 최우수 성능을 보인다. 적응형-균등·랜덤·혼합도 Baseline 대비 소폭 개선을 달성한다.




그림 2. 전략별 터널 구간 성능 지표 시각화

터널 구간에 대한 핵심 평가 지표인 RMSE_hole과 R^2 _hole에서 PITAM이 Baseline과 타 전략들을 상회함은, PINN 가이드 선택이 관측 예산을 가장 필요한 위치에 집중하는 전략적 효과를 입증한다.

3. 통신량 비교

표 6과 그림 3은 각 조건의 통신 비용을 비교한다. Baseline은 $t \geq t_{inc}$ 부터 40기 RSU와 60개 Probe가 동시에 활성화되어 순간 업링크가 100 msg/step으로 급증한다. 제안 방법은 $t \in [\text{incident}, \text{stage1.5}]$ 구간에서 28기 RSU만 활성화하고, Phase 2 이후 Probe 60개가 추가되어 88 msg/step에 이른다.

누적 업링크 기준으로 Baseline이 264,000 msg인 반면 제안 방법은 217,200 msg로, 46,800 msg(17.7%) 절감을 달성한다. 이는 동일한 Probe 예산 하에서도 RSU 선택적 활성화가 실질적인 통신 절감을 만들어 낸다.

4. 결과 해석

세 가지 관점에서 핵심 결과를 정리한다.

첫째, PINN 가이드 배치의 우위. PITAM은 동일한 Probe 예산 60개를 PINN 복원 결과의 점수 맵 기반으로 배치하여, 균등 및 무작위 배치

<표 6> 통신량 구간별 비교(단위: message 수)

구간	Baseline	PITAM	절감율
사고 전	24,000	24,000	0%
Probe 투입 전	30,000	8,400	-72%
Probe 투입 후	210,000	184,800	-12%
누적 합계	264,000	217,200	-17.7%




그림 3. 시간별 순간(상) 및 누적(하) 업링크 비교

대비 RMSE_{hole}에서 각각 0.5%, 0.6% 추가 개선을 달성한다. 점수 함수가 PDE 잔차가 높고 밀도가 급변하는 충격과 인근 영역을 효과적으로 식별하여 관측 예산을 집중 배분한 결과이다.

둘째, warm-start fine-tune의 핵심 역할. Stage 1→Stage 1.5 전환 시 warm-start 재학습만으로 RMSE_{hole}이 30.1% 감소한다. 이는 Phase 2에서 추가 활성화된 8기 RSU의 정보를 이전 단계 모델에 효율적으로 통합한 덕분이며, Stage 1.5가 이미 Baseline 수준에 근접한 복원 품질을 달성했음은 3단계 파이프라인의 설계 효율성을 뒷받침한다. 다만 후속 연구에서 분리 ablation을 통해 warm-start에 대한 분리 검증 역시 필요하다.

셋째, 통신 비용 - 복원 성능 트레이드오프. 제안 방법은 Baseline 대비 누적 업링크를 17.7% 절감하면서 RMSE_{hole}을 1.0% 개선한다. 즉, 더 적은 통신으로 더 나은 복원 품질을 달성하는 것으로, PINN 가이드 선택적 활성화가 단순한 전체 활성화보다 정보 효율 측면에서 우수하다.

V. 결론 및 향후 연구

본 논문은 터널과 같이 Probe 관측이 소실되는 비대칭 결측 환경에서, RSU 시계열과 부분 차량 궤적을 결합하여 교통 밀도장을 복원하는 PINN 기반 프레임워크 PITAM을 제안하였다. 사고 발생 시각이 외부 신고로 주어진다 가정 하에, PINN 복원 결과의 PDE 잔차·기울기·불확실도 기반 점수 함수로 비활성 RSU를 선별 활성화하고, 이를 기반으로 터널 구간 에 Probe 예산을 배치하는 3단계 관측 전략을 설계하였다.

SUMO-TraCI 기반 3차선 링 도로 실험에서 PITAM은 비적응형 Baseline 대비 터널 구간의 RMSE를 1.0%, R²를 0.6% 개선하면서 누적 업링크를 17.7% 절감하였다. 특히 Phase 2의 warm-start 재학습만으로 Phase 1 대비 RMSE_{hole}이 30.1% 개선되어 이미 Baseline 수준에 근접함으로써, PINN 가이드 단계적 활성화 전략의 실효성이 입증되었다. 이는 제한된 통신 예산 하에서 센서를 전면 활성화하는 비적응형 방식이 항상 최적이지 아니며, PINN 복원 결과를 활용한 선택적 활성화가 통신 효율과 복원 품질을 동시에 개선할 수 있음을 시사한다.

