

End-to-End自動運転時代の V2X通信技術

塚田 学

東京大学 情報理工学系研究科



Tsukada Lab.
Computer Network Group

End-to-End自動運転時代のV2X通信技術

- なぜ今 End-to-End × V2X なのか
- アーキテクチャの転換点：ルールベースから End-to-End へ
- End-to-End 時代の協調型自動運転
- 塚田研究室の研究紹介

インターネットの普及で重要な要素 → 研究・開発で重視している要素

オープンアーキテクチャ

参照モデル・アーキテクチャ
標準プロトコル
標準インターフェイス
標準データフォーマット
標準識別子

相互運用性

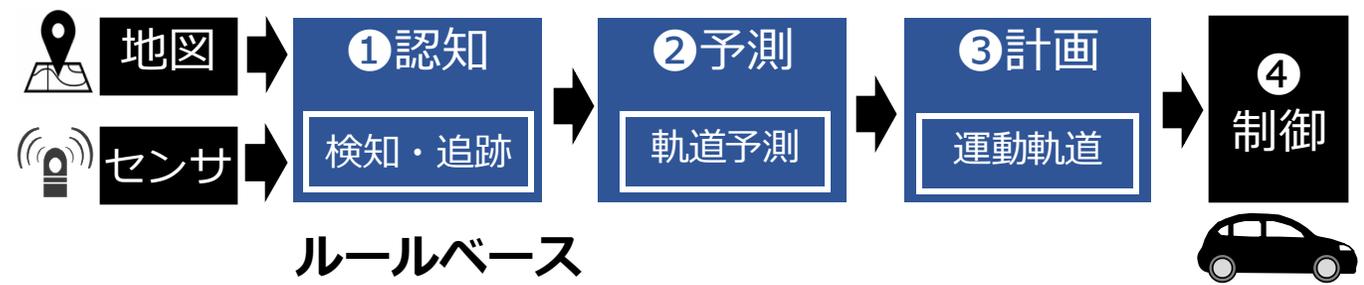
標準化機関：IETF
(Internet Engineering Task Force)
オープン規格：RFC
(Request for Comments)
イベント：Interop

オープンプラットフォーム

参照実装：
BSD
(Berkeley Software Distribution)
Linux
オープンソース実装

📍 ルールベースから End-to-End へ

- 各機能モジュールとそのアウトプットを開発者が設計



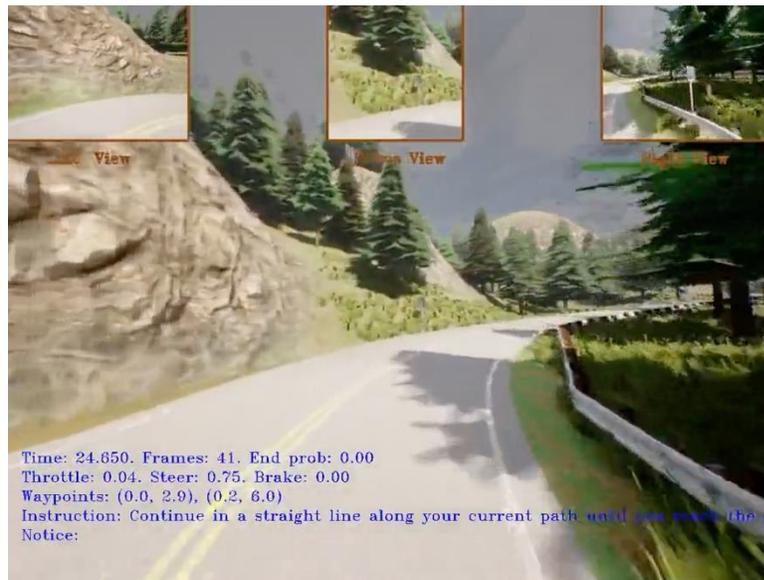
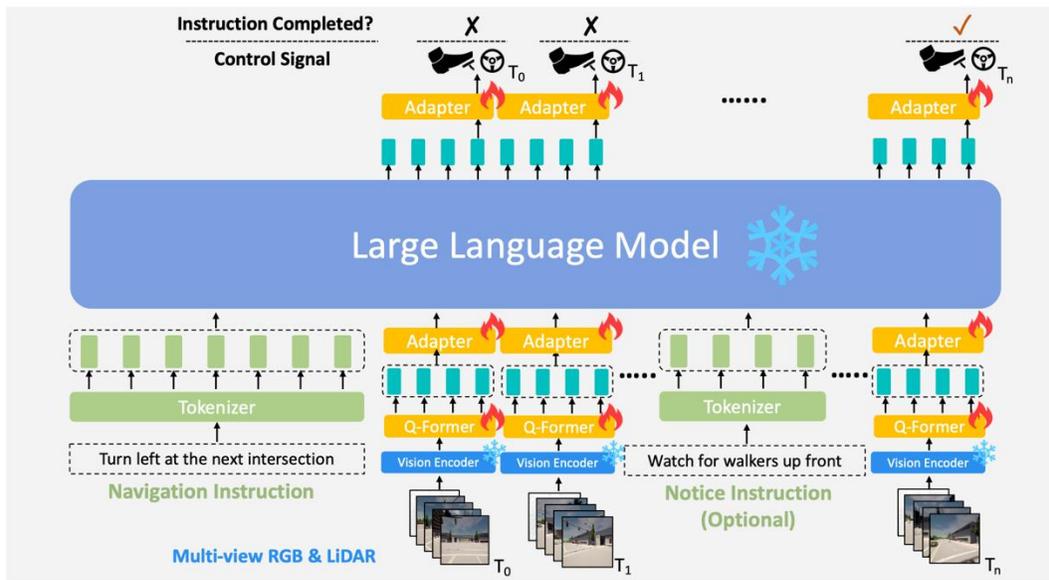
- ✗ モジュール間の誤差の蓄積
- ✗ モジュールごとの最適化 (全体の運転タスクの非最適)
- ✗ 複雑な状況下でのルールの網羅性 (未知のシナリオへの汎化能力)

- AIモデルを開発しインプットを与えることで運転



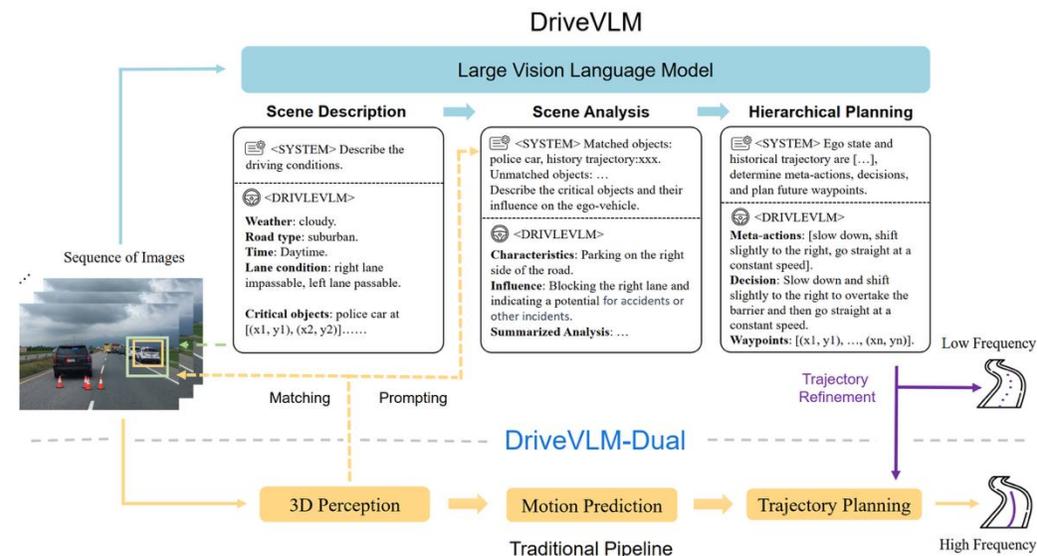
- ✓ 誤差蓄積の低減
- ✓ より一貫性のある意思決定
- ✓ 無数のエッジケースに対応 (未知のシナリオへの汎化能力)
- ✗ 解釈可能性と説明可能性
- ✗ 安全保証
- ✗ データ依存性

End-to-End 自動運転



Hao Shao, et al., "LMDrive: Closed-Loop End-to-End Driving with Large Language Models", CVPR2024

X.Tian¹, J. Gu¹, B. Li, Y. Liu, et al.
"DriveVLM: The Convergence of Autonomous Driving and Large Vision-Language Models", CoRL2024



🌀 ルールベースから End-to-End へ

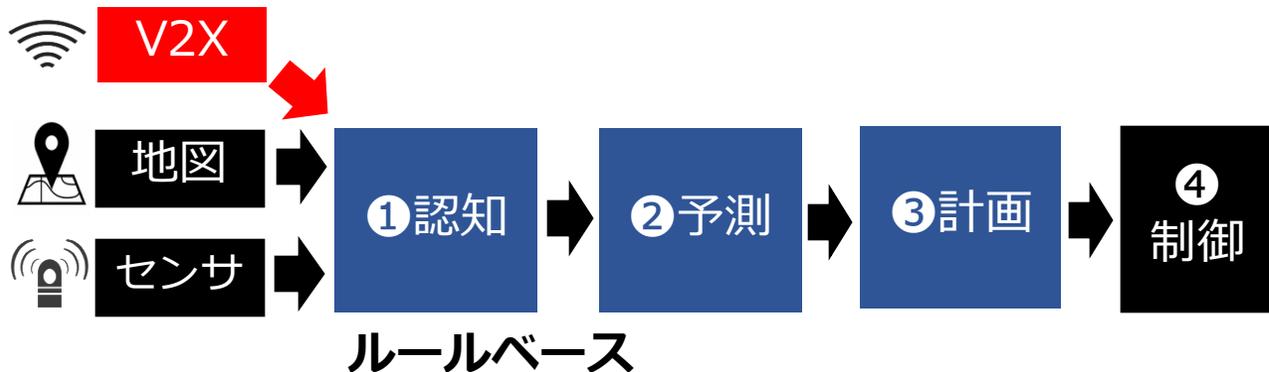
| 特徴 | ルールベース（モジュラー型） | End-to-End（統合型） |
|----------|--------------------------------|--------------------------------------|
| アーキテクチャ | 逐次的なモジュールパイプライン（認識→予測→計画→制御） | 統合された（しばしば単一の）学習ベースモデル |
| 意思決定ロジック | 事前定義されたルール、有限状態機械、階層的論理 | データから学習されたパターン、ニューラルネットワークによる推論 |
| データ依存性 | 専門知識、ルール定義に依存。データは主にモジュール評価に使用 | 訓練データの質と量に強く依存 |
| スケーラビリティ | 複雑化に伴いルール管理が困難、拡張性に限界 | データと計算リソースによりスケールする可能性。エッジケース対応に優位 |
| 適応性・汎化能力 | 未知の状況への適応が困難、人間らしい運転の模倣が難しい | 複雑な状況への適応、未知のシナリオへの汎化が期待される |
| 解釈可能性 | 比較的高い。ルールの追跡が可能 | 低い。「ブラックボックス」問題 |
| 誤差伝播 | モジュール間で誤差が蓄積・増幅しやすい | 統合されているため誤差蓄積は少ない可能性があるが、入力誤差の影響は大きい |
| 安全性検証 | ルールベースのため検証しやすい側面もあるが、網羅性は課題 | 確率的な挙動のため、形式的な保証が困難 |



本講演のテーマ

～End-to-End自動運転時代のV2X通信技術～

- 協調型自動運転はルールベースを対象に開発されてきた



共通の通信アーキテクチャ
共通技術の仕様標準化
相互運用性とその検証

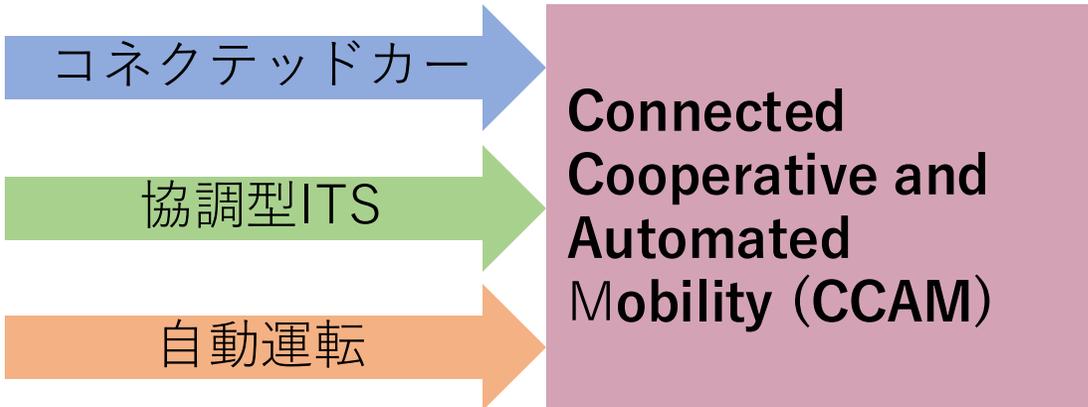
➡ 人手でメッセージを設計・定義し、
コンセンサスをもとに標準化

- End-to-End自動運転時代のV2Xはどうあるべきか？



AIファーストなV2Xメッセージの交換？
相互運用性のための標準化はどうなる？

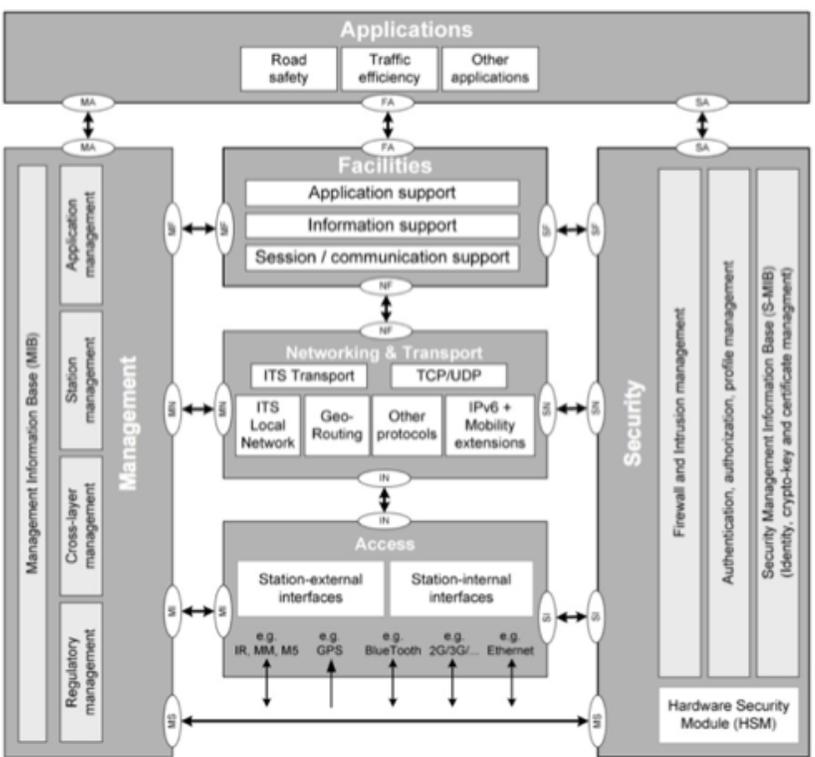
Connected Cooperative and automated mobility



- 共通の通信アーキテクチャ
- 共通技術の仕様標準化
- 相互運用性とその検証



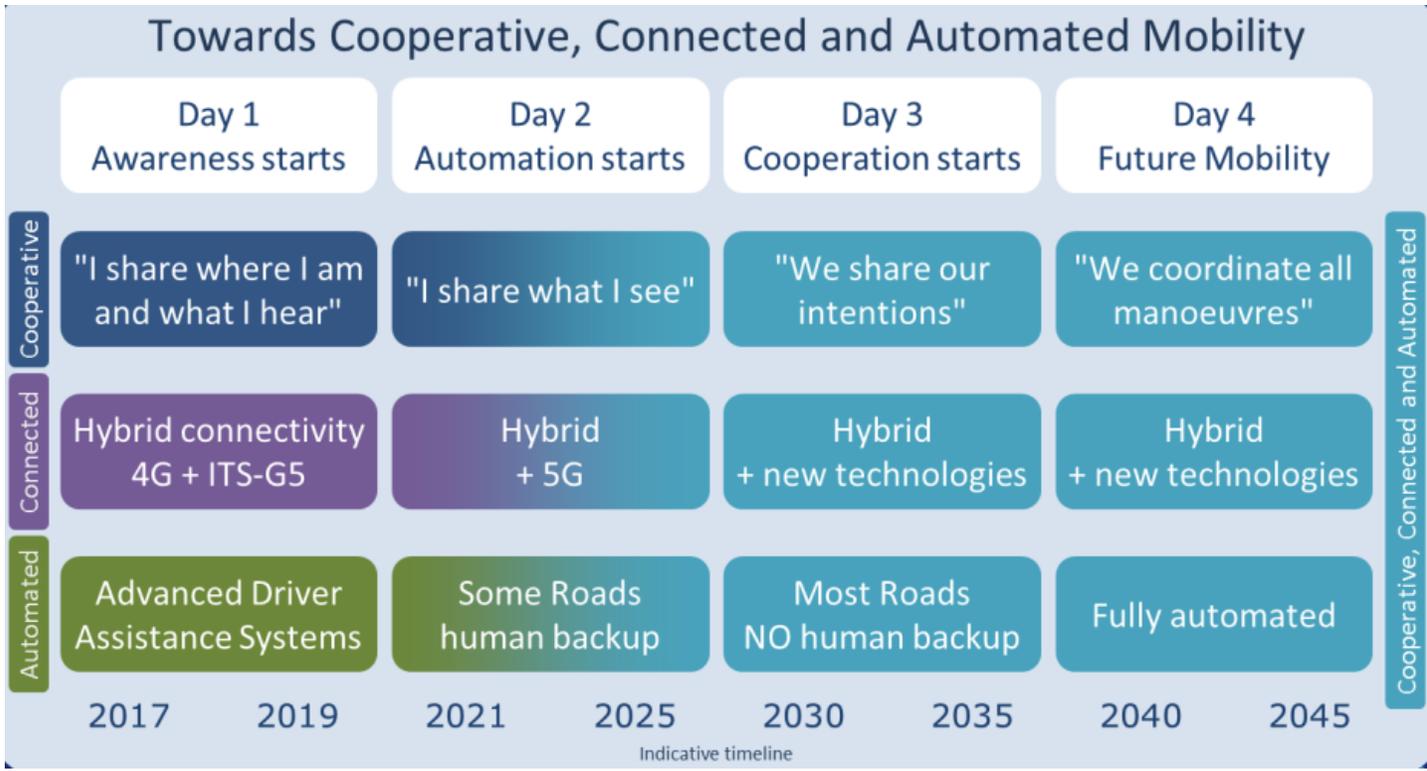
ITS Station
参照基盤



ETSIプラグテスト(2012)

欧州委員会のロードマップ

- Day 1
 - Cooperative Awareness Message (CAM)
 - Vehicle status information
 - ETSI **EN** 302 637-2 (2014)
 - Decentralized Environmental Notification Message (DENM)
 - Traffic information
 - ETSI **EN** 302 637-3 (2014)
 - Local Dynamic Map (LDM)
 - Realtime database of surrounding environment
 - ETSI **EN** 302 895 (2014)
- Day 2
 - Collective Perception Message (CPM)
 - Sensor information sharing
 - ETSI **TS** 103 324 (Specification, 2023)
 - ETSI **TR** 103 562 (Analysis, 2019)
- Day 3+
 - Future path sharing
 - Maneuver Coordination Message (MCM)
 - ETSI **TR** 103 578 (Analysis, 2024)



