

2021年度

「戦略的イノベーション創造プログラム（SIP）第2期／自動運転（システムとサービスの拡張）／自動運転技術（レベル3、4）に必要な認識技術等に関する研究」

# 成果報告書

2022年3月

国立大学法人 金沢大学  
学校法人中部大学 中部大学  
名城大学

---

---

本報告書は、国立研究開発法人新エネルギー・産業技術総合開発機構(NEDO)が管理法人を務め、内閣府が実施した「戦略的イノベーション創造プログラム(SIP)第2期／自動運転(システムとサービスの拡張)」(NEDO管理番号:JPNP18012)の成果をまとめたものです。

---

---

目次

1. 研究開発の内容及び目標	5
1.1. 研究開発全体の概要	5
1.2. 研究テーマごとの研究開発内容と目標	8
a. 「信号機認識技術の開発及び認識が困難な条件の検討」	8
b. 「遠距離の物体を検知するために必要となる AI 技術の開発」	11
c. 「高精度自己位置技術の開発」	13
d. 「SAKURA-DIVP と連携したシミュレータおよびシナリオの検証」	15
e. 「自律型自動車が走行する状態での問題点の検討」	17
f. 「実証実験」	19
1.3. 成果の要約	20
a. 「信号機認識技術の開発及び認識が困難な条件の検討」	20
b. 「遠距離の物体を検知するために必要となる AI 技術の開発」	22
c. 「高精度自己位置技術の開発」	23
d. 「SAKURA-DIVP と連携したシミュレータおよびシナリオの検証」	24
e. 「自律型自動車が走行する状態での問題点の検討」	25
f. 「実証実験」	26
2. 研究開発成果	27
2.1. a. 「信号機認識技術の開発及び認識が困難な条件の検討」	27
① パターン認識による信号認識と交差点進入判断アルゴリズムの開発	27
② セマンティックセグメンテーションによる信号認識アルゴリズムの開発	44
2.2. b. 「遠距離の物体を検知するために必要となる AI 技術の開発」	56
① 遠距離向け車載カメラの選定・検知アルゴリズム開発	56
② LiDAR およびミリ波レーダに基づく遠方物体認識	68
2.3. c. 「高精度自己位置技術の開発」	74
① GNSS/INS の開発	74
② マップマッチング技術の開発	81
2.4. d. 「SAKURA-DIVP と連携したシミュレータおよびシナリオの検証」	92
① 人工知能(AI)に基づく歩行者の行動予測	92
② 時系列追跡による車両の行動予測とパスプランニング	102

---

---

---

---

2.5. e. 「自律型自動車が走行する状態での問題点の検討」	106
① ロボティクス技術を活用したデッドロック回避	106
② 人工知能(AI)を活用したデッドロック回避	117
2.6. f. 「実証実験」	121
3. 実施体制	127

---

---

## 1. 研究開発の内容及び目標

### 1.1. 研究開発全体の概要

市街地での Level4 相当の自動運転自動車には、車載された AI による高度で自律的な認知・判断機能とともに、それを支援する道路設備、通信設備等のインフラが必要となる。しかし、道路設備・通信設備等のインフラを日本全国に設置するには莫大な予算が必要になるため最低限必要とされるインフラや、またそのインフラのもとで必要とされる認知判断技術を検討する必要がある。一方、最先端の自動運転技術は産業界でまさに競争領域となっているため、最低限必要とされるインフラをオープンな立場で議論可能なアカデミア（大学）の知見が必要不可欠となる。

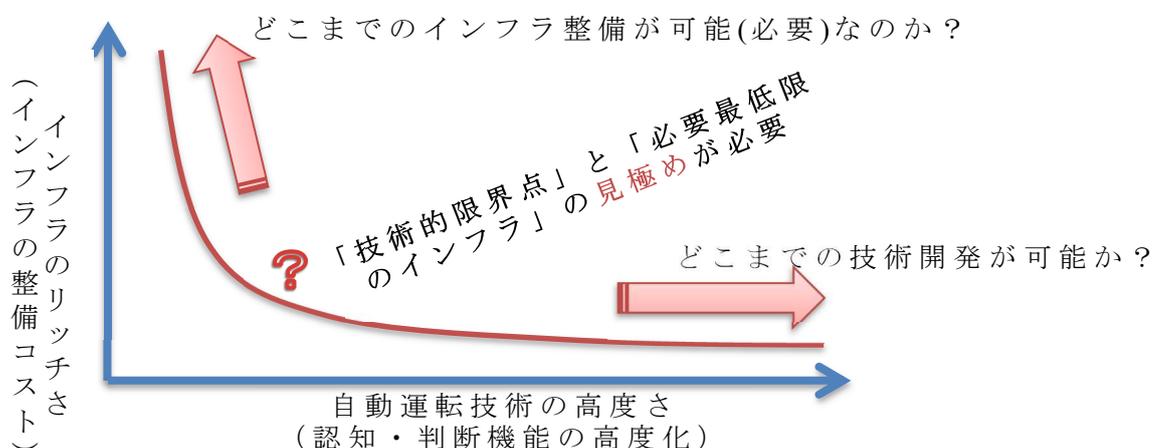


図 1.1-1 インフラのリッチさと自動運転技術の高度差の関係

そこで本事業では、既に自動運転の公道走行実証を行っている大学や、関連する要素技術の最先端の研究を実施している大学との連携により、一般の交通参加者や他の自動運転車が混在する市街地の複雑な交通環境下におけるレベル4相当の自律型完全自動運転車の認知・判断技術を構築する。また、これによって得られる自動運転技術を通して、市街地の自動運転に必要な道路設備及び通信設備などの最低限のインフラを見極める。この必要最低限のインフラのもとで必要となる認知判断技術をオープンな研究体制で議論し、提言を示すことで得られた知見を自動車産業に関連するハードウェア、ソフトウェア、インフラなど多方面のコミュニティに貢献する。

---

なお、本事業の略称を AD-URBAN (FOT project of Automated Driving system under Real city environment based on Academic Researcher's Neutral knowledge) プロジェクトと称する。

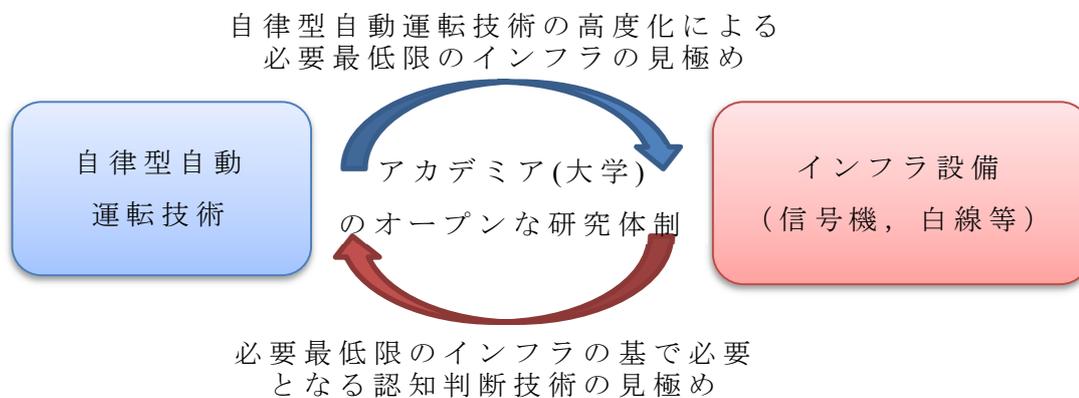


図 1.1-2 必要最低限のインフラの見極めと認知判断技術の見極め

具体的には、以下に示す 6 項目の研究開発項目を下図に示すスケジュールに基づいて検討する。

- a. 「信号機認識技術の開発及び認識が困難な条件の検討」
- b. 「遠距離の物体を検知するために必要となる AI 技術の開発」
- c. 「高精度自己位置技術の開発」
- d. 「SAKURA-DIVP と連携したシミュレータおよびシナリオの検証」
- e. 「自律型自動車が走行する状態での問題点の検討」
- f. 「実証実験」

### 自動運転技術（レベル3、4）に必要な認識技術等に関する研究

スケジュール		FY2021	FY2022
a) 信号機認識技術の開発及び認識が困難な条件の検討	信号機認識技術の開発	点滅信号機を含む信号認識課題の整理	
	V2Iを用いた実証	自律型/V2I/V2Nの実証および比較評価	
b) 遠距離の物体を検知するために必要となるAI技術の開発	DIVP Prj.連携	シミュレーションを活用した認識技術の高度化	
		シミュレーションを活用した認識技術の安全性評価	
c) 高精度自己位置技術の開発	みちびきの利用可能性向上	INS誤差モデル化(シミュレーション用)	
		シミュレーションを活用したマップマッチング/みちびき有効性評価	
d) SAKURA-DIVPと連携したシミュレータおよびシナリオの検証	市街地における行動予測とパスプランニング技術の開発	シミュレーションを活用した高度化	
	SAKURA/DIVP Prj.連携	シミュレーションを用いたテスト環境構築	シナリオカバレッジ検証・改善
e) 自律型自動運転車の走行時における問題点の検討	デッドロック検討	緊急車両情報等の車線変更支援情報(V2N)の有効性検討	
		緊急車両の自律型認識技術の構築	シミュレーションを活用した高度化
f) 実証実験	V2Iを用いた実証	V2Nを用いた実証	シミュレータへの交通環境再現
			一般道走行実証データ収集とデータセット公開

図 1.1-3 研究開発項目と開発スケジュール

---

---

## 1.2. 研究テーマごとの研究開発内容と目標

### a. 「信号機認識技術の開発及び認識が困難な条件の検討」

自動運転においてスムーズな交差点走行を行うにあたり、信号機の状態を正確に認識することが重要である。信号機は点灯色及び矢印の状態が時間変化する道路特徴物であり、一般的には2種類の方法での認識が検討されている。1点目はオンボードセンサによる信号機の自律的な認識であり、2点目は信号機本体と車両とのV2I等の通信による認識である。前者は、車載カメラを搭載した自動運転自動車から画像処理によって信号機の点灯状態や矢印灯を認識する必要がある。太陽光や天候による悪条件下においても頑健な手法の実現が要求されている。後者は信号機の現在の状態やその後の灯火変化のタイミング情報などの正確な信号情報取得が期待され、運転支援システムの一つとして都心部を中心に導入が進められている。自動運転においても、通信情報を得ることによる円滑な交差点走行が期待できるものの、通信機の設置コストの面で課題があるため全ての道路への導入は困難である。

本事業では自動運転時の信号機認識における課題である「認識性能の改善」及び「通信情報の活用による交差点走行の状況判断」の実現を目的とする。車載向けなどの用途で開発されている最新のカメラを活用し、従来のパターン認識技術(①)と最新の人工知能技術(②)の側面から技術開発を行うことで信号認識の性能を最大限に高めた最先端の認識アルゴリズムを実現する。高度な信号認識アルゴリズムの開発に加えて、信号認識の本質的課題である信号機の隠れが発生する状況を考慮して、インフラ支援信号機のV2I及びV2N通信によって得られる信号情報の活用方法も検討する。例えば、信号の先読み情報を取得することで不必要な加減速を抑えた最適な交差点進入判断が実現可能である。そこで、V2I及びV2N通信としてインフラ支援型信号機を併用した交差点進入判断アルゴリズムを開発し、これを活用した公道実証実験を実施して効果を検証する(①)。信号認識技術の開発とインフラ設備との連携した自動運転技術の開発を相互に行うことで、必要十分な認識能力を得るためのセンサスペックおよびインフラ設備設置について検討する。

以下に実施内容および2021年度の目標を示す。

#### ① パターン認識による信号認識と交差点進入判断アルゴリズムの開発

パターン認識による信号認識では、車両位置からデジタル地図を参照して撮影画像内の信号機を検出して、点灯状態を認識する。車載カメラの画角・解像度に依存するが、120m程度の遠方から認識する場合は10×10ピクセル以下の信号灯や矢印灯を認識する必要があるため、特に矢印信号の状態を正確に認識することが課題である。ま

---

---

---

---

た、非常に厳しい逆光時では認識アルゴリズムとしての課題だけではなくハードウェアの性能限界によって本質的に認識不適な画像が撮影される。こうした本質的課題を解決可能なセンサの選定および性能評価が重要である。このため、2018年度では多様な天候・日照条件での信号機認識において、ハードウェアの性能限界による影響を可能な限り低減させ、目標達成に必要なカメラの仕様を検討した。2019年度の開発では、このカメラを用いてデータ収集および下記②の研究テーマにも使用可能なデータセットの作成を進めた。またこのデータセットを用いて遠方でピクセル数の小さい信号灯及び矢印灯に特化した認識アルゴリズムを開発し、認識率 95%の達成を達成した。2020年度では交差点進入判断における信号認識の環境不調の要因調査及び悪条件として逆光に特化した認識アルゴリズムを開発して 120m 以内の信号灯及び矢印灯の認識率 99%を達成した。2021年度に認識対象を点滅信号に拡張し、赤及び黄色の点滅信号の認識アルゴリズムを開発して認識率 95%の達成を目指す。

高度な信号認識により適切な交差点走行が期待できるものの、車載カメラによる認識のため前方に大型車両が停止している場合や樹木による隠れが発生する場合は信号機の認識は本質的に不可能である。そのような問題が頻繁に発生する交差点では、インフラ支援型信号機から取得する信号情報が望ましい。V2I 及び V2N 通信では、現在の信号状態に加えて、自車が交差点に到達するときの状態を事前に知ることができるため、交差点進入時の急加減速を緩和して乗り心地や省エネに配慮した走行の実現が期待できる。しかしながら、インフラ支援信号機を取得した自動運転自動車と先読み情報を持たない一般車両が混在する状況下において、どのような効果や課題が起り得るのかを明らかにすることが重要な課題である。そこでインフラ支援型信号機の情報を活用した交差点進入アルゴリズムの開発を目的とし、2018年度にはインフラ支援型信号機を簡易的に模擬できる試験用信号機を作成した。2019年度はこの試験用信号機やテストコースを用いてインフラ支援型信号機の情報を活用した交差点進入アルゴリズムの開発を行った。2020年度では開発した交差点進入判断アルゴリズムの有効性を一般道で検証してテストコース同様に急減速回避の効果を確認した。2021年度はV2N通信による有効性の検証するための環境構築を行い、走行データの計測を開始する。

---

---

## ② セマンティックセグメンテーションによる信号認識アルゴリズムの開発

信号機や信号灯の一部が隠れている場合や風景に溶け込んでいる場合、古いランプ式信号機のような点灯部の輝度が十分ではない場合において、従来の矩形や円形特徴を認識する手法では正確に信号機の位置と色を認識することが困難である。このような課題に対応するため、ディープラーニングを活用したセマンティックセグメンテーションにより信号機の位置を画素単位で抽出する。これにより、局所的な形状の情報だけでなく、画像全体の構図を考慮することができ、また信号機が小さくかつ部分的にしか見えていない場合でも信号機であることを検知可能となる。

一方で、信号機は、赤、緑信号及び矢印灯以外にも点滅信号もあり、自動運転自動車は点滅信号への対応が不可欠である。赤、緑信号および矢印信号の場合は、静止画から信号機認識が可能であるが、点滅信号の場合は時系列での認識処理が必要となる。2021年度は、点滅信号への対応に向けてデータセットを構築し、精度評価を行う。

---

---

## b. 「遠距離の物体を検知するために必要となる AI 技術の開発」

安全かつスムーズな自動運転を行うためには、車両周辺の自動車、二輪車、歩行者等を確実に検知することが重要となる。特に市街地で交差点を右折する場合、対向車線を走行する車両は相対速度が高い。自車が右折可能かの判断を行うためには、相対速度を考慮して遠方から検知する必要がある。一般道交差点において、安全な速度で右折するためには、対向車の速度を鑑み約200m 遠方の車両を検知する必要がある。また、信号機のない横断歩道において、歩行者の横断を妨げず、かつ安全に減速するには約70m 遠方から歩行者を検知する必要がある。このような遠方の歩行者や車両などの物体を検知する方法は2種類ある。1つ目はパッシブ型のセンサである車載カメラの画像を利用した物体検知手法、2つ目はアクティブ型のセンサである LiDAR やミリ波レーダを利用した物体検知手法である。車載カメラの画像を利用した物体検知手法の場合、一般的な車載カメラで撮影した画像において、遠方の車両や歩行者などの物体のサイズは比較的小さい。従来 of 物体検出手法で高精度に検出できる物体の高さは128 ピクセル以上必要であり、遠方の物体を検知することが困難である。そのため、遠方でも検知可能な高さを確保できるように画角を絞り込んだカメラを選定する必要がある。一方で、LiDAR やミリ波レーダを利用した物体検知手法においても遠方物体を観測可能である。そして得られる観測点群の分布などから機械学習で物体種別の識別が可能であるが遠方の観測が疎になるため、物体らしさの特徴が十分に得られず誤検出や未検出が多くなる課題がある。

本事業では、移動体検知における課題である「遠距離の移動体の検知性能の改善」の実現を目的とする。高度な検知性能を実現するには、遠距離の移動体検知に適したスペックを有する車載カメラを活用し、最新の人工知能技術により遠距離にいる小さな物体を検知するアルゴリズムを実現することが不可欠である。このため物体検知技術の開発と必要十分な検知能力を得るためのセンサスペックを検討する(①「遠距離向け車載カメラの選定・検知アルゴリズム開発」)。また、LiDAR やミリ波レーダによる観測情報に対しても遠方物体の認識性能を改善するアルゴリズム(②「LiDAR およびミリ波レーダに基づく遠方物体認識」)を開発する。そしてパッシブ型及びアクティブ型のセンサを活用することで遠距離の物体を正確な認識を実現する。また、シミュレーションを活用した認識技術の高度化及び一貫性評価に関しても検討する。

以下に実施内容および2021年度の目標を示す。

---

---

## ① 遠距離向け車載カメラの選定・検知アルゴリズム開発

遠距離の物体に対する自動運転自動車の認識性能を評価するためには、大規模なデータセットを用意する必要がある。一方、テストコースや実際の道路などで得られるデータセットは現実的なシーンであるものの、さまざまな条件下で遠距離の物体を含むデータを十分に確保するのが困難といった課題がある。そこで、SIP 他事業（Driving Intelligence Validation Platform, DIVP プロジェクト）で構築しているシミュレーション環境を活用して、現実的なシーンを網羅した遠距離に物体が存在するデータを生成し、学習および評価に活用する。2021 年度は、シミュレーション環境と現実環境で撮影したデータに対する相違を明らかにし、現実的なデータを生成できるシミュレーション環境を構築する。そして、認識性能を評価するためのデータセットを構築するための条件を決定する。

## ② LiDAR およびミリ波レーダに基づく遠方物体認識

LiDAR による物体識別では、観測した物体の点群情報から得られる形状や運動状態に関する特徴量から機械学習で識別する手法が提案されており、自動車、二輪車、歩行者のマルチクラス分類において 95%以上の認識率が報告されている。しかし、LiDAR の観測が疎になる 50m 以上の距離の物体に対してはさらなる認識精度の改善が課題となっている。そこで、2018 年度では、最新型の LiDAR を導入して各対象物に対する観測距離を評価した。最新型の LiDAR を導入することで観測距離の改善が期待できるが、遠方の観測が疎になる本質的な課題は変わらない。したがって、遠方物体の認識精度を大幅に改善するためには遠距離に有効な特徴量の設計が重要である。そこで、2019 年度では上記①の研究開発項目にも使用可能なデータセットを作成するとともに機械学習における特徴量設計において遠方物体に特化した特徴量を検討し、認識距離に改善を実施した。2020 年度では遠距離認識に特化したセンサフュージョンアルゴリズムを実現するため、デジタル地図を併用した認識アルゴリズムを開発した。デジタル地図から走行中に注目すべき道路領域を逐次抽出することで注目領域に特化して認識距離の改善を図り、200m 以内の自動車及び 70m 以内の歩行者を 90%以上で認識可能であることを検証した。2021 年度では、シミュレーションを用いた認識技術の高度化を図るため、SIP 他事業である DIVP 事業にて開発したシミュレーション環境との連携のための環境構築を実施して LiDAR による遠距離物体認識の一致性検証を実施する。

---

---

### c. 「高精度自己位置技術の開発」

デジタル地図を活用する市街地自動運転において、車両位置を高精度に推定する自己位置推定技術が重要となる。自己位置推定では GNSS などのセンサで測位した位置を初期位置として地図と LiDAR などのセンサの観測をマップマッチングすることで実現する。このとき、高精度な位置情報が測位されていることで、信頼性の高い初期位置を取得可能となるだけでなく、マッチング結果のバリデーションを行うためにも利用可能となる。本事業では、汎用的な GNSS と INS を用いつつも、自動運転システムに適用可能な位置が推定可能な GNSS/INS の技術開発を行う。また、LiDAR 等のマップマッチングの技術と併用した高精度自己位置推定アルゴリズムの開発を行い、地図の鮮度に起因する実環境と地図との差異が自己位置推定へ与える影響について調査する。なお、GNSS/INS の精度が劣化する可能性が高く、また、地図にも特徴が無い場所では、上記の開発ができたとしても、“道路に設置されたインフラ”による位置推定に頼らざるを得ない場所も存在することが予想される。そのため、自動運転システムを安定して運用可能な条件についても検討を実施する。

以下、ベースとなる①GNSS/INS の開発、地図を利用した②マップマッチングに分け、実施内容および 2021 年度の目標を示す。

#### ① GNSS/INS の開発

GNSS/INS の開発では自動運転に必要な位置精度を、走行車線の判定が可能な位置推定精度 1.5m、GNSS/INS だけでも自動運転システムの運用が可能な位置推定精度 0.3m の 2 つに設定する。まず、1.5m の位置精度の達成のため、汎用的な GNSS を用いつつも安定して推定可能な手法として、GNSS Doppler の有効性を最大限活用した手法の検討を実施する。この手法では、GNSS の疑似距離を利用し、正確な車両の数百メートルの軌跡情報を利用することでマルチパスを排除し、平均化の効果により位置の高精度化を可能とする。次に、0.3m の位置精度の達成のため、従来の整数不定性の決定に用いられている LAMBDA 法/Ratio Test の枠組みを拡張し、より信頼度が高く位置推定精度が判定可能なアルゴリズムの検討を実施する。本手法は、車両の運動の高精度な推定技術を拡張することで、従来の LAMBDA 法/Ratio Test の枠組みでも高精度な絶対位置の確度を高く推定可能な手法となる。これらの手法を組み合わせ、低コストセンサでロバストに 1.5m の位置精度を達成しつつ、状況に応じて信頼度を高く 0.3m の位置精度を達成することが可能になると考える。

これらを実現するため、2018 年度では従来技術の整理、及び精度評価を都市部の実環境で実施を行い、改善点の検討を行い RTK-GNSS の FIX 率の改善と 1.5m 位置精度の改善を実施した。また、2019 年度では高さ方向の変動に注目

---

---

---

---

した信頼度の判定手法の提案を行い、2020年度ではみちびきを活用した測位性能の評価を及び、手法の改善を行った。さらに、2021年度からはGNSS/INSの相対位置精度にも注目を払い、Dead Reckoning性能の改善を実施し、方位角の最適化による性能向上手法の提案を行う。

## ② マップマッチング技術の開発

マップマッチングは自動運転の根幹の技術であり、位置を照合する特徴が少ない道路でマッチング誤差が増大すると自動運転が破綻してしまう。このような場所で自動運転自動車を運用するには、現状では高精度なGNSS/INSを導入し、車両の運動の信頼性を担保するか、もしくはインフラを設置する必要があった。そこで本研究では、安定した自動運転の運用にはインフラの設置及びメンテナンスは不可避であるという前提に立ち、道路整備・メンテナンスすべきインフラ項目を明らかにすることを主目的とした、マップマッチング技術の開発を行う。

2018年度から2020年度にかけては、まず非降雨時を前提としたマップマッチングアルゴリズムの研究開発を行い、目標精度0.1mの位置推定精度を達成した。2021年度以降に関しては、降雨時においても目標精度0.1mを達成可能な位置推定手法の開発検討を行う。2021年度は、初期検討として高精度なGNSS/INSを用いたマップマッチングアルゴリズムを開発する。2022年度は、車載グレードのGNSS/INSを用いることを想定したマップマッチングアルゴリズムを開発し、目標精度0.1mを達成する。また、推定誤差の情報を分析することでインフラに関する検討を可能にすることを目指す。また、そのためにDIVP事業との連携によってシミュレーションを利用した降雨データの再現と位置推定の性能限界評価を行う。

---

---

#### d. 「SAKURA-DIVP と連携したシミュレータおよびシナリオの検証」

市街地には、車、バイク、自転車、歩行者といった多種多様の移動体が多数存在している。このような移動体に衝突せず安全に走行を行うためには、移動体の将来の行動を予測し、それを考慮した自車の走行軌道(将来自車が取べき経路と速度)を計画する必要がある。これらの移動体のうち、歩行者のような低速の移動体は速度が遅いが、急に移動方向を変更することもあり、将来の軌道を正確に予測することが困難であるという課題がある。そのため、歩行者のような低速で移動する物体に関しては、単なる運動状態のみではなく、体や顔の向き等を求めることも重要である。

一方、車のように高速で移動する物体に関しては、その運動状態を推定することで、速度ベクトルから将来の軌道をだまかに予測することができる。しかし、その移動速度が速いため、安全な走行を行うためには将来の軌道を陽に考慮した高度な軌道計画(パスプランニング)技術が必要となる。

そこで本研究課題では、AI 技術にもとづき移動速度の低い歩行者の属性(体の向きや年代層等)を求め、その行動を予測する技術(①「人工知能(AI)に基づく歩行者の行動予測」と、時系列的な追跡によって高速で移動する車の行動を予測し、その将来軌道を考慮して軌道計画を行う技術(②「時系列追跡による車両の行動予測とパスプランニング」)について研究を行う。そしてこれらの技術を組み合わせることで、市街地の複雑な環境下においてスムーズかつ安全に走行可能な技術を構築する。

一方で、パスプランニングの評価は実環境下において検証を行う場合、同等の条件下での検証を繰り返し行うことは困難である。同一条件下での検証を通じて、課題抽出と改善を繰り返し行うためには、実環境と同等の認識ができるシミュレータが必要となる。そこで、SIP 自動運転の他の施策関係者等によって開発されたシミュレータを用い、市街地走行で課題となっているシーンに関してシミュレータを用いた行動予測及びパスプランニング技術の高度化を図るとともに、シミュレーションと現実環境の一致性検証を行う。そして、市街地走行におけるインフラ支援の必要性の有無やインフラに対する要望の取りまとめを行うことを目的とする。

以下に実施内容および 2021 年度の目標を示す。

##### ① 人工知能(AI)に基づく歩行者の行動予測

シミュレータ環境下での評価を行うために、まず実環境とシミュレータ環境(SIP 他事業(DIVP プロジェクト)で開発しているシミュレーション環境)の一致性を検証しなければならない。2021 年度は、実環境で課題となっている複数のシーンにおいて、認識アルゴリズムの一致性検証を行い、実環境とシミュレーション環境の差異を明確にする。