향후 연구로는 다음 세 가지 방향을 검토할 수 있다. 첫째, 실제 통신 환경 모델링이다. 본 연구는 업링크 메시지 수를 통신 비용의 프록시로 사용하였으나, 실제 V2I 환경에서는 채널 혼잡, 패킷 손실, 전파 지연 등이 복원 품질에 직접 영향을 미친다. NS-3 등의 네트워크 시뮬레이터와 SUMO를 연동하여 실제 통신 레이어를 모델링하면, 통신 지연이 PINN 복원 결과에 미치는 영향과 RSU 활성화 타이밍의 민감도를 보다 현실적으로 분석할 수 있다. 둘째, 실 도로망으로의 확장 및 실증이다. 본 연구는 단순화된 링 도로를 대상으로 하였으나, 분기·합류·교차로를 포함하는 2차원 네트워크에서는 교통류 보존식의 경계 조건이 복잡해진다. OpenStreetMap 기반 실제 지형 데이터를 SUMO에 임포트하여 도심 격자망 또는 고속도로 분기 구간에서의 PITAM 적용성을 검증하는 것이 중요한 다음 단계이다. 셋째, 이질적 관측 비용을 고려한 예산 최적화이다. RSU 활성화와 Probe 보고는 단위 통신 비용이 다를 수 있으며, Probe 종류에 따라 비용 구조가 달라진다. 이를 반영한 예산 제약 최적화 문제로 정식화하면 통신 효율을 더욱 정밀하게 제어할 수 있다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-지역지능화혁신인재양성사업의 지원을 받아 수행된 연구임(IITP-2026-RS-2022-00156287)(34%) 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 인공지능융합혁신인재양성사업 연구 결과로 수행되었음(IITP-2026-RS-2023-00256629)(33%) 본 연구성과는 2025년도

정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(RS-2025-25398164)(33%)

참고 문헌

- [1] Seo, Toru, et al. "Traffic state estimation on highway: A comprehensive survey." *Annual reviews in control* 43 (2017): 128-151.
- [2] Huang, Archie J., and Shaurya Agarwal. "Physics informed deep learning for traffic state estimation." *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*. IEEE, 2020.
- [3] Baloul, Nail, et al. "Traffic Flow Reconstruction from Limited Collected Data." *2025 IEEE 64th Conference on Decision and Control (CDC)*. IEEE, 2025.
- [5] Kessler, Lisa, Felix Rempe, and Klaus Bogenberger. "Multi-sensor data fusion for accurate traffic speed and travel time reconstruction." *Frontiers in Future Transportation* 2 (2021): 766951.
- [6] Xing, Jiping, et al. "Traffic state estimation of urban road networks by multi-source data fusion: Review and new insights." *Physica A: Statistical Mechanics and its Applications* 595 (2022): 127079.
- [7] Seo, Toru, and Takahiko Kusakabe. "Probe vehicle-based traffic state estimation method with spacing information and conservation law." *Transportation Research Part C: Emerging Technologies* 59 (2015): 391-403.
- [8] Chapman, Michael A., Cao Min, and Deijin Zhang. "Continuous mapping of tunnel walls in a GNSS-denied environment." *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 41 (2016): 481-485.
- [9] Yaqoob, Raffay. "A Recent Survey of Event Triggered Control of Nonlinear Systems." *arXiv preprint arXiv:2202.01684* (2021).
- [10] Wang, Jianrui, et al. "Integrated adaptive communication in multi-agent systems: Dynamic topology, frequency, and content optimization for efficient collaboration." *Neurocomputing* 617 (2025): 129068.
- [11] Ma, Ziyuan, Yudong Luo, and Jia Pan. "Learning selective communication for multi-agent path finding." *IEEE Robotics and Automation Letters* 7.2 (2021): 1455-1462.
- [12] Raissi, Maziar, Paris Perdikaris, and George E. Karniadakis. "Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations." *Journal of Computational physics* 378 (2019): 686-707.
- [13] Cai, Shengze, et al. "Physics-informed neural networks for heat transfer problems." *Journal of Heat Transfer* 143.6 (2021): 060801.
- [14] Shi, Rongye, Zhaobin Mo, and Xuan Di. "Physics-informed deep learning for traffic state estimation: A hybrid paradigm informed by second-order traffic models." *Proceedings of the AAAI conference on artificial intelligence*. Vol. 35. No. 1. 2021.
- [15] Wilkman, Dennis, et al. "Online traffic density estimation using physics-informed neural networks." *2025 IEEE 64th Conference on Decision and Control (CDC)*. IEEE, 2025.
- [16] Shahrbabaki, Majid Rostami, et al. "A data fusion approach for real-time traffic state estimation in urban signalized links." *Transportation research part C: emerging technologies* 92 (2018):

525-548.

- [17] Gao, Jingqin, Kaan Ozbay, and Abdullah Kurkcu. "Multi-source data fusion for urban traffic state estimation: A case study of New York City." (2018).
- [18] Peng, Chen, and Fuqiang Li. "A survey on recent advances in event-triggered communication and control." *Information Sciences* 457 (2018): 113-125.
- [19] Farooq, Ahmad, and Kamran Iqbal. "Bandwidth-Efficient Multi-Agent Communication through Information Bottleneck and Vector Quantization." *arXiv preprint arXiv:2602.02035* (2026).
- [20] Shibata, Kazuki, Tomohiko Jimbo, and Takamitsu Matsubara. "Deep reinforcement learning of event-triggered communication and consensus-based control for distributed cooperative transport." *Robotics and Autonomous Systems* 159 (2023): 104307.
- [21] Siddique, Umer, Abhinav Sinha, and Yongcan Cao. "Adaptive event-triggered reinforcement learning control for complex nonlinear systems." *2025 American Control Conference (ACC)*. IEEE, 2025.