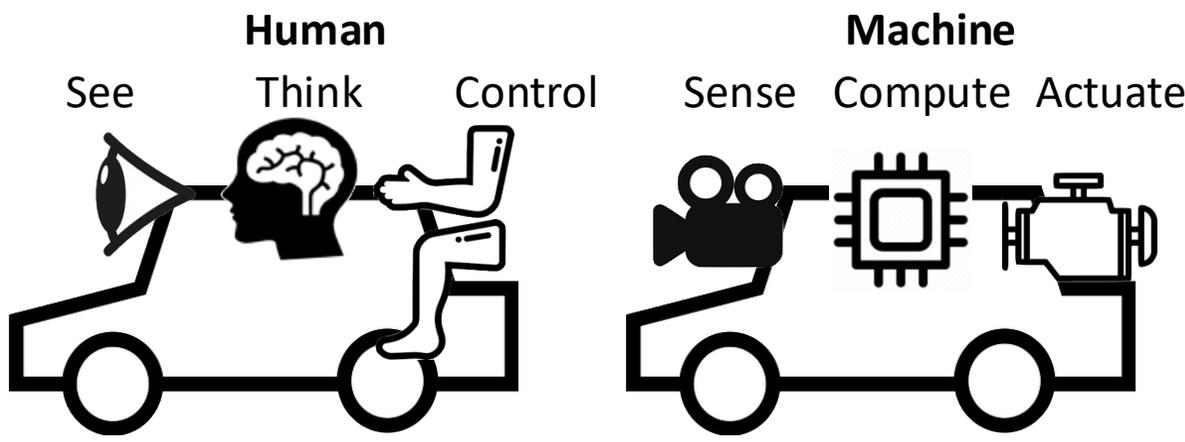
Source: European Commission, "C-ROADS Platform for C-ITS in Europe", C-ROADS PORTUGAL STAKEHOLDER WORKSHOP, 2017

ETSIやIEEE WAVEの標準に準拠した車載器・路側機



- EN**: 欧州標準 (European Norm) 欧州各国の標準化組織に承認された技術標準。
- TS**: ETSI技術仕様 (ETSI Technical Specification) ETSI技術委員会内で承認された技術仕様書。
- TR**: 標準化議論に有用な技術報告 (TR, Technical Report)

Autonomous Driving



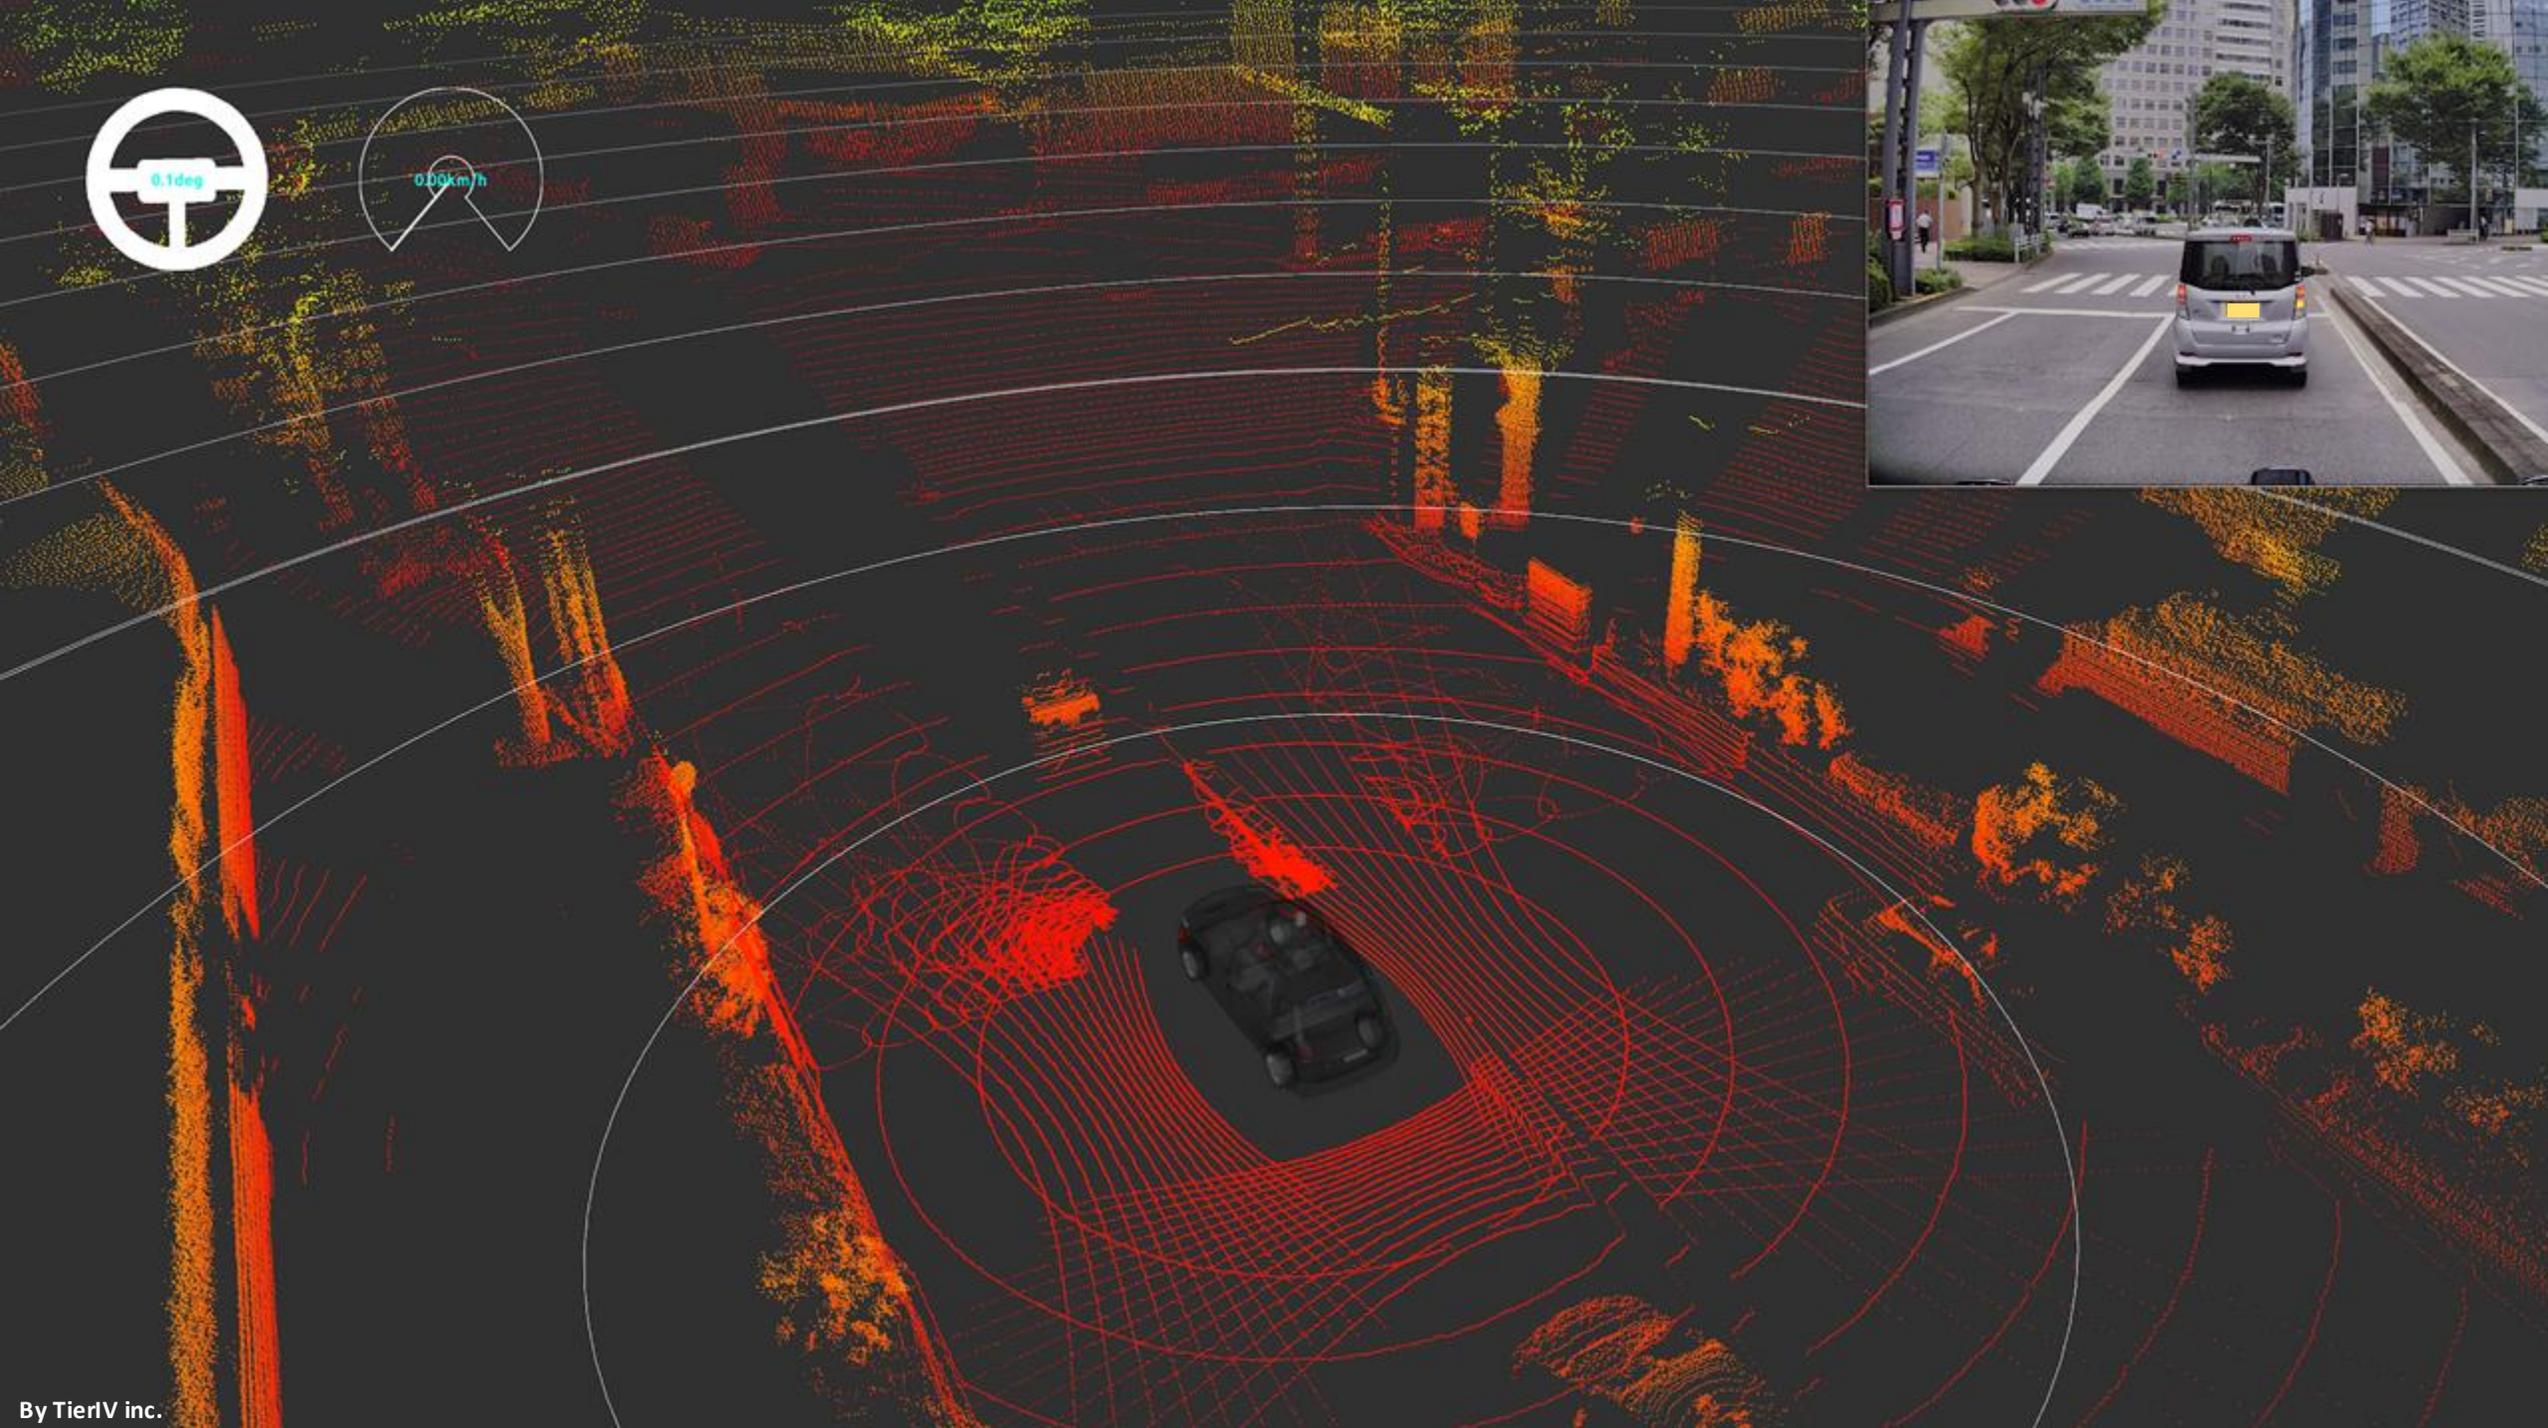
| Level | acceleration, steering, brake | Monitoring | Fallback performance | Modes and limitation | |
|---------|-------------------------------|------------|----------------------|----------------------|---------|
| Level 0 | | | | n/a | to 2000 |
| Level 1 | | | | Limitation | 2000s |
| Level 2 | | | | Limitation | 2010s |
| Level 3 | | | | Limitation | Today |
| Level 4 | | | | Limitation | By 2025 |
| Level 5 | | | | No limitation | By 2045 |

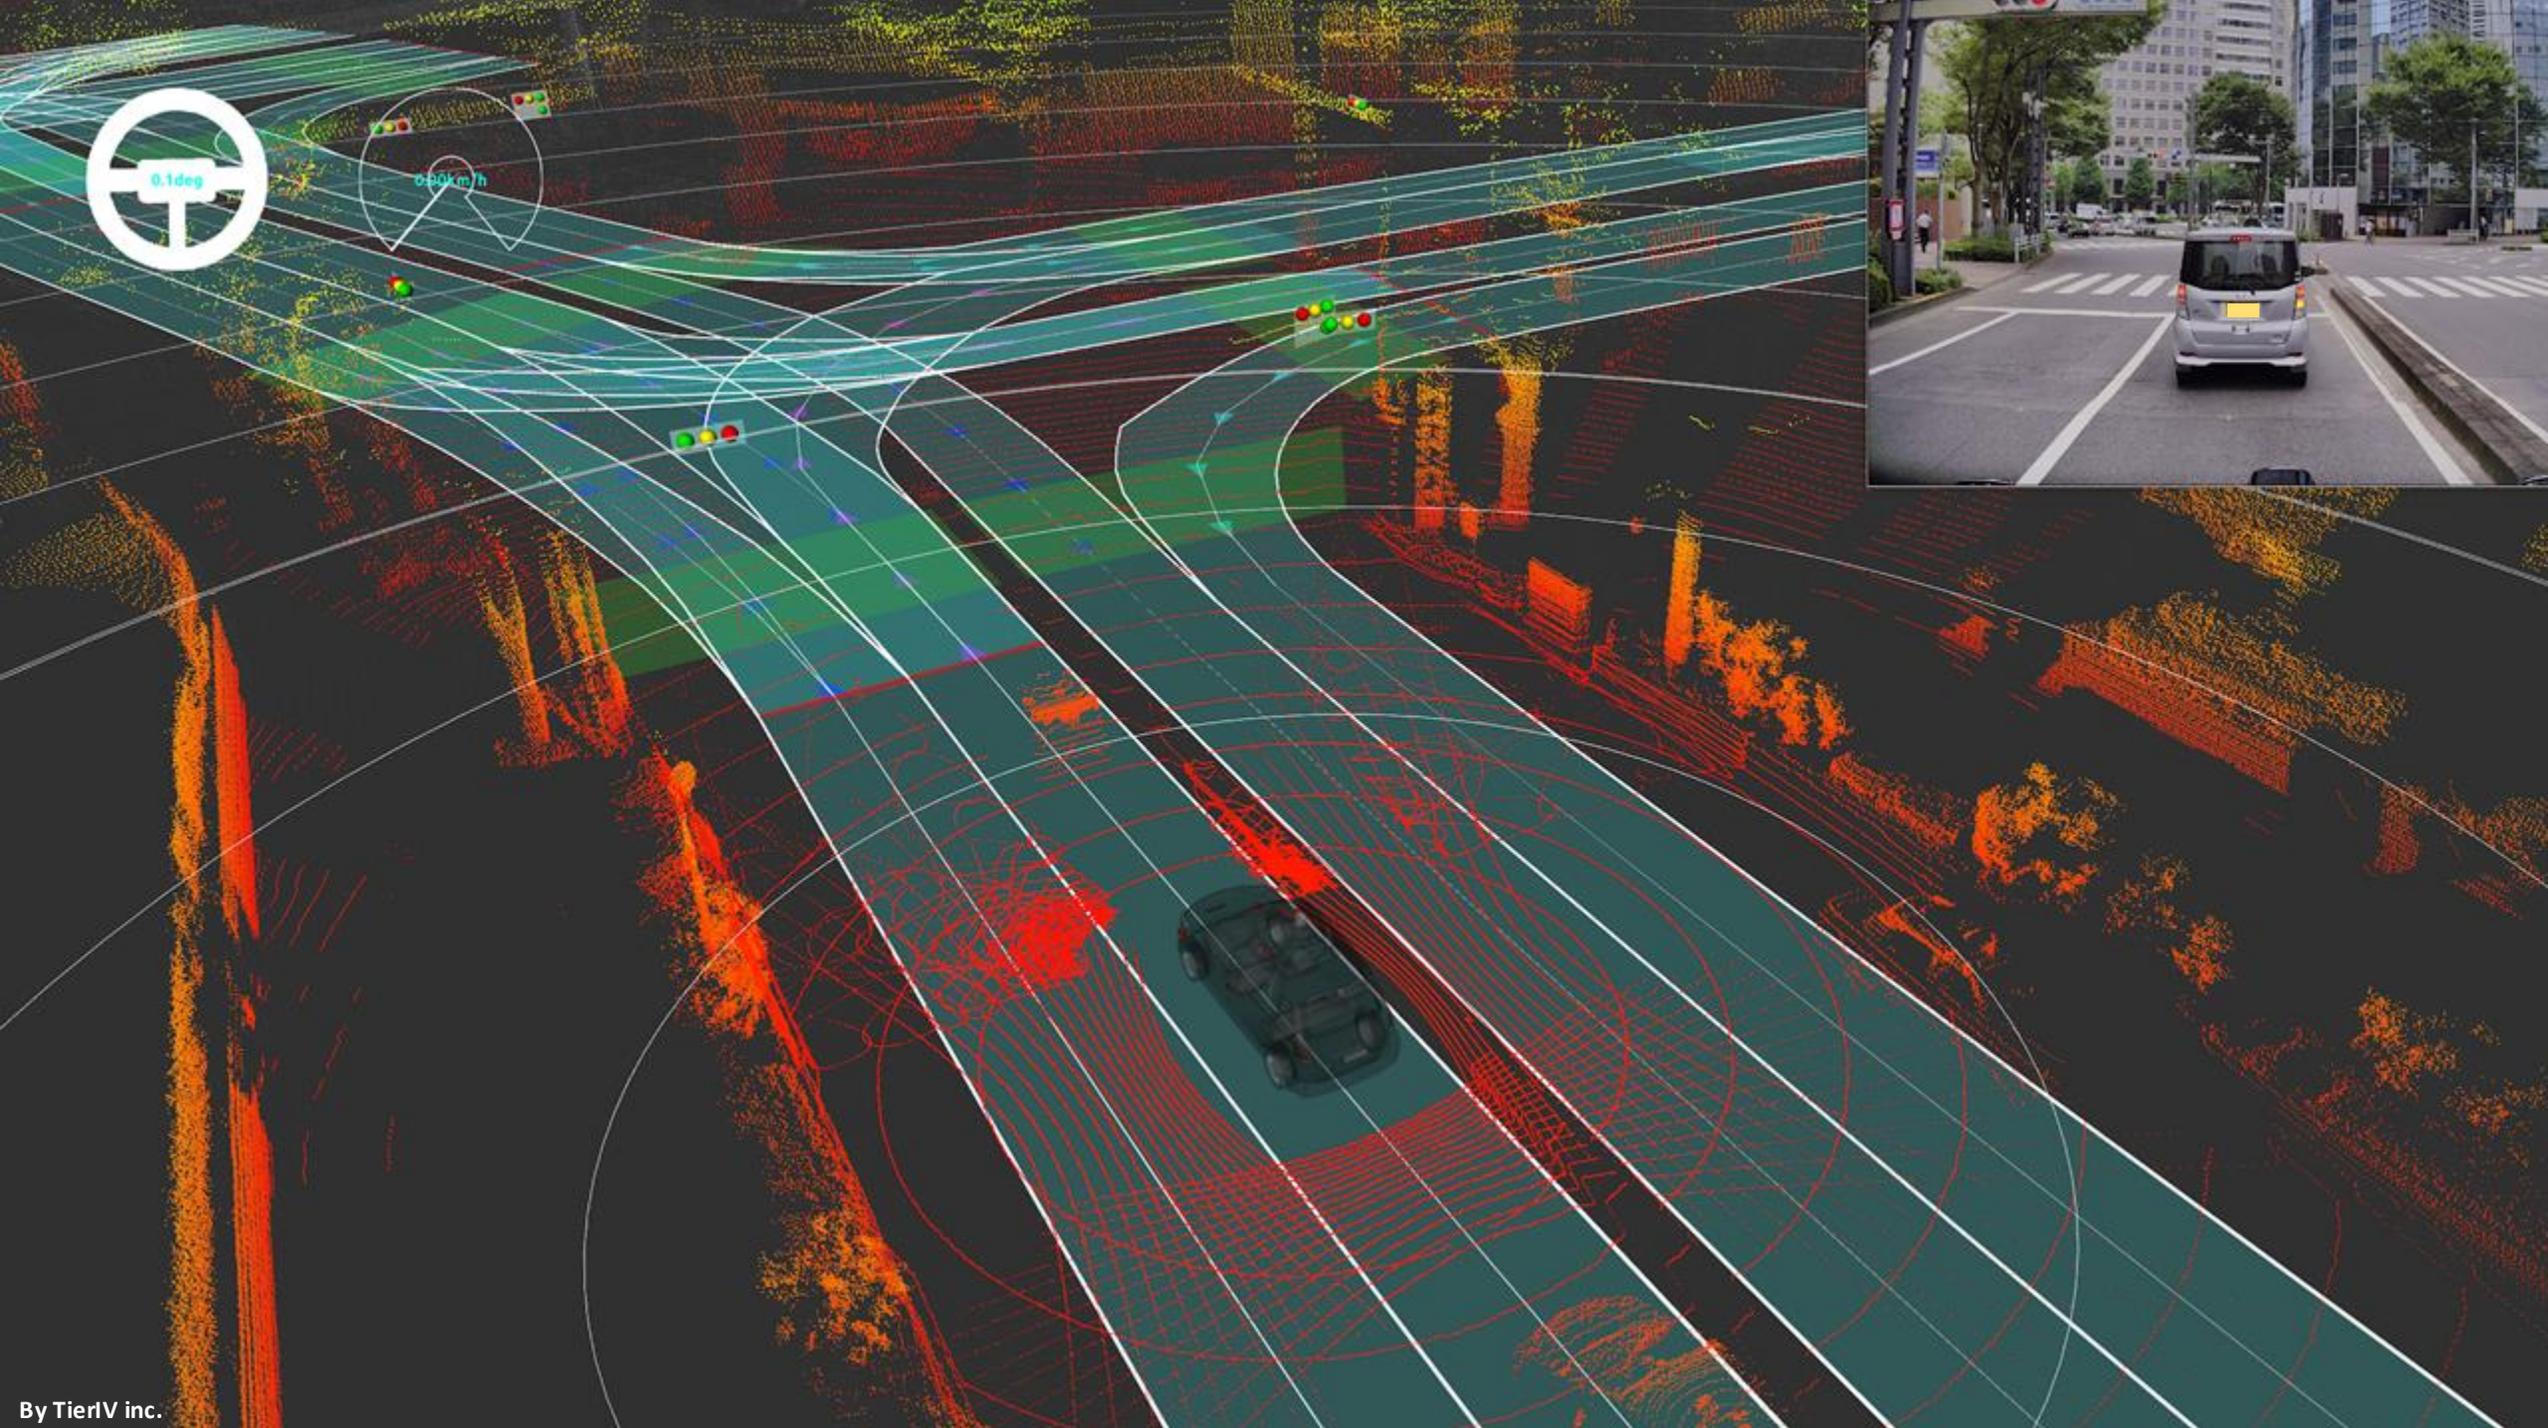
Human
 System
 SAE (J3016) Automation Levels