---

---

## ② 時系列追跡による車両の行動予測とパスプランニング

市街地における自動運転では、移動物体の将来の予測軌道を求め、その軌道に衝突しない自車の走行軌道をリアルタイムに計画することが重要となる。ただし、特に多数の移動車両が存在する都市部においては、これを実現するためには様々な問題に対処する必要がある。例えば、都市部では自車周辺に多数の移動車両が存在しているため、これらの移動車両同士で一時的に隠ぺいされて死角(オクルージョン)が頻繁に生じる。また自転車等の複雑な動きをするような移動物体の将来の予測軌道をどのように精度よく求めるのかも課題となる。さらに、都市部での走行では複数車線ある道路に多数の車両が存在している場合が多く、自動運転自動車はこれら多数の車両に囲まれた状況が生じる。このため、このような相対的に狭いスペースの中で多数の移動物体の将来予測軌道を考慮して、どのようにしてスムーズかつ安全に走行するのかも課題となる。そこで本研究課題では、移動物体の運動状態とその形状を精度よく推定し、移動物体の将来軌道を予測する技術を開発する。そして、これらの移動物体の予測軌道を考慮して市街地においてスムーズかつ安全に走行可能な軌道計画技術を構築する。

2019年度は、2018年度に検討した複数個所の走行エリアにおけるデータ収集を進めるとともに、移動物体の運動状態と形状を同時推定するアルゴリズムの車両システムへの実装とリアルタイム性検証を行った。また、移動物体の将来軌道予測アルゴリズムおよび軌道計画技術の基礎設計を行った。2020年度では開発したアルゴリズムを順次車両システムへ実装していき、市街地環境における自動運転の平均走行持続可能距離 5.0km を達成した。また、自動運転のオーバーライドにおける不調要因を分析した。2021年度では、実証実験で得られた認識不調による課題シーンの抽出及び改善を図るためにシミュレータを活用したアルゴリズム改善を実施する。そこで SIP 他事業 (DIVP プロジェクト) で開発しているシミュレーション環境と自動運転システムとの連携を行い、課題となるシーンのシミュレーション環境での再現試験を実施する。

---

---

#### e. 「自律型自動車が走行する状態での問題点の検討」

現代の交通社会においては、自動運転自動車が公道を走行するような状況は少ないため、自動運転自動車同士が交差点などの複雑な環境下において遭遇する可能性は極めて低い。一方、将来の道路交通では、多数の自動運転自動車が混在して走行する状態となることが予想され、自動運転自動車同士が様々な交通状況において互いに遭遇する可能性が高くなる。

一般的に自動運転自動車は法令を順守して走行を行うため、その振る舞いは基本的に交通ルールに基づく運転行動となる。このため複雑な環境下において自動運転自動車同士が遭遇した場合、例えば商業施設の出入り口における進入・退出時、幹線道路への合流時等の状況において、互いに身動きが取れなくなるいわゆる「デッドロック問題」を引き起こす可能性がある。また、緊急車両接近時など、優先車両に進路を譲るための運転行動の変化に伴い「デッドロック問題」が生じる可能性がある。したがって、将来自動運転自動車が行き交う交通環境に向けたデッドロック回避対策の検討を行うことが重要となる。このため、本研究課題では①「ロボティクス技術を活用したデッドロック回避」と、②「人工知能(AI)技術を活用したデッドロック回避」に関する個別の技術について検討を行う。そして互いの技術に基づきデッドロックが生じる状況や技術課題等について検討を進め、個別技術の高度化を進める。最終的には、これらの①、②の技術を融合させた高度なデッドロック回避技術を構築する。そして高度なデッドロック回避策をとったとしても自律型の自動運転技術のみではデッドロックが発生してしまう状況(交差点形状、道路幅、交通量等)を明らかにする(自律型自動運転自動車が走行すべきでない道路環境・交通状況等の明確化)。また、デッドロック回避に対してどのようなインフラ支援があるべきかについて提言を行うことを目的とする。

以下に実施内容および2021年度の目標を示す。

##### ① ロボティクス技術を活用したデッドロック回避

自動運転システムにおいて、自動車の振る舞いを決定するパスプランニング技術には、大きく分けて自動運転自動車が目的地に到達可能なルートを計画する技術、交通ルール等に基づいて大まかな車両の振る舞いを決定する技術、そして細かい障害物への回避や先行車両の追従などの細かい挙動を計画する技術に大別可能であると考えられる。本研究課題では、こうした自動運転の基本的な意思決定をシミュレーションソフト上で再現するための環境を構築し、複数の自動運転車が走行する環境下でデッドロックが発生しやすい状況を明らかにする。そしてこのようなデッドロック発生シーンに対する回避策を、意思決定技術および軌道計画技術の高度化に関する観点から検討し、これらのデッドロックが回避可能であるか否かの検討を進める。2019年

---

---

---

---

度は、複数の自動運転自動車の挙動を再現可能なシミュレーションソフトの開発を行った。さらに、シミュレーションソフトに基づいて机上検討を行い、デッドロックの発生しやすい場所・走行条件（交差点形状，走行条件，交通量等）を明確化し，デッドロックが発生するシーンを5件以上明らかにした。交通ルールを厳密に遵守する自動運転自動車に対して，交通ルールに対して曖昧な運転行動をとる一般車両が存在する場合，デッドロックにより走行不能となる状況が起こりやすいことを確認した。2020年度では，交通ルールの曖昧さが発生するデッドロックの発生シーンに対する回避アルゴリズムを検討してシミュレーション及び実車試験を通してデッドロック回避アルゴリズムの有効性を検証した。2021年度では，交通ルールが曖昧となる状況として緊急車両遭遇時の回避走行の実現に注目する。緊急車両に対するデッドロック回避の有効性を評価するため，開発済みの試験車両に緊急車両を認識するための車載センサやV2X通信装置を搭載し，センサフュージョンによる緊急車両の認識アルゴリズムを開発する。また，緊急車両の接近に伴うデッドロックの回避シーンを検討してシミュレーション環境に反映する。

## ② 人工知能(AI)を活用したデッドロック回避

デッドロックを回避するシーンとして、緊急車両を優先して走行させるために，自動運転自動車が避ける制御を行うことも想定される。特に，緊急車両が自動運転自動車から遠方に存在する場合，デッドロックが生じる前に回避を行うことが可能である。2021年度は，画像認識による緊急車両の認識アルゴリズムを開発する。また，緊急車両を優先して走行させるためのデッドロックシーンを検討し，シミュレーション環境を構築する。

---

---

#### f. 「実証実験」

上記テーマ a.～e. の検討を踏まえて、公道での実証実験を実施する。公道での実証実験の効率的な実施のため、本事業では、合計 2 台の試験車両を構築する。2 台の試験車両を制作する理由としては、テーマ a.～e. において計画した研究開発において東京臨海部における公道走行試験、石川県金沢市における公道走行試験を始め、各地でセンサデータ取得試験等も行うこととしており、効率的な運用を行うことを可能とするためである。またテーマ e. に関しては、そもそも複数の試験車両を用いた試験を行うことを予定しているため、本研究では 2 台の試験車両を用いることとしている。

構築する試験車両には、市販車両に対して自動運転 ECU を追加搭載し、CAN(Controller Area Network)通信によるコマンドでハンドル、スロットル/ブレーキ、シフトレバー、ウィンカー等が制御可能な状態に改造する。また、複数の LiDAR(Light Detection and Ranging)、ミリ波レーダ、カメラ等の周辺環境認識センサや、GNSS(Global Navigation Satellite System) / INS(Inertial Navigation System)等の自己位置推定センサ、V2X 車載端末等を搭載する。そして、これらの自動運転 ECU、各種センサ等を用いて自動運転が行える状態にした試験車両を用いて、公道走行をはじめとする各種実証実験を実施する。なお構築した自動運転システムが公道走行に支障がないかの事前検証に関しては、国土交通省運輸支局による構造変更検査登録等を通して、公道走行に違法性がないことを確認する。また公道走行前にはテストコースにおける事前検証や、第三者機関による安全性評価を実施したのち、公道走行実験を開始する。また公道走行時には、警察庁が公表している「自動走行システムに関する公道実証実験のためのガイドライン」および関係機関の指示に従い実証実験を行うものとする。

2021 年度は、2020 年度に引き続き石川県金沢市および東京臨海部を中心としたエリアでの走行試験を進めるとともに、SIP 他事業により整備された V2N インフラを用いた公道走行実証を開始する。また関係者及びマスコミ等を対象とする試乗機会を設け、SIP 事業の国民への成果発信に努めるとともに、自動運転技術の現状と理解を深める取り組みを実施する。

---

---

### 1.3. 成果の要約

#### a. 「信号機認識技術の開発及び認識が困難な条件の検討」

##### ①. パターン認識による信号認識と交差点進入判断アルゴリズムの開発

2021年度は認識対象を点滅信号機に拡張して、赤及び黄色の点滅信号の認識アルゴリズムを開発して性能評価を実施した。認識アルゴリズムでは2020年度までに開発していた信号認識のアルゴリズムをベースとしてフレーム単位で得られる認識結果の推移から点滅状態を判別するアルゴリズムを実装した。金沢市内における走行データを対象とした性能評価では、通常の日照条件における評価データに対して目標値である95%の認識率を達成した。一方、逆光や順光となると認識率の低下を確認しており、特にランプ式信号の順光時は点灯・消灯間のランプの輝度の差が小さくなるためフレームごとの認識では消灯時の誤認識が課題として確認された。しかし、画像差分による点滅認識の有効性を検証したことで認識アルゴリズムの改善案を基礎検討した。

次に、DIVP事業と連携した仮想環境を活用した信号機認識の一致性評価を実施した。通常のシーンにおけるシミュレーションデータの認識率の一致性検証やこれまでの評価で確認している代表的な環境不調である逆光時の画像飽和の影響などを検証した。

さらに、これまでに評価してきた信号認識の成果を還元するため、信号認識における悪条件シーンの走行画像データセット提供を開始した。東京臨海部及び金沢市周辺などで計測した走行データから逆光、順光、夜間、雨天など幅広い環境条件の交差点進入シーンの画像データに対して信号機や交通参加者などの物体をタグ付けして整備することで当該研究分野への貢献を目指している。

---

---

## ②. セマンティックセグメンテーションによる信号認識アルゴリズムの開発

点滅信号機のデータセットを構築し，点滅信号機の検出および識別における課題調査を行った．点滅信号機の検出では，無灯火状態の信号機が森などの背景に溶け込むようなシーンにおいて検出が困難であることがわかった．また，遠方に複数の信号機があるシーンにおいて，時系列での追跡が困難であることがわかった．一方，地図情報に基づく ROI (Region-Of-Interest)があると，信号機の位置が大まかにわかっているので，時系列での追跡失敗が少ないことも確認した．

信号機状態の識別では，ランプ式の信号機の識別が困難であることを確認した．ランプ式の信号機は無灯火状態でも灯火領域に色味が現れている．そのため，青信号または赤信号に誤識別するケースがある．識別精度の向上に向けては，無灯火状態のランプ式信号機のデータを追加することが必要であると考えられる．

---

---

## b. 「遠距離の物体を検知するために必要となる AI 技術の開発」

### ①. 遠距離向け車載カメラの選定・検知アルゴリズム開発

シミュレーション環境と現実環境で撮影したデータに対する相違を明らかにするために、公開データセットと DIVP 事業のシミュレーション環境で生成したデータセットを対象に調査を行った。公開データセットの場合、色の表現を高品質に再現する CG レンダリングエンジンを採用しており、実環境の映像で生じる偽色を再現できていない。そのため、遠方物体に対して過渡に検出できてしまう傾向がある。一方、DIVP 事業のシミュレーション環境の場合、反射特性などを考慮して映像を現像しているため、偽色を再現できている。そのため、実環境と同様に遠方物体に対して検出精度が低下する傾向がある。これより、実環境とシミュレーション環境での一致性の1つとして、偽色の再現性がわかった。一方、影などにより物体が暗く写るシーンでは、再現性がやや低下するため、今後さらなる原因調査を行う必要がある。

### ②. LiDAR およびミリ波レーダに基づく遠方物体認識

2020 年度までの評価では、遠距離物体の認識において LiDAR 及びカメラをフュージョンによる物体認識の有効性を検証してきた。2021 年度は、シミュレーションを活用した認識技術の高度化を目指して、シミュレータと連携した環境構築並びに LiDAR による物体認識の一致性を検証する。DIVP 事業で開発されているシミュレータで生成された LiDAR データを用いた物体認識を行うための環境を構築して、遠距離物体を評価するための実走行データ及びシミュレーションデータを生成して両データに対する一致性評価を実施した。一致性評価では LiDAR による物体認識アルゴリズムとして PointPillars のネットワークを活用して注目車両の検出率を評価することで双方のデータにおいて同程度の認識率が得られたことを確認した。今後はシミュレータにより生成されたカメラ画像の認識結果との連携をおこない、センサフュージョンによる評価環境の一致性の検証を進める。

---

---

## c. 「高精度自己位置技術の開発」

### ①. GNSS/INS の開発

GNSS/INS の開発では、自動運転に用いる位置精度を利用するために、1.5m の位置精度の実現、及び 0.3m 以下の位置精度を達成している場所を判定する手法の提案を行った。まず、1.5m の位置精度の実現に関しては、お台場で 30cm@77%/1.5m@90%、新宿で 30cm@57%/1.5m@92%の範囲で達成できることを 2018 年度に確認した。2019 年度では 0.3m 以下の位置精度を達成している場所の判定に注力を行い、汎用の GNSS 受信機を用いた実験で、東京都お台場付近、東京都新宿付近で、0.3m 以下の位置精度の判定が 99%で実現できる可能性を確認した。次に 2020 年度では 2019 年度に開発を行った 0.3m の位置精度を判定する手法を、準天頂衛星みちびきから放送されている CLAS 信号への対応を行い、測位精度の改善を行った。その結果、みちびきから放送される CLAS 信号を利用したお台場での評価試験において、0.3m 以下の位置精度の判定が 99%で実現できる結果を得た。ただし、受信可能な衛星数が減少する場合には測位、及び 0.3m 以下の判定の性能が劣化する傾向も確認した。

そこで 2021 年度では、高精度に位置が推定できる地点間の補間をする際に重要となる、DR(Dead Reckoning)の高精度化を実施した。まず、DR 区間の誤差とその要因について検証した結果、10 秒の DR の場合は初期方位角が影響することを確認した。次に、初期方位角の性能を向上させるため、過去数十秒間の FIX 解を使用して初期方位角を最適化させる手法を提案した。評価試験では都市部の評価コースにおいて、10 秒間 DR した際の誤差が 0.3[m]以下になる割合が 87.7[%]を達成し、提案手法の有効性を確認した。

### ②. マップマッチング技術の開発

マップマッチング技術の開発では、高精度 GNSS/INS を使用することを前提とした降雨時にも高精度に位置推定可能なマップマッチングアルゴリズムの開発を行った。マップマッチング方式としては、金沢大学が開発を行っており公道走行実験での実績があるテンプレートマッチングを利用した位置推定アルゴリズムをベースとし、地図上における自車両の位置を推定する手法を開発・実装した。2018 年度に選出した金沢市内の評価ルートにおける精度検証を行い、降雨時においても目標精度である 0.1m が達成可能であることを確認した。また、自己位置推定の性能限界調査のため、DIVP 事業との連携によってシミュレーションでセンサ不調シーンを再現し検証の効率化を図った。路面の材質や濡れ状態の条件を変更することにより、性能限界の評価を行なった。

---

---

---

---

#### d. 「SAKURA-DIVP と連携したシミュレータおよびシナリオの検証」

##### ①. 人工知能(AI)に基づく歩行者の行動予測

パスプランニングに必要な歩行者の行動予測の要素技術となる歩行者検出について、現実環境とシミュレーション環境における認識アルゴリズムの一致性検証を行った。シミュレーション環境において、時間帯や鏡面反射成分、歩行者などのアセットの分解能など諸条件を変えて調査した結果、鏡面反射成分の影響は小さく、アセットの分解能が歩行者の検出率に影響することがわかった。また、歩行者および道路にテクスチャを付与してより再現性を高めた場合、現実環境の検出率と同程度になることがわかった。加えて、現実環境のように背景に建物を配置して複雑な環境を再現すると、現実環境の検出率と同程度になることもわかった。車内の内装をトリミングし、外界のみを検出領域とした場合、検出率が大きく向上することもわかった。ただし、この条件は歩行者のサイズが大きくなったことに起因することも考えられるため、今後歩行者の大きさと背景の関係について調査する必要がある。

##### ②. 時系列追跡による車両の行動予測とパスプランニング

これまでの実証実験において確認された認識及びパスプランニングの課題を改善するために、2021年度は、このような認識不調により自動運転継続に課題となるシーンに注目してシミュレーションによる再現を行うことで検証の効率化およびパスプランニング技術の高度化を図った。SIP他事業であるDIVP事業で開発しているシミュレーション環境と自動運転システムとの連携を行い、カメラやLiDARなどのセンサデータを生成可能な環境を構築した。そしてシミュレータで生成したデータと実環境で得られるセンサデータとの一致性を検証するための再現環境を構築した。

また2020年度までの実証実験では、行動予測及びパスプランニングに関する課題のシーンとして、死角のある環境での飛び出しのシーンを確認した。立体物の多い環境での右折判断などでは物理的遮蔽の影響を考慮したパスプランニングが重要となる。2021年度においては、物理的遮蔽による死角領域の認識技術の開発と、対向車両の存在を想定した判断技術の構築を行なった。また、今後の検証に向けた準備として、実際の交差点走行を想定したシナリオを構築しシミュレーションによる不調シーンのシナリオ生成を行なった。

---

---

e. 「自律型自動車が走行する状態での問題点の検討」

①. ロボティクス技術を活用したデッドロック回避

2021年度は、緊急車両に対するデッドロック回避の有効性評価を行うにあたって、試験車両にマイクやV2X通信装置を搭載し、センサフュージョンによる緊急車両認識アルゴリズムの検討・開発を行なった。緊急車両のサイレン音を認識するために車載マイクを利用した音認識技術を開発し、サイレン音と環境音との識別が可能であることを確認した。また、東京臨海部においてV2N通信による模擬緊急車両の位置情報配信実験に参加し、データ計測および配信データの品質などを中心に検証した。その結果として、配信情報から模擬緊急車両の存在方向を把握するために十分な精度で位置情報が取得可能であることを確認した。

加えて、シミュレーション環境への反映を目的とした準備として、モデル化を行う緊急車両との遭遇シーンの抽出および実データに対するタグ付け作業を行った。

②. 人工知能(AI)技術を活用したデッドロック回避

緊急車両とのデッドロックを回避するために、緊急車両のデータ収集および認識アルゴリズムの検討を行った。データは金沢市内で9シーン収集することができた。緊急車両として、救急車とパトカーを対象とし、物体検出アルゴリズムを学習および評価した。2つの評価シーンにおいて、緊急車両のランプが点灯している際、それぞれ正しく認識できた。一方、ランプが消灯している際、一般車両と認識することがある。

また、AIを活用して緊急車両とのデッドロック回避を検証するためのシミュレーション環境を構築した。構築した環境は、渋滞時に後方から緊急車両が走行するシーンとした。今後、緊急車両の認識アルゴリズムについて、距離による認識精度の限界を確認するとともに、時系列での認識手法を検討する。また、構築したシミュレーション環境において、他車両と連携し、スムーズに緊急車両が走行できるスペースを空けることができるか検討する。

---

---

#### f. 「実証実験」

2019 年度に構築した 2 台の試験車両をベースに、緊急車両のサイレン音の認識も可能とするため、自動運転自動車の周辺環境の環境音を計測可能なマイクも新たに追加し、走行環境音を含めた走行環境情報の収集を可能とした。またインフラ協調型の自動運転機能の構築のため、SIP 別施策として実施されている東京臨海部実証実験において、2021 年度から実施された V2N を使用した実証実験に参加すべく、2020 年度まで使用していた実証実験用車載機に加え、セルラー通信によってインフラからの情報を取得可能な車載機を新たに搭載し、実証実験を実施した。そして、V2N によってネットワークから配信される降雨情報、車線別道路交通情報、模擬緊急車両位置情報、信号予定情報が受信可能であることを確認した。そしてこれらの取り組みを通し、2021 年度は東京臨海部での走行実証実験に関しては合計 61 日間実施し、自動運転状態で約 1,075.4km を走破した。

また 2021 年 4 月 20 日、21 日に東京臨海部において実施されたメディア向け試乗会に参加し、試験車両の展示、試乗機会の提供等を実施し、社会受容性向上に資する取り組みについても実施した。

---

---

## 2. 研究開発成果

### 2.1. a. 「信号機認識技術の開発及び認識が困難な条件の検討」

#### ① パターン認識による信号認識と交差点進入判断アルゴリズムの開発

公道走行における安全かつ安定した周辺認識を実現するため、精密なデジタル地図と単眼カメラを用いた信号認識アルゴリズムを開発する。市街地の交通環境のうち特に交差点走行における安全性を確保するため、信号機の点灯状態を確実に認識することが重要である。しかし、日照条件や背景、対象物体の周囲物体との遮蔽、および撮影画像のコントラストなど、様々な要因の影響を受けて取得するカメラ画像の視認性が変化する可能性がある。このような状況における安定した認識の実現が要求されている。2020年度までの取り組みでは、東京臨海部で計測した走行データに対する評価において、120m以内の信号灯及び矢印灯を99%で認識するためのアルゴリズム開発を進めてきた。その結果から逆光・順光・隠蔽・背景同化・夜間などの環境条件において認識が困難となる特徴的なシーンを確認した（図2.1.①-1）。



(a) 隠蔽



(b) 背景同化



(c) 夜間



(d) 逆光

図 2.1.①-1 東京臨海部の実証実験で確認した環境不調による認識困難なシーンの例（2020年度報告資料より）

---

---

---

---

2021年度は認識対象を点滅信号機に拡張して、赤及び黄色の点滅信号の認識アルゴリズムを開発して認識率95%の達成を目指した。また、これまでに検証してきた認識が困難となるシーンをシミュレーション環境下で再現した評価環境の構築に取り組んだ。SIP他事業であるDIVP(Driving Intelligence Validation Platform)事業において開発されているセンサのシミュレーション環境と連携した環境不調の再現実験を実施した。さらに、東京臨海部の実証実験においてV2N通信による有効性の検証のためのデータ計測環境を構築した。具体的には以下の研究項目・分析を実施した。

- ・点滅信号の認識アルゴリズムの検討・性能評価
  - ・仮想環境を活用した信号機認識の一致性検証
  - ・交差点進入時の悪条件シーンの走行画像データセット提供
- 以降では具体的な研究開発成果について個別に述べる。

#### ・点滅信号の認識アルゴリズムの検討・性能評価

2019年度までの成果としてデジタル地図を活用した信号灯・矢印灯の認識アルゴリズムを開発してきた[1]。図2.1.①-2に示すように、信号機位置などが登録されたデジタル地図を用いて画像上の信号機領域(Region-Of-Interest, ROI)を抽出し、ROI領域内のカメラ画像から信号灯及び矢印灯の点灯状態を認識する方法である。一般的に信号灯火は、周囲より明るい色を持つこと、すなわち高い彩度と明度を持つ特徴があるため、色合いの特徴や信号灯の円形形状などの特徴に注目して候補点を抽出して対象物であるかを識別する。また、地図情報に含まれる信号機情報には位置だけでなく、設置方向(縦型・横型)や矢印灯(左、直進、右)の有無及び矢印灯の配置も含まれている。そこで対象の信号機が矢印灯を持つ場合、矢印灯の状態認識を行う。

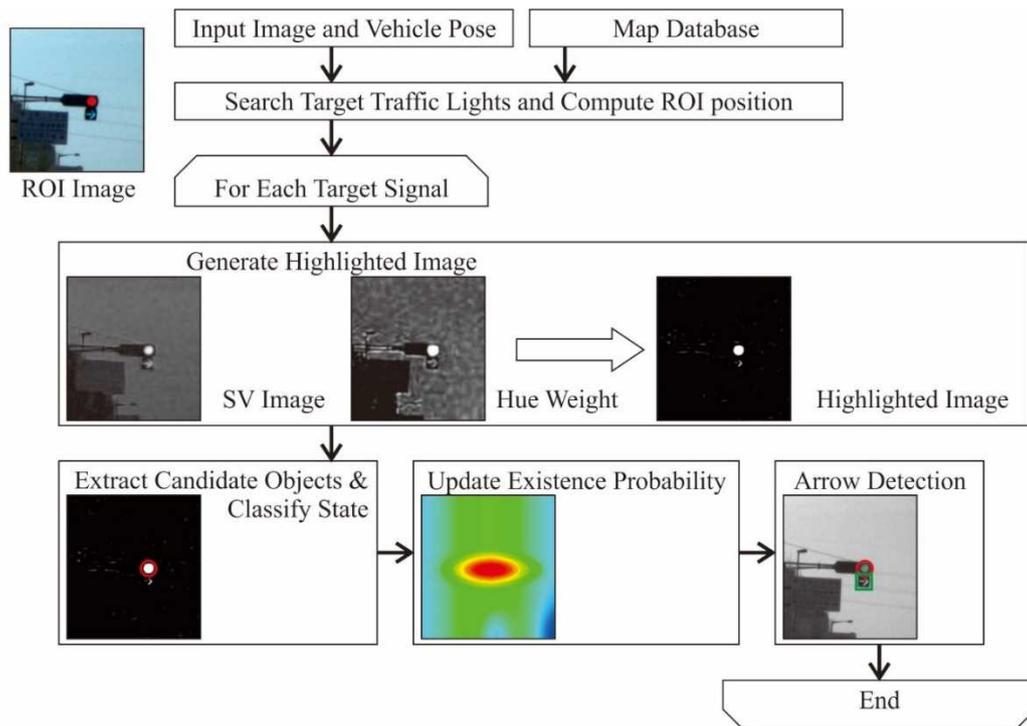


図 2.1.①-2 信号認識アルゴリズムの概要

2021 年度では前述の通り認識対象を点滅信号に拡張して、黄色及び赤色点滅信号の認識に取り組む。点滅信号は約 1 秒周期で点灯・消灯を繰り返しており、特定の交差点や交通量が減少する深夜の交差点などで利用されている。基本的には従来どおりの信号機認識アルゴリズムを用いることで各フレームの点灯状態の認識が期待できる。したがって、簡易的な点滅状態の認識アルゴリズムとして、認識した点灯状態ごとに点灯・消灯の変化を周波数解析する方法を検討する。得られた点滅周期が適切な周期範囲の場合は点滅状態として認識可能とする。通常信号認識と比べて、自動運転における点滅信号の認識では下記の技術的課題が想定される。

- ・ 信号消灯時に画像内に存在する類似物体を点灯物として誤認識
- ・ 赤色及び黄色の点灯色誤識別

消灯時の背景誤認識は周辺に存在する街灯などの点灯物や消灯している他の信号機を点灯として誤認識するなどが考えられる。また、点灯色の誤識別は一般的に黄色信号及び赤色信号は点灯色の色相値の差が小さいことが理由である。そのため、周囲の日照条件などによっては点灯色を誤識別しやすい対象物である。通常交差点を通過する際には、黄色・赤色信号ともに停止線手前での停止義務がある（黄色信号時は安全に停止できない場合を除く）。

基本的にはどちらの点灯状態でも減速走行が要求されるため、仮に信号認識時の点灯状態を誤識別しても自動運転走行には致命的な問題とはならない。一方、点滅信号の交差点を走行する際には、黄色点滅時は他の交通に注意した交差点通過を、赤色点滅時は一時停止義務が要求される。点灯時とは異なり点滅時では黄色及び赤色時に要求される運転行動が異なるため確実な点灯色の識別が必要である。2021年度の取り組みでは点滅信号の走行データ収集を開始し、点灯状態の認識率を評価することで点滅信号認識時の基礎的な課題を抽出する。

点滅信号の性能評価に当たり対象エリアでの走行データを収集する。これまでの実証実験で対象としている東京臨海部の走行エリアでは点滅信号の交差点が十分に存在しないため、金沢市内で点滅信号の走行データを計測した。異なる日照条件のデータとして表 2.1.①-1 に示す条件の走行データを収集した。点滅信号の走行シーンにおける特徴的な画像の様子を図 2.1.①-2 に示す。

表 2.1.①-1 点滅信号の評価データ件数

種別	ROI 数
通常点滅信号（赤色・黄色点滅）	1,195
逆光点滅信号（赤色点滅）	374
順光点滅信号（赤色点滅）	392

収集した走行データには LED 式信号だけではなくランプ式信号も含まれている。ランプ式信号では後方から太陽光に照らされる順光時において、消灯しているランプの輝度が高くなり点灯・消灯間のランプの輝度に十分な差が得られない不調を 2020 年度の検証で確認している（図 2.1.①-3(d)）。こうした環境不調が想定される中で信号点滅時の認識の様子を評価する。

評価指標としては以下に示す、F-value を認識率として性能を評価する。ただし、TP は正解数、FP は誤検出数、FN は未検出数である。上記の評価データに対して Precision, Recall, F-value を算出する。

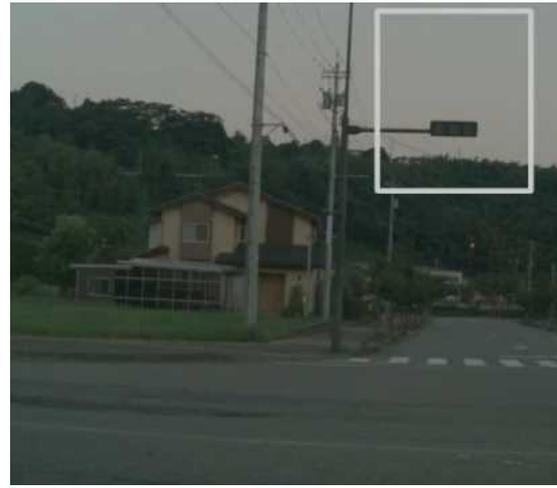
$$Precision = \frac{TP}{TP + FP} \quad (2.1.①-1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2.1.①-2)$$

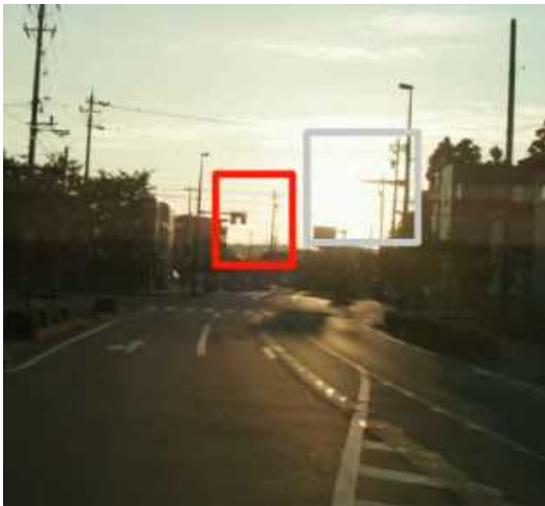
$$F-value = \frac{2Precision \cdot Recall}{Precision + Recall} \quad (2.1.①-3)$$



(a) 点灯時の様子（赤色点滅）



(b) 消灯時の様子（赤色点滅）



(c) 逆光時の様子（赤色点滅）



(d) 順光の様子（赤色点滅）

図 2.1.①-3 点滅信号の評価用データ  
(画像中の枠が ROI, 枠の色が点灯色を表す)

評価結果として、各日照条件による認識率を表 2.1.①-2 に示す。表 2.1.①-2 では、収集した走行データの環境条件の種別ごとに点滅信号機のフレームごとの点灯状態及び周波数解析に基づく点滅状態の認識結果をまとめたものである。また 2020 年度までの評価において、対象交差点に複数の信号機が存在する場合は交差点単位で多数決判定することで個別信号機の誤認識の低減を確認している。本評価においても複数の信号機が存在する場合に多数決戦略の交差点単位の認識を採用した。評価結果より、多くの条件において交差点単位の判別による認識率の改善を確認した。また、点滅状態の認識において通常的环境下では目標値としている 95%以上の認識率を達成していることから、信号機を視認しやすい条件下においては基礎検討していたアルゴリズム

ムで十分に判別可能であることが確認された。

表 2.1.①-2 点滅信号の認識における評価結果

	通常点滅信号			逆光点滅信号			順光点滅信号		
	Prec.	Recall	F-val.	Prec.	Recall	F-val.	Prec.	Recall	F-val.
点灯状態 個別単位	0.946	0.933	0.936	0.874	0.791	0.800	0.777	0.598	0.520
点灯状態 交差点単位	0.958	0.939	0.946	0.915	0.859	0.874	0.777	0.581	0.495
点滅状態 個別単位	0.965	0.987	0.976	0.976	0.551	0.705	1.000	0.276	0.432
点滅状態 交差点単位	0.962	0.992	0.977	0.975	0.686	0.805	1.000	0.308	0.471

表 2.1.①-2 にて示した評価結果では通常の点滅シーンと比べて逆光・順光となることで認識率が低下していることを確認している。各シーンのフレームスや交差点数などの条件が異なるため直接的な比較は困難であるが、全体的には逆光及び順光のシーンでは Precision に対して Recall の値が低下しており未検出が増大していることが確認できる。そこでそれらの特徴的なシーンを図 2.1.①-4 及び図 2.1.①-5 に示す。それぞれのシーンは図 2.1.①-3(c)及び(d)にて示した交差点の接近シーンにおけるフレームごとの認識の様子と対応しており、(a)、(c)及び(d)にて示すプロットは各フレームで点灯物を検出した場合の状態並びに色相・彩度・明度である。

まず、逆光のシーンは図 2.1.①-3(c)中の右側の ROI に対する認識結果の様子が図 2.1.①-4 である。逆光時は画像中の太陽周辺の画素が飽和するため、信号機と太陽が接近するときの視認性が低下する。評価データの前半 1,2 秒間太陽の影響で信号点滅を確認できないフレームであるが完全に飽和した瞬間を過ぎたあとも安定して点滅を検出するには数秒要していることが確認できる。そのため、視認性が改善するまでの区間で未検出が発生している。しかしながら、逆光による太陽光の影響範囲は限定的であることが 2020 年度までの評価において確認できており、図 2.1.①-3(c)においても他方の信号機は正常に視認できている。したがって、交差点に複数の信号機が視認できる場合は双方の認識結果を併用して認識結果の改善が期待できる。

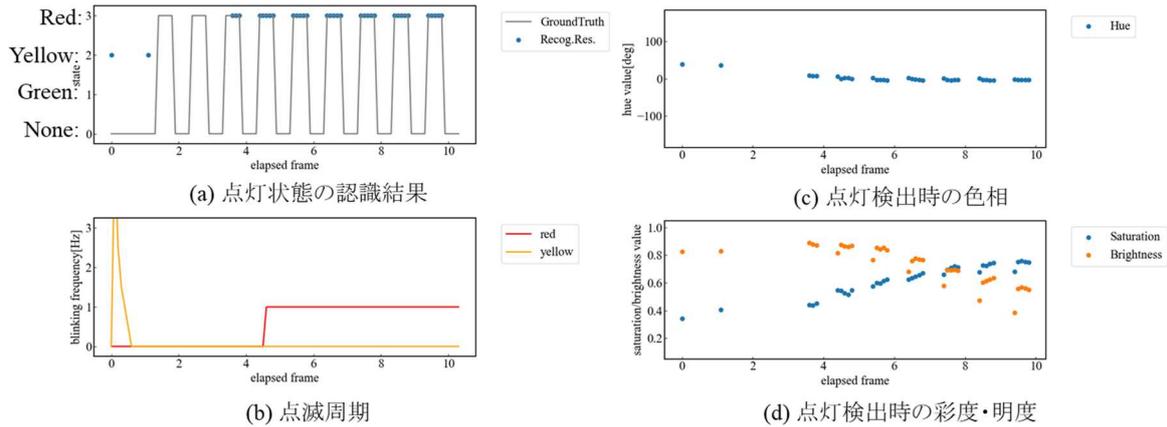


図 2.1.1-4 逆光点滅信号の特徴的な認識の様子

次に，順光のシーンは図 2.1.1-3(d)に対する認識結果が図 2.1.1-5 と対応している．順光時のランプ式信号機では消灯しているランプも太陽光が照らすことで明るくみえるため，通常時と比べて点灯・消灯間の輝度差が低くなる．点灯・消灯間では相対的な輝度差はあるものの，消灯時の輝度も高くなる．その結果，フレームごとに点灯物を検出する現在のアプローチでは消灯時のランプを誤検出する頻度が増大して点滅状態の認識が困難となる．一方，デジタル地図を活用した信号認識では注目したい信号機の領域を ROI として抽出するため，各フレームで対象信号機の領域を同程度の範囲で切り出し可能である．そこでフレームごとの ROI 画像の差分によって画素値の変化する領域を検出する方法も検討した．図 2.1.1-6 は同シーンにおける画像差分で検出した点滅領域の色相及び輝度の様子を示す．赤信号の点滅シーンのため色相値 0 付近で輝度に変化している様子が確認できる．消灯時の輝度も高い値を示しているが点灯・消灯での輝度値の変化を捉えることが確認できるため，輝度変化に注目した点滅領域の認識も効果的であると言える．

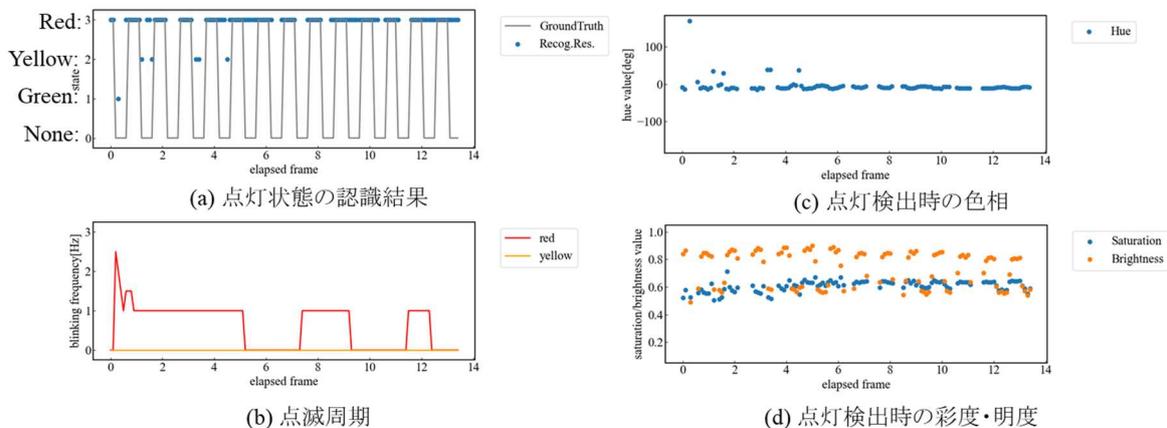
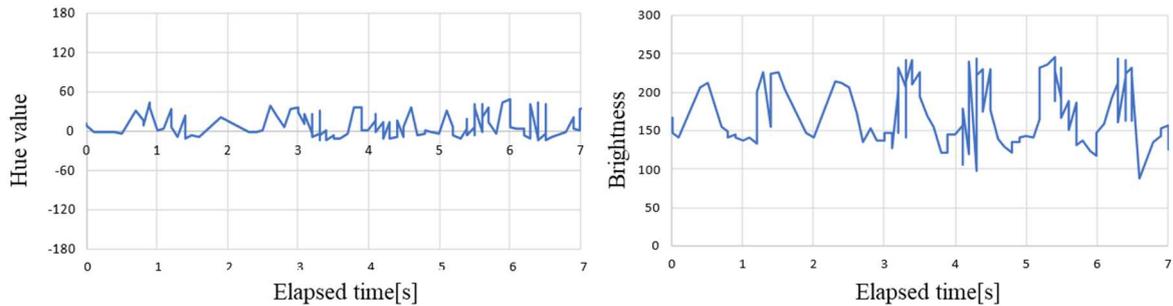


図 2.1.1-5 順光点滅信号の特徴的な認識の様子



(a) 色相

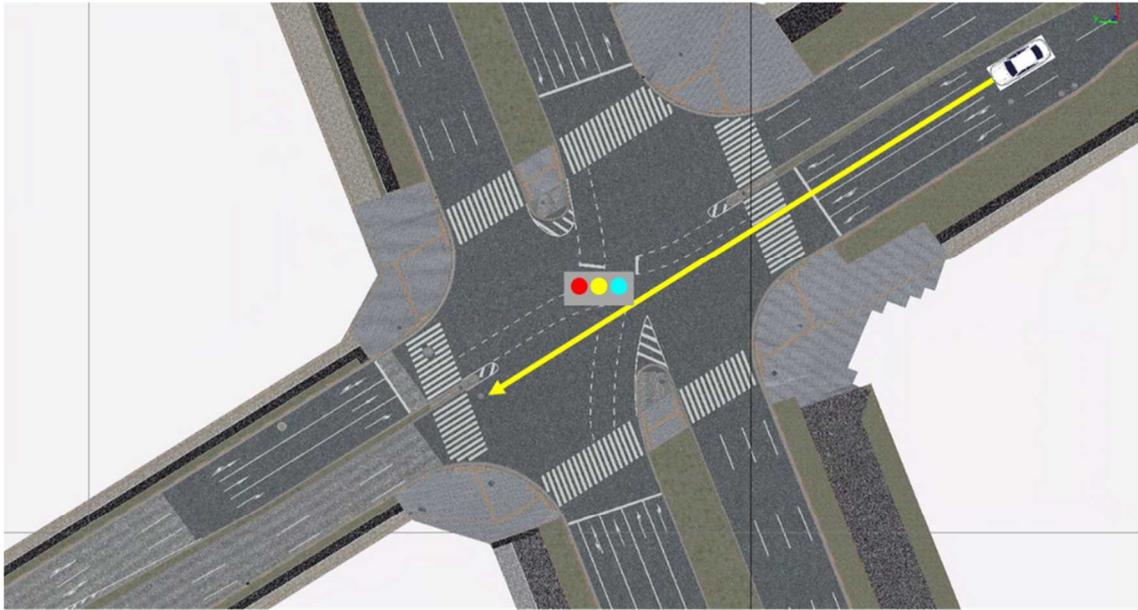
(b) 輝度

図 2.1.1-6 順光点滅信号における画像差分による点滅領域の検出

### ・ 仮想環境を活用した信号機認識の一致性検証

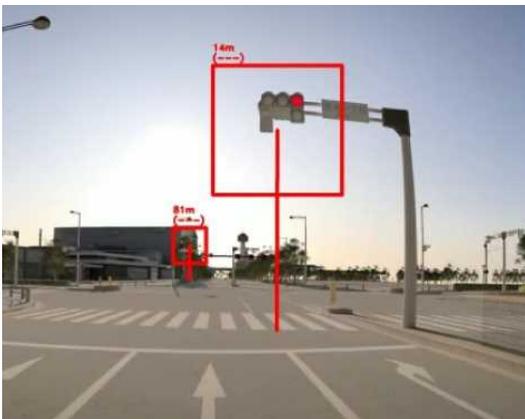
2020 年度までに東京臨海部の走行データで評価してきた信号機認識では、図 2.1.1-1 のように隠蔽・背景同化・夜間・逆光などの環境不調において認識が困難となるシーンを確認してきた。しかしながら、こうした不調の発生頻度は低く、特定の時間帯、天候、周辺構造物の配置などの条件が重なったときに認識が困難となる。このようなレアシーンの検証は実走行で遭遇することが困難と言えるためシミュレーションによる検証環境の構築が重要である。前述の通り、SIP 他事業の DIVP 事業では自動運転の安全性検証のためのセンサシミュレーション環境が開発されている。そこで DIVP 事業と連携した、信号認識の評価環境の一致性検証を実施した。評価においては、東京臨海部でモデル化されている交差点で生成したシミュレーション画像を用いて一般的な条件における認識性能の一致性検証のほか、実証実験では遭遇していない激しい雨天時の認識結果の差異を検証した。

シミュレーションで対象としたシーンは東京臨海部の青海一丁目交差点としており、図 2.1.1-7 のように交差点を東方向から西方向に直進する走行において、信号機の点灯色（赤・青・黄の 3 パターン）や天候（晴・曇・激しい雨天）を変化させた走行データを生成した。実際に生成したシミュレーション画像例及び生成画像に対する認識例を図 2.1.1-8 に示す。このようにして生成したシミュレーション画像と 2020 年度までに評価していた認識結果の傾向を比較する。ただし、使用しているカメラの解像度及び画角などの条件が異なるため、距離及びカメラの内部パラメータなどから算出した対象信号機の画素サイズの違いによる認識率を評価する。



-  自車両：青海一丁目交差点を東方向から西方向に直進走行
-  信号機：赤，青，黄で3パターン
- 天候：通常天候（晴・曇）・雨天（激しい降雨）

図 2.1.①-7 信号認識の一致性評価におけるシミュレーションシナリオ  
（青海一丁目交差点）



(a) 通常天候（点灯色：赤）

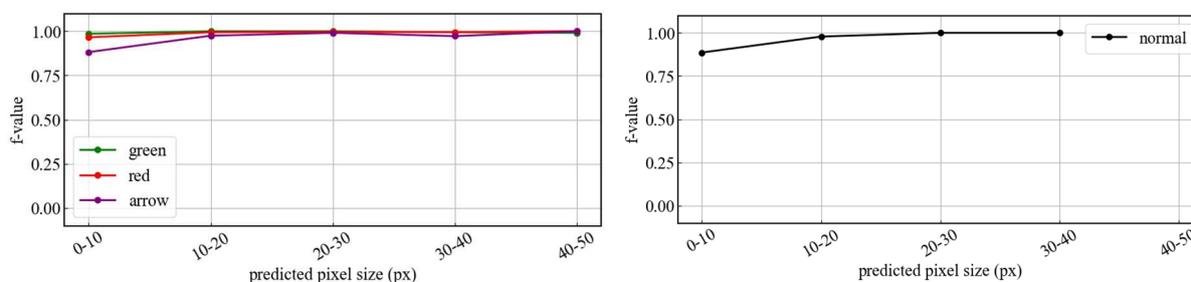


(b) 激しい雨天（点灯色：黄）

図 2.1.①-8 生成したシミュレーション画像例  
（ROI の枠の色は認識結果の点灯状態）

図 2.1.①-9 及び表 2.1.①-3 に通常天候及び雨天における評価結果を示す。通常天候におけるデータでは、画素数が 10 ピクセルを下回りおおよそ 100m 以上遠方となるシーンでは認識率が低下している傾向が確認されているが近距離では全体的に高い認識率を示しており、実データ及びシミュレーション間の平均認識率も同程度であることが確認できる。また、雨天のシー

ンに関しては実走行データでは通常天候と概ね同程度の認識率が得られており雨の有無による大きな違いは確認されていなかった。一方で、実環境よりも激しい雨天をシミュレーションした仮想環境のデータでは雨によって全体的な認識の低下を確認した。雨天時の特徴的な評価データの画像を図 2.1.①-10 に示す。実走行データの雨天では降水量が数 mm/h 程度のためフロントガラスに付着する雨滴の量が少なく信号との視認性への影響は大きくないことが確認できる。しかしながら、激しい降雨を想定したシミュレーションデータではワイパーの動作間にフロントガラスに付着する雨滴量が多いため信号機の全体形状の視認性が低下していることが確認できる。このようにシミュレーションにより生成したレアシーンを活用することで、認識アルゴリズムで想定すべき環境不調における検証が期待される。

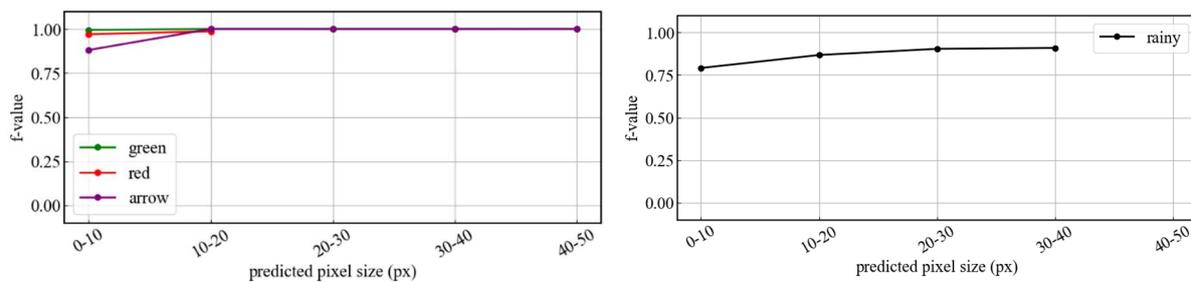


(a) 実走行データ

(通常天候, ROI 数: 59,101)

(b) シミュレーションデータ

(通常天候, ROI 数: 668)



(c) 実走行データ

(雨天, ROI 数: 5,303)

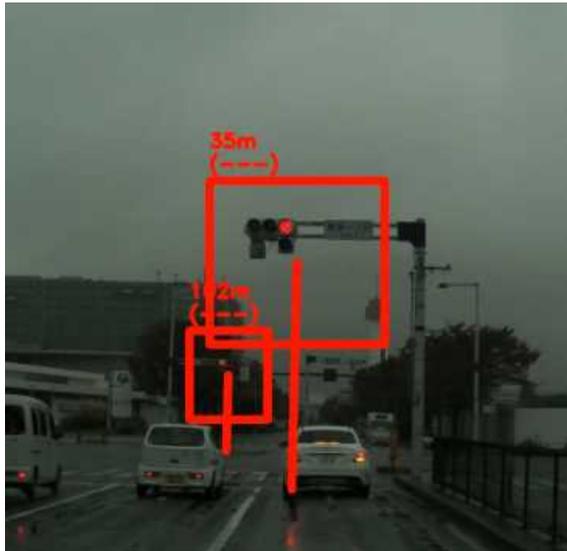
(d) シミュレーションデータ

(激しい雨天, ROI 数: 780)

図 2.1.①-9 信号認識における一致性評価結果 (f 値)

表 2.1.①-3 信号認識における一致性評価結果 (f 値の平均値)

	通常天候	雨天
実走行データ (赤・青信号)	0.992	0.989 (数 mm/h)
シミュレーションデータ (赤・青・黄信号)	0.989	0.868 (数十 mm/h)



(a) 実走行データ  
(赤信号, 雨天)

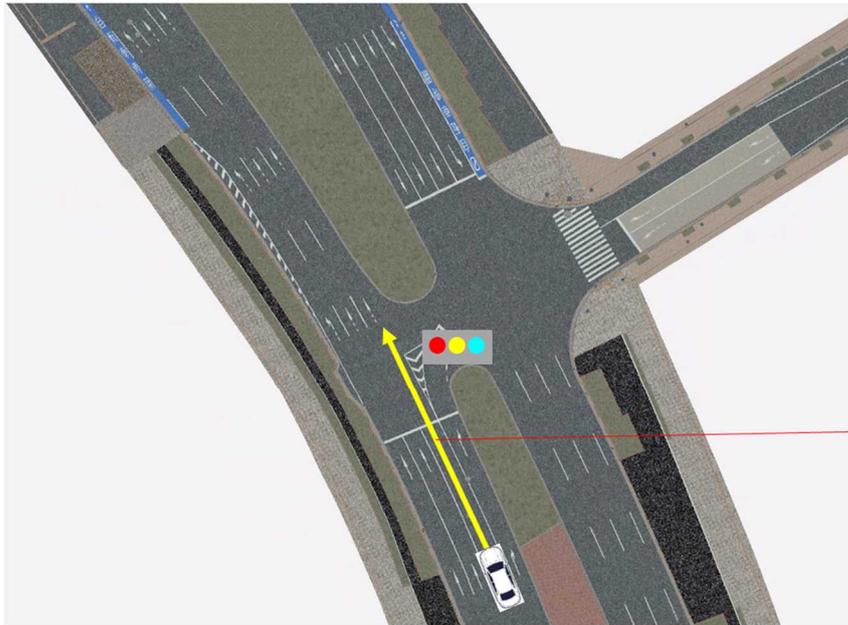


(b) シミュレーションデータ  
(黄色信号, 激しい雨天)

図 2.1.①-10 雨天時の走行画像例

次に、太陽光の影響として逆光の環境不調のシーンの再現について検証する。東京臨海部の検証では、カメラ画像内に太陽が入る逆光だけではなく、太陽光がビルに反射する間接的な逆光の影響もレアシーンとして確認しており、逆光による飽和領域と信号機が重なることで画像内の視認性の低下が想定される。一方で、2020年度の検証では逆光の影響は限定的であることも確認しているため、こうした逆光による不調シーンの特徴がシミュレーション画像において再現されているかを確認した。図 2.1.①-11 にシミュレーションのシナリオを示す。実証実験での走行において逆光の不調シーンが確認された青海一丁目交差点及び東京テレポート駅前交差点を対象としてそれぞれのシミュレーションデータを生成した。実際に生成したシミュレーション画像の検証例を図 2.1.①-12 及び図 2.1.①-13 に示す。それぞれ逆光による画像飽和の様子が実画像同様に再現されていることが確認され、走行条件に応じて点灯部の視認性が悪化している様子が再現された。シミュレーション画像では自車・信号機・太陽との相対位置関係を調整した画像を任意に生成可能なため、より詳細にパラメータを振った検証への活用が期待できる。