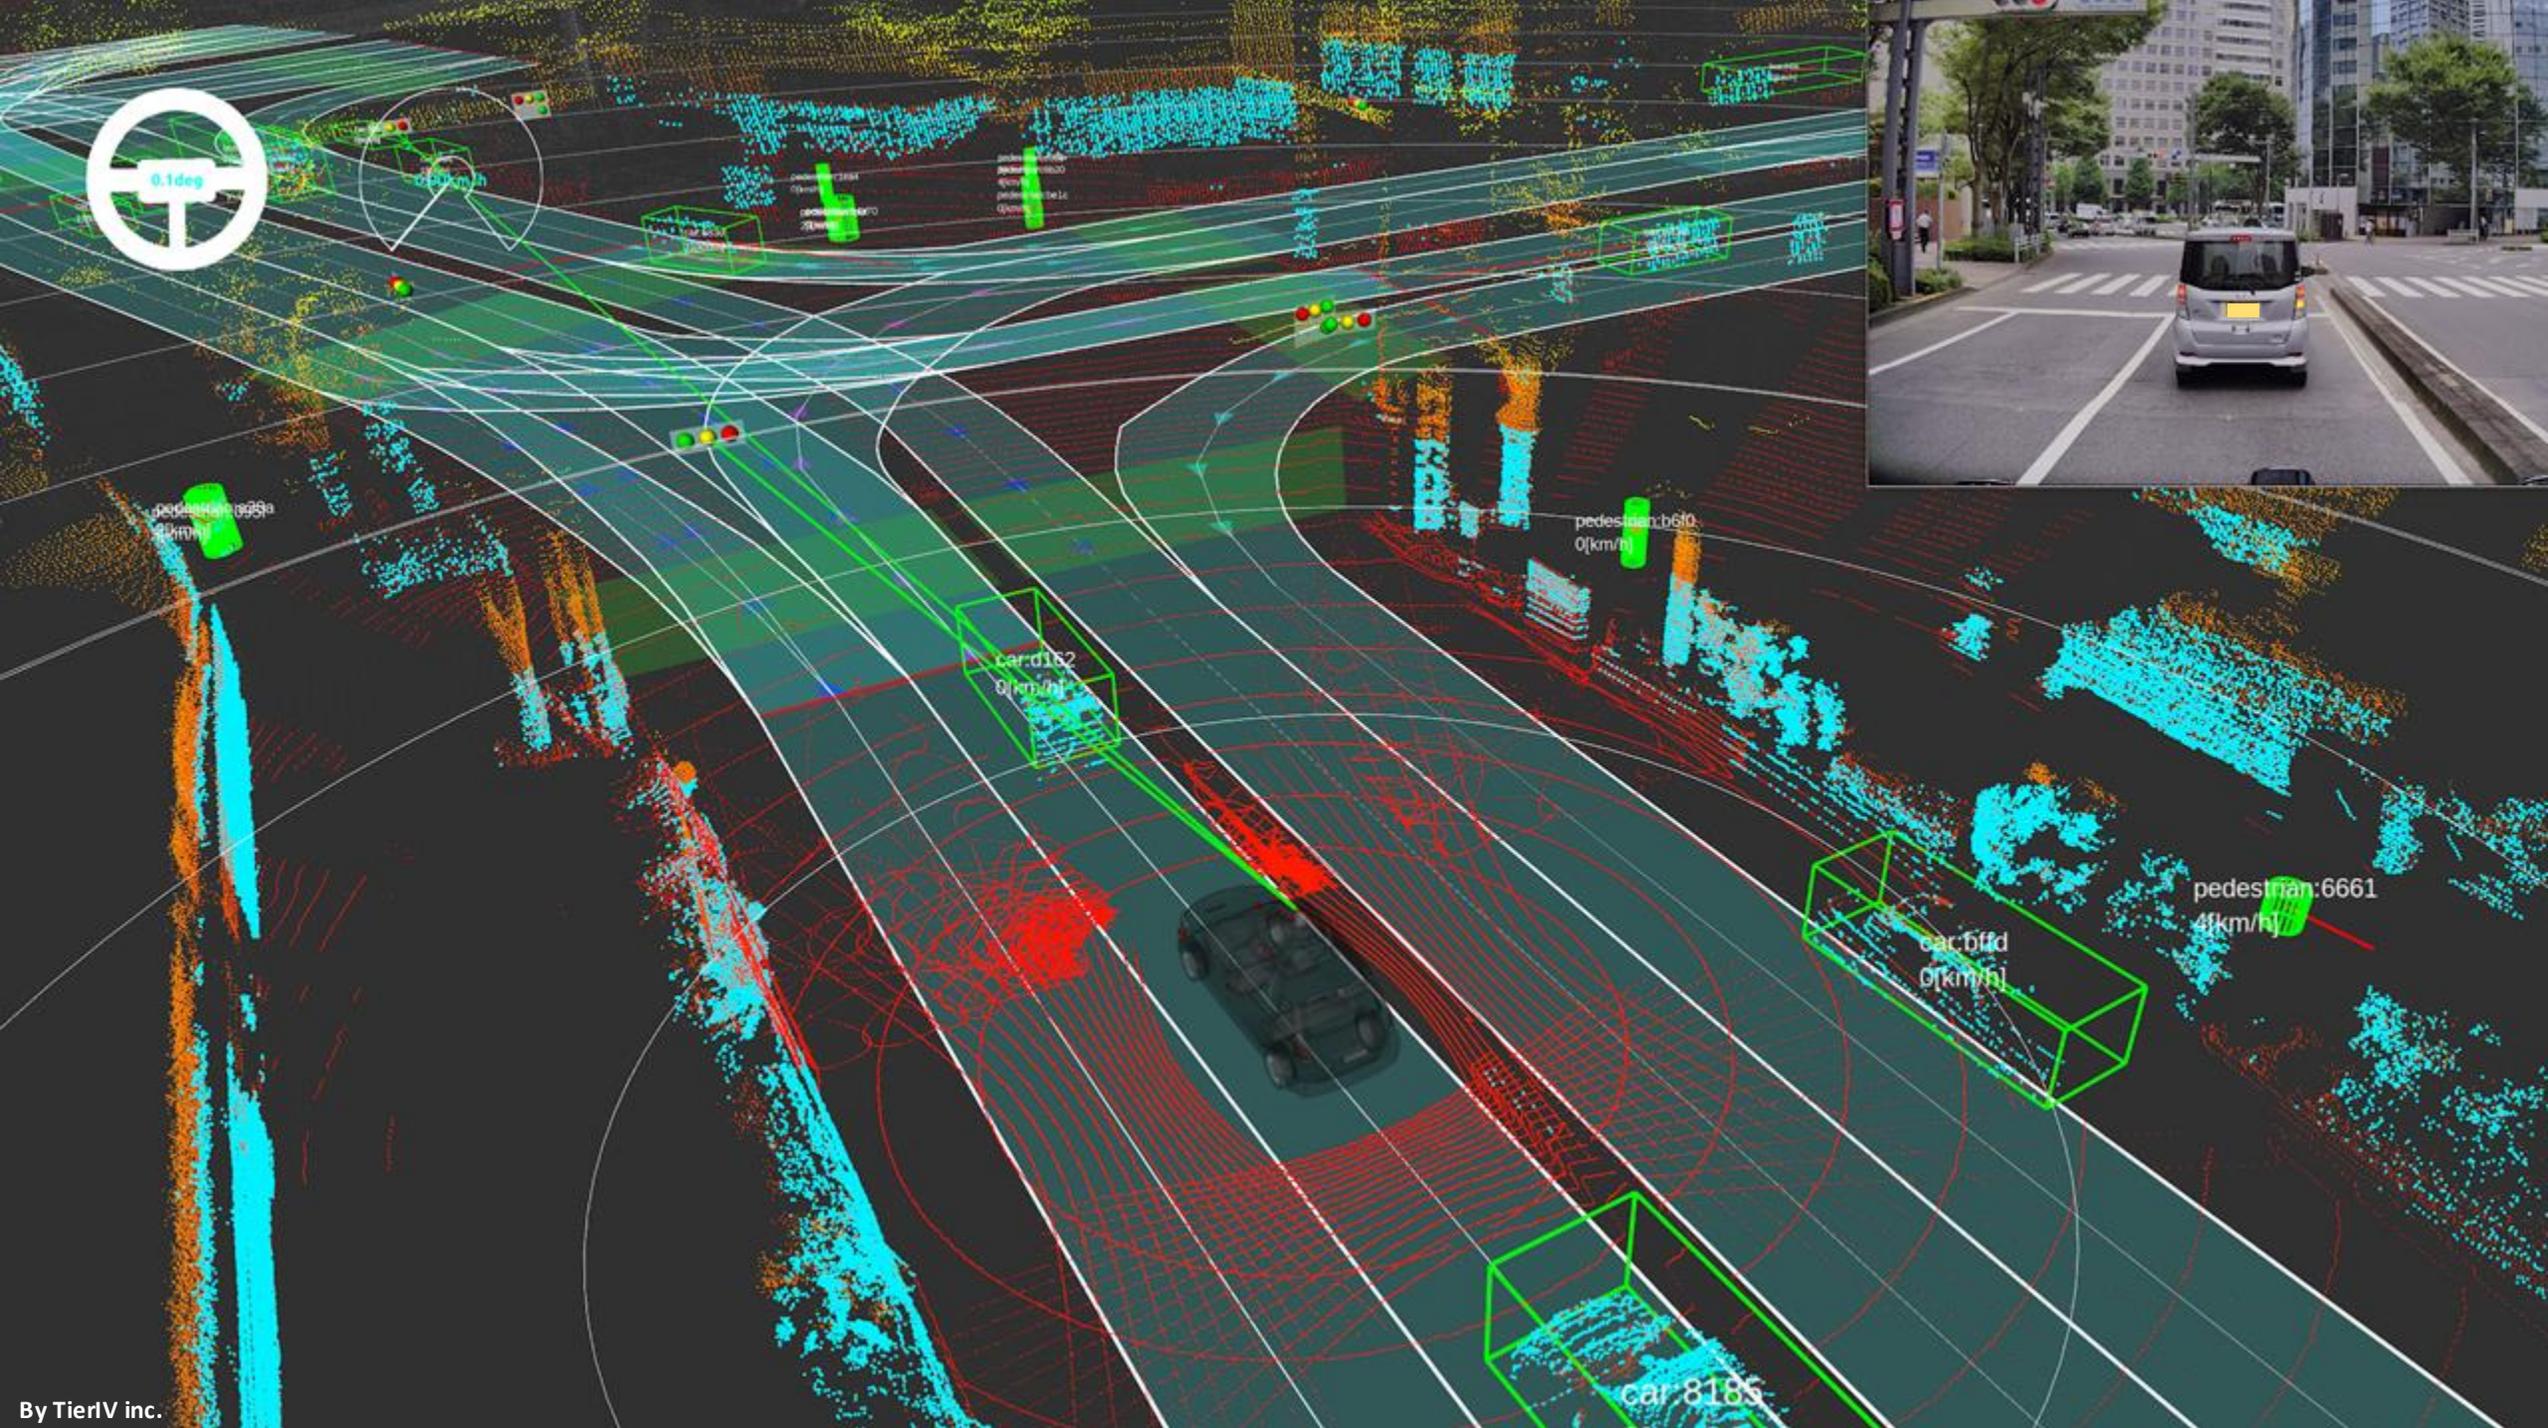
- Open Source softwares

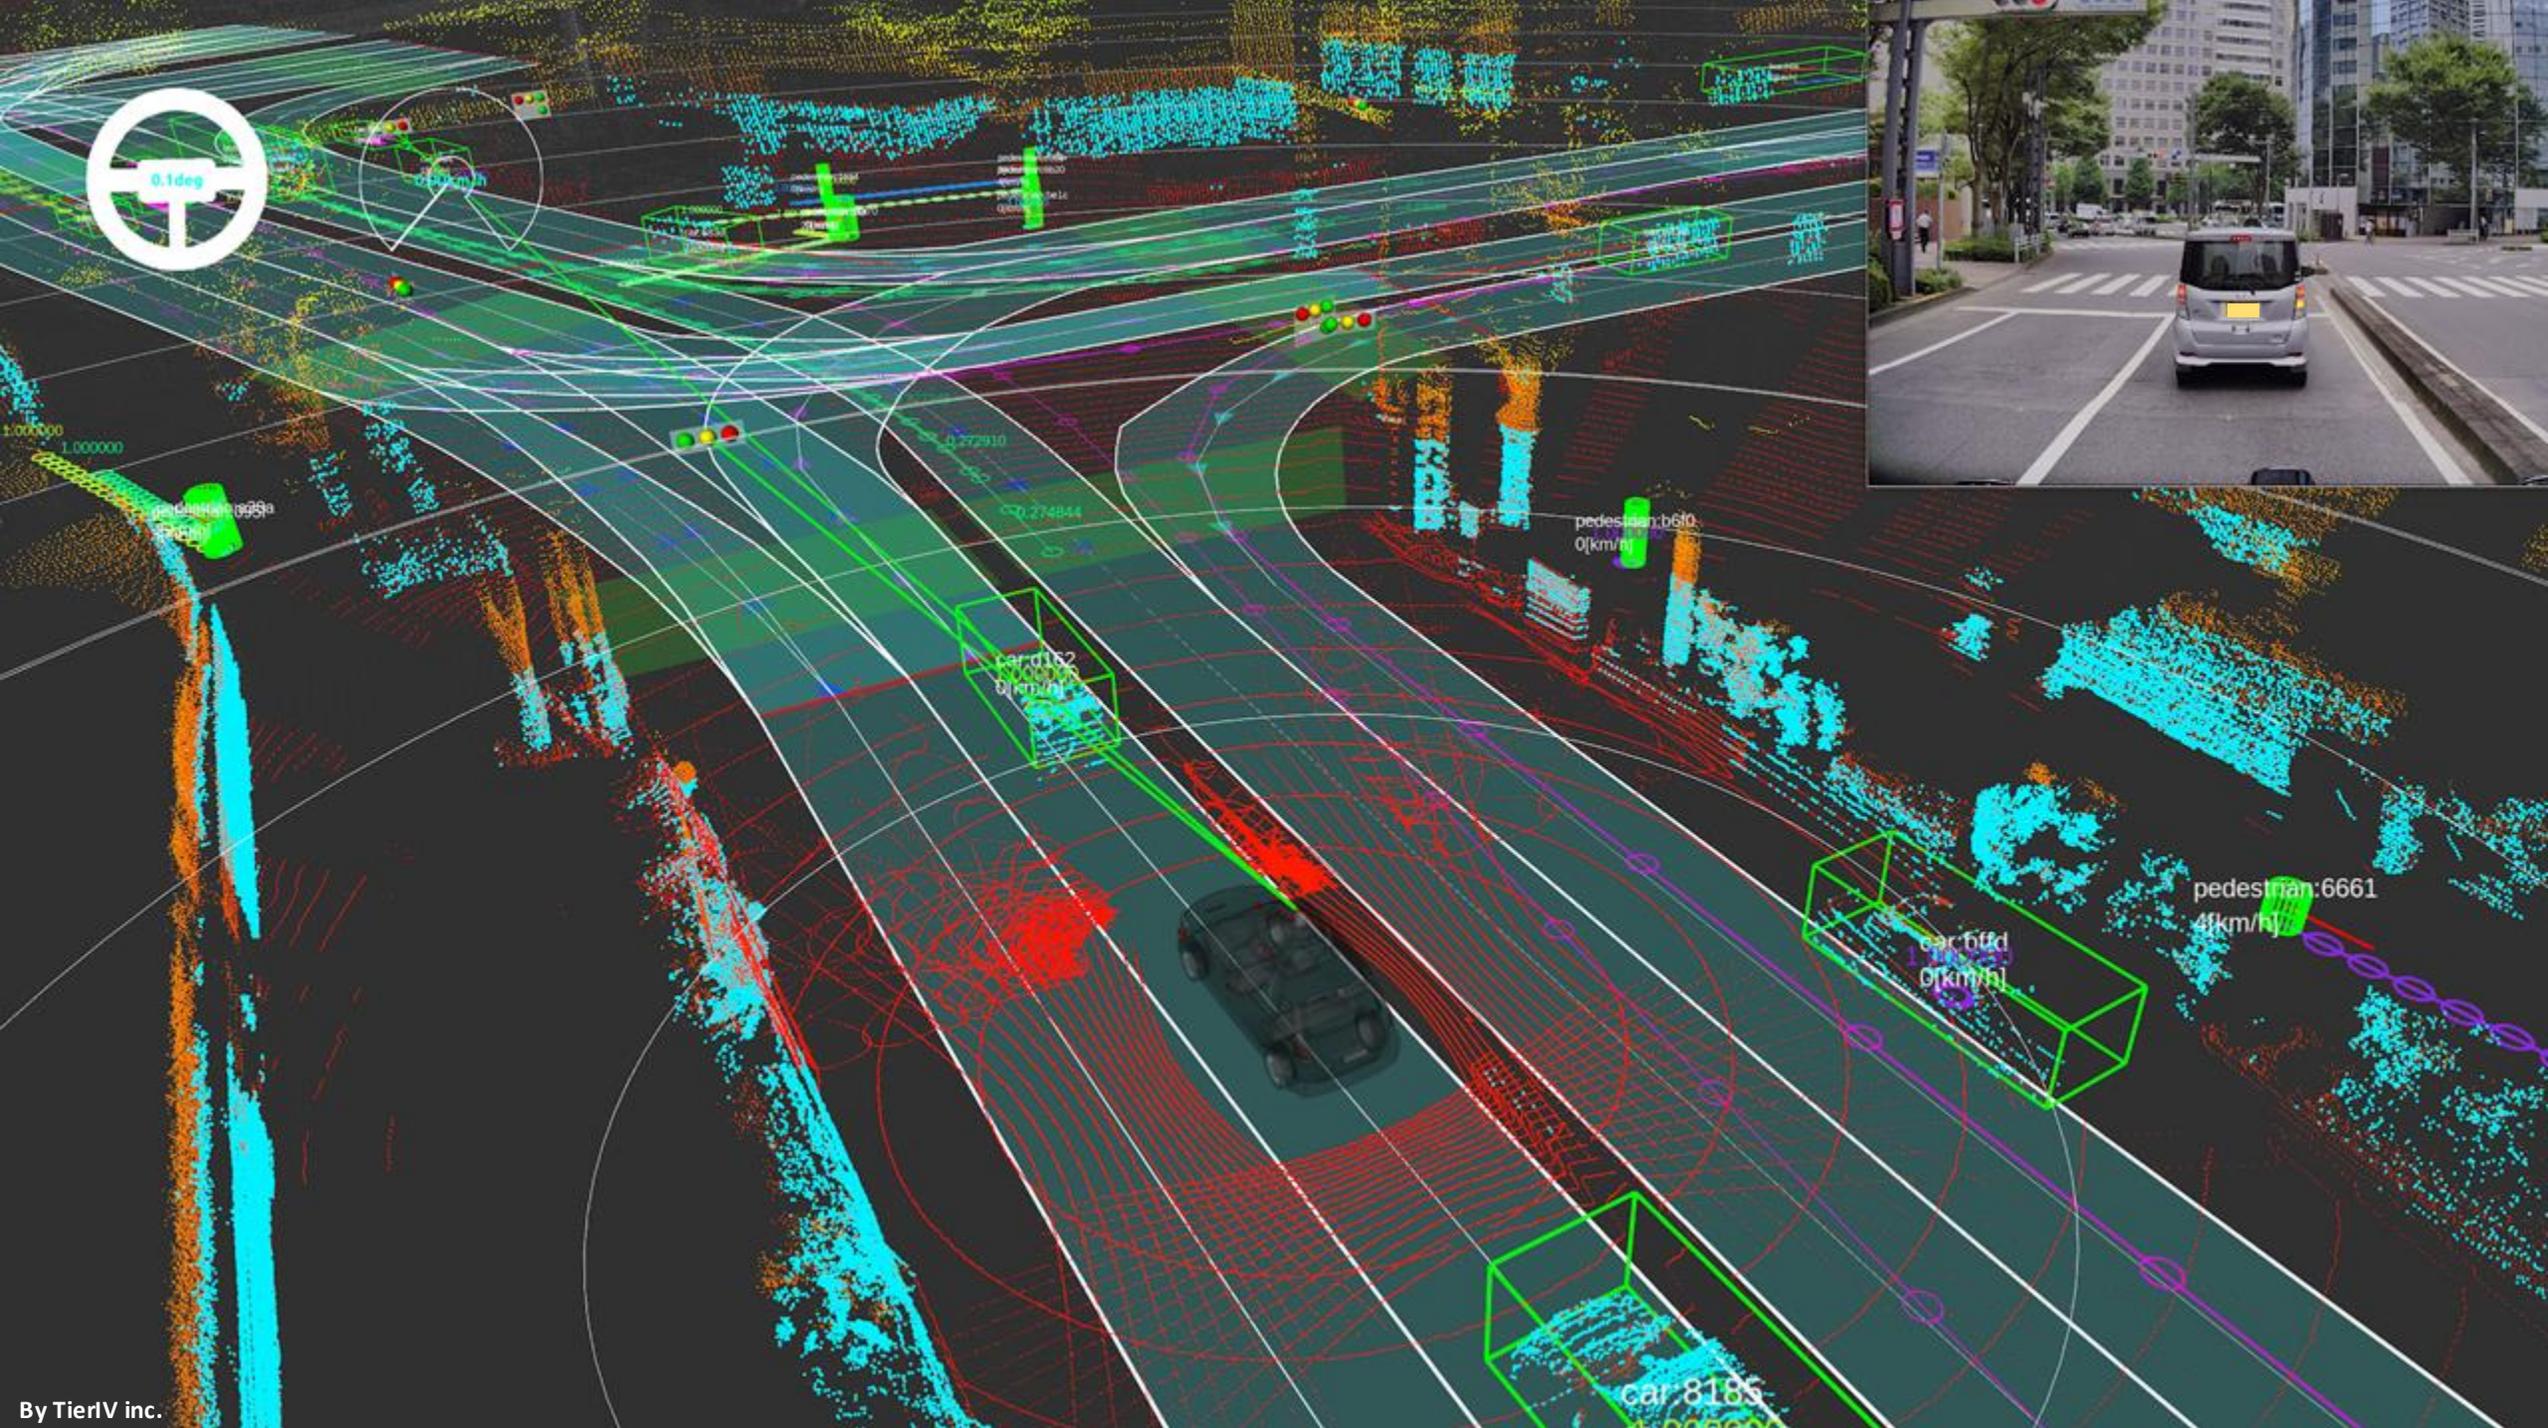
<https://www.autoware.ai/>

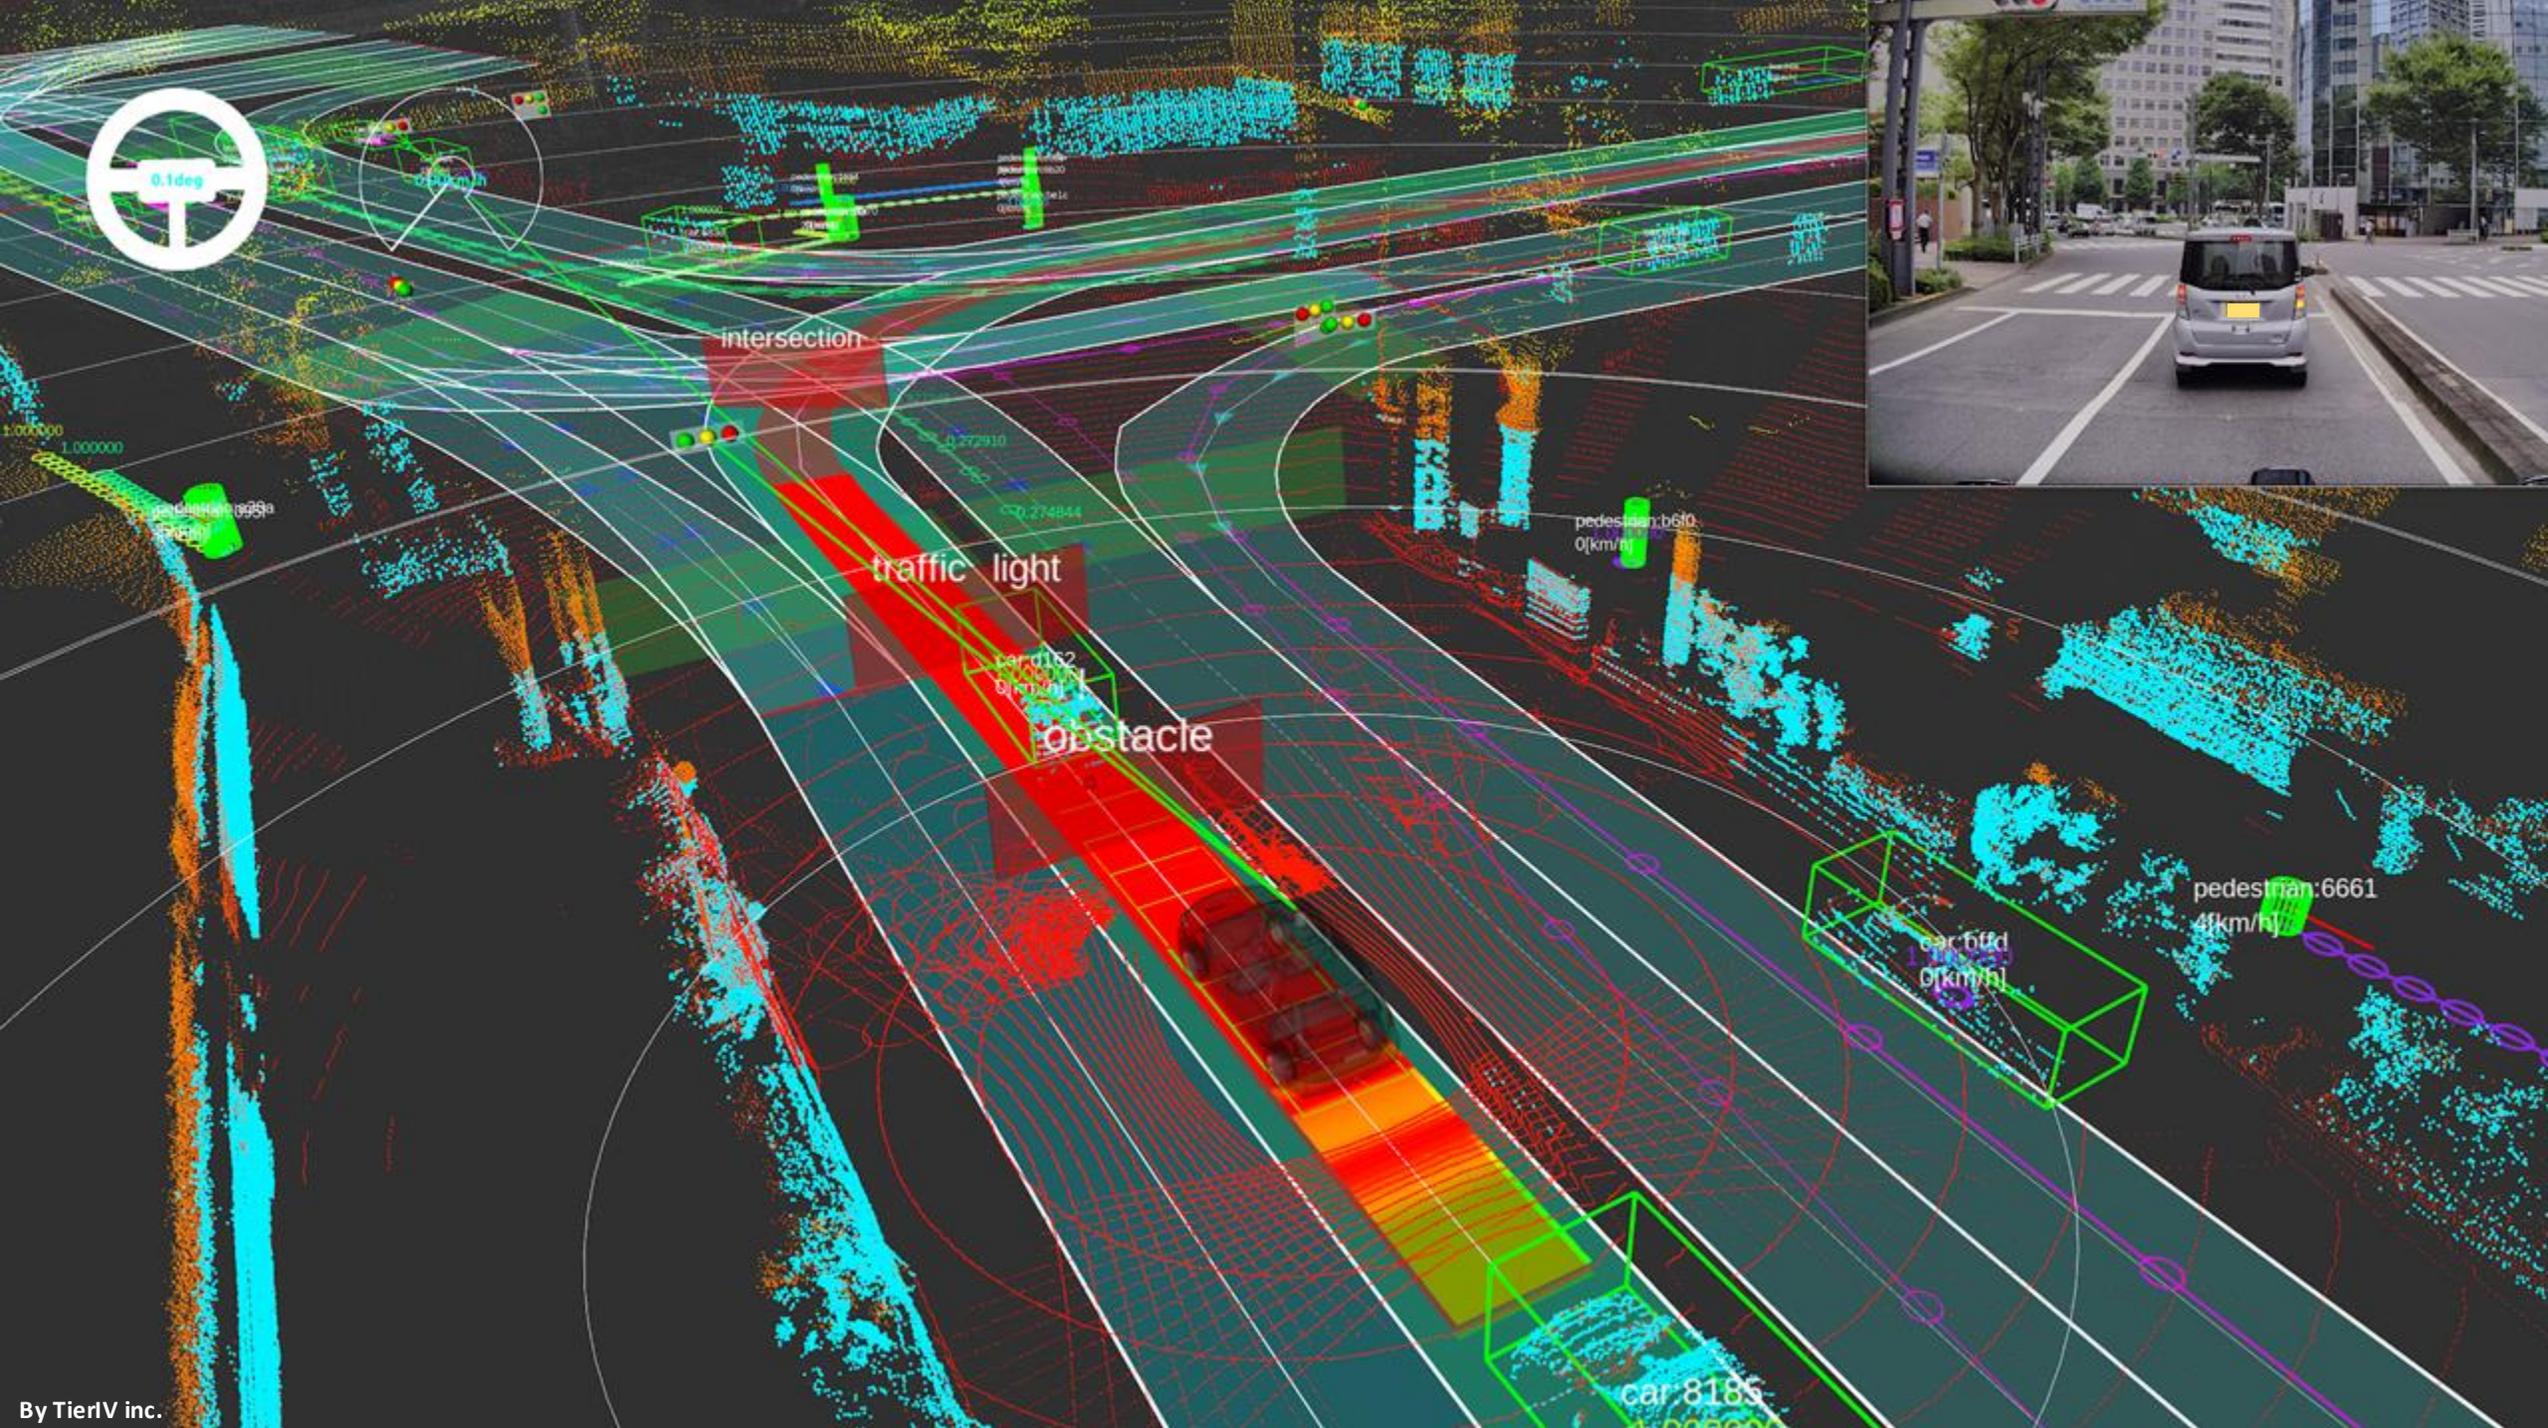
<https://apollo.auto/>

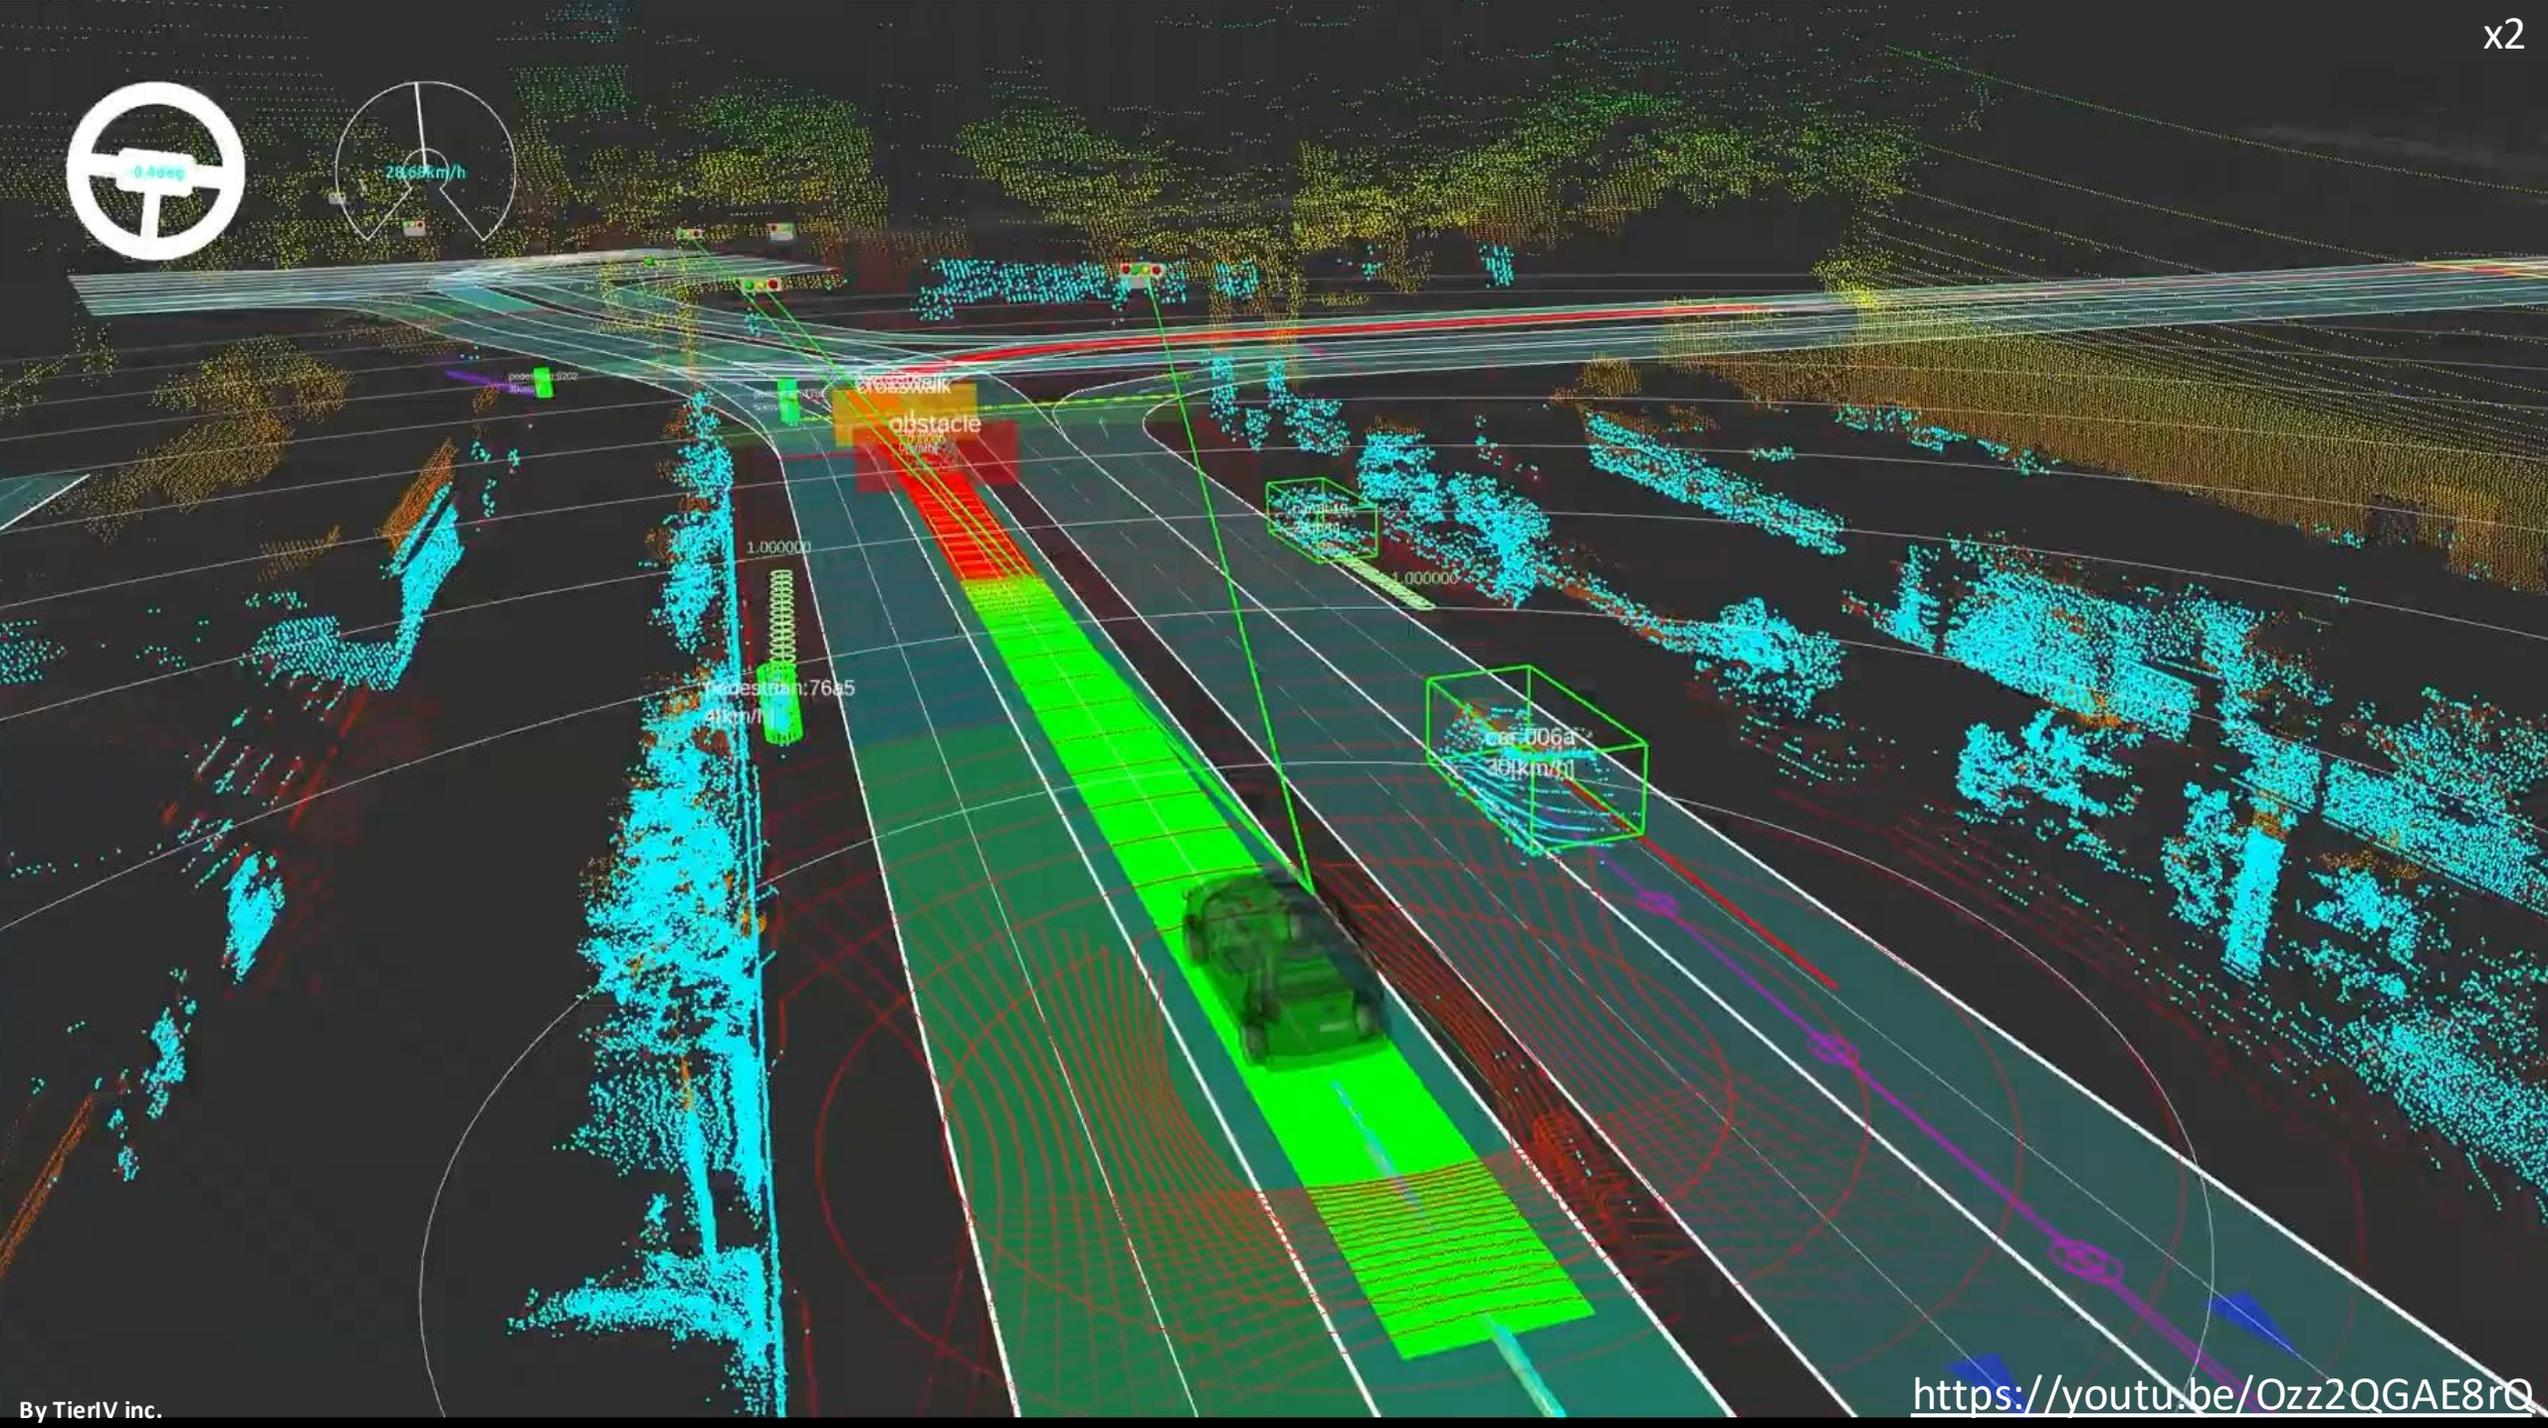












1.000000

pedestrian: 76a5
41km/h

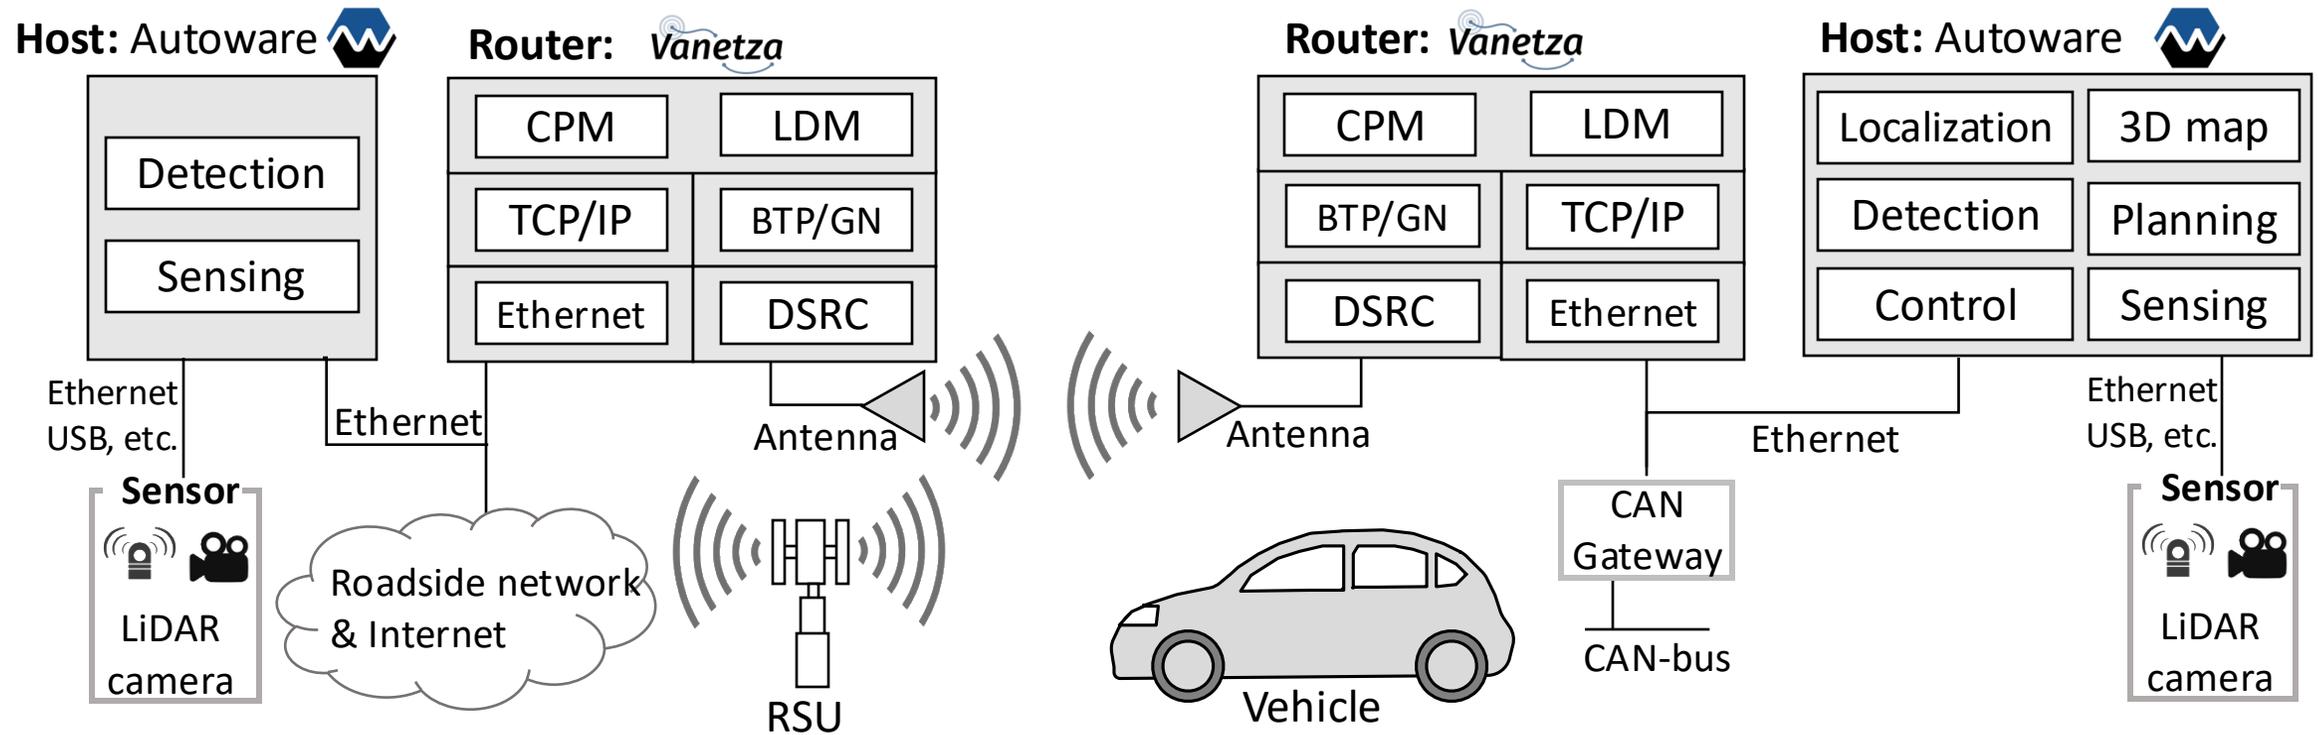