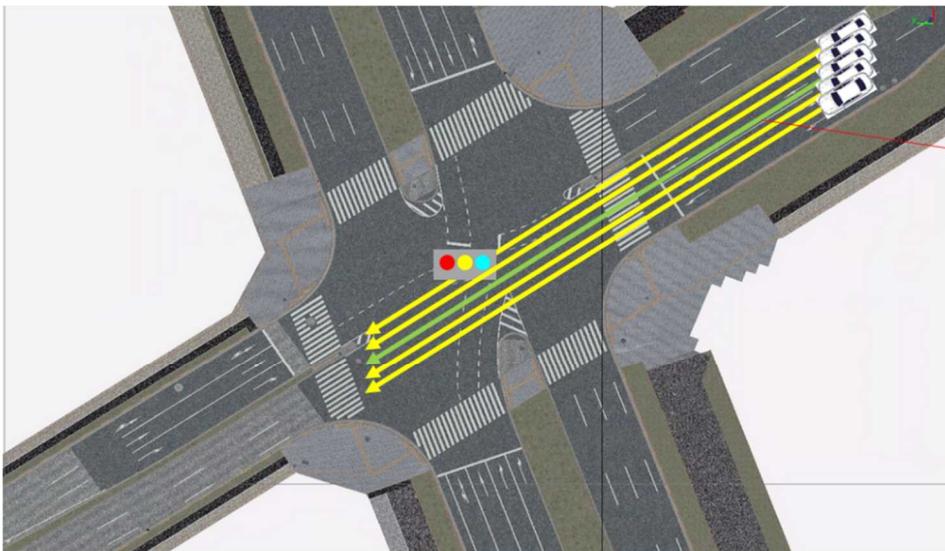
以上より、2021年度はシミュレーションと連携した環境構築や基本的な条件での評価・検証を実施した。今後はシミュレーション可能なシーンの拡張に伴いシミュレーション画像の生成を継続的に行いながら評価を進める予定である。



信号機が逆光になる経路のシナリオを作成

-  自車両：ビル反射光と信号機が重なる走行経路を設定
  -  信号機：青で1パターン
- 太陽：N35.62° E139.77の2020/11/25 11:00の位置

(a) ビル反射光の検証におけるシミュレーションシナリオ  
(東京テレポート駅前交差点)



信号機が逆光になる経路

-  自車両：青海一丁目交差点を東方向から西方向に走行する経路に変動を加えたシナリオを作成
  -  信号機：青で1パターン
- 太陽：N35.62° E139.77の2020/11/25 15:00の位置

(b) 逆光時の検証におけるシミュレーションシナリオ  
(青海一丁目交差点)

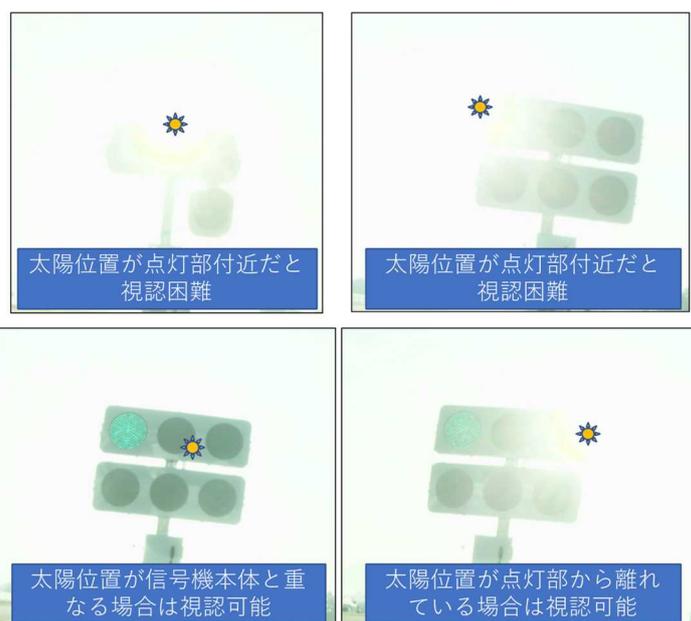
図 2.1.①-11 太陽光の影響に関するシミュレーション例



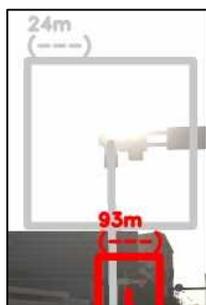
(a) 実画像

(b) シミュレーション画像

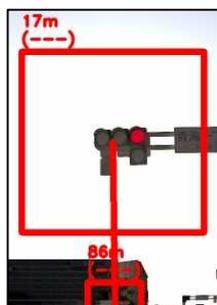
図 2.1.①-12 ビル反射光のシミュレーションに関する検証例



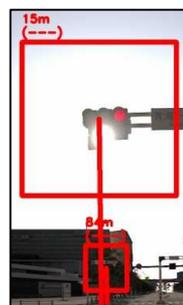
(a) 実画像 (2020 年度報告書より)



(b) シミュレーション  
画像 (太陽が点灯部  
付近で視認困難)



(c) シミュレーション  
画像 (太陽が信号機と  
重なり視認可能)



(d) シミュレーション画像  
(太陽位置が点灯部から  
離れて視認可能)

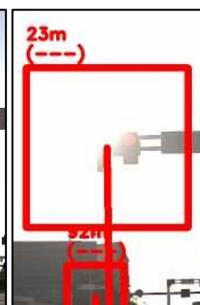


図 2.1.①-13 逆光のシミュレーションに関する検証例

---

・ 交差点進入時の悪条件シーンの走行画像データセット提供

これまでの実証実験において、信号認識における認識不調として逆行，順光，背景同化，隠蔽，夜間などが確認されている．こうした悪条件下で得られる走行データは認識アルゴリズムの研究において有益であるため，研究目的でのデータ提供を目的とした走行映像のデータベース構築を開始した[2][3]．データベース構築に必要な走行データは，2021年5月17日より開始しており，東京臨海副都心地域及び羽田空港周辺の一般道や石川県の金沢市周辺及び小松市内の一般道を対象としている．計測車両には図 2.1.①-14 のように「金沢大学」及び「走行映像収集中」と表示し，研究室ウェブサイト[3]にて案内することで本活動を周知した．



図 2.1.①-14 走行映像データ収集の計測車両

交差点に進入する際の連続データに対して地図情報等を併用して認識するシステムを構築することを可能とするために，画像撮影時の位置情報なども含めて下記のデータを取りまとめた．また，表 2.1.①-4 に本データセットに含まれる画像フレーム数，交差点進入シナリオの回数を示す．本データセットを AD-URBAN Open Image Dataset v1 として整備し，2022年3月末より国内の所属機関における研究活動の目的に限定して提供を開始した[2][4]．

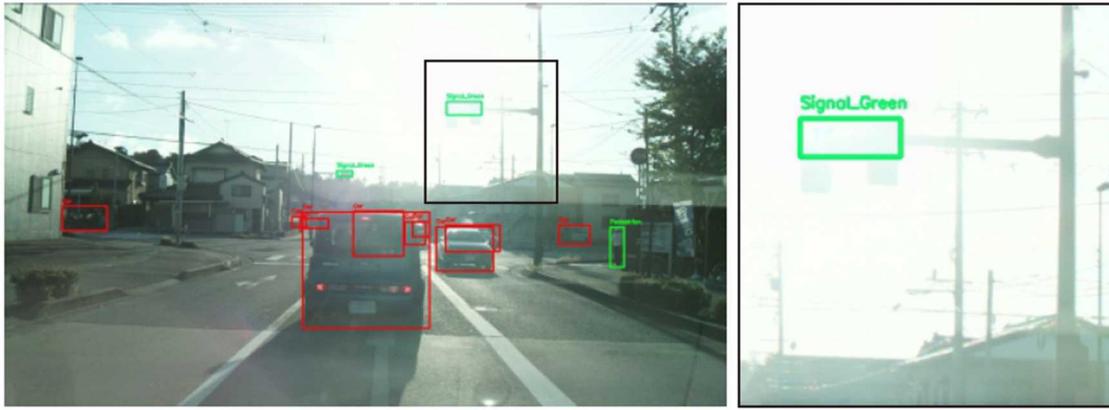
---

- 前方画像（解像度: 1920x1080, 移動量に応じて 1.5~2Hz 程度でラベルを付与. 停車時のフレームは除く）
- 物体矩形枠情報（計 11 クラス）
  - 信号機（赤信号機, 青信号機, 黄信号機）
  - 矢印灯（左矢印灯, 直進矢印灯, 右矢印灯）
  - 交通参加者（車, バス, トラック, 二輪車, 歩行者）
  - 各オブジェクトには隠れレベルを 4 段階で付与
    - ◇ 隠れなし
    - ◇ 部分的隠れ（50%未満の隠れ）
    - ◇ 大部分隠れ（50%以上の隠れ）
    - ◇ 隠れ不明
- 付属情報
  - カメラ内部・外部パラメータ
  - 撮影日時, 車両位置情報（緯度, 経度）等
- 地図情報（本データセットに関連する信号機地図）
  - 信号機位置（2次元位置, 向き）
  - 対象信号機の付属情報（矢印灯の有無等）

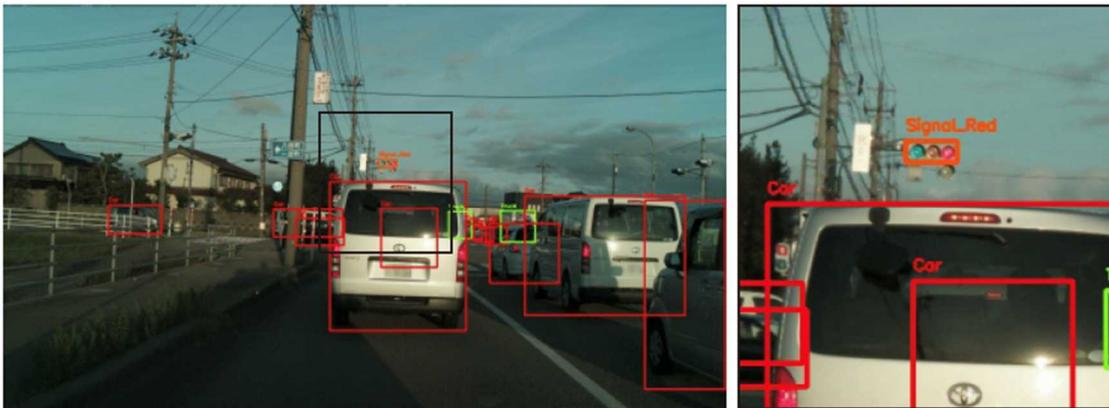
表 2.1.①-4 AD-URBAN Open Image Dataset v1 の画像データ数

走行エリア	フレーム数	シナリオ数
東京臨海部	2,987	78
石川県金沢市周辺	2,010	47
合計	4,997	125

図 2.1.①-15 に本データセットの画像例を示す. 非常に厳しい環境条件のデータを確保することで, 当該研究分野における研究活動への貢献を目指している. ただし, 提供画像に含まれるプライバシーに配慮して画像データ中の顔やナンバープレートにはモザイク処理を行っている.



(a) 逆光時の交差点接近シーン



(b) 順光時の交差点接近シーン

図 2.1.①-15 AD-URBAN Open Image Dataset の画像例

【参考文献】

- [1] K. Yoneda, A. Kuramoto, N. Suganuma, T. Asaka, M. Aldibaja, and R. Yanase, Robust Traffic light and Arrow detection using Digital map with Spatial prior information for Automated driving, Sensors, Vol.20, No.4, [doi:10.3390/s20041181](https://doi.org/10.3390/s20041181), 2020.
- [2] 米陀佳祐, 柳瀬龍, 菅沼直樹, 市街地自動運転の信号機認識における悪条件下の走行画像データセットの構築, ロボティクス・メカトロニクス講演会 2022, 2022年6月発表予定, 2022.
- [3] 金沢大学計測制御研究室, より高度な自動運転車両の研究に役立てるためのデータ収集用実験車両の公道走行を開始します, <http://its.w3.kanazawa-u.ac.jp/information.html>, 2021年5月アクセス.
- [4] 金沢大学高度モビリティ研究所 GitHub ページ, AD-URBAN Open Image Dataset ダウンロードページ, [https://github.com/AdmoreKanazawa/open\\_data](https://github.com/AdmoreKanazawa/open_data), 2022年3月アクセス.

---

---

## ② セマンティックセグメンテーションによる信号認識アルゴリズムの開発

点滅信号機には、無灯火状態と灯火状態がある。無灯火状態および灯火状態は1フレームの画像から判定可能であるが、それらの状態が常時同じなのか、繰り返しているのかは1フレームの画像からは判定できない。そのため、点滅信号機は複数のフレームから判定を行う必要がある。また、これまで本プロジェクトでは点灯状態を対象として、信号機の認識を行ってきたため、点滅信号機を含むデータセットが存在しない。また、世界的に見ても点滅信号機のデータセットは公開されていない。そのため、点滅信号機の認識可能な条件が定かではない。2021年度は、点滅信号機を含むデータセットを構築する。そして、これまでに開発したセマンティックセグメンテーションによる信号機認識アルゴリズムをもとに、複数フレームから信号機の状態判定を行う機能を追加し、点滅信号機認識に発展させる。2021年度は、本点滅信号機認識アルゴリズムを用いて、点滅信号機データセットを評価し、以下の調査を行った。

- ・セマンティックセグメンテーションでの無灯火信号機の認識可能距離の調査
- ・点滅状態を含む信号機の識別精度の調査
- ・信号機の種類による信号機の識別精度の調査

### 信号機認識について

これまでの検証から、セマンティックセグメンテーションを用いた信号機認識は、物体検出を用いた信号機認識よりも、遠方にある小さな信号機や一部が隠れている信号機に対して認識に有効であることを確認した[5]。また、セマンティックセグメンテーションによる信号機の位置検出と、地図情報を組み合わせた信号機認識を行うことで信号機アルゴリズムの高精度化を確認した。2021年度は、これまでの信号機認識アルゴリズムをベースとして、点滅信号機の認識が可能か調査する。その際、セマンティックセグメンテーション手法にHRNet[1]だけでなく、2020年に提案されたSegFormer[2]を用いて、信号機の検出性能を比較する。信号機の状態識別にはResNet50[3]を使用する。

#### ・セマンティックセグメンテーションについて

セマンティックセグメンテーションは画像の画素毎にクラス識別を行う問題であり、近年活発に研究されている。信号機はクラス識別する対象クラスの1つであり、道路や自動車、歩行者などを含めて多クラスの識別を行う。セマンティックセグメンテーション手法の1つであるHRNetおよび新たな手法であるSegFormerについて以下にまとめる。

---

---

## HRNet

セマンティックセグメンテーションでは、入力画像を徐々に縮小して特徴を捉えるエンコーダと特徴を徐々に元画像サイズまで拡大するデコーダ構造を採用している。その際、エンコーダの途中で獲得する高解像度な特徴マップをデコーダに直接与えるスキップ接続させることが多い、しかし HRNet[2]は、図 2.1.②-1 のように高解像度の特徴マップに対してサブネットワークで処理を並列で施し、多様な特徴を捉えている。これにより、高い認識精度を達成している。ここで、図 2.1.②-1 の矢印は畳み込み層 (Convolution 層, 以下 conv. と略) である。下矢印では特徴マップが小さくなる conv. を行い、以降のサブネットワークでも同様に conv. を繰り返し行う。そして、それぞれの特徴マップを結合することで情報を共有している。並列処理を行うサブネットワークは、深い層ほど増えていく。各サブネットワークは、解像度が低下するとチャンネル数が設定したチャンネル幅 (W) だけ倍増していく。共有部分でアップサンプリングを行う際は、 $1 \times 1$  の conv. を行った後、バイリニア補間を行い、チャンネル数とサイズを調整する。また、ダウンサンプリングを行う際にはストライド 2 の  $3 \times 3$  conv. を行い、特徴マップのサイズを縮小する。HRNet の出力部分は、タスクにより異なる構造をしている。セマンティックセグメンテーション用に考案された HRNet V2 では、最終的に得られた特徴マップを高解像度の特徴マップに合わせてアップサンプリングを行い連結する。その後、conv. を行うことで最終的な出力を獲得する。

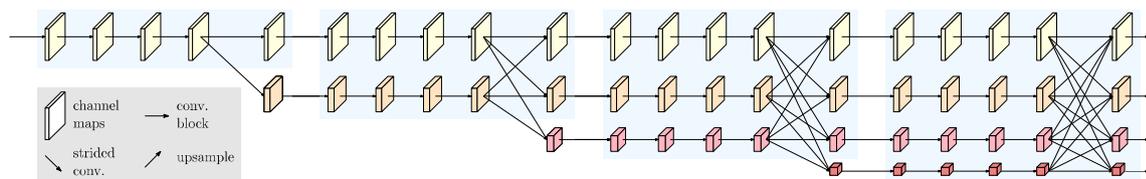


図 2.1.②-1 HRNet の構造

## SegFormer

SegFormer は、自然言語処理分野で高い機械翻訳精度を達成している Transformer をベースとする新たな手法である。SegFormer は、図 2.1.②-2 のように、Transformer のエンコーダ部と MLP デコーダで構成されている。Transformer エンコーダには、階層型 Transformer である Mix Transformer を使用している。Mix Transformer は、入力画像を一定のグリッドサイズに分割する際、Overlap Patch Embedding により、グリッド同士が重なるように分割することで局所的な連続性を保つように入力する。また、Transformer エンコーダ内部の Transformer Block では、Self-

---

---

Attention の計算量を削減するため key, value の次元数を縮小させる Efficient Self Attn を導入して, 特徴マップのスケールを階層ごとに縮小している. そして, 入力画像サイズの変化に対して頑健にするため Mix-FFN では, 式(1)のように全結合層 (MLP) 部分にチャンネルごとに conv.を行う  $3 \times 3$  の Depth Wise Conv. ( $\text{conv}_{3 \times 3}$ ) を導入している. ここで, 活性化関数には GRLU 関数を用いている.

$$x_{out} = MLP \left( GRLU \left( \text{conv}_{3 \times 3} \left( MLP(x_{in}) \right) \right) \right) + x_{in} \quad (2.1.② - 1)$$

出力  $x_{out}$  を再度 Efficient Self-Attn に入力し, 特徴を獲得する. そして, 次の Transformer Block に入力するために, Overlap Patch Merging でグリッド同士が重なるよう特徴マップを分割する. Transformer エンコーダでは, この処理を 4 回繰り返す.

MLP デコーダは, 局所的な特徴と大局的な特徴を獲得するため, 階層ごとの特徴を活用する. 各階層の特徴マップを MLP レイヤに通過させて, 特徴マップを連結する. その際, 特徴マップを Upsample によって拡大する. 連結した特徴マップをチャンネル方向の MLP レイヤに与えることで最終的な出力を獲得する. また, SegFormer は, self-attention を用いているため画像全体の特徴を捉えて認識が可能である. CNN ベースの手法では, 有効受容野が局所部分のみであり, 層が深くなるにつれて周辺の特徴を捉えることができるようになるのに対して, SegFormer では浅い層でも大局的な特徴を捉えることが可能である. そのため, CNN ベースの手法に比べてテクスチャの違いやノイズに頑健である.

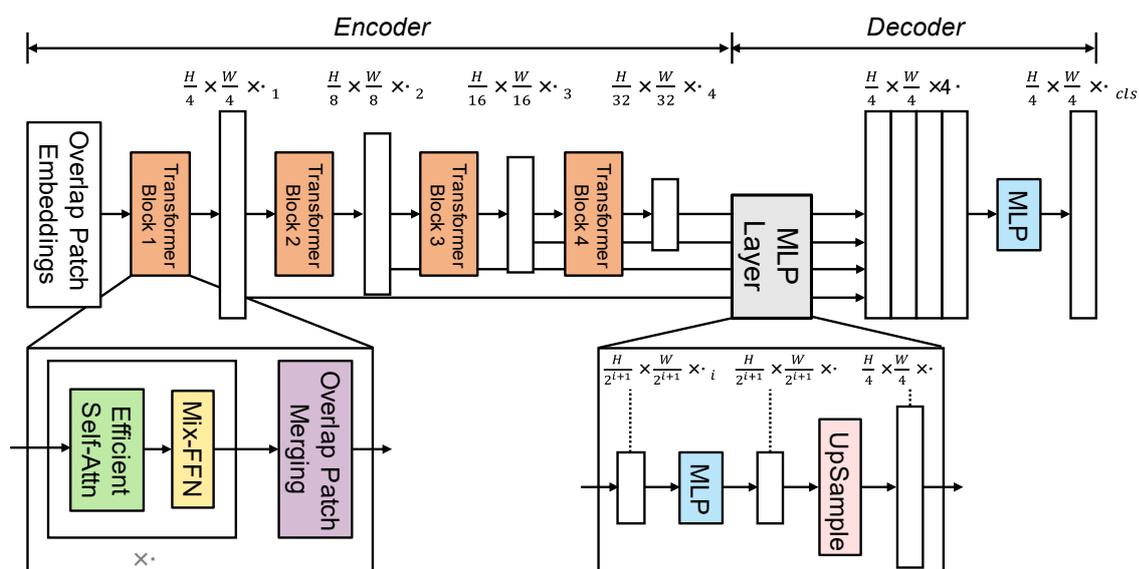


図 2.1.②-2 SegFormer の構造

### ・ 信号機検知アルゴリズム

セマンティックセグメンテーションを用いた信号機検知アルゴリズムは、図 2.1.②-3 のように、セマンティックセグメンテーションにより信号機候補領域を検出し、候補領域が信号機か否かを畳み込みニューラルネットワークで判定する流れである。信号機の検出では、セマンティックセグメンテーションの結果に対して、マスク処理を行い、信号機領域のみを獲得する。獲得した信号機候補領域の外接矩形を切り抜き、一定サイズにリサイズした画像を状態識別器に入力する。そして、赤信号、青信号またはその他の3クラス識別を行う。

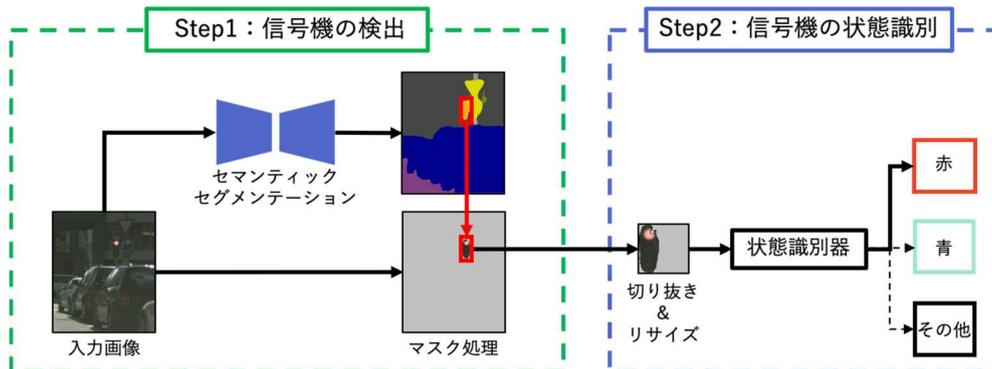


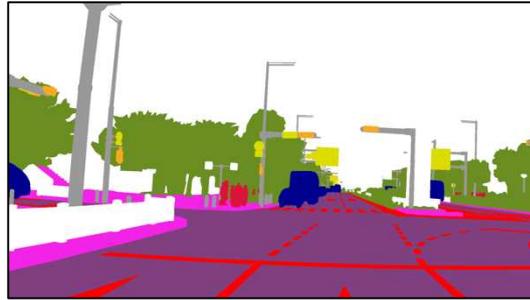
図 2.1.②-3 セマンティックセグメンテーションによる信号機認識の流れ

### ・ 東京臨海部データセット

セマンティックセグメンテーションの学習には、本事業での検討のために収集した東京臨海部データセットを使用する。本データセットの構築のために、580 枚の画像に正解情報をアノテーションした。セマンティックセグメンテーション用のデータの例を図 2.1.②-4 に示す。セマンティックセグメンテーション用データは、昼間、夜間、晴天、雨天といった異なる時間帯や気候時に撮影された車載カメラ画像である。しかし、データセットには、無灯火状態の信号機が含まれていない。そこで、点灯状態の信号機画像を合成し、40 枚の無灯火状態のセグメンテーションデータを作成した。作成したデータを加えた 620 枚を用いてセマンティックセグメンテーションの学習を行った。



(a) 車載カメラ画像



(b) クラス分け画像

図 2.1.②-4 セマンティックセグメンテーションのための学習データ例

#### ・点滅信号機データセット

評価に使用する点滅信号機データセットは、金沢市街で撮影した車載画像である。本データセットは、10Hzで撮影した55シーン、108基の信号機で構成されている。そのうち、63基が点滅信号機、45基が青または赤信号機であり、画像としては13420枚含まれている。また、図 2.1.②-5のように同一の信号機で灯火状態と無灯火状態の信号機があるシーンが含まれる。異なる交差点で撮影したシーンだけでなく、同一の場所で異なる時間帯に撮影したシーンもある。各データには、信号機ごとにラベル情報を付与している。ラベル情報は、信号機の大まかな領域を示したROI、交差点ID、信号機ID、信号機の灯火色、距離である。



(a) 灯火状態



(b) 無灯火状態

図 2.1.②-5 点滅信号機の例

#### ・セマンティックセグメンテーションでの認識可能距離の調査

灯火状態と無灯火状態において、セマンティックセグメンテーションを用いて信号機の位置を検出できる距離を調査する。本調査では、点滅信号機付近の背景の変化ごとにシーンを分け、灯火状態および無灯火状態で検出可能な平均距離を比較する。HRNetを用いた場合に検出可能な平均距離の比較結果を表 2.1.②-1に示す。表 2.1.②-1より、灯火状態での検出可能距離が130m程度である

のに対して、無灯火状態では、110m程度である。シーン別に比較すると、背景が森から空に変化するシーンでは、検出可能距離が他のシーンよりも短くなっている。

SegFormerによる灯火状態および無灯火状態での検出可能な平均距離の比較結果を表 2.1.②-2 に示す。表 2.1.②-2 より、HRNetと比較して数メートル程度灯火状態での検出可能距離が長い。一方、無灯火状態ではHRNetよりも検出可能な平均距離が短くなっている。HRNet, SegFormerともに、無灯火状態では、灯火状態よりも検出可能な平均距離が短くなっている。これらの結果から、無灯火状態の信号機の検出が難しいことがわかる。

背景が森から空に変化するシーンにおけるHRNetおよびSegFormerによる信号機の認識結果例を図 2.1.②-6, 図 2.1.②-7 に示す。図 2.1.②-6 のように点灯状態の場合、背景が森の場合でも信号機の色が目立つため、信号機領域を検出できている。一方、図 2.1.②-7 のように無点灯状態では、目立つ領域がなく、信号機の明るさが比較的暗いため、境界が不明瞭になっている。そのため、信号機の形状を捉えることができず、信号機領域を検出できていない。

表 2.1.②-1 HRNet の検出可能距離 [m]

シーン	最遠距離	検出可能距離 (灯火)	検出可能距離 (無灯火)
背景均一 (建物または空)	142	137	117
背景変化 (森→空)	123	107	67
背景変化 (建物→空)	138	133	102
背景変化 (標識→空)	136	129	112

表 2.1.②-2 SegFormer の認識可能距離

シーン	最遠距離	検出可能距離 (灯火)	検出可能距離 (無灯火)
背景均一 (建物または空)	142	140	111
背景変化 (森→空)	123	111	54
背景変化 (建物→空)	138	136	113
背景変化 (標識→空)	136	131	120

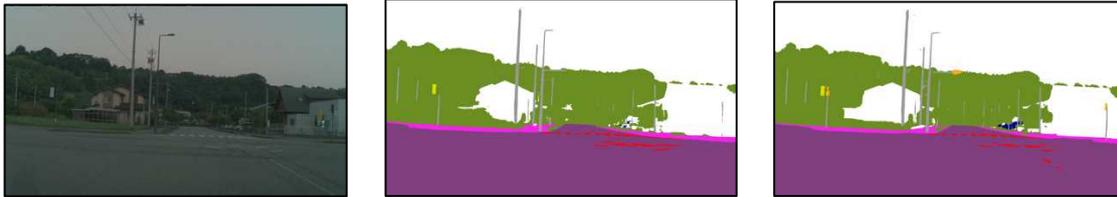


(a) 車載カメラ画像

(b) HRNet

(c) SegFormer

図 2.1.②-6 灯火信号機のセグメンテーション結果



(a) 車載カメラ画像

(b) HRNet

(c) SegFormer

図 2.1.②-7 無灯火信号機のセグメンテーション結果

\*)オレンジ色の領域が信号機の領域

一方で、図 2.1.②-8 のように信号機の背景が空の場合、無灯火状態の信号機でも信号機領域を検出できている。これより、セマンティックセグメンテーションによる信号機の検出では、信号機の形状や点灯している領域があるかどうか、すなわち注目しやすい領域があるかどうかことが重要となる。無灯火状態では、信号機の特徴である灯火部分が存在しないため、形状のみで判断を行う必要がある。しかし、信号機と背景の色が近い場合、信号機の境界部分を識別しにくくなるため、形状を捉えることができず、無灯火信号機の検出が難しくなっている。



(a) 車載カメラ画像

(b) セグメンテーション結果

図 2.1.②-8 背景が空の場合における信号機領域の検出結果例

\*)オレンジ色の領域が信号機の領域

#### ・点滅状態を含む信号機の識別精度調査

セマンティックセグメンテーションによる信号機領域の検出結果を用いて、

ResNet50[3]による信号機の識別を行う。点滅信号は、赤信号の灯火状態と無灯火状態を繰り返している。そこで、一定時間において、赤信号と無灯火状態の出現比率が近い場合を点滅信号機と判定する。また、1つのシーン内には、複数の信号機が同時に写っている。それぞれの信号機を時系列で同一と見做す必要がある。そのために、各フレームで信号機ごとにIDを割り振るよう物体追跡手法を利用する。物体追跡手法には、Deep SORT[4]を用いる。Deep SORTは、カルマンフィルタを使用して物体追跡を行うSORTとオブジェクトの類似性を比較するCNNモデルを併用する手法である。物体追跡手法の場合は地図情報がない状態である。ここでは、物体追跡手法の代わりに地図情報を用いた場合と比較する。地図情報として、本データセット内で付与されているROIを用いる。

物体追跡を用いた場合とROIを用いた場合の認識結果を表2.1.②-3および表2.1.②-4に示す。DeepSORTを用いた場合、赤信号や青信号は正しく認識できていることが確認できる。一方で点滅信号機は、63基中36基を正しく点滅信号機と識別している。

地図情報としてROIを用いた場合では、赤信号と青信号はDeepSORTと同様に正しく認識が行えている。一方で点滅信号は、63基中38基を正しく点滅信号機と識別している。物体追跡を利用した場合、同じ信号機に対して同じIDを割り当てることができないケースが生じて、正しく点滅信号機と判定できないことが多くなっていると考えられる。一方、ROIの場合、同一ROI内に複数の信号機が含まれることがある。これにより、物体追跡と同様に識別が困難な状況がある。

表 2.1.②-3 物体追跡を利用した信号機識別の結果

状態	正解数	不正解数	識別率[%]
青信号	13	0	100.0
赤信号	3	0	100.0
点滅信号	36	27	57.1

表 2.1.②-4 ROIを利用した信号機識別の結果

状態	正解数	不正解数	識別率[%]
青信号	13	0	100.0
赤信号	3	0	100.0
点滅信号	38	25	60.3

Deep SORT による信号機識別結果を図 2.1.②-9 に示す. 図 2.1.②-9 のように複数の信号機が近くにあるシーンでは, 信号機領域をセマンティックセグメンテーションにより検出できていたとしても, 画像上での位置が大きく移動すると誤って別の信号機に ID を割り当てることもある. 図 2.1.②-9 では, 時刻  $t$  において手前の信号機 ID が 87 となっているが, 時刻  $t+1$  では, 奥の信号機 ID が 87, 手前の信号機 ID が 154 となっている. これは, 画像上の座標位置としては, 時刻  $t$  における手前の信号機と時刻  $t+1$  における奥の信号機の位置が近いからである.



(a) 時刻  $t$



(b) 時刻  $t+1$

図 2.1.②-9 信号機 ID が変化する例

地図情報として ROI を用いた信号機識別結果を図 2.1.②-10 に示す. ROI を用いた場合, セマンティックセグメンテーションにより信号機領域を正しく検出できていると同じ信号機に対して同一の ID を割り当てることができている. これは, 信号機を中心として ROI が設定されているため, 位置が大きくずれないからである. 一方で, 図 2.1.②-11 のように, 対象の信号機がセマンティックセグメンテーションで検出できなかった場合, 後ろの信号機に ID が割り当てられてしまい, 点滅状態の信号機を赤信号機と誤識別することがある. これは, ROI の領域が大きいことに起因する.



(a) 時刻  $t$



(b) 時刻  $t+1$

図 2.1.②-10 ROI を使った認識結果



(a) 時刻 t



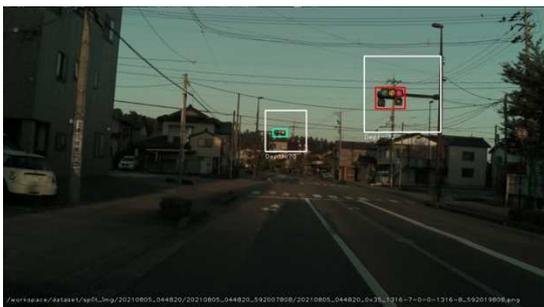
(b) 時刻 t+1

図 2.1.②-11 後ろの信号機を誤識別してしまう場合

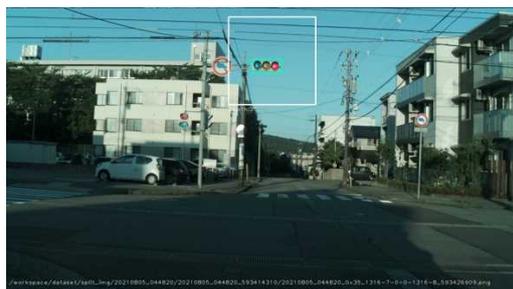
### ・ 信号機の種類による信号機の識別精度の調査

次に信号機の種類による状態識別精度を調査する．物体追跡を利用した信号機識別(表 2.1.②-3)において，不正解であった 27 基の点滅信号基のうち，14 基はランプ式の信号機であった．図 2.1.②-12 および図 2.1.②-13 にランプ式の信号機に対する状態識別結果を示す．図 2.1.②-12 は灯火状態，図 2.1.②-13 は無灯火状態である．図 2.1.②-12 の左側のように信号機の色がはっきりと視認できる場合，2 つの信号機をそれぞれ青信号，赤信号と正しく識別できている．一方，図 2.1.②-12 の右側のように信号機が明るい場合，赤信号にもかかわらず青信号と誤って識別している．

図 2.1.②-13 は図 2.1.②-12 と同一シーンでの無灯火状態の識別結果である．2 つのシーンともに無灯火状態にもかかわらず青信号と識別している．これらのシーンでは無灯火状態であるが，ランプ式の信号機は，灯火領域に各色がわずかに現れているため，赤信号や青信号と識別している．

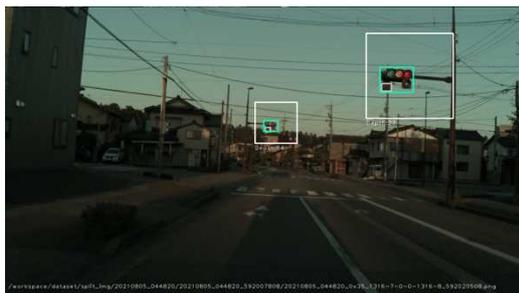


(a) シーン 1



(b) シーン 2

図 2.1.②-12 ランプ式信号機に対する信号機識別結果（灯火状態）



(a) シーン 1



(b) シーン 2

図 2.1.②-13 ランプ式信号機に対する信号機識別結果（無灯火状態）

この問題の解決方法として、学習データの追加が考えられる。信号機識別の学習に用いている東京臨海部データセットは、お台場周辺で撮影した映像をもとに構成されており、ほとんどが LED 式の信号機である。今後、金沢周辺で撮影した灯火状態のランプ式信号機を学習データに追加することを検討する。

#### ・まとめ

2021 年度は、点滅信号機のデータセットを構築し、点滅信号機の識別精度評価した。

信号機を検出するセマンティックセグメンテーションは、無灯火状態の信号機がシーンにより困難であることがわかった。特に、信号機が森などの背景に溶け込むようなシーンでは信号機の境界が曖昧となり、検出が難しくなることが確認できた。

信号機の識別では、物体追跡または ROI 情報により、時系列で信号機に対して ID 付けを行う必要がある。DeepSORT による物体追跡では、自車両の移動により信号機の位置が大きく移動するため、ID 付けが困難となるシーンがあることがわかった。特に、信号機周辺に別の信号機がある場合は、ID 付けを失敗しやすい。一方、地図情報として各信号機の ROI がある場合、信号機の位置が大まかにわかっており、ROI は信号機を中心として設定されているため、位置が大きく移動しにくい。そのため、ID 付けの失敗が少ない。しかしながら、ROI 情報の領域サイズが大きいと複数の信号機が含まれることがあるため、ID 付けを失敗するケースもある。信号機の識別においては正しく ID 付けができることが重要となる。そのため、距離情報などを併用することが精度向上には不可欠であると考えられる。

信号機の種類による識別精度を調査した結果、ランプ式の信号機の識別が困難であることを確認した。ランプ式の信号機は無灯火状態でも灯火領域に色味が現れている。そのため、青信号または赤信号に誤識別するケースがある。識

---

---

別精度の向上に向けては、無灯火状態のランプ式信号機のデータを追加することが必要であると考える。

**【参考文献】**

- [1] J. Wang et al., “Deep High-Resolution Representation Learning for Visual Recognition” , CVPR, 2019.
- [2] E. Xie et al. “SegFormer: Simple and Efficient Design for Semantic Segmentation with Transformers” , NeurIPS, 2021.
- [3] K. He et al., “Deep Residual Learning for Image Recognition” , CVPR, 2016.
- [4] N. Wojke et al., “Simple Online and Realtime Tracking with a Deep Association Metric” . ICIIP, 2017.
- [5] S. Masaki, et al., “Distant Traffic Light Recognition Using Semantic Segmentation” , Transportation Research Record, Vol. 2675, No. 11, pp. 97-103, 2021.

## 2.2.b. 「遠距離の物体を検知するために必要となる AI 技術の開発」

### ① 遠距離向け車載カメラの選定・検知アルゴリズム開発

遠距離の物体に対する自動運転自動車の認識性能を評価するためには、大規模なデータセットを用意する必要がある。一方、テストコースや実際の道路などで得られるデータセットは現実的なシーンであるものの、さまざまな条件下で遠距離の物体を含むデータを十分に確保するのが困難といった課題がある。そこで、SIP 他事業（DIVP プロジェクト）で構築しているシミュレーション環境を活用して、現実的なシーンを網羅した遠距離に物体が存在するデータを生成し、学習および評価に活用する。2021 年度は、シミュレーション環境と現実環境で撮影したデータに対する相違を明らかにし、現実的なデータを生成できるシミュレーション環境を構築する。そして、認識性能を評価するためのデータセットを構築するための条件を決定する。

#### ・実環境とシミュレーション環境のデータセット

自動車分野における AI 活用の研究は盛んに行われており、車載カメラや LiDAR で取得されたデータセットが複数一般公開されている。シミュレーション環境と現実環境で撮影したデータに対する相違を明らかにするために、まず公開データセットを用いた事前調査を行う。表 2.2.①-1 に示すように、実環境データは Waymo や Audi(A2D2)などから公開されている。一方で対応するシミュレーションデータは用意されていない。図 2.2.①-1 のように、Cityscapes は、シミュレーションデータとして、SynScapes が公開されているが、実環境データとシミュレーションデータが一致せず、再現性がない。図 2.2.①-2 のように、KITTI は、シミュレーションデータとして VirtualKITTI が公開されており、実環境データとシミュレーションデータが一致し、再現性がある。

表 2.2.①-1 データセット詳細

実環境データ	シミュレーションデータ	シーンの一致性
Waymo Open datasets[1]	-	-
ApolloScape[2]	-	-
A2D2[3]	-	-
BDD100k[4]	-	-
CityScapes[5]	SynScapes[7]	再現性無し
KITTI[6]	VirtualKITTI[8]	再現性有り
KITTI	VirtualKITTI2[9]	再現性有り



(a)CityScapes

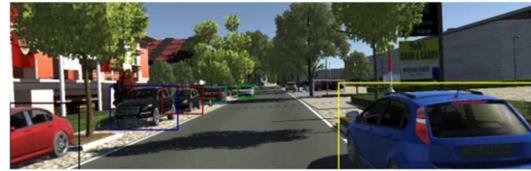


(b)SynScapes

図 2.2.①-1 Cityscapes と Synscapes の例



(a)KITTI



(b)Virtual KITTI

図 2.2.①-2 実環境とシミュレーション環境が存在するデータセット

KITTI には、シミュレーションデータを高画質化した VirtualKITTI2 も公開されている。ここでは、実環境データに KITTI、シミュレーションデータに VirtualKITTI および VirtualKITTI2 を用いて、物体検出の評価を行い、精度の相違となる原因を調査する。

#### ・KITTI データセットでの物体検出精度の一致性検証

物体検出による精度の一致性を検証するために、距離別の検出精度を比較する。本評価を行うにあたり、2 点ほど問題がある。1 点目は、利用するデータセットである KITTI には画像全体に対して距離の真値が付与されているが、物体ごとに距離の真値が付与されていない点である。そこで、図 2.2.①-3 に示すように、画像に対して Mask R-CNN[10]を用いて物体領域の抽出を行う。そして、KITTI の距離真値と照合し、物体ごとに距離値を設定した。2 点目の問題は、実環境データである KITTI とシミュレーションデータである VirtualKITTI および VirtualKITTI2 間で、一部一致しない物体が存在する点である。一致しない物体については、目視で確認を行い、手動で評価対象から排除し、評価を行った。

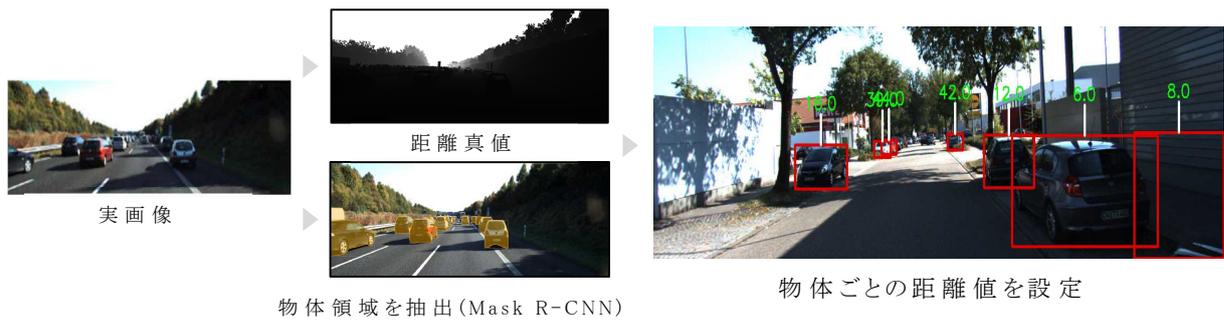


図 2.2.①-3 物体ごとの距離アノテーション付与アルゴリズム

表 2.2.①-2 距離ごとの物体数

距離	KITTI	VirtualKITTI
0m~10m	132	128
10m~20m	294	244
20m~30m	305	272
30m~40m	244	266
40m~50m	137	196
50m~60m	94	106
60m~70m	48	79

表 2.2.①-2 に距離ごとの物体数を示す。シミュレータでの描画制限や、オクルージョンの関係で物体が消失した影響で、両環境で物体数が完全一致はしていない。

KITTI, VirtualKITTI および VirtualKITTI2 データセットにおける距離別の物体検出精度の比較実験を行う。物体検出モデルには、一般的な物体検出モデルの Faster R-CNN[11], 最新の物体検出モデルの Pyramid Vision Transformer (PVT)[12]を用いる。距離別の物体検出精度を図 2.2.①-4 および図 2.2.①-5 に示す。これらの結果より、0m から 50m までの近距離物体では、実環境と VirtualKITTI2 は同程度の検出精度となっている。VirtualKITTI は、実環境および VirtualKITTI2 よりも検出精度が低くなっている。VirtualKITTI2 は、VirtualKITTI よりも高画質であり、実環境に近い映像になっていると言える。

一方、50m から 80m の遠距離物体では、実環境よりも VirtualKITTI2 の方が高精度になっている。図 2.2.①-6 に、遠距離の物体に対して検出精度が一致しない結果例を示す。ここで、赤色の枠は正しく検出した結果、青色の枠は未検出の物体を示している。

これらの結果より、近距離時では物体の見え方、テクスチャの再現性が実環境とシミュレーション環境で大きな相違はなく、一致性が高いと言える。しかしながら、遠距離の物体に対して、シミュレーション環境では物体の輪郭などが明瞭に表現されすぎており、実環境で生じる遠距離物体に対するノイズの再現性が不十分で、一致性が低い。

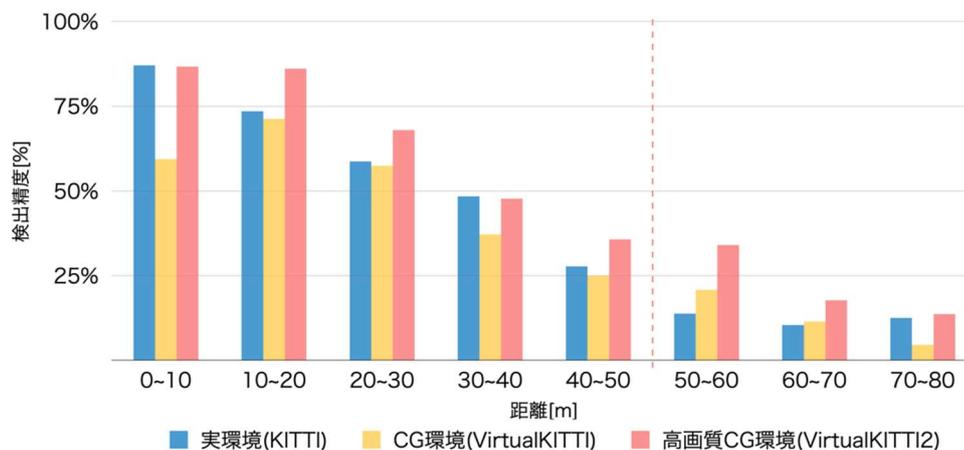


図 2.2.①-4 Faster R-CNN による距離別の検出精度

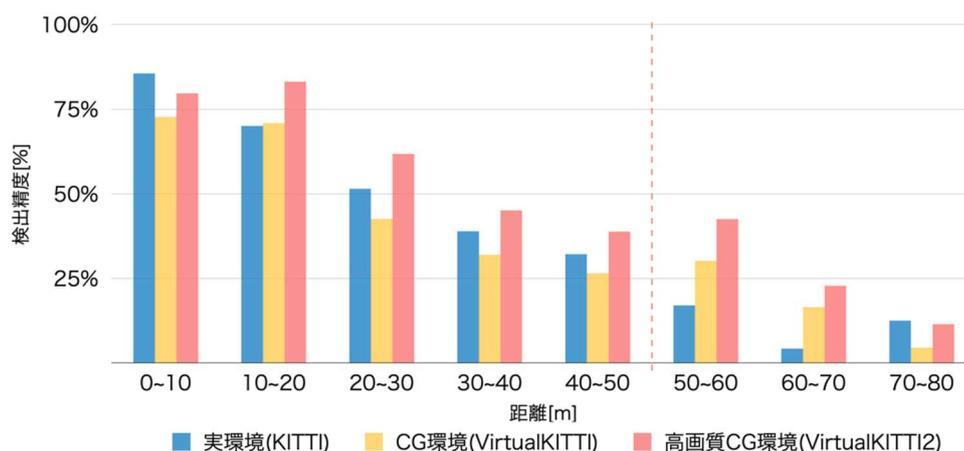
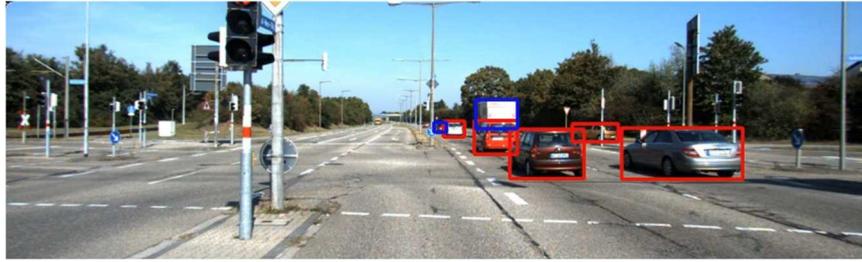
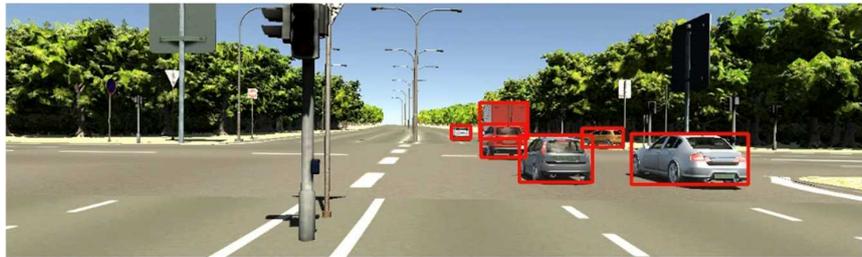


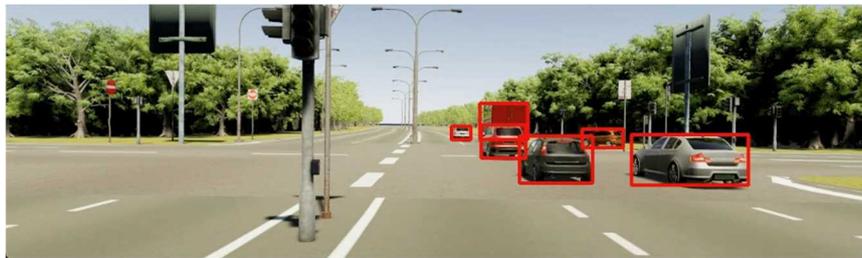
図 2.2.①-5 PVT による距離別の検出精度



(a) KITTI



(b) Virtual KITTI



(c) Virtual KITTI2

図 2.2.①-6 遠方の物体の再現性が低い検出例

赤:検出 青:未検出(IoU>=0.5)

図 2.2.①-7 に、遠方の物体に対して、検出精度が高くなるシーンと検出対象となる車両の拡大図を示す。実環境の KITTI は、車両の輪郭付近の色が曖昧で偽色が発生している。一方で、Virtual KITTI および Virtual KITTI2 は、車両の輪郭ははっきりとしており、実環境で生じる偽色が発生していない。Virtual KITTI および Virtual KITTI2 は、CG をレンダリングするソフトウェア(Unity)を利用しており、高品質な映像を生成できる。そのため、色の再現性は高いものの、実環境をカメラで撮影した際に生じる現象までは再現できていない。これが、実環境とシミュレーション環境データの差異になっていると考えられる。



(a)KITTI



(b) Virtual KITTI



(c)Virtual KITTI2

図 2.2.①-7 検出精度が高くなるシーンと車両の拡大図

#### ・DIVP シミュレーションを用いたデータセット作成

SIP 他事業 (DIVP プロジェクト) で構築しているシミュレーション環境は、実世界の反射特性、カメラパラメータが再現されている。そのため、KITTI のような公開データセットよりも実世界に近いデータを生成することが期待できる。さらに、本シミュレーション環境を活用することで、同一シーンにおいて異なる天候や時間帯のデータも生成できるため、さまざまな条件を網羅した遠距離に物体が存在するシーンが再現できる。本シミュレーションにより生成したデータと実環境との差異を調査するために、実世界の東京臨海部を撮影し、DIVP シミュレータで再現したデータセットを作成した。本データセットは日本科学未来館前を走行した実環境のデータを再現しており、同日に 6 回走行し、走行経路が異なるシーンを含んでいる。図 2.2.①-8(a)は、東京臨海部の実環境のデータ、図 2.2.①-8(b)は、DIVP シミュレータで再現した画像である。

また、生成する天候や太陽の位置を変更して異なる時刻のデータを再現した画像を図 2.2.①-9 に示す。



(a)実環境

(b)シミュレーション環境

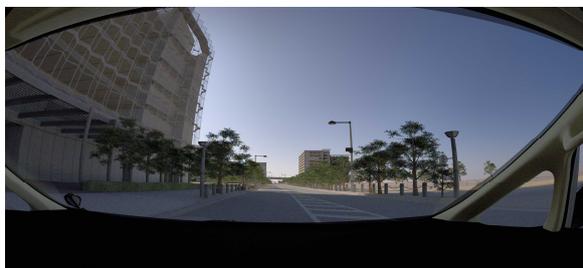
図 2.2.①-8 DIVP シミュレータによる東京臨海部の再現シーン例



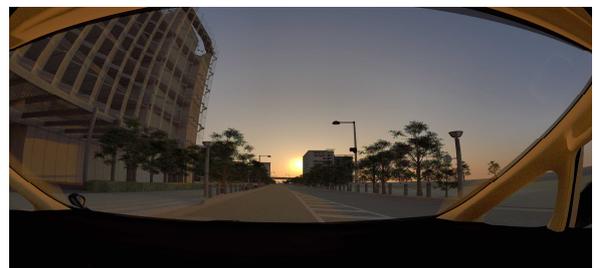
(a)天候：雨



(b)天候：曇り



(a)時刻：13 時



(b)時刻：16 時

図 2.2.①-9 DIVP シミュレータによる東京臨海部の再現シーン例

#### ・DIVP シミュレーション環境の再現性の調査

DIVP シミュレーション環境を活用して、再現した東京臨海部のデータについて、実環境とシミュレーション環境での物体検出の差異を調査する。図 2.2.①-10 に、各環境における物体検出による精度比較を示す。実環境では、遠距離になるに従い、検出精度が低下している。シミュレーション環境のデータについても同様に遠距離になるに従い、検出精度が低下している。公開データセットである KITTI では、遠距離は実環境よりもシミュレーション環境のデータに対して精度が高くなるという不一致が生じていたが、