car: 006a
31km/h

V2X協調認識システムの設計

- ホスト・ルータの分離設計
 - ルータ: 通信 → 協調型システム
 - Host: アプリケーション → 自律型システム
- V2X協調認識システムをAutowareに実装



<https://tlab-wide.github.io/AutowareV2X/latest/>
 Yu Asabe, Ehsan Javanmardi, Jin Nakazato, Manabu Tsukada, Hiroshi Esaki, "AutowareV2X: Reliable V2X Communication and Collective Perception for Autonomous Driving", In: The 2023 IEEE 97th Vehicular Technology Conference (VTC2023-Spring), Florence, Italy, 2023.

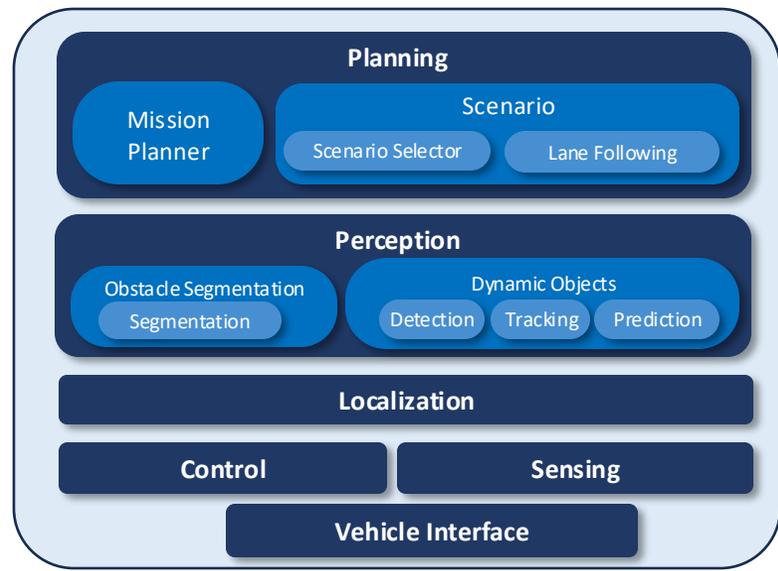


EXPERIMENT

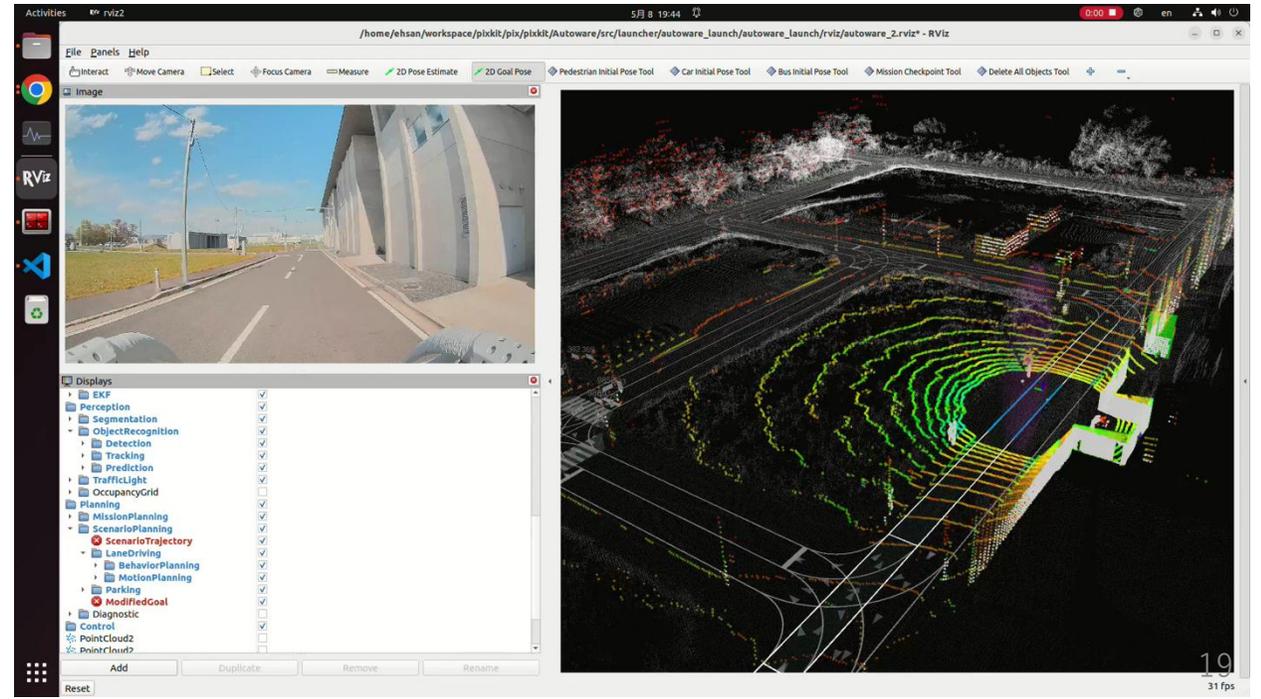
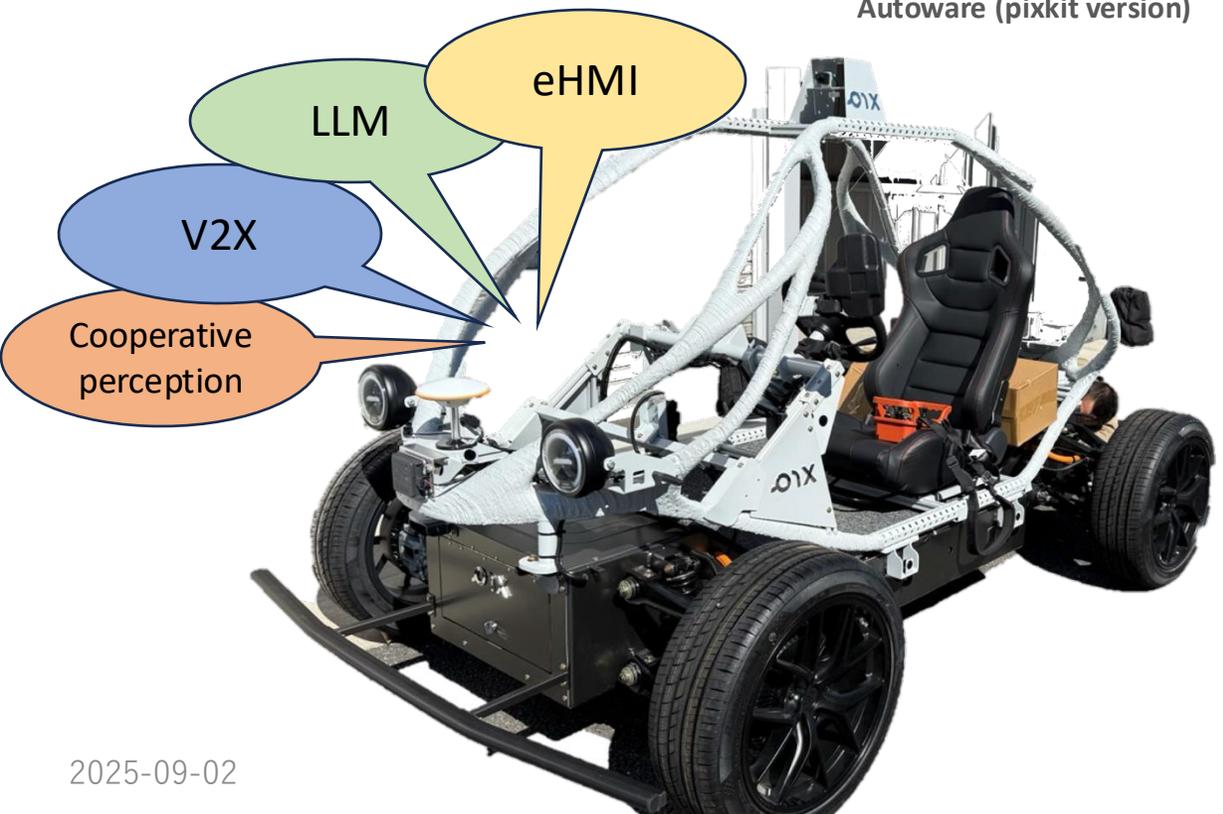
U-TOKYO KASHIWA CAMPUS



Autonomous Driving



Autoware (pixkit version)



② Digital twin simulatorと フィールドテスト

All route in Kashiwanoha





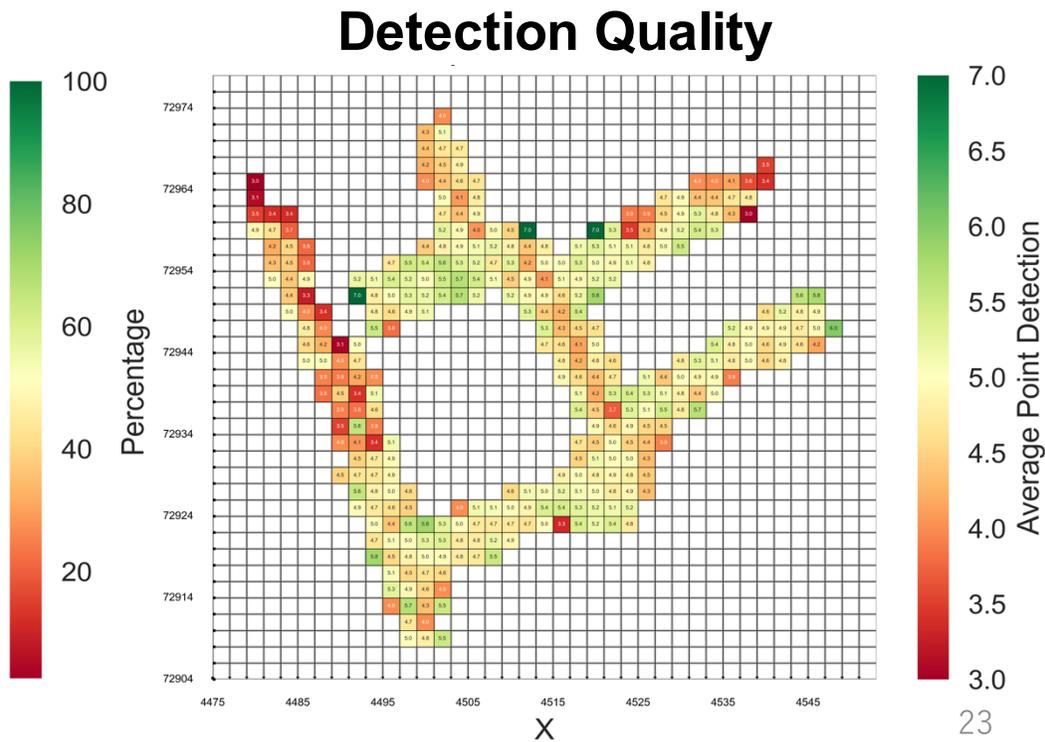
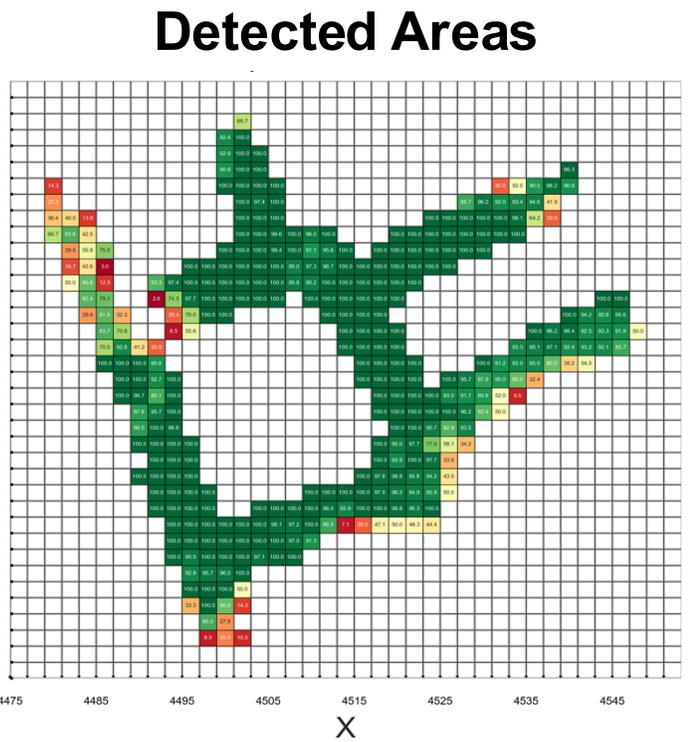
Digital Twin simulator

The screenshot displays the Digital Twin simulator interface, which is divided into several key sections:

- 3D Simulation (Left):** A third-person view of a white bus driving on a road at night. The bus is surrounded by green bounding boxes representing detected objects. A "Time Scale" slider is visible at the bottom, set to $x 0.42$.
- Control Panel (Middle):** A central interface for managing the vehicle's operation. It includes:
 - Operation Mode:** Buttons for STOP, AUTO, LOCAL, and REMOTE.
 - AutowareControl:** A green "Enable" button and a "Disable" button.
 - Routing:** Buttons for SET, INITIALIZED, STOPPED, INCH, Clear Route, and Init by GNSS.
 - GEAR and PARKING:** Indicators for the current gear and parking status.
 - Send Velocity Limit:** A field set to 0 [km/h] and a "Set Emergency" button.
- Properties Panel (Top Right):** A list of system components and their status, including Map, Sensing, Localization, Perception, Object Recognition, Detection, Tracking, Prediction, TrafficLight, OccupancyGrid, Planning, Control, Debug, PredictedObjects, and Topic.
- Top-Down View (Right):** A perspective view of the road from above, showing the vehicle's sensor range (green and red lines) and a steering wheel icon indicating a heading of 0.0deg . A speedometer icon shows 0.00km/h with a "limited 72km/h" indicator.

路側機設置シミュレーション

- 歩行者通路と横断歩道に（手動・ランダム）生成される歩行者と自転車の検知
- 設置された路側機からのカバー範囲と検知品質の評価
- バスなどの遮蔽物を考慮した評価





③塚田研究室におけるEnd-to-End自動運転時代のV2X研究アプローチ

Co3SOP : 次世代データセット

PHCP : 異種協調認識の現状打破

PrefDrive : E2E × LLM で行動選好

End-to-End自動運転時代のV2X通信

協調システムが“学習データ → 特徴共有 → 意思決定”まで End-to-End でつながると、V2X の価値は最大化する

データ
セット

Co3SOP : 次世代データセット

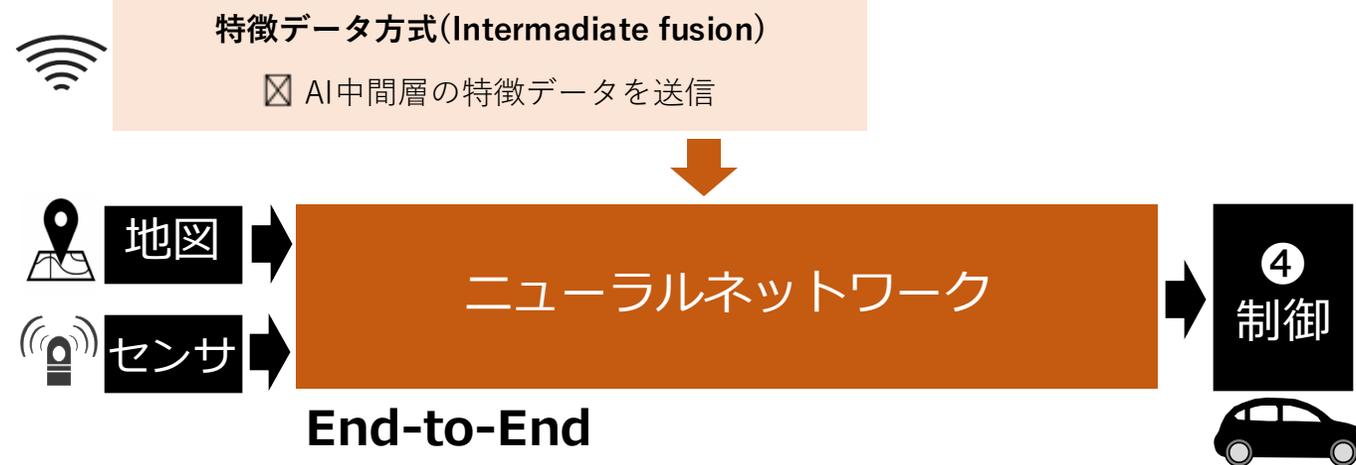
<https://github.com/tlab-wide/Co3SOP>

Co3SOP: A Collaborative 3D Semantic Occupancy Prediction Dataset and Benchmark for Autonomous Driving

特徴
共有

PHCP : 異種協調認識の現状打破

You Share Beliefs, I Adapt: Progressive Heterogeneous Collaborative Perception



意思
決定

PrefDrive : E2E × LLM で行動選好

Yun Li, Ehsan Javanmardi, Simon Thompson, Kai Katsumata, Alex Orsholits, Manabu Tsukada, "PrefDrive: Enhancing Autonomous Driving through Preference-Guided Large Language Models", In: 36th IEEE Intelligent Vehicles Symposium (IV2025), Cluj-Napoca, Romania, 2025.

<https://github.com/LiYun0607/PrefDrive/>



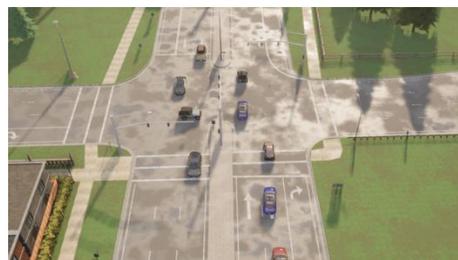
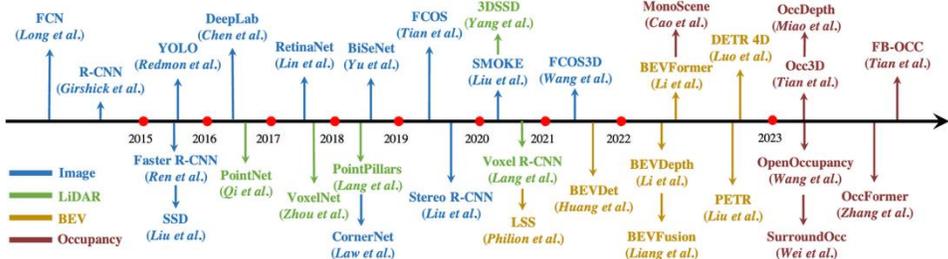
Co3SOP : 協調型3Dセマンティック占有率予測データセット

Collaborative 3D Semantic Occupancy Prediction

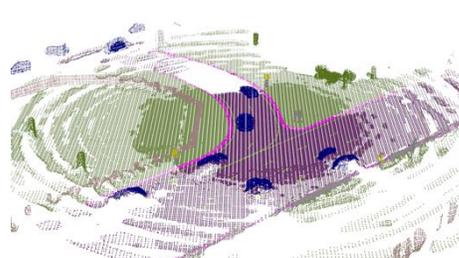
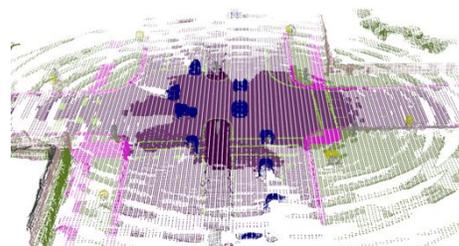
- 自動運転における3D環境認識の重要性
 - 周辺環境の3次元形状と意味情報（道路、車両、歩行者など）をボクセル単位で密に理解する
 - 従来の物体検出（バウンディングボックス）やセマンティックセグメンテーション（2D）より詳細な情報を提供し、高度な自動運転に不可欠
- 既存データセットの限界
 - LiDARベースのアノテーション
 - 協調知覚 (Collaborative Perception) への未対応
- Co3SOP: 協調型3Dセマンティック占有率予測の研究を加速するため、高品質なアノテーションを持つ大規模シミュレーションデータセットを構築

データセットの特徴

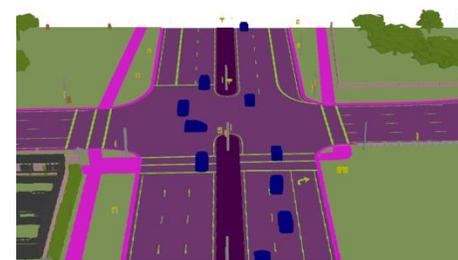
- ベース: 協調型物体検出データセット OPV2Vのシナリオを再現・拡張
- 協調シナリオ: 70以上のV2Vシナリオ、最大7台の車両が参加
- 詳細なラベル: 「空(empty)」クラスを含む24クラスのセマンティックラベルを提供
- 公開: データ、コード、ベンチマークをオープンソース化
- <https://github.com/tlab-wide/Co3SOP>



Carla Scenarios



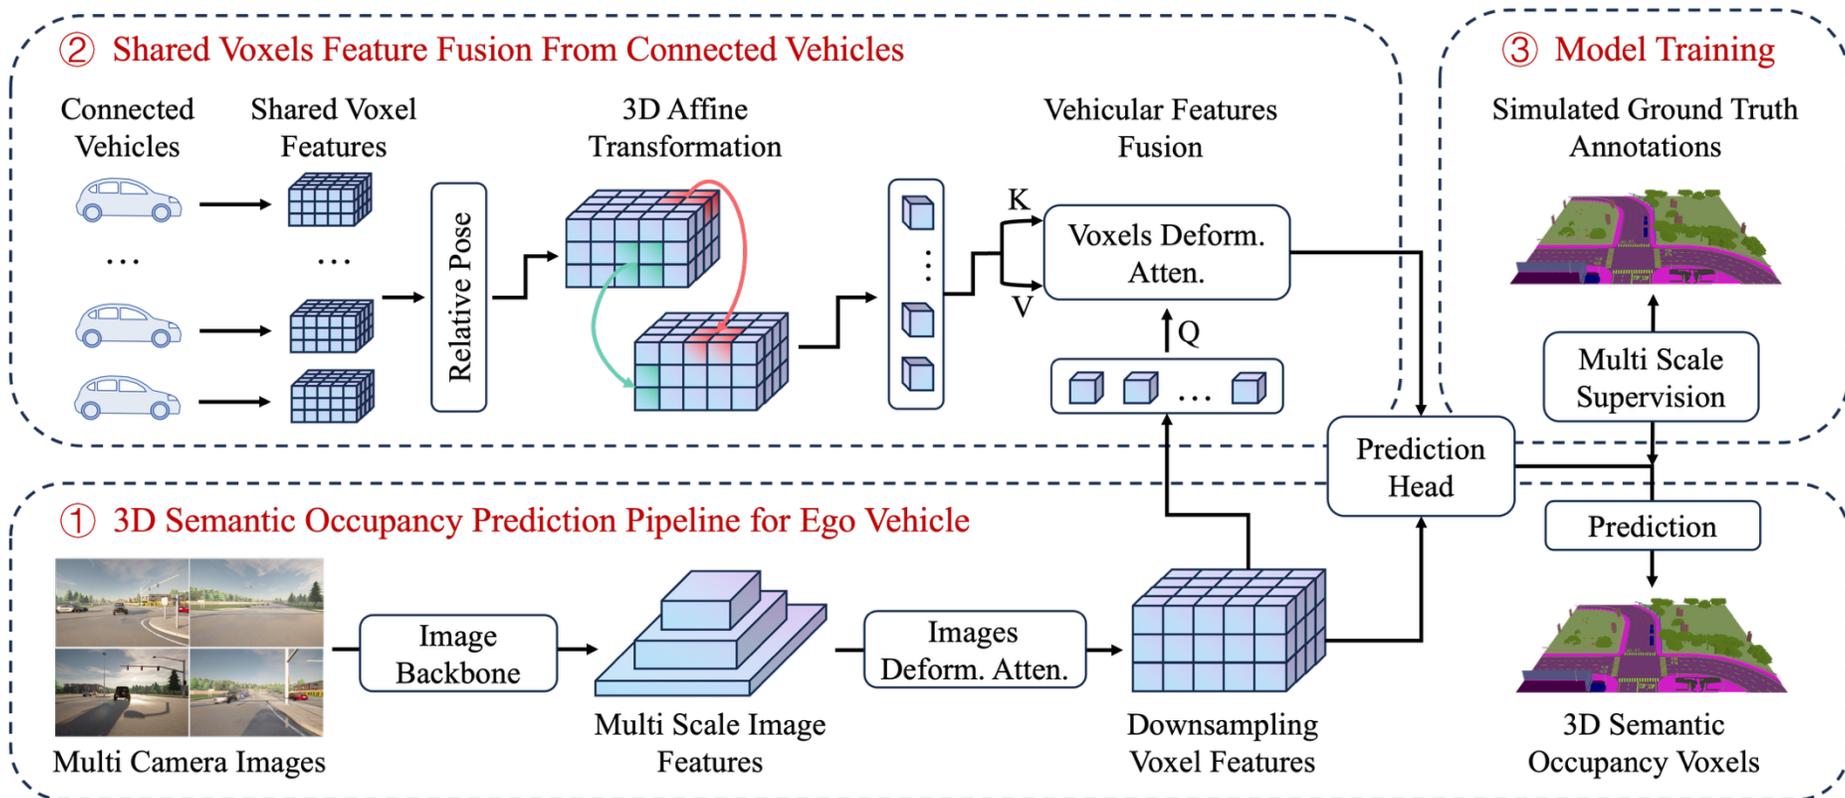
Lidar Generated



Simulated Annotation



ベンチマークとベースラインモデル評価



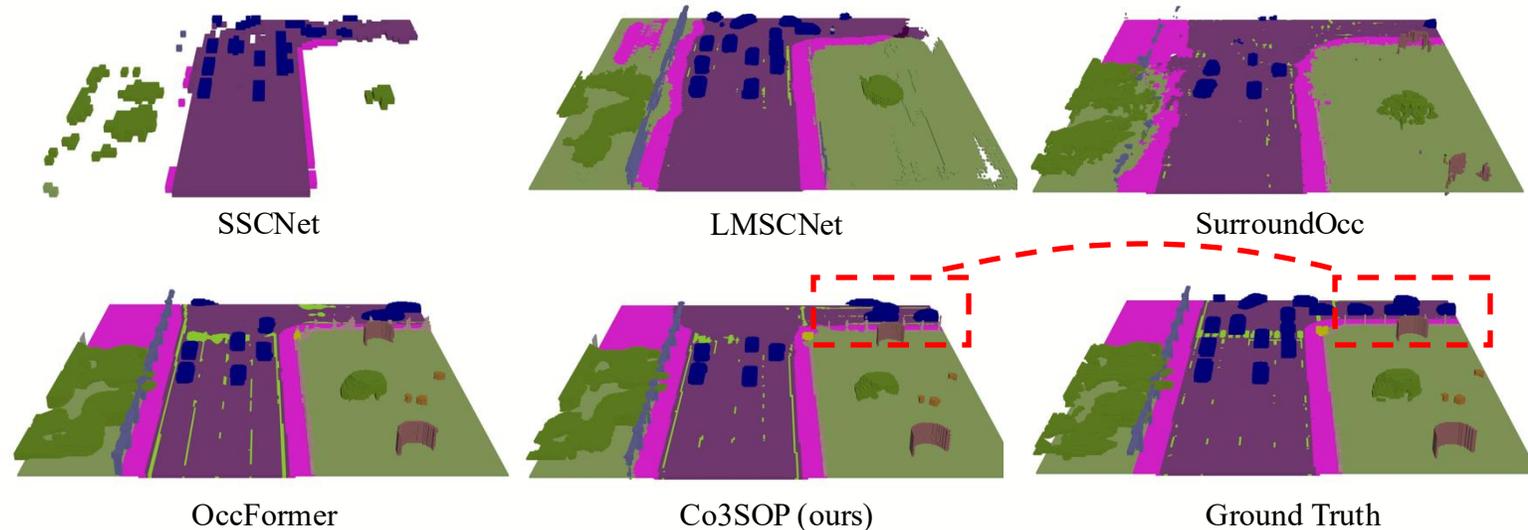
- 協調の効果を異なるスケールで評価するため、2つのタスクを設定
 - 小範囲 (Small-range): 25.6m x 25.6m x 4.8m (解像度 0.1m)
 - 大範囲 (Large-range): 51.2m x 51.2m x 4.8m (解像度 0.2m)
- 評価指標: mIoU (mean Intersection over Union)