DIVP シミュレーション環境のデータでは実環境と一致する傾向である。

一方で、シミュレーション環境のデータは実環境のデータよりも検出精度の低下がやや大きく、検出精度低下の傾向に差異が見られる。そこで、シーンごとに定量評価する。図 2.2.①-11 に影の影響が少ないシーンでの距離別精度比較結果を示す。これより、実環境と類似する精度低下の傾向であることがわかる。一方、影の影響が大きいシーンでは、図 2.2.①-12 に示すように、距離別の検出精度の傾向が実環境とシミュレーション環境で大きく異なることがわかる。

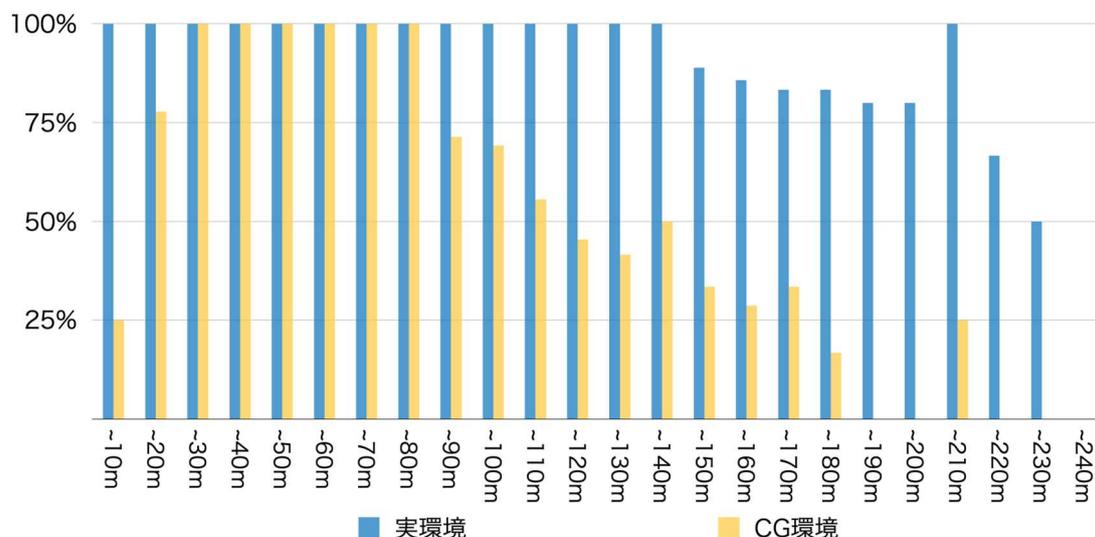


図 2.2.①-10 距離別の検出精度

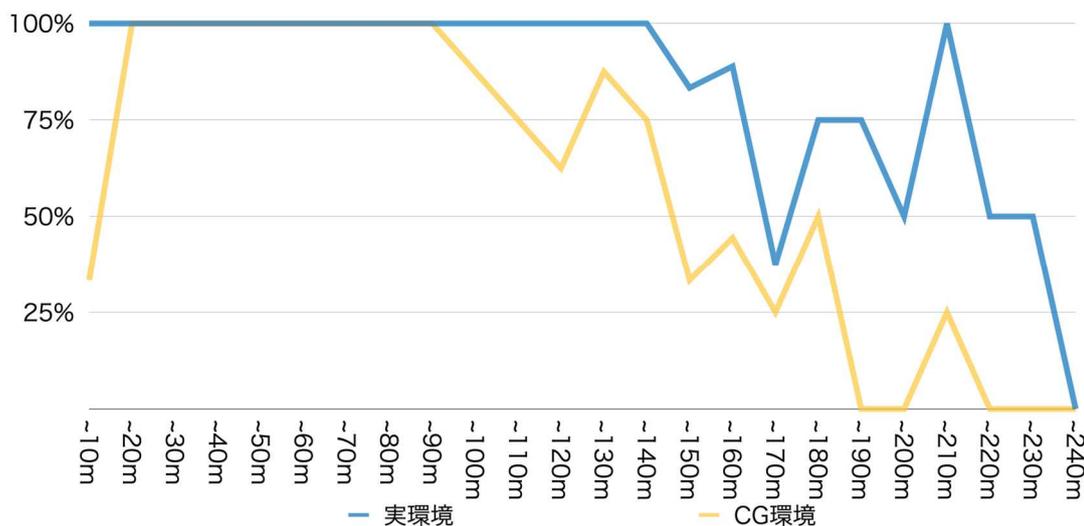


図 2.2.①-11 影の影響が少ないシーンでの距離別検出精度

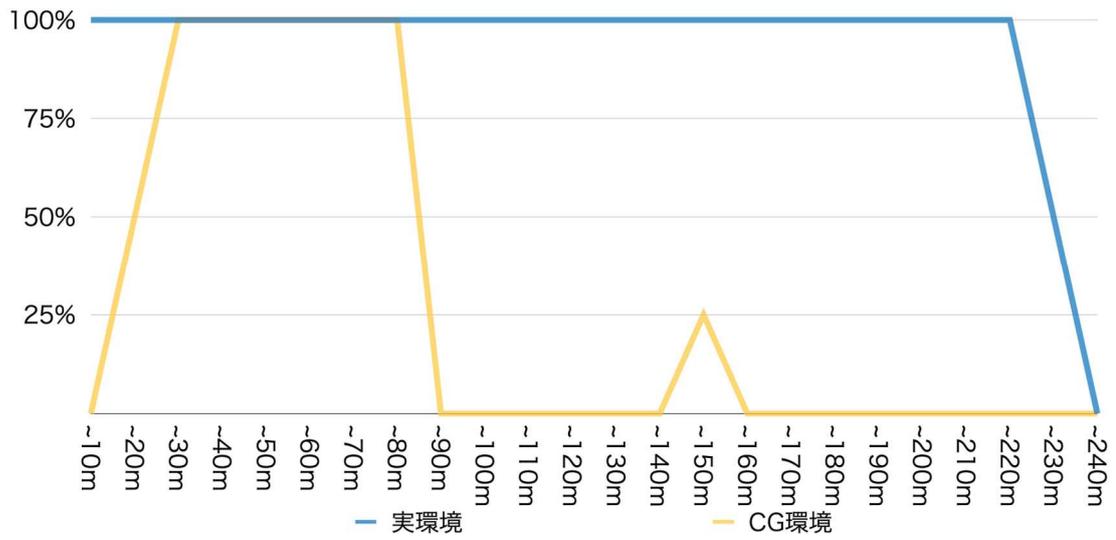


図 2.2.①-12 影の影響が大きいシーンでの距離別検出精度

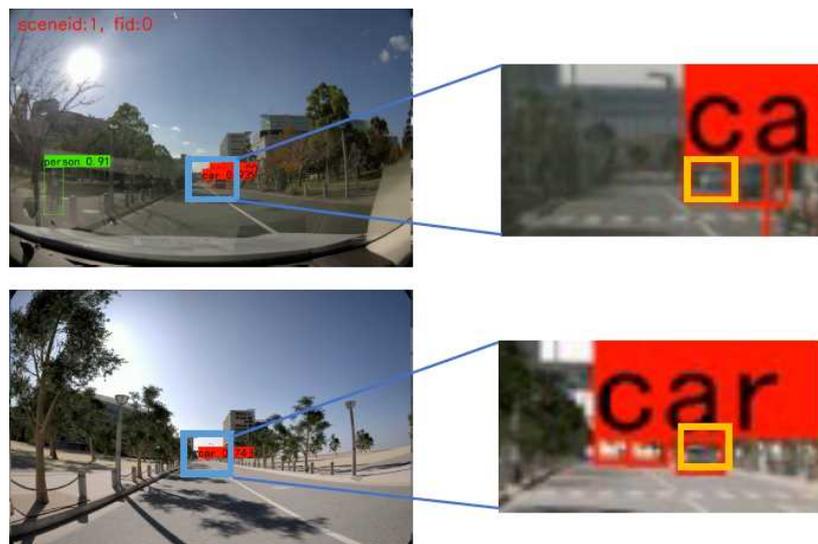


図 2.2.①-13 影の影響が少ないシーンでの検出結果例

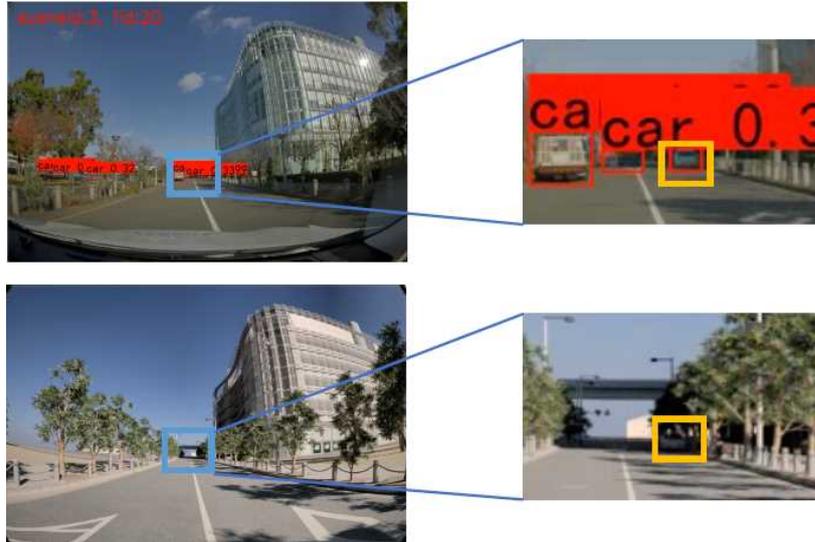


図 2.2.①-14 影の影響が大きいシーンでの検出結果例

図 2.2.①-13 に影の影響が少ないシーンにおける遠方物体検出結果を示す．これより，黄色枠で囲んだ 150m 程度遠方の車両を検出できていることがわかる．一方で，影の影響が大きいシーンにおける遠方物体検出結果例を図 2.2.①-14 に示す．このシーンでは，黄色枠で囲んだ 150m 程度遠方の車両を検出できていない．図 10 のシーンにおいて検出対象としている車両の領域を拡大した画像を図 2.2.①-15 に示す．これより，シミュレーション環境のデータは実環境よりも影が濃くかかっており，実環境のデータと大きな違いが見られる．



図 2.2.①-15 影の影響が大きいシーンにおける車両の拡大図

DIVP シミュレーション環境は、Raw データからの現像処理を行っており，公開データセットに比べ，リアルな偽色の再現，実環境と同様の色目，実環境と同様の輪郭の滑らかさを再現できている．そのため，遠方物体に対して，精度が低下する傾向も正しく再現できている．一方で，影が濃くでるシーンなど，一部で再現性が十分でないシーンもあることがわかった．今後，DIVP とさらに連携して本現象の分析調査を実施する．

---

---

## ・まとめ

2021年度は、シミュレーション環境と現実環境で撮影したデータに対する相違を明らかにするために、公開データセットとDIVP事業のシミュレーション環境で生成したデータセットを対象に調査を行った。その結果、公開データセットで用いているUnityのような高画質なCGレンダリングエンジンでは、色の表現を再現しており、実環境のデータで生じる偽色まで再現できていない。そのため、遠方物体に対して過渡に検出できてしまう傾向がある。これより、画像として高品質にすることが正しいとは限らないことがわかった。一方、DIVP事業のシミュレーション環境のように、反射特性を考慮して画像を現像する場合は、偽色の再現まで可能であり、実環境と同様に遠方物体に対して検出精度が低下する傾向を再現できている。これより、実環境とシミュレーション環境での差異の1つとして、偽色の再現性があることがわかった。DIVP事業のシミュレーション環境は、現実的なデータを生成できる環境であるといえる。

一方、影などにより物体が暗く写るシーンでは、再現性がやや低下し、認識性能も低下する。今後、この原因を調査し、天候や時間帯を条件としてデータセットを構築することを検討する。

## 【参考文献】

- [1] P. Sun et al., “Scalability in Perception for Autonomous Driving: Waymo Open Dataset”, CVPR, 2020.
  - [2] M. Liao, et al., “DVI: Depth Guided Video Inpainting for Autonomous Driving”, ECCV, 2020.
  - [3] J. Geyer, et al., “A2D2: Audi Autonomous Driving Dataset”, arXiv, 2020.
  - [4] F. Yu, et al., “A2D2: Audi Autonomous Driving Dataset”, CVPR, 2020.
  - [5] M. Cordts, et al., “The Cityscapes Dataset for Semantic Urban Scene Understanding”, CVPR, 2016.
  - [6] A. Geiger, et al., “Are we ready for Autonomous Driving? The KITTI Vision Benchmark Suite”, CVPR, 2012.
  - [7] M. Wrenninge, et al., “Synscapes: A Photorealistic Synthetic Dataset for Street Scene Parsing”, arXiv, 2018.
  - [8] A. Gaidon, et al., “Virtual Worlds as Proxy for Multi-Object Tracking Analysis”, CVPR, 2016.
  - [9] Y. Cabon, et al., “Virtual KITTI 2”, arXiv, 2020.
  - [10] K. He, et al., “Mask R-CNN”, ICCV, 2017.
  - [11] S. Ren, et al., “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks”, NIPS, 2015.
- 
-

---

---

[12] W. Wang, et al., “Pyramid vision transformer: A versatile backbone for dense prediction without convolutions”, ICCV, 2021.

## ② LiDAR およびミリ波レーダに基づく遠方物体認識

自動運転中における車両周辺の交通参加者（自動車，二輪車，歩行者）を確実に検知するため，センサフュージョンによる遠距離に特化した物体認識アルゴリズムを検討する．2020年度までの取り組みでは，3次元LiDARを用いた遠方物体の認識において遠方のスパースさを補うためにカメラ画像とのフュージョンが効果的であることを検証し，デジタル地図を併用して注目領域を限定することでカメラによる認識の遠距離化を実現してきた．このようなLiDAR及びカメラなどによる認識では周辺物体の配置や隠れの程度，天候など環境条件の変化により認識が困難となる．そこで2021年度は，シミュレーションを活用した認識技術の高度化を目指して，シミュレータと連携した環境構築並びにLiDARによる物体認識の一致性を検証する．

自動運転の走行環境の安全性を評価するためのプラットフォームとして，SIP他事業であるDIVP（Driving Intelligence Validation Platform）事業ではカメラやLiDARなどのセンサ情報をシミュレーション可能な環境が開発されている．そこで，環境不調をモデル化したシミュレーション環境として，DIVP事業のシミュレータとの連携をすすめ，LiDARデータの物体認識の評価を行うための環境を構築する．なお，同シミュレータを活用したカメラによる物体認識の一致性評価については2.2.①節を参照されたい．

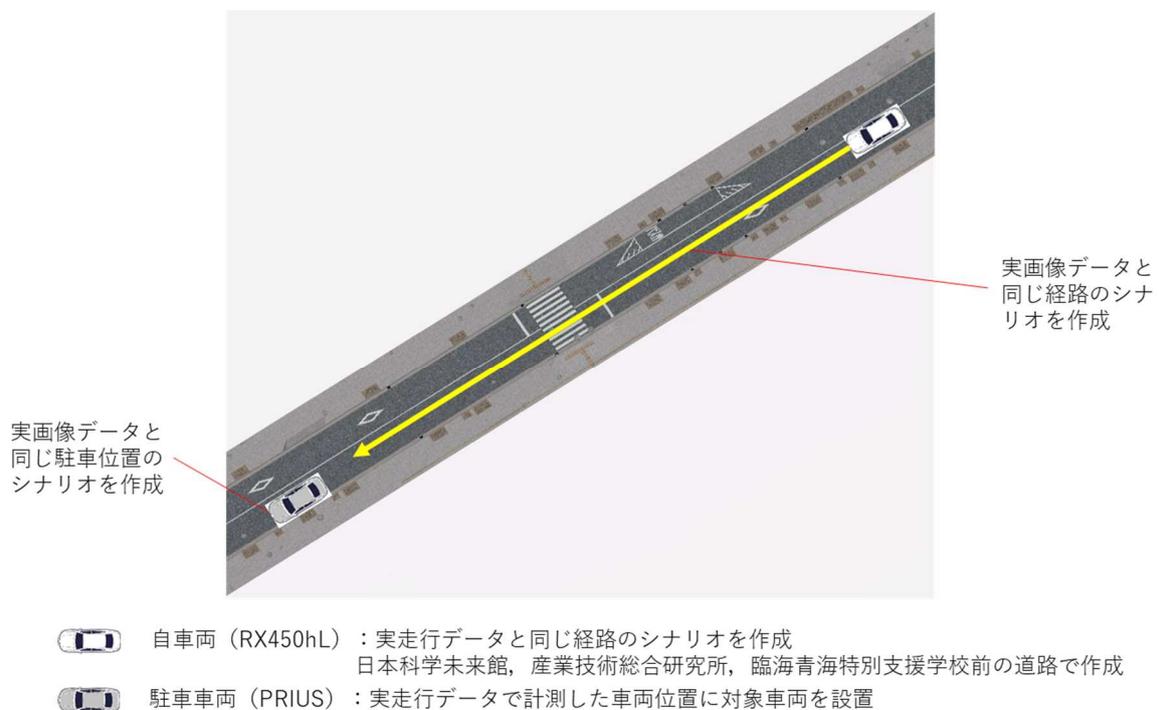
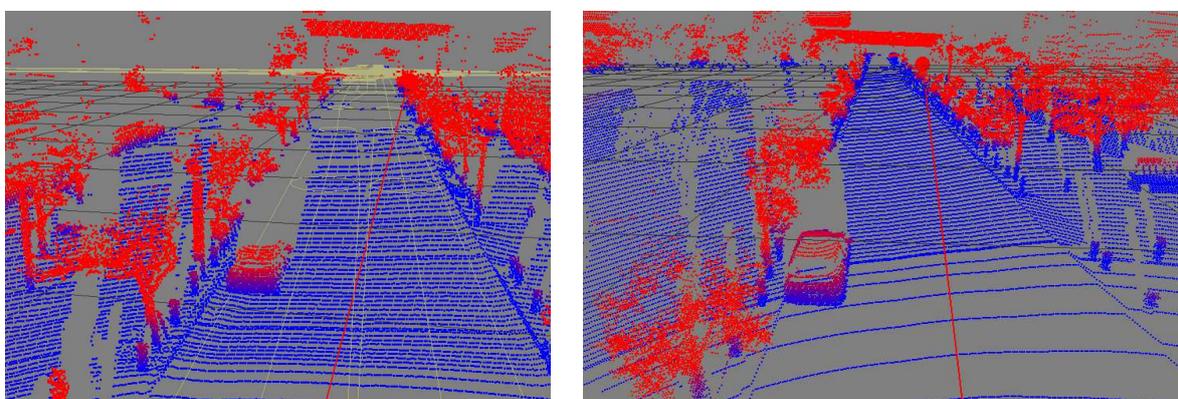


図 2.2.②-1 遠距離物体認識の評価のためのシミュレーションシナリオ  
（日本科学未来館付近）

図 2.2.②-1 にモデル化したシミュレーションシナリオの例を示す。センサデータの一致性を評価するにあたり、モデル化されている車両と同一タイプの車両を実際に駐車させて計測車両が接近するデータを計測した。このときに走行する計測車両及びターゲットの駐車車両の位置情報に用いてシミュレーションのシナリオを生成した。図 2.2.②-1 のような走行シナリオをターゲット車両の配置や走行道路を変更して計 4 パターンの走行シナリオを用意した。なお、シミュレーション時間の都合上、接近する車両の走行データは 1[sec]ごとの位置情報を用いて生成しており、対象車両が自車から 200[m]の範囲にあるフレームを評価対象とする。全シナリオの評価フレーム数は 106 フレームである。実際にモデル化したシミュレーションデータの LiDAR データの様子を図 2.2.②-2 に示す。



(c) 実走行データ (LiDAR)

(d) 生成データ (LiDAR)

図 2.2.②-2 モデル化した走行データ例 (対象物までの距離約 20[m])

対象物体である駐車車両の認識には PointPillars の DNN モデルを利用する [1]。PointPillars は図 2.2.②-3 のように特定範囲の点群から特徴を抽出して範囲内の物体を 3D-Box として認識可能なネットワークである。本評価では、KITTI データセット [2] を用いて学習した交通参加者の検出ネットワークを構築して車両の検出率を評価する。PointPillars では入力可能な範囲を事前に設定して学習を行っており、本学習モデルでは約 70[m]x70[m] の矩形領域内の点群を入力している。本評価では遠距離の物体も評価対象としているため、1 フレームのデータに対して入力範囲を移動させながら複数回の推論処理を適用しており、200[m] までの点群がカバーされるようにしている。

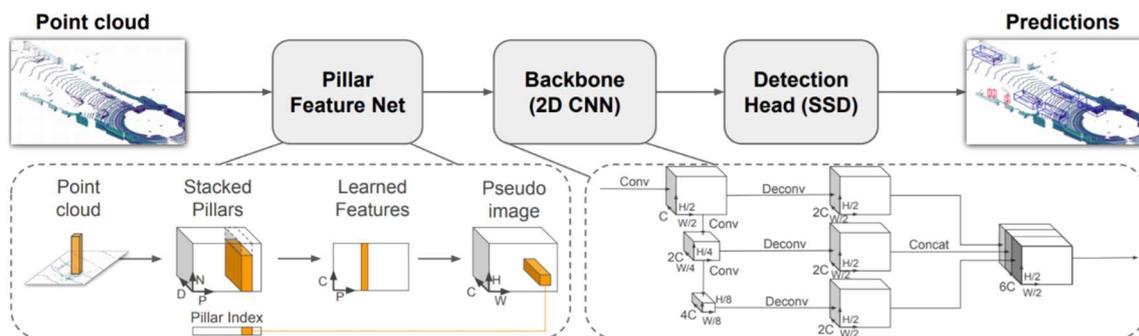


図 2.2.②-3 PointPillars による LiDAR 点群に対する物体認識[1]

評価結果として距離ごとの検出率の傾向を図 2.2.②-4 に示し，特徴的な認識結果の様子を図 2.2.②-5，図 2.2.②-6 及び図 2.2.②-7 に示す．評価フレーム数が全体で 106 フレームしかないため細かい認識率の差異を比較するには十分なデータではないが，全体的には同程度の検出率の傾向が得られた．双方のデータにおいて遠距離になるにつれて点群数が少なくなるため徐々に検出率が低下している傾向が確認できる．今後はシミュレータにより生成されたカメラ画像の認識結果との連携をおこない，センサフュージョンによる評価環境の一致性の検証を進める．

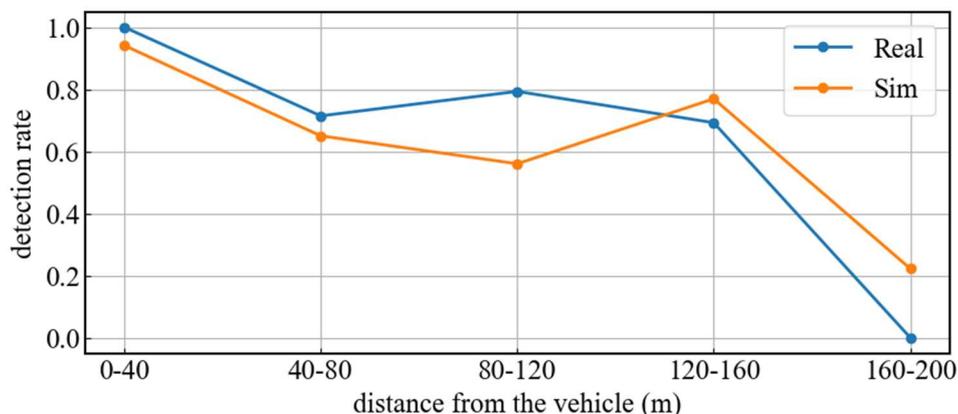


図 2.2.②-4 LiDAR の遠距離物体認識における一致性評価結果

【参考文献】

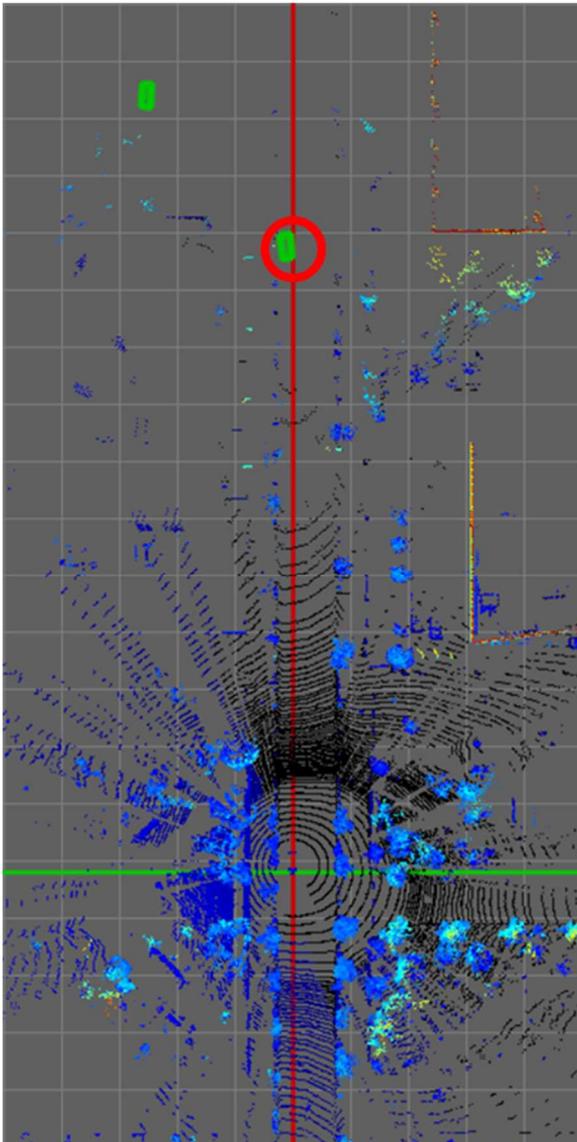
- [1] A.H.Lang, S.Vora, H.Caesar, L.Zhou and J.Yang, PointPillars: Fast Encoder for Object Detection from Point Clouds, International Conference on Computer Vision and Pattern Recognition, pp.12689-12697, 2019.
- [2] A. Geiger and P. Lenz and R. Urtasun, Are we ready for Autonomous Driving? The KITTI Vision Benchmark Suite, Conference on Computer Vision and Pattern Recognition (CVPR), pp.3354-3361, 2012.



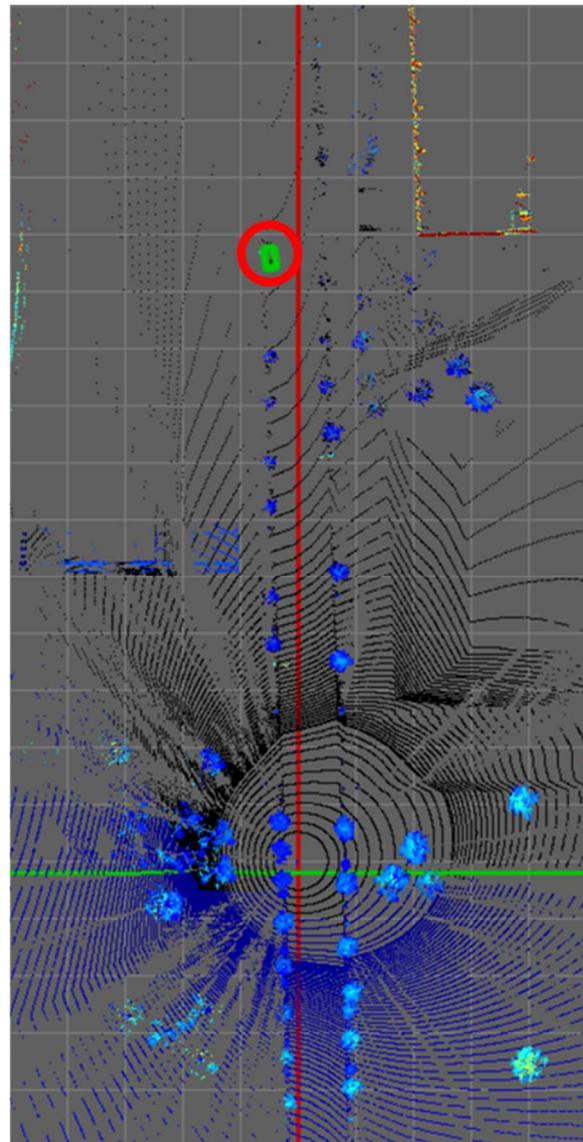
(a) 実走行データ（カメラ画像）



(b) 生成データ（カメラ画像）



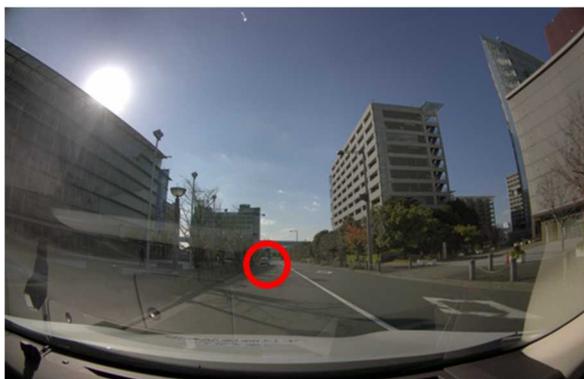
(c) 実走行データ（LiDARデータ）



(d) 生成データ（LiDARデータ）

図 2.2.②-5 評価シナリオの検出例（対象物までの距離：約 110[m]）

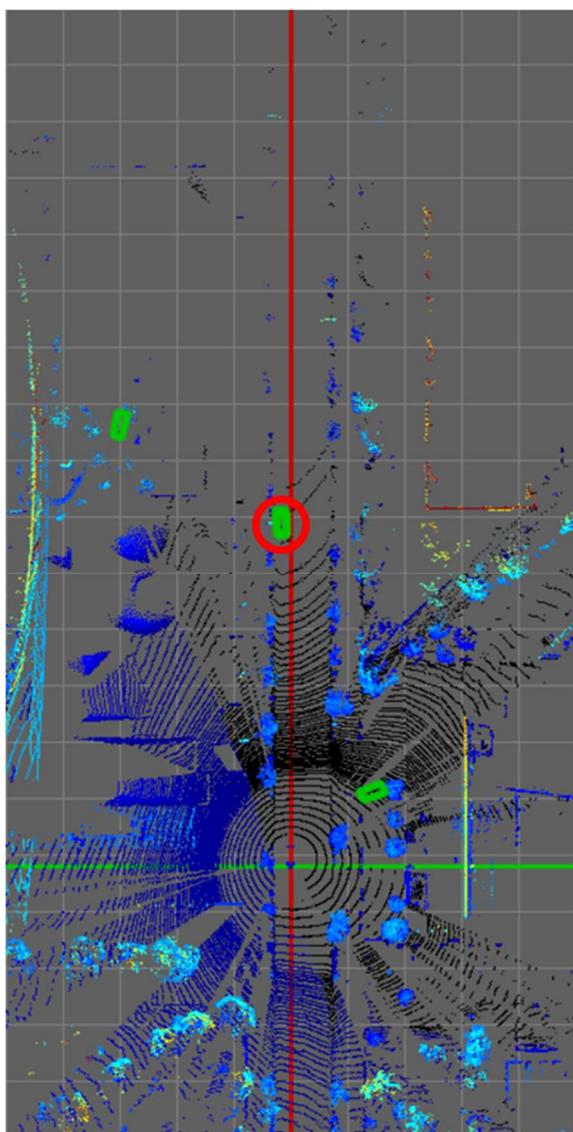
（赤丸：認識対象物，緑矩形：検出物体）



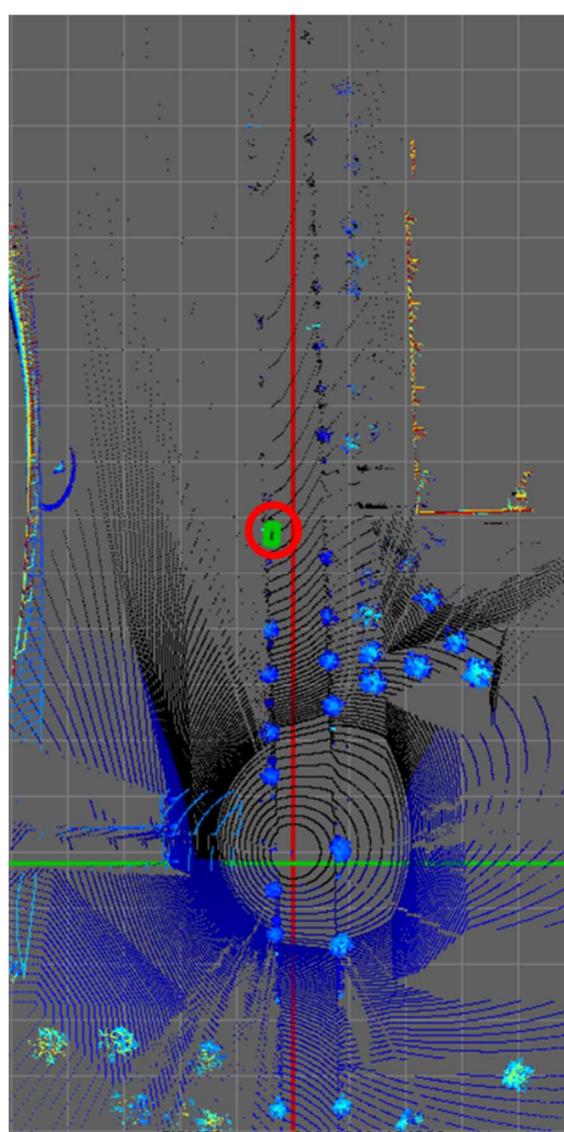
(a) 実走行データ（カメラ画像）



(b) 生成データ（カメラ画像）



(c) 実走行データ（LiDAR データ）



(d) 生成データ（LiDAR データ）

図 2.2.②-6 評価シナリオの検出例（対象物までの距離：約 60[m]）

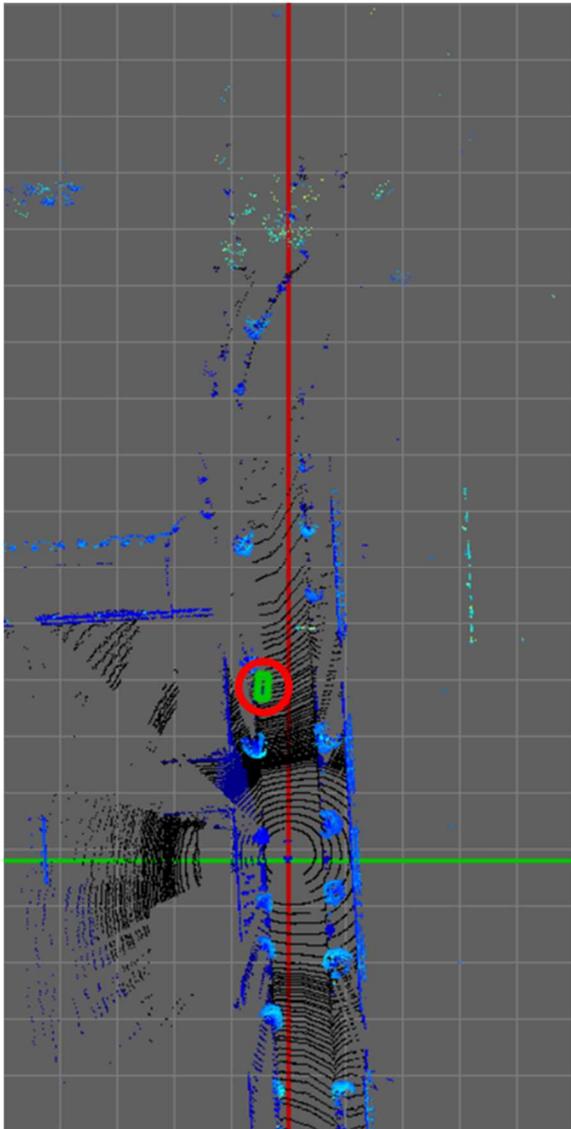
（赤丸：認識対象物，緑矩形：検出物体）



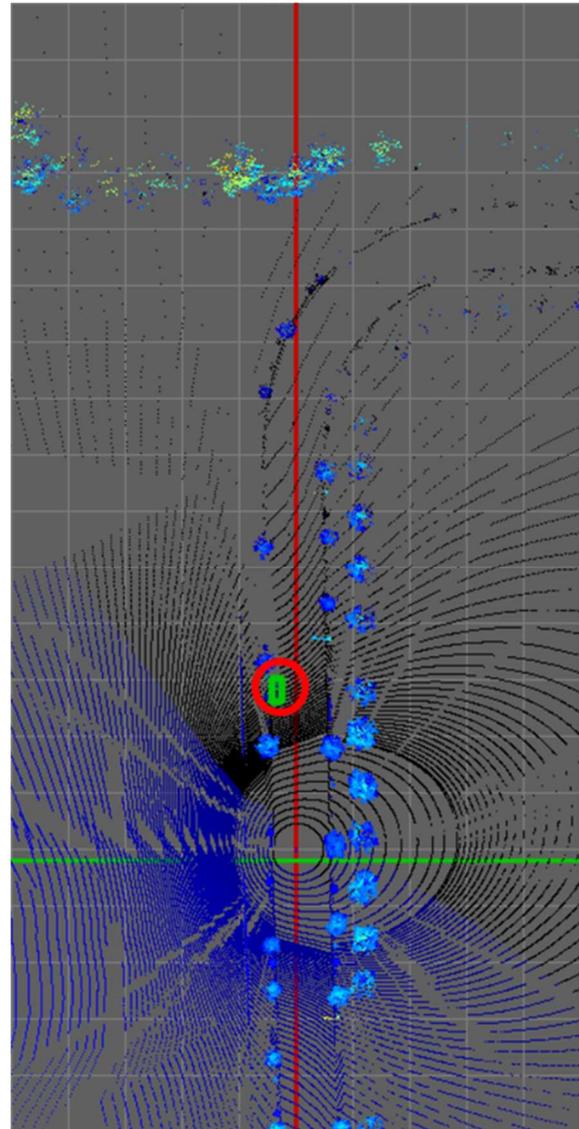
(a) 実走行データ（カメラ画像）



(b) 生成データ（カメラ画像）



(c) 実走行データ（LiDARデータ）



(d) 生成データ（LiDARデータ）

図 2.2.②-7 評価シナリオの検出例（対象物までの距離：約 30[m]）

（赤丸：認識対象物，緑矩形：検出物体）

---

---

## 2.3.c. 「高精度自己位置技術の開発」

### ① GNSS/INS の開発

#### a GNSS/INS における DR 誤差とその改善

自動運転車両や運転支援システムでは、精度と信頼性が高い車両位置が求められる。また、その要求精度は平面誤差 0.3[m]以下が要求されている[1]。ここで、GNSS(Global Navigation Satellite System)には RTK(Real Time Kinematic)-GNSS と呼ばれる測位手法があり、そのうち FIX 解は cm 級の位置推定が可能である[2]。また、FIX 解の信頼性を判定する手法[3]もあるため、FIX 解が得られる場所では要求精度を達成できる可能性が高い。しかし、トンネルや高架下などの環境では GNSS が使用できないため DR(Dead Reckoning)で位置推定する必要がある。一方、DR はジャイロセンサで求めた方位角と車輪速センサから得られる車速の積算で位置推定をするため、走行時間が延びるにつれて位置誤差が大きくなる問題がある。そこで 2021 年度では DR 時の位置推定性能の向上を目的として、DR の誤差の主な要因の明確化と、その主要因に対しての性能改善手法を提案する。

#### b DR 時の誤差要因の解析

DR 時の誤差要因のうち、特に位置推定性能に影響すると考えられるものとして、初期位置、初期方位角、滑り角、ヨーレイト誤差の変動、車輪速が挙げられる(図 2.3.①-1)。本研究ではまず、これらの誤差要因の DR 時の位置推定性能への影響を検証する。そのため、図 2.3.①-1 の誤差要因を高精度なセンサで計測した値を利用し、他は従来手法の値を用いて DR を 10 秒間行い、その結果を真の位置と比較する。ここで、評価用の高精度なセンサとして Applanix 社 POSLV220 を用いる。また、コースは東京都お台場の市街地を利用した。ここで図 2.3.①-2 に、それぞれの誤差要因を高精度センサで補正し、10 秒間 DR した際の横方向誤差の累積度数を示す。図 2.3.①-2 より、10 秒間 DR を行った場合、初期方位角が最も位置推定性能に影響することが確認できる。

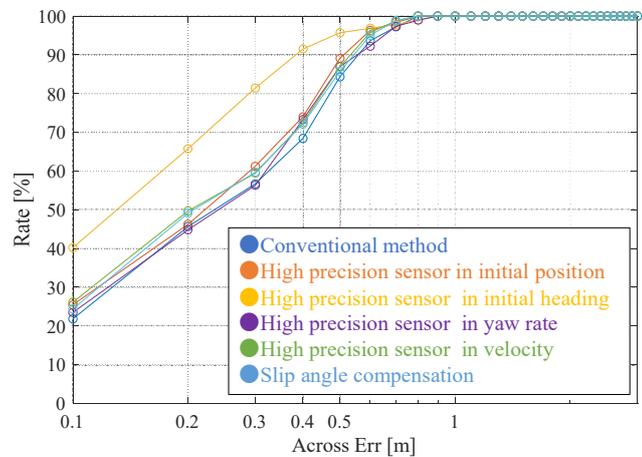
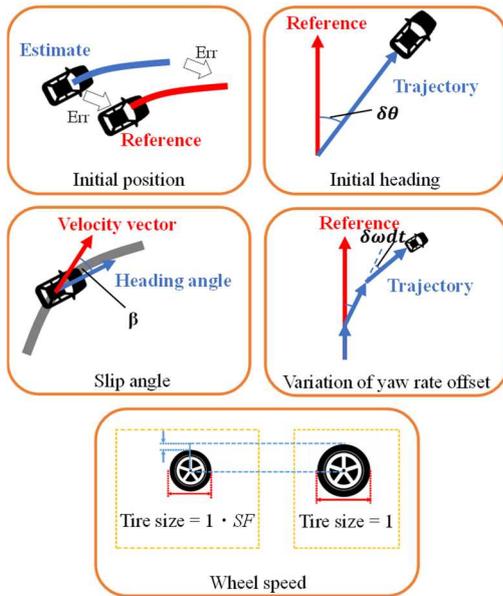


図 2.3.①-1 DR 誤差の要因

図 2.3.①-2 DR 誤差の要因と位置誤差

c 初期方位角探索手法の提案

DR 時の誤差要因の解析により，初期方位角が DR の性能に大きく影響を及ぼすことが確認できた．そこで，初期方位角の性能を向上させることにより，DR の位置推定性能を向上させる手法を提案する．提案手法では，DR 直前の数十秒間の軌跡を FIX 解にフィッティングさせることで，初期方位角を推定し，高精度な方位角を基準に DR を実施することで，位置推定性能を向上させる．この概要を図 2.3.①-3 に示す．

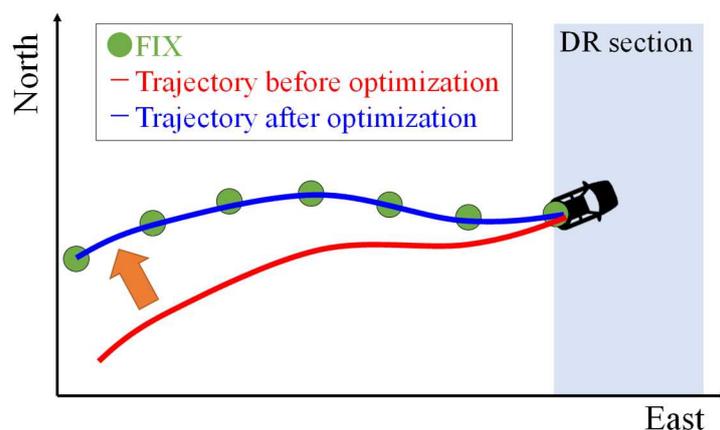


図 2.3.①-3 FIX 解を利用した初期方位角の探索の概要

提案手法ではまず，DR 区間に入る直前で，現在から過去に向かって方位角を推定する．ここで，方位角の推定を式(2.3.①-1)に示す． $\psi_{\text{gyro}}$  は方位角， $\psi_{\text{init}}$  は初期方位角， $\dot{\psi}$ はジャイロセンサのヨーレート値， $\delta\dot{\psi}$ はヨーレート誤差を示す．

$$\psi_{\text{gyro}} = \psi_{\text{init}} + \int_t^{t-k} (\dot{\psi} + \delta\dot{\psi}) dt \quad (2.3.①-1)$$

次に，式(2.3.①-1)で求めた方位角を用いて現在から過去に向かって軌跡を推定する．軌跡の推定を式(2.3.①-2)，式(2.3.①-3)に示す．ここで， $T_e$ は軌跡の東方向座標， $T_n$ は軌跡の北方向座標， $V$ は速度を示す．

$$T_e = \int_t^{t-k} V \cos(\psi_{\text{gyro}}) dt \quad (2.3.①-2)$$

$$T_n = \int_t^{t-k} V \sin(\psi_{\text{gyro}}) dt \quad (2.3.①-3)$$

この時， $\dot{\psi}$ はジャイロセンサの値であること， $V$ は従来手法で高精度に補正できていることを考えると，軌跡の性能に影響を与えるパラメータは $\psi_{\text{init}}$ と $\delta\dot{\psi}$ であり，これらを最適化すれば良いことが分かる．

次に，軌跡を FIX 解にフィッティングさせることで，初期方位角 $\psi_{\text{init}}$ を求める．なお軌跡は相対的な変動量であるため，FIX 解を初期値として与える必要がある(式(2.3.①-4)，式(2.3.①-5))．ここで， $FIX_e$ は軌跡の東方向座標， $FIX_n$ は軌跡の北方向座標である．

$$T_e' = T_e + FIX_e^t \quad (2.3.①-4)$$

$$T_n' = T_n + FIX_n^t \quad (2.3.①-5)$$

その後，式(2.3.①-6)より FIX 解と軌跡の残差平方和を計算し，残差平方和が最小になるような $\psi_{\text{init}}$ と $\delta\dot{\psi}$ を求める(式(2.3.①-7))．最終的に推定した初期方位角 $\psi_{\text{init}}$ を用いて DR を行うことで，DR の位置性能が向上することが期待できる．

$$RSS = \sum (T_e' - FIX_e)^2 + (T_n' - FIX_n)^2 \quad (2.3.①-6)$$

$$C(\psi_{\text{init}}, \delta\dot{\psi}) = \text{argmin}(RSS) \quad (2.3.①-7)$$

#### d 評価試験

評価試験は、東京都お台場の15[km]のコースで行った。図2.3.①-4に評価コースを示す。なお、本試験では将来的な車載グレードに相当するセンサを利用する。具体的にはGNSS受信機にSeptentrio社mosaic-X5を用い、IMUにはアナログデバイス社ADIS16475を用いる。提案手法に使用するFIX解は、CLAS(Centimeter Level Augmentation Service)を使用したPPP-RTKにより測位した値に対し、FIX解の信頼性判定手法で信頼性を判定した値を利用する。また、リファレンスにはApplanix社POSLV220を使用し、従来手法[4]との比較を行う。



図2.3.①-4 FIX解を利用した初期方位角の探索の概要

ここで、図2.3.①-5に提案手法と従来手法で推定した方位角の累積度数による比較を示す。図2.3.①-5の方位角誤差0.15[deg]の達成割合をみると、提案手法により93.2[%]を達成しており、従来手法と比べて3[%]向上していることも確認できる。ここで0.15[deg]に注目したのは、車の平均時速が40[km/h](11.1[m/s])とすると、10秒間DRした際の誤差を0.3[m]以内にしたときの方位角の目標値は $\tan^{-1}(0.3/(11.1 \times 10)) = 0.15[\text{deg}]$ になるためである。

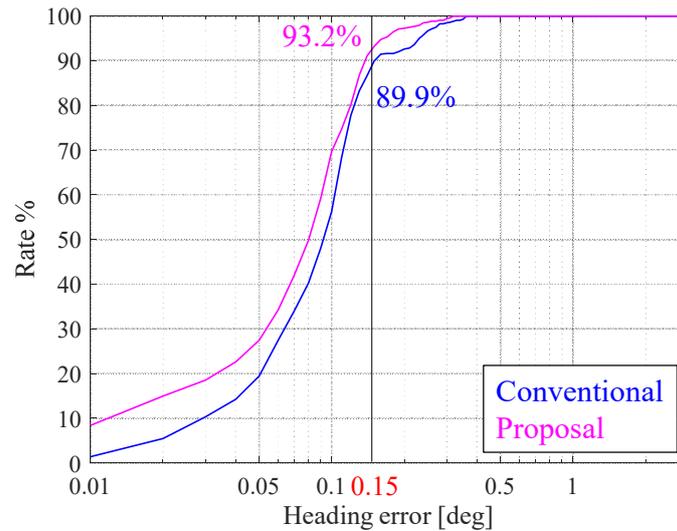


図 2.3.①-5 方位角精度（累積度数）

また，図 2.3.①-6 に提案手法と従来手法で推定した方位角を使用して 10 秒間 DR を行った軌跡の道路直交方向誤差のヒストグラムを示し，図 2.3.①-7 にその累積度数を示す．図 2.3.①-6，図 2.3.①-7 より，提案手法では従来手法に比べて道路直交方向誤差の誤差が小さいことが確認できる．これは，図 2.3.①-5 より，提案手法の方が方位角誤差が小さいときの頻度が高いことが影響していると考えられる．また，図 2.3.①-7 より，誤差 0.3[m]の達成割合に注目すると，提案手法により 87.7[%]を達成しており，従来手法と比べて 13[%]向上していることも確認できる．

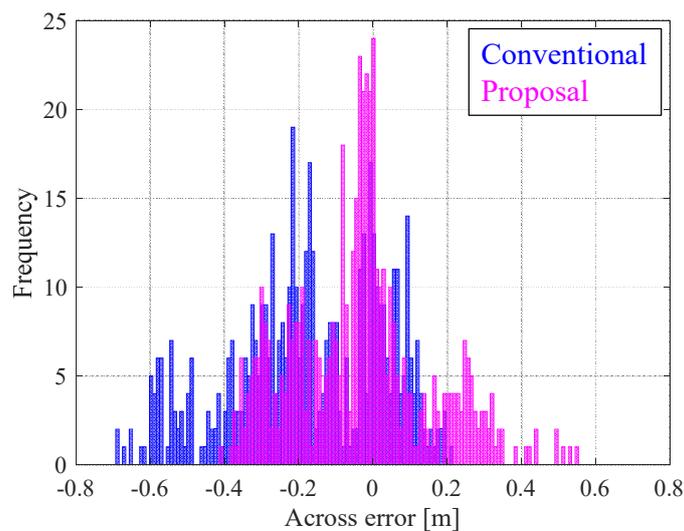


図 2.3.①-6 DR 位置誤差（ヒストグラム）

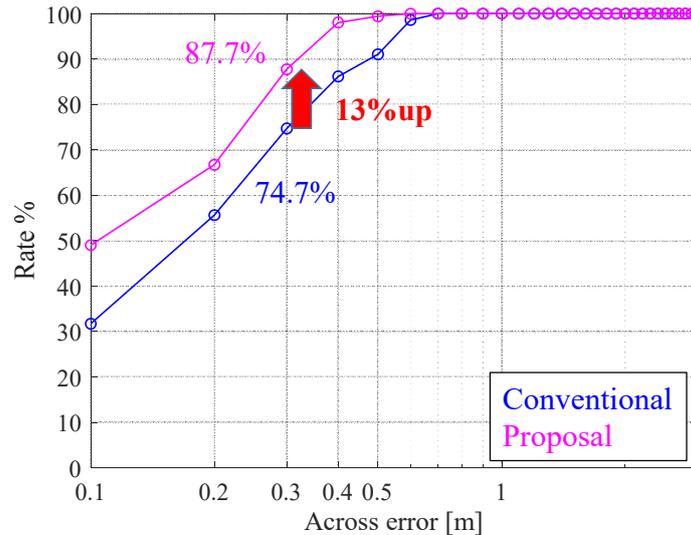


図 2.3.①-7 DR 位置誤差（累積度数）

e まとめ

2021 年度では、車両の自動走行において重要である自己位置推定の高精度化を目的として、DR の高精度化を実施した。まず、DR 区間の誤差とその要因について検証した結果、10 秒の DR の場合は初期方位角が影響することを確認した。次に、初期方位角の性能を向上させるため、過去数十秒間の FIX 解を使用して初期方位角を最適化させる手法を提案した。評価試験では都市部の評価コースにおいて、10 秒間 DR した際の誤差が 0.3[m]以下になる割合が 87.7[%]を達成し、提案手法の有効性を確認した。

【参考文献】

[1] Yoshiko Kojima, Noriyoshi Suzuki, Yoshikazu Hattori, "Precise Localization using Tightly Coupled Integration based on Trajectory Estimated from GPS Doppler", Proc. of International Symposium on Advanced Vehicle Control(AVEC) 2010, No168,p1-6

[2] Tomoji Takasu, Akio Yasuda, "Development of the low-cost RTK-GPS receiver with an open source program package RTKLIB", International Symposium on GPS/GNSS, Jeju, Korea, 4-6 Nov. 2009.