- ベースラインモデル (Co3SOP-Base) の提案
 - カメラ画像を入力とする協調型3D占有予測モデル
- Ego予測パイプライン: 画像特徴抽出 (ResNet101-DCN) → 2D-3D変換 (Image Deformable Attention) → 占有予測
- V2V特徴融合パイプライン: 受信特徴量を3Dアフィン変換で位置合わせ → Ego特徴量と融合 (Voxel Deformable Attention)



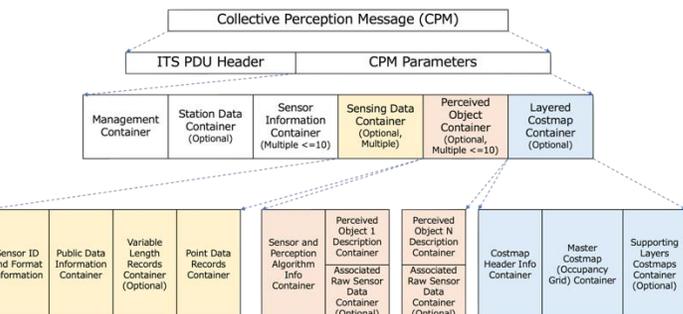
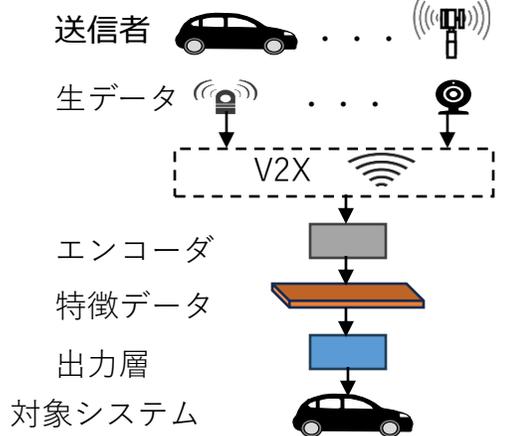
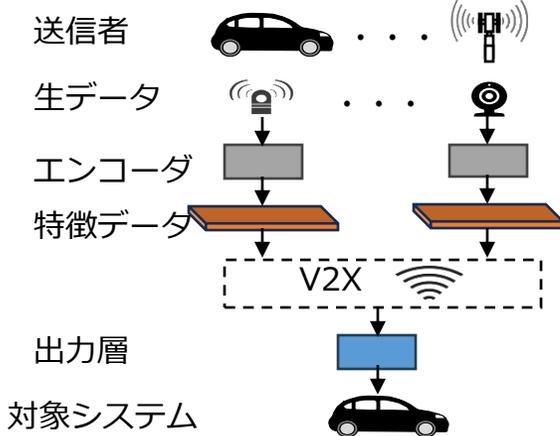
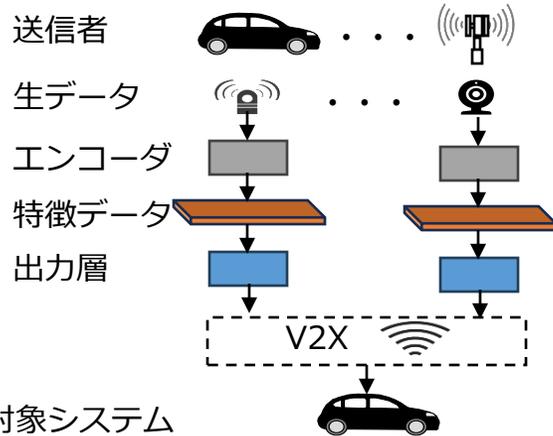
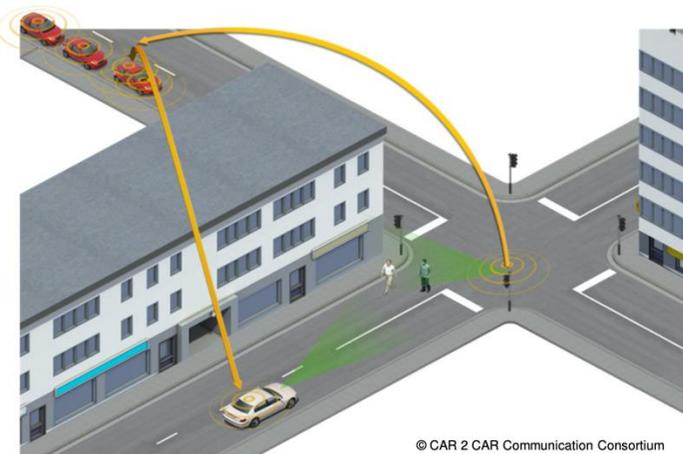
実験結果と考察

- Co3SOP-Baseは、SSCNet, LMSCNet (LiDARベース), OccFormer, SurroundOcc (カメラベース) と比較して、両タスクで最高のmIoUを達成
- Co3SOP: 協調型3Dセマンティック占有予測のための初の高品質・大規模シミュレーションデータセットを提供。
- 貢献: 正確なアノテーションにより、協調認識アルゴリズム（特に特徴量融合）の研究開発と公正な評価を促進。
- 示唆: V2V協調は3D占有予測の精度と範囲を大幅に向上させる可能性を示す。



| Method | SSCNet | | LMSCNet | | OccFormer | | SurroundOcc | | Co3SOP-Base | |
|----------------|--------|-------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| Modality | Lidar | | Lidar | | Camera | | Camera | | Camera | |
| Range | 25.6m | 51.2m | 25.6m | 51.2m | 25.6m | 51.2m | 25.6m | 51.2m | 25.6m | 51.2m |
| mIoU | 13.21 | 9.58 | 24.92 | 20.35 | 29.48 | 25.41 | 28.71 | 25.76 | 30.01 | 27.32 |
| Buldings ■ | 1.84 | 0.17 | 8.67 | 3.09 | 11.63 | 11.93 | 10.63 | 7.57 | 9.12 | 8.71 |
| Fences ■ | 0.16 | 1.48 | 22.27 | 18.01 | 14.17 | 11.60 | 11.06 | 13.28 | 12.57 | 14.53 |
| Other ■ | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.35 | 0.00 | 1.77 | 0.00 | 0.09 |
| Poles ■ | 3.60 | 0.14 | 29.57 | 24.95 | 19.67 | 12.62 | 17.22 | 13.51 | 20.52 | 15.11 |
| Roadlines ■ | 0.00 | 0.16 | 2.57 | 0.57 | 39.64 | 22.10 | 26.78 | 22.13 | 34.33 | 28.56 |
| Roads ■ | 0.23 | 25.88 | 86.70 | 75.84 | 87.40 | 75.30 | 86.87 | 79.53 | 87.88 | 79.05 |
| Sidewalks ■ | 19.22 | 9.57 | 42.24 | 48.66 | 45.32 | 51.41 | 46.61 | 45.23 | 44.52 | 44.51 |
| Vegetation ■ | 41.43 | 30.89 | 43.77 | 34.90 | 42.78 | 39.77 | 44.92 | 35.60 | 45.71 | 37.00 |
| Vehicles ■ | 71.73 | 48.09 | 85.35 | 75.63 | 75.70 | 51.25 | 75.95 | 52.34 | 80.06 | 64.42 |
| Walls ■ | 0.26 | 0.49 | 9.97 | 10.39 | 13.41 | 15.53 | 12.37 | 12.92 | 10.77 | 13.20 |
| Trafficsigns ■ | 0.00 | 0.00 | 18.19 | 0.02 | 9.73 | 7.68 | 17.27 | 11.72 | 12.50 | 9.89 |
| Guardrail ■ | 8.22 | 12.72 | 12.02 | 6.07 | 35.53 | 41.41 | 48.49 | 42.17 | 52.94 | 51.47 |

V2X協調認識



オブジェクト方式 (Late fusion)

- ☑ 認識された物体の位置情報を送信
- ℹ 共通の標準仕様
Collective Perception Message (CPM) ETSI TS 103 324
2015から8年議論し2023年に成立
- ✓ 消費が少ない
- ✗ 性能が低い
- ✓ 共通仕様により相互運用性を確保
- ✓ 市場の製品投入が始まっている

特徴データ方式 (Intermediate fusion)

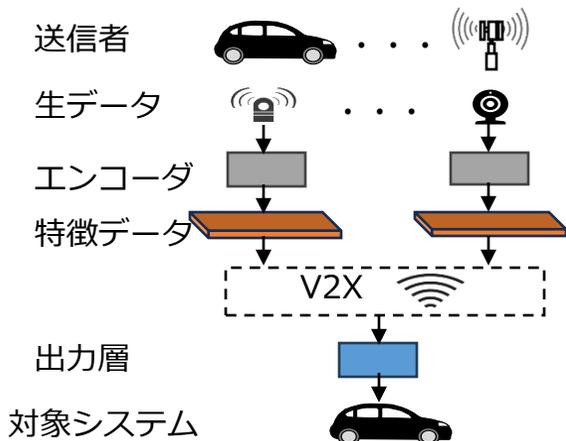
- ☑ AI中間層の特徴データを送信
- ℹ AAI, CVPR, ICCVなどのAI系トップカンファレンスで2022年ごろから注目されるテーマ
- ✗ 消費激しい
- ✗ 性能が低い
- ✗ 多様なAIモデルの相互運用性欠如
- ✗ どのように普及させるかは未知数

生データ方式 (Early fusion)

- ☑ 画像や点群などの生データを送信
- ℹ 研究アイデアとしては存在
・注目度は低い
- ✗ 消費激しい
- ✓ 性能が高い
- ✗ 現状の無線性能では普及は困難

PHCP：異種協調認識の現状打破

Progressive Heterogeneous Collaborative Perception



- 特徴データ方式は、全参加者が同一のAIモデルで統一されていることを前提
- 多様なベンダが存在する実社会での普及の目処は立たない
- 特徴データ方式の普及を阻む異種混合性 (Heterogeneity)
 - 融合方式異種性：オブジェクト方式、特徴方式、生データ方式の混在
 - AIモデル異種性：複数のAIモデルによる様々な特徴データの混在
 - センサ機器異種性：画像や点群などセンサデータの混在
 - データセット異種性：学習データが多様である場合、センサ・AIモデルが同一でも、特徴データに偏りができる
 - タスク異種性：特徴データ方式は、協調認識だけでなく、セグメンテーションや予測など多様なタスクに適応可能であり、下流タスクが混在

特徴データ方式 (Intermediate fusion)

☒ AI中間層の特徴データを送信

📘 AAAI, CVPR, ICCVなどのAI系トップカンファレンスで2022年ごろから注目されるテーマ

- ✔ 無線資源の現実的
- ✔ 物体融合の性能が高い

- ✘ 多様なAIモデルの相互運用性欠如
- ✘ どのように普及させるかは未知数

既存研究の限界:

- 特徴エンコーダやアダプタを事前学習・再学習するアプローチが多い
- 課題: 新しい協力者が参加するたびに共同学習が必要だったり、全協力者向けのモデルを事前保持する必要があり、実用的でない

本研究の問い：事前学習なしで適応できるか？

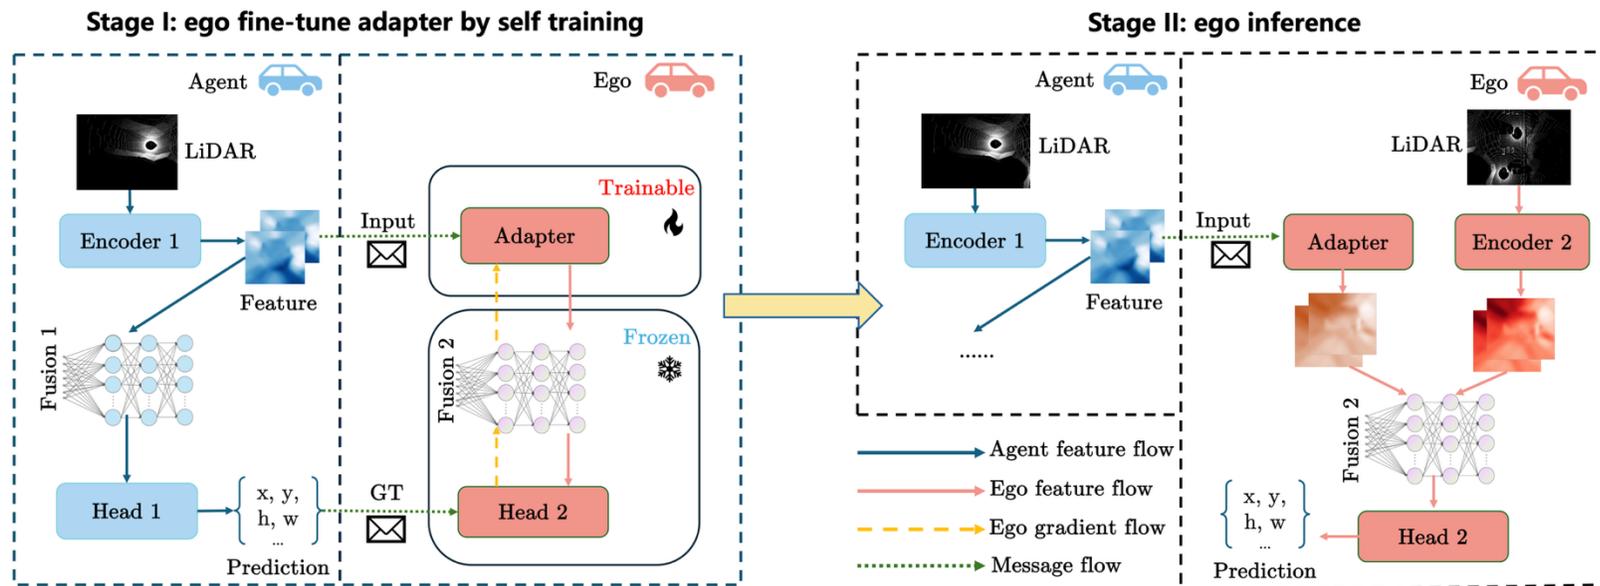
- メッセージ受信者は、協力者に関する事前知識や共同学習なしに、推論時 (Inference Stage) に動的にモデルパラメータを適応させられるか？



PHCP : 推論時自己学習による適応型協調認識

「You Share Beliefs, I Adapt」

協力車両が「信念 (Beliefs = 特徴量と疑似ラベル)」を共有し、Ego車両がそれに「適応 (Adapt)」する



Hao Si, Ehsan Javanmardi, Manabu Tsukada, "You Share Beliefs, I Adapt: Progressive Heterogeneous Collaborative Perception", In: International Conference on Computer Vision (ICCV2025), Honolulu, Hawai'i, 2025.

- 協力車両 (Agent) は、自身のLiDARデータから中間特徴量と物体検出結果 (疑似ラベルとして使用) を生成し、Ego車両へ送信 (最初のkフレーム)。
- Ego車両は、受信した特徴量と疑似ラベルを用いて、協力車両ごとに専用の特徴アダプタ (Feature Adapter) をファインチューニング。
 - アダプタの構造: 軽量のCBAM (Convolutional Block Attention Module) を利用し、チャンネルと空間方向の不整合を調整。
 - 学習戦略: TFA (Two-stage Fine-tuning Approach) に基づき、アダプタのみを学習 (Ego車両の他モジュールは固定)。

- 協力車両は中間特徴量のみをEgo車両へ送信 (k+1フレーム以降)。
- Ego車両は、ステージIで学習したアダプタを用いて受信特徴量を自身の特徴空間に変換。
- 変換後の特徴量と自身のEgo特徴量を融合し、最終的な物体検出結果を出力。
- 特徴アダプタの役割は、異なるエンコーダ (例: PointPillars vs SECOND) によって生じる特徴マップのチャンネル次元や関心領域の不整合 (Domain Gap) を吸収。

実験によるPHCPの有効性実証と結論

1. 実験設定

- **データセット:** OPV2V およびその拡張OPV2V-H (シミュレーションベース)。
- **異種混合シナリオ:** 異なるLiDARエンコーダ (PointPillars vs SECOND) を搭載したエージェント間の協調。
- **評価指標:** mSAP (mean Scenario Average Precision) @ IoU 0.3, 0.5, 0.7。

2. 主な実験結果

• 定性的評価

- PHCPにより、Ego車両の視野外やオクルージョン領域の物体検出が大幅に改善。特徴マップの整合性も向上。

• PHCPとDirect Fusion (ベースライン) との比較

- ベースライン: 事前学習なしで異種モデルの特徴量を直接融合。
- 全IoU閾値で **mSAPが約30%以上大幅に向上**

• 既存手法との比較

- 比較対象: 既存の協調認識手法 (F-Cooper, CoBEVT, AttFusion, V2X-ViT, HEAL等) これらは通常、ラベル付きデータセット全体で事前学習を行う。
- PHCPは、**少量のラベルなしデータのみを使用**するにも関わらず、データセット全体で学習した多くの既存手法を上回り、SOTA手法 (HEAL) に匹敵する性能を達成

3. 結論と貢献

- **結論:** PHCPは、異種混合環境における協調認識のドメインギャップ問題に対し、**推論時に少量のラベルなしデータで自己学習する新しい実用的な解決策**を提示した。

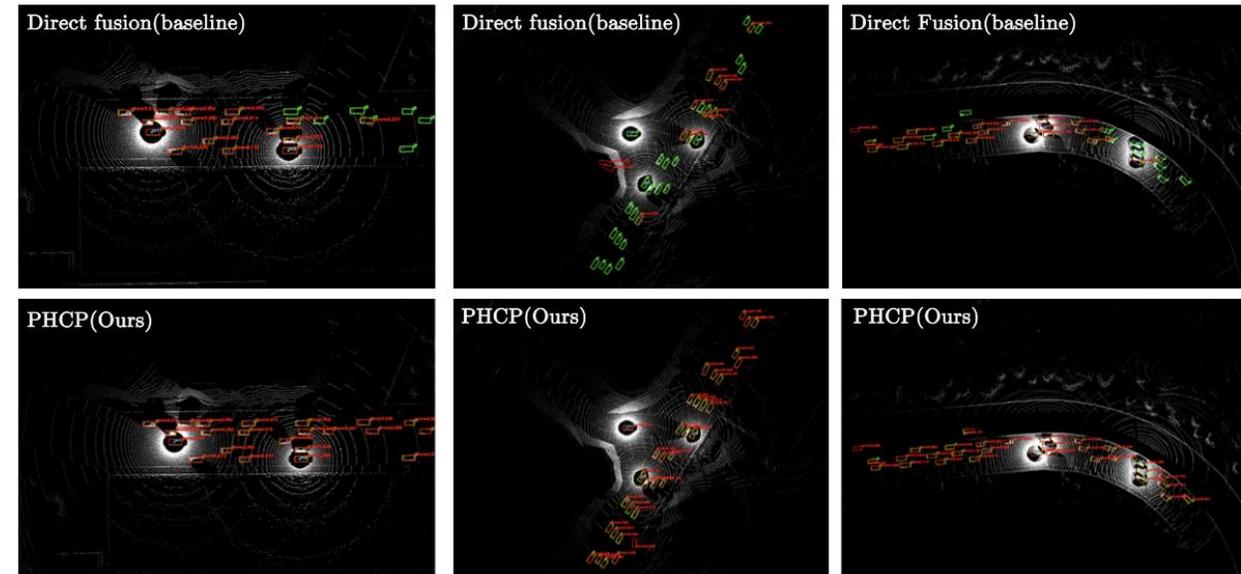


Figure 6. Visual comparison of three scenarios between our method and the baseline. Each scenario involves two, three, and four collaborative agents participating in collaborative perception. The red and green boxes represent the prediction and ground truth.

| Method | AP@IoU 0.5 in Scenarios | | | | | | | | | | | | | | | | mSAP@IoU | | |
|-------------------|-------------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 0.3 | 0.5 | 0.7↑ |
| Direct Fusion | 83.2 | 31.9 | 68.2 | 69.0 | 83.9 | 54.7 | 54.3 | 86.8 | 59.9 | 35.0 | 40.2 | 40.5 | 34.0 | 55.4 | 82.0 | 72.5 | 59.7 | 59.5 | 53.0 |
| PHCP(Ours) | 96.2 | 98.4 | 96.2 | 94.2 | 96.3 | 95.2 | 82.6 | 97.0 | 95.2 | 95.9 | 88.9 | 96.2 | 80.6 | 85.6 | 90.9 | 89.0 | 92.9 | 92.4 | 85.9 |

Table 1. Comparison between our methods and the direct fusion baseline

| Method | AP@IoU 0.7 in Scenarios | | | | | | | | | | | | | | | | mSAP@IoU | | |
|-------------------|-------------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 0.3 | 0.5 | 0.7↑ |
| F-Cooper[3] | 84.1 | 50.8 | 69.7 | 56.3 | 79.4 | 65.5 | 57.0 | 76.1 | 61.2 | 57.6 | 58.0 | 60.9 | 48.4 | 49.6 | 72.6 | 77.3 | 91.2 | 83.1 | 63.4 |
| CoBEVT[21] | 78.7 | 67.2 | 79.5 | 71.8 | 82.0 | 71.2 | 62.2 | 87.4 | 70.3 | 71.2 | 66.4 | 60.4 | 54.1 | 66.8 | 83.9 | 79.7 | 94.8 | 91.2 | 72.0 |
| AttFusion[35] | 84.0 | 68.5 | 87.0 | 71.4 | 92.6 | 78.6 | 63.7 | 84.0 | 72.8 | 73.5 | 74.4 | 76.3 | 65.1 | 75.7 | 83.7 | 84.9 | 93.0 | 89.9 | 77.3 |
| V2X-ViT[34] | 81.7 | 74.9 | 90.8 | 79.2 | 88.7 | 84.8 | 65.7 | 92.1 | 90.1 | 81.3 | 78.4 | 87.6 | 73.1 | 83.4 | 90.6 | 82.6 | 94.3 | 92.3 | 82.8 |
| PHCP(Ours) | 89.2 | 92.6 | 90.4 | 87.4 | 92.2 | 94.1 | 67.1 | 95.2 | 89.6 | 94.7 | 84.7 | 91.5 | 70.7 | 83.8 | 89.0 | 80.8 | 92.8 | 92.3 | 87.1 |
| HEAL[19] | 89.1 | 93.4 | 97.6 | 91.3 | 93.6 | 96.6 | 76.2 | 97.2 | 93.0 | 97.5 | 89.7 | 94.5 | 86.9 | 87.7 | 93.1 | 90.0 | 95.5 | 95.1 | 91.7 |

Table 2. Comparison between our methods and other collaborative methods. Notably, we achieve these results using only a small amount of unlabeled data.



PrefDrive : LLM自動運転に人間の「好み」をどう教えるか？

既存LLMベース自動運転の課題:

- **運転の質:** 必ずしも人間のドライバーが好む運転（スムーズな加減速、適切な車間距離、特定の運転スタイルなど）と一致しない。
- **安全性・信頼性:** 交通ルール遵守や経路維持などの運用要件との整合性に課題が残る場合がある。
- **学習コスト:** 大規模モデルの事前学習・ファインチューニングには膨大な計算資源が必要

本研究の着眼点：嗜好学習 (Preference Learning)

- 人間の「好み」のデータを活用し、LLMの出力をより望ましい運転行動に近づけるアプローチ。
- RLHF や DPO などの技術が登場。

PrefDriveの目的:

- LLMに **運転嗜好** を効率的に学習させ、運転性能と人間との親和性を向上させる **新しいフレームワーク** を提案する。
- **コンシューマGPU** での学習を可能にし、研究のアクセシビリティを高める。

Yun Li, Ehsan Javanmardi, Simon Thompson, Kai Katsumata, Alex Orsholits, Manabu Tsukada, "PrefDrive: Enhancing Autonomous Driving through Preference-Guided Large Language Models", In: 36th IEEE Intelligent Vehicles Symposium (IV2025), Cluj-Napoca, Romania, 2025.

<https://github.com/LiYun0607/PrefDrive/>



PrefDrive : 嗜好ガイド付きLLMによる自動運転

1. システムアーキテクチャ

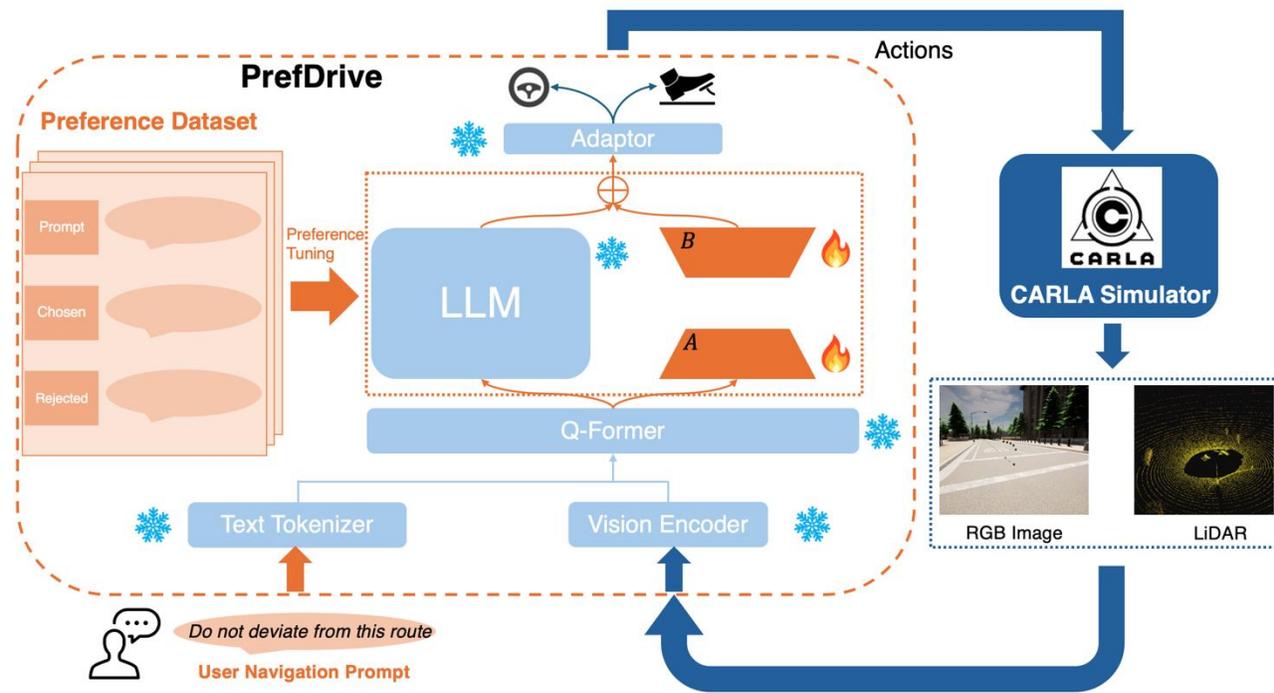
1. **入力:** マルチモーダルセンサーデータ (カメラRGB、LiDAR点群) + 自然言語によるナビゲーション指示。
2. **構成:**
 1. Vision Encoder (ResNet, PointPillar) + Text Tokenizer
 2. Q-Former (マルチモーダル特徴融合)
 3. LLM (意思決定コア、例: LLaMA2-7B)
 4. Adaptor (LLM出力を運転操作へ変換)
3. **学習対象:** LLM と Adaptor 部分を **嗜好データ** を用いてファインチューニング。

2. 嗜好学習アルゴリズム : Direct Preference Optimization (DPO)

1. **利点:** 従来のRLHFのように報酬モデルを別途学習させる必要がなく、よりシンプルかつ安定して学習可能
2. **学習データ**
 1. 各状況 (prompt) に対し、「好ましい運転行動 (chosen)」と「好ましくない運転行動 (rejected)」のペアを用意。
 2. 行動だけでなく、その **理由付け (reasoning)** も学習データに含める。
 3. 74,040シーケンスの大規模データセットを構築・公開。
3. **学習目的 (論文 Eq. 2):** LLMが「好ましい行動」の尤度を「好ましくない行動」の尤度よりも高くなるように学習する。

3. 効率的なファインチューニング技術:

1. **PEFT (Parameter-Efficient Fine-tuning):**
 1. **LoRA (Low-Rank Adaptation):** LLM本体の大部分を凍結し、少数の追加パラメータのみを学習することで、計算コストとメモリ使用量を大幅に削減
 2. **4-bit 量子化 (QLoRA):** モデルのパラメータを低精度 (4bit) で表現し、さらにメモリ効率を向上
2. **結果:** コンシューマ向けGPU (例: RTX 3090 Ti) 1枚での7Bモデルのファインチューニングを実現。



```
{
  "prompt": "Given the driving scenario: The vehicle is at an intersection traveling at 5.2 m/s with vehicles nearby approaching a traffic light. The navigation system indicates: Turn left at the intersection.\nWhat's the safest driving action to take and why?",
  "chosen": "The safest action is to slow down and turn left because this follows the recommended navigation instruction safely. This leads to waypoint (245.1, -127.8).",
  "rejected_list": [
    {
      "action": "Accelerate aggressively through the intersection while turning left would be dangerous because excessive speed during turns risks loss of control. This incorrect path leads to waypoint (247.6, -98.2).",
      "risk_level": "high",
      "risk_type": "aggressive"
    },
    {
      "action": "Maintain current speed without adjusting for the intersection conditions would be dangerous because failing to adapt to the turning situation could result in delayed reactions. This incorrect path leads to waypoint (240.2, -124.3).",
      "risk_level": "medium",
      "risk_type": "inattentive"
    },
    {
      "action": "Brake suddenly and significantly reduce speed before turning would be dangerous because overly cautious behavior could surprise following vehicles and cause rear-end collisions. This incorrect path leads to waypoint (249.8, -125.6).",
      "risk_level": "low",
      "risk_type": "overcautious"
    }
  ]
}
```

実験によるPrefDriveの有効性実証

1. 実験設定:

1. シミュレータ: CARLA (Town 01: 学習・評価、Town 04: 汎化性能評価)
2. 比較対象:
 1. LMDrive (ベースライン)
 2. SFT (Supervised Fine-tuning): 「好ましい行動」のみで学習 (DPOとの比較用)。
3. 評価指標: LangAutoベンチマーク (総合スコア、違反件数、経路逸脱など) + 運転動態指標 (完了時間、加速度、他車との距離など)。

2. 主な実験結果:

1. 性能向上 (論文 Table II):

1. PrefDriveはベースラインに対し、**総合スコア、経路完遂率、交通ルール遵守 (信号無視減: 最大28.1%)** などで有意に改善。
2. 特に **車両停止 (Vehicle Blocked) の完全排除** など、嗜好学習の効果がみられる。
3. SFTのみ (NoPrefDPO) の改善は限定的であり、DPOによる嗜好学習の有効性を示唆。

2. **汎化性能:** 学習に使用していないTown 04でも同様の改善傾向を示し、汎化能力を確認。

3. **学習効率 (論文 Fig. 6):** DPO学習が安定して進行し、モデルが「良い/悪い」応答を明確に区別できるようになったことを確認。

3. 貢献:

1. LLMベース自動運転に **人間の嗜好を導入・学習** させる初のフレームワークを提案。
2. **大規模な運転嗜好データセット** と学習済みモデルを公開し、コミュニティの研究を促進。

TABLE II
COMPARATIVE ANALYSIS OF LANGAUTO BENCHMARKS IN CARLA TOWN 01 AND TOWN 04

| Method | Composite Score (↑) | Penalty Score (↑) | Route Completion (↑) | Layout Collisions (↓) | Traffic Light Violations (↓) | Route Deviation (↓) | Vehicle Blocked (↓) |
|--------------------|----------------------|---------------------|----------------------|-----------------------|------------------------------|---------------------|-----------------------|
| Town 01 | | | | | | | |
| LMDrive (baseline) | 53.00 | 0.86 | 59.10 | 0.73 | 0.22 | 1.32 | 0.11 |
| PrefDrive (ours) | 56.12 (↑5.9%) | 0.88 (↑1.5%) | 64.15 (↑8.5%) | 0.27 (↓63.5%) | 0.16 (↓28.1%) | 1.36 (↑3.0%) | 0.00 (↓100.0%) |
| NoPrefDPO | 51.45 (↓2.9%) | 0.91 (↑4.8%) | 55.17 (↓6.7%) | 0.61 (↓17.0%) | 0.20 (↓11.9%) | 1.74 (↑31.7%) | 0.08 (↓25.0%) |
| Town 04 | | | | | | | |
| LMDrive (baseline) | 60.11 | 0.93 | 65.25 | 0.00 | 0.24 | 1.86 | 0.00 |
| PrefDrive (ours) | 65.93 (↑9.7%) | 0.96 (↑3.2%) | 69.93 (↑7.2%) | 0.00 (0.0%) | 0.00 (↓100.0%) | 1.77 (↓4.8%) | 0.00 (0.0%) |
| NoPrefDPO | 62.27 (↑3.6%) | 0.94 (↑0.7%) | 68.35 (↑4.7%) | 0.00 (0.0%) | 0.05 (↓80.1%) | 1.77 (↓4.6%) | 0.00 (0.0%) |

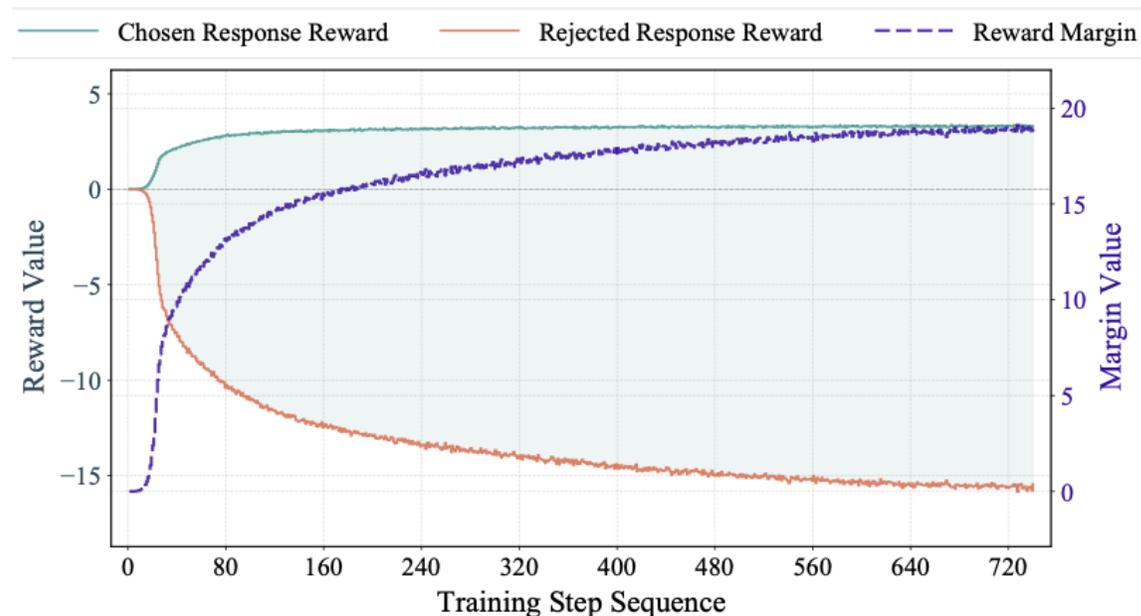
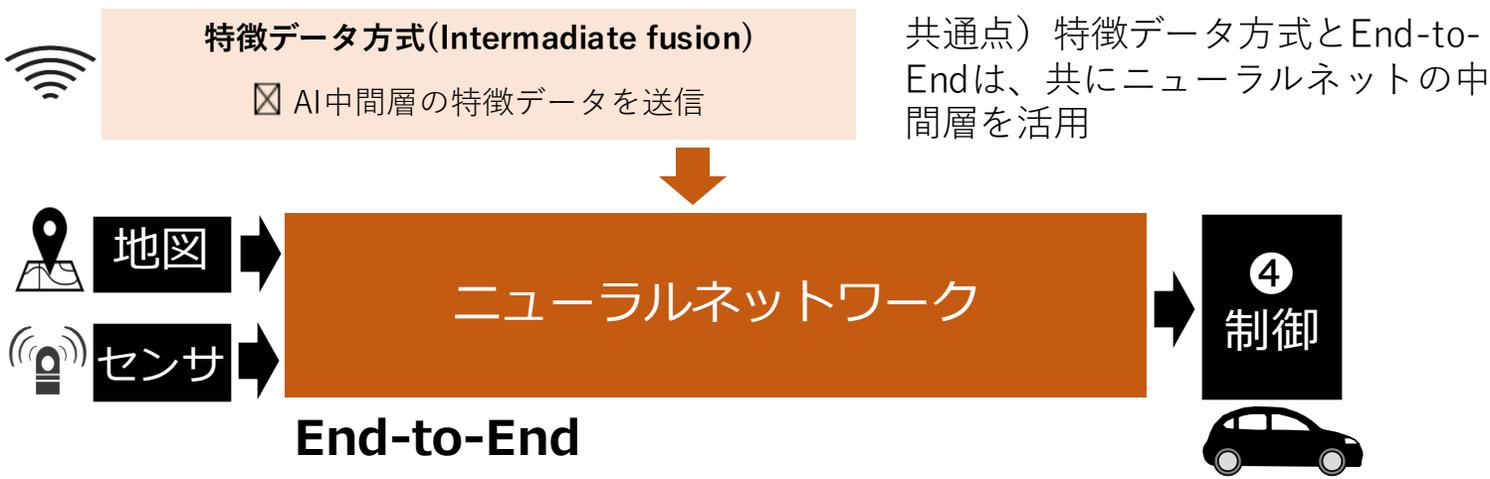
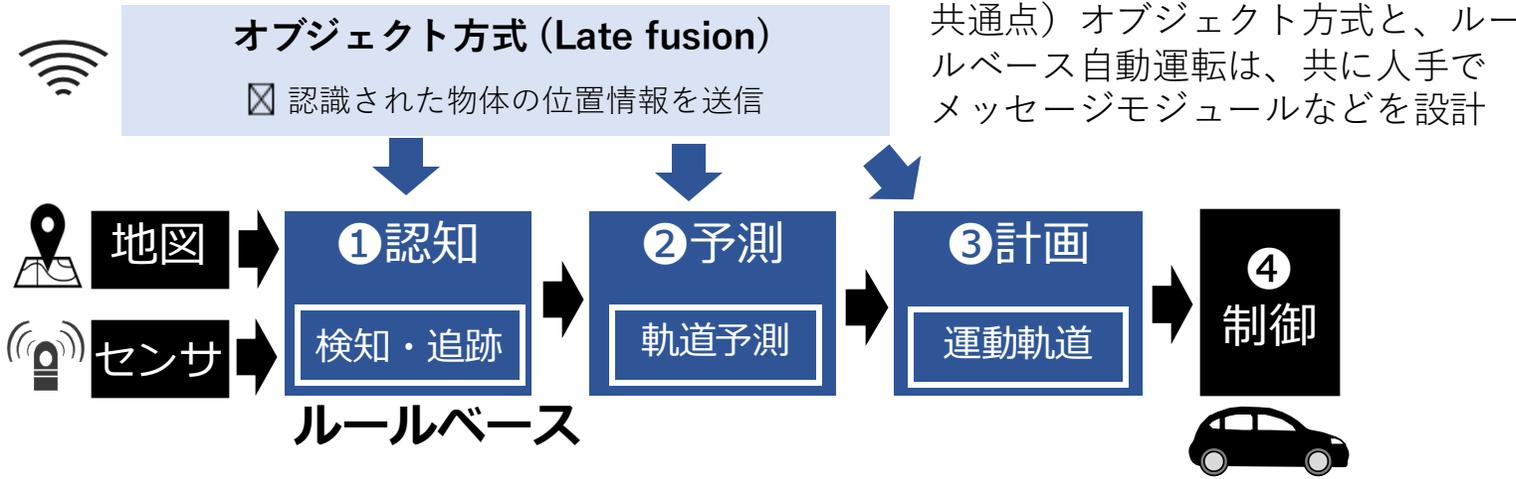


Fig. 6. Training process of DPO.

End-to-End x V2X



① Autoware V2X
標準技術を用いた協調型自動運転のオープンソース化

② Digital twin simulatorとフィールド実験環境、路側機設置の最適化に向けた取り組み

③ 塚田研究室におけるEnd-to-End自動運転時代のV2X研究アプローチ

Co3SOP : 次世代データセット
PHCP : 異種協調認識の現状打破
PrefDrive : E2E × LLM で行動選好



Tsukada Lab.

Computer Network Group