[3] Aoki Takanose, Yoshiki Atsumi, Kanamu Takikawa, Junichi Meguro, "Improvement of Reliability Determination Performance of Real Time Kinematic Solutions Using Height Trajectory", Sensors, 21, 2, 2021.1

[4] Junichi Meguro, Takuya Arakawa, Syunsuke Mizutani, Aoki Takanose, "Low-cost Lane-level Positioning in Urban Area Using Optimized Long Time Series GNSS and

---

---

IMU Data”, International Conference on Intelligent Transportation Systems (ITSC),  
Sep. 2018

## ② マップマッチング技術の開発

地図上での車両の現在位置を推定する自己位置推定において、センサから得られた情報と地図との照合を行うことで走行経路やその経路上の位置を特定する技術であるマップマッチングは、高精度に自車の位置を把握するために必要不可欠である。トンネル内や高層ビル街などのGPSの電波を捉えにくいような場所では、GPSから正確な位置を得ることが出来ない。そのため、継続的に高精度な位置を推定するためにはマップマッチングによる位置の補正が重要となる。

2021年度においては、降雨時の自己位置推定のための初期検討として高精度GNSS/INSを使用し、姿勢角を既知としたマップマッチングアルゴリズムの開発および位置精度（目標精度0.1m）の評価を行なった。

### 降雨時における高精度マップマッチング技術の開発

#### ・自己位置推定アルゴリズムの概要

自己位置推定のベースとなるアルゴリズムの概要を図2.3.②-1に示す。位置推定における初期位置にはGPSから得られる位置を使用し、その後はデッドレコニングとマップマッチングにより位置の推定を継続的に行なっていく。デッドレコニングとは、センサから得られる速度ベクトルとデータ取得周期から移動距離を積算し位置を計算する方法である。一時刻前のデッドレコニング位置 $x_{t-1,DR}$ 、速度 $v$ とデータ取得周期 $\Delta t$ から現時刻のデッドレコニング位置 $x_{t,DR}$ は $x_{t,DR} = x_{t-1,DR} + v \Delta t$ で計算される。GPSは電波受信状況によって短い時間で位置が大きく変化してしまう場合があるが、デッドレコニングにより位置を計算することでより滑らかな軌道を得ることができる。しかしながら、デッドレコニング単体の推定位置はセンサノイズの影響により誤差が蓄積される。そのため、デッドレコニング位置 $x_{t,DR}$ に対する誤差 $\Delta x_{t,DR}$ をマップマッチングによりセンサデータと地図を照合することで推定し、正確な車両位置を求める。

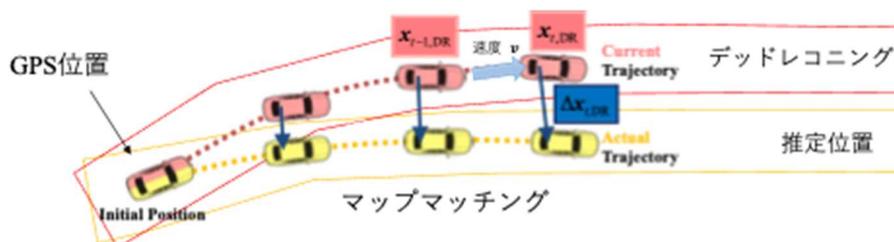


図 2.3.②-1. 自己位置推定アルゴリズム概要

テンプレートマッチングによる自己位置推定技術は文献[1]で示すように自動運転の公道実証実験において用いられている実績があるため、テンプレートマッチングをベースにマップマッチング技術の開発を行った。

テンプレートマッチングでは、地図画像とセンサからリアルタイムに得られた路面パターンの画像の類似度を計算する。マッチングに使用する画像は図のようなオルソ画像という正射投影により歪み補正を行った画像の形式で表現される。図 2.3.②-2 に示すように、テンプレート画像（センサデータ画像）を  $(d_x, d_y)$  だけずらしたときの類似度を計算し、その結果として相関分布という類似度の分布を得ることができる。このとき分布のピークが実際の車両位置である可能性が最も高い場所である、すなわちオフセットの尤度分布と捉えることができる。したがって、この尤度分布を確率分布に変換し、1 時刻前の確率分布から得られる事前確率と掛け合わせ事後確率分布を計算することでピークを時系列的にトラッキングし、オフセットを推定する。

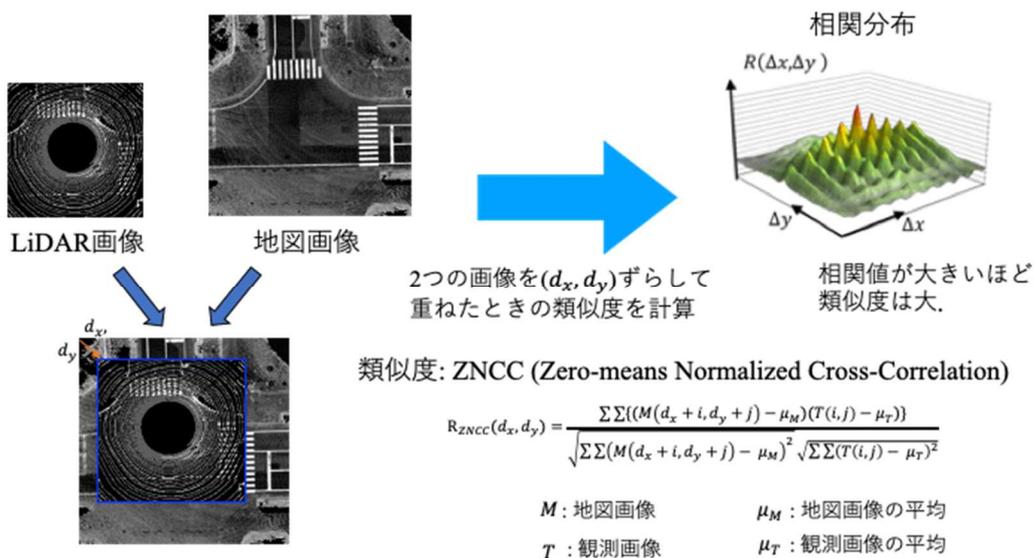


図 2.3.②-2. テンプレートマッチングの外観図

降雨時においては、路面が濡れることでレーザーが水面で鏡面反射を起こすことによって、路面に対する入射角の大きいレーザーほど反射率が低下する傾向がある。この状態で LiDAR 画像を生成すると、反射率を平均化することによって画像全体が暗くなり、画像コントラストの低下が発生する。そのため、光の反射のモデルを考慮して、レーザーごとに反射率を補正する必要がある。水面での鏡面反射はフレネルの式、アスファルト面での拡散反射は Lambert モデル[2]によりモデル化を行い、入射角と反射率の関係を求めた。Lambert モデルは、拡散反射を表すために利用される一般的な反射モデルである。反射光はどの角度から見ても一定であり、その強度は入射光と反射表面の法線

との角度(入射角)に依存する。入射角が大きくなる(反射面に対して平行に近づく)ほど拡散反射光の強度は小さくなる。この関係に基づき、各レーザについて反射率が同等になるような補正を行うことでコントラスト低下を抑えた画像を生成する(図 2.3.②-3)。

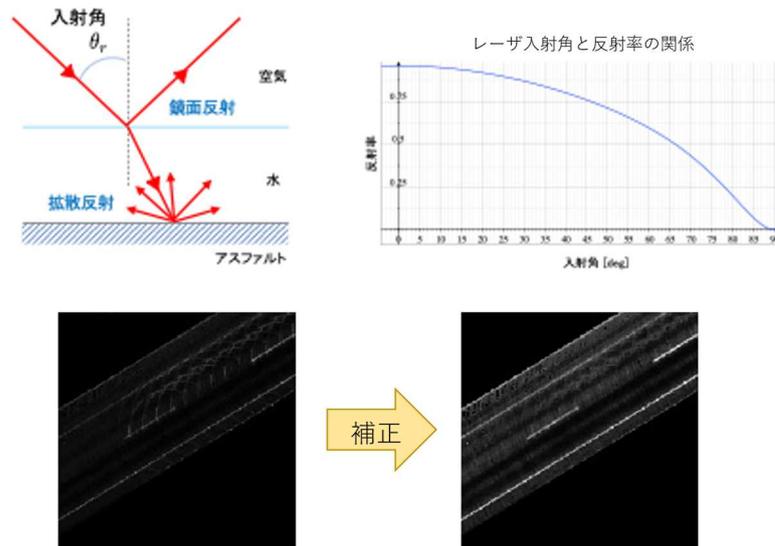


図 2.3.②-3.入射角による反射率の補正

また、マッチング時の相関値の計算にはZNCC (Zero-mean Normalized Cross-Correlation; ゼロ平均正規化相互相関) を用いているため、2つの画像のコントラストの差がその値に影響を及ぼす。そこで、LiDAR画像全体に対してコントラスト補正を行うことで、マッチング対象となる地図画像のコントラストに合わせる処理としてヒストグラムマッチングを導入した。

#### ・マップマッチングの精度評価

上記のアルゴリズムを実装し、実走行データを用いて精度検証を行なった。検証には、金沢市内において降雨時に走行したデータを用いる。データ計測は2021年11月22日の16時頃に行なっており、降雨量は7.5mm/hであった(気象庁の公表)。

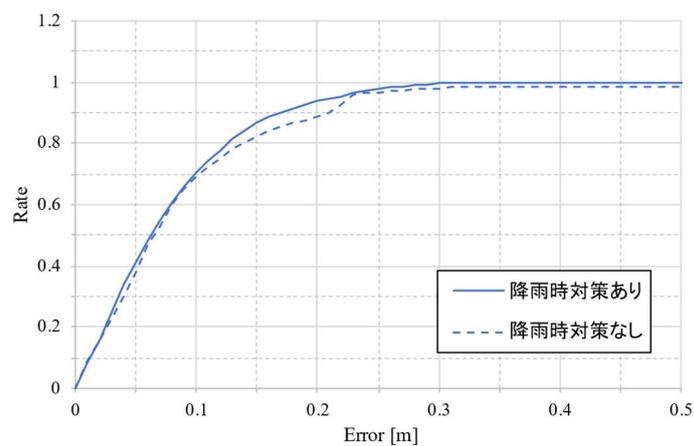
GNSS/INSのデータに対して後処理補正処理を行うことで、数cm単位の精度で位置情報を得ることができる。これを真値として精度評価を行うが、電波の受信状況によっては位置精度の低下が起こる場合があるため、GNSS/INSが出力する精度情報をもとに位置精度が概ね数cmに収まっている区間を抽出し、データの集計を行うものとする。車両縦方向・横方向の位置推定誤差を表 2.3.②-1 に示す。降雨時対策を行わなかった場合、車両縦方向誤差、横方向誤差ともに目標精度の0.1mよりも大きいRMS誤差となっており、特に車両

縦方向は最大で 2m 近くの誤差が発生している。それに対して，降雨時の対策を行うことで，RMS 誤差としては車両縦方向・横方向ともに目標精度である 0.1m が達成できており，最大誤差も比較的小さくなっている。しかしながら，最大誤差としては 0.4m 程度のデータも存在していることがわかるため，どの程度の誤差がどのくらいの頻度で発生しているのかについても評価した。

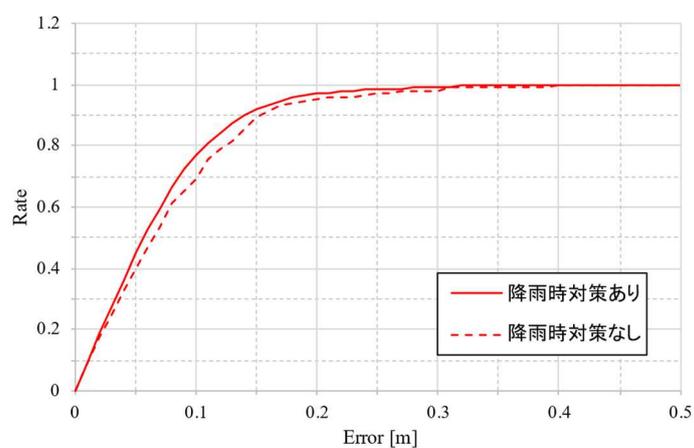
表 2.3.②-1. 降雨時の自己位置推定誤差.

		車両縦方向	車両横方向
降雨時対策 あり	RMS 誤差 [m]	0.10	0.09
	最大誤差 [m]	0.41	0.42
降雨時対策 なし	RMS 誤差 [m]	0.21	0.11
	最大誤差 [m]	1.95	0.70

図 2.3.②-4 に車両縦方向・横方向誤差それぞれについての累積割合のグラフを示す。横軸が誤差の大きさ，縦軸にその誤差以内に収まっているデータの割合を表している。このグラフから，車両縦方向・横方向誤差ともに降雨時対策を行うことで，車両縦方向誤差については 0.2m 以内の誤差の割合が約 5% 向上し，車両横方向誤差については 0.1m 以内の誤差の割合が約 7% 向上している。このように，誤差の累積割合の観点からも降雨時対策により精度が向上していることが示された。降雨時対策を行った場合，0.2m 以内に収まる割合が 9 割以上を占めており，それより大きい誤差のデータが非常に少ないことがわかる。また，0.1m～0.2m の誤差が 2 割程度を占めているが，0.2m 以上の誤差が発生している瞬間の推定位置をもとに地図画像と LiDAR 画像とを重ねると，路面パターンの重なりにずれがないことが確認できる(図 2.3.②-5)。つまり，実際には地図に対して 1 画素以内(1 画素の解像度は 0.125m)の誤差で位置が求まっていることになる。このように真値との誤差と実際のずれ量に差が出る要因としては，評価データの GNSS/INS の誤差に加えて，地図の位置誤差(地図作成時のデータにおける GNSS/INS の誤差)が含まれることが挙げられ，これにより実際の誤差と比較して数値上大きくなる可能性がある点は留意すべきである。以上の結果より，概ねの場所で目標精度である 0.1m の位置推定が達成できていると考えられる。



(a) 車両縦方向誤差



(b) 車両横方向誤差

図 2.3.②-4. 自己位置推定誤差の累積割合.

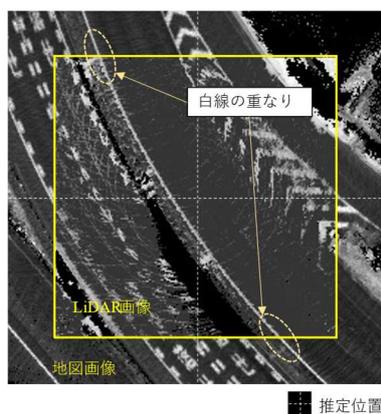


図 2.3.②-5. 推定位置をもとに地図画像と LiDAR 画像を重ねた結果.  
真値との誤差は車両縦方向 0.20m, 車両横方向 0.22m であったが, 白線の重なりを見ると, 地図画像とのずれは 1 画素未満であることが確認できる.

---

---

その一方で、場所によってはそれ以上の大きな誤差が発生しており、路面の濡れによって位置推定精度に影響があることも示唆されている。そこで、雨量の増加などによる路面の濡れ方等の条件がどのように推定精度に影響するのかを調査し、性能限界を明らかにすることがインフラ提言にとって重要となる。

しかしながら、実環境において様々な場所で任意の濡れ状態を再現することは困難であり、データ収集に大きな課題がある。そこで、DIVP (Driving Intelligence Validation Platform)事業との連携によって実環境をシミュレーションで再現し、自己位置推定の精度評価および性能限界の調査の効率化を図る。

#### ・DIVP 事業との連携による性能限界評価

DIVP のシミュレータでは、路面の濡れモデルが以下のような 5 段階のレベルで定義されている。

- Level 0: 乾いている状態
- Level 1: 路面に水が染み込んでいる状態
- Level 2: 染み込んだ水が飽和し、路面から染み出している状態
- Level 3: 1mm 程度の薄い水膜が路面に張っている状態
- Level 4: 数 mm の厚い水膜が路面に張っている状態

路面の濡れ方を変化させることにより、自己位置推定にどのような影響があるのかを調査した。また、路面の材質によっても LiDAR 画像の見え方に差異が生じる。アスファルト舗装の路面においては、白線と路面のコントラストが大きいですが、遮熱性舗装の路面では赤外線を反射しやすいために、白線と路面とのコントラストが小さくなり路面の濡れによる影響をより受けやすいことが想定される。そのため、アスファルト路面、遮熱性舗装路面による違いについても調査を行なった。

---

---

[遮熱性舗装路面での評価]

遮熱性舗装路面において、路面の濡れレベルを変化させたときの LiDAR 画像(コントラスト補正なし)を図 2.3.②-6 に示す。実際の環境と同様に、濡れレベルが大きくなるに従って、反射率が低下していることが確認できる。実際に自己位置推定を行う際には、コントラスト補正後の画像に対してマッチングを行う。そのため、コントラスト補正前後の画像に対して地図とのマッチングを行い、その結果としての相関分布において相関のピークが正しい位置に現れているかを確認した。遮熱性舗装路面においては、Lv.1 と Lv.2 の間に性能限界があることがわかったため、その間の条件をより細かく設定し、同様の検証を行なった。Lv.1.9 までの濡れレベルにおいては相関分布のピークが正しい位置に現れており、Lv.2 の結果においてはピークが正しい位置に得られていない(図 2.3.②-7)。相関分布のピーク位置に基づいて地図画像と LiDAR 画像を重ねたとき、Lv.1.9 のマッチング結果では両者の路面パターンがずれなく重なるが、Lv.2 のマッチング結果では大きくずれた位置で重なっており正しく位置が推定されていない。したがって、Lv.1.9 の濡れ方が性能限界であると考えられる。

実際にシミュレーションデータに対して自己位置推定を適用した結果を図 2.3.②-8 に示している。Lv.1.9 の推定位置は真値と概ね一致しており、Lv.2 の推定位置は誤差が拡大している。

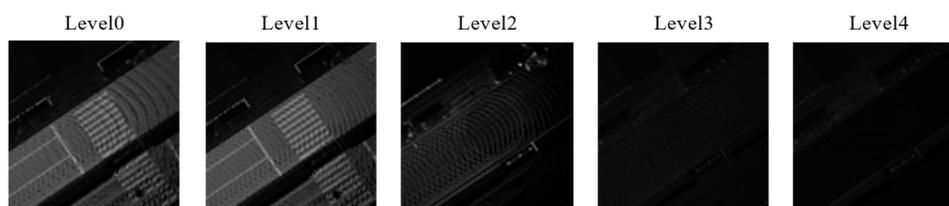


図 2.3.②-6. 各レベルにおける LiDAR 画像

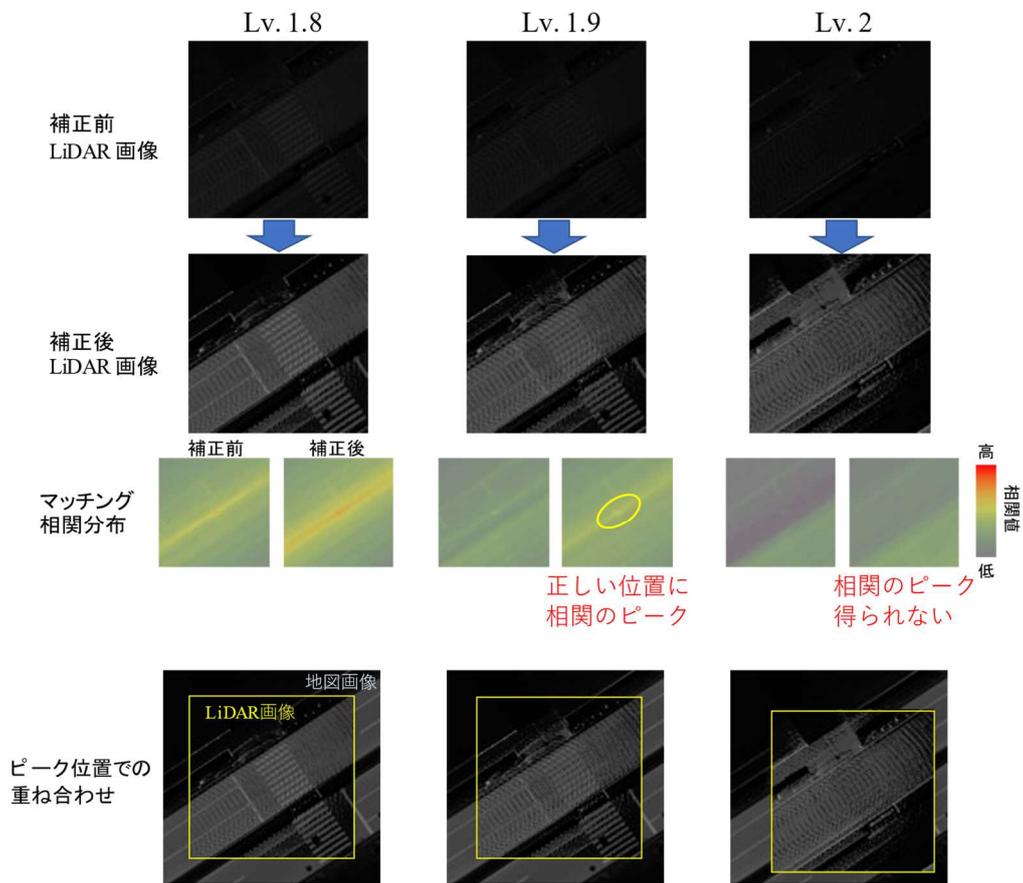
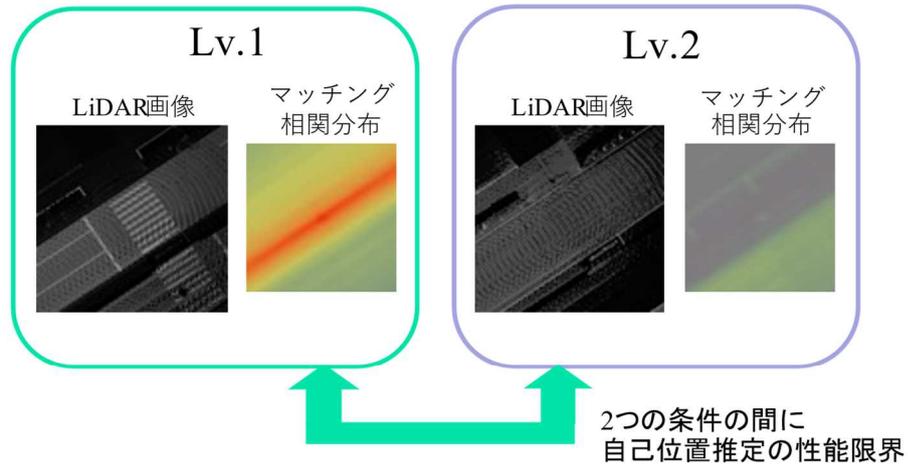


図 2.3.②-7. 性能限界付近の相関分布

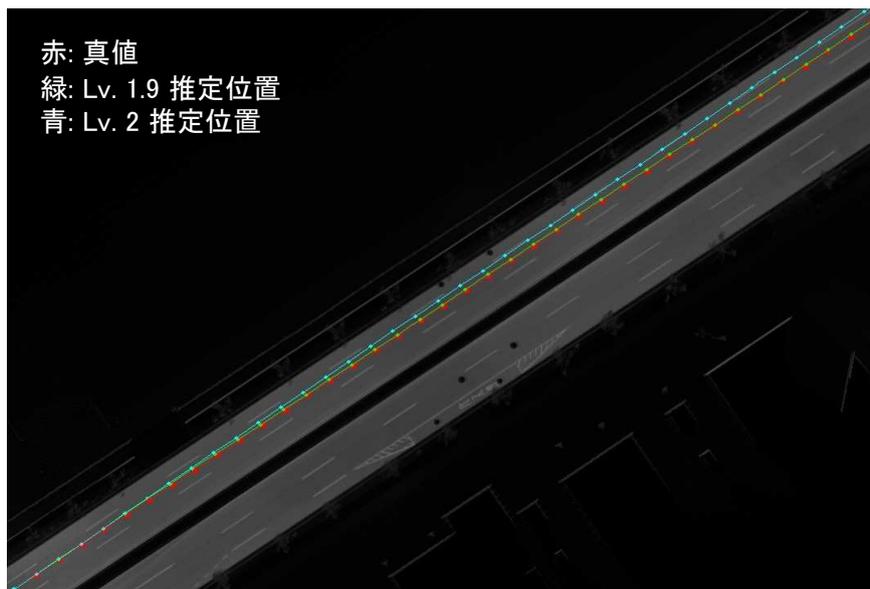


図 2.3.②-8. 遮熱性舗装路面における Lv.1.9 と Lv.2 の自己位置推定結果

[アスファルト路面での評価]

アスファルト舗装路面において、路面の濡れレベルを変化させて遮熱性舗装路面の場合と同様に評価を行なった。アスファルト路面の場合、濡れレベルが大きくなったとき、相関値の全体的な低下は見られるものの相関のピークは得られている(図 2.3.②-9)。そのため、最大の濡れレベル Lv.4 のデータにおいても図 2.3.②-10 に示す通り、自己位置推定結果が概ね真値に一致している。

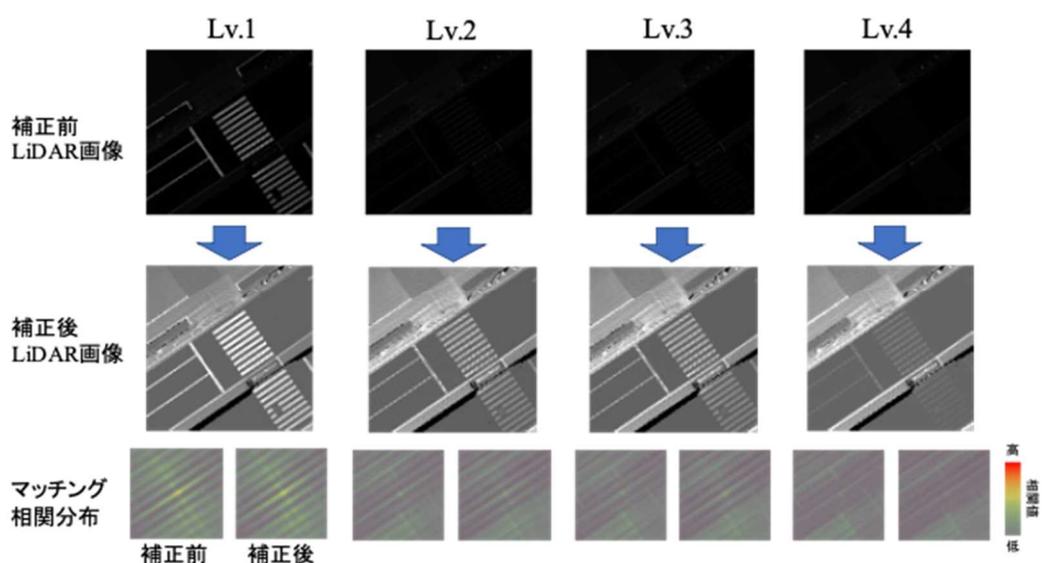


図 2.3.②-9. 各レベルにおける LiDAR 画像と相関分布(アスファルト路面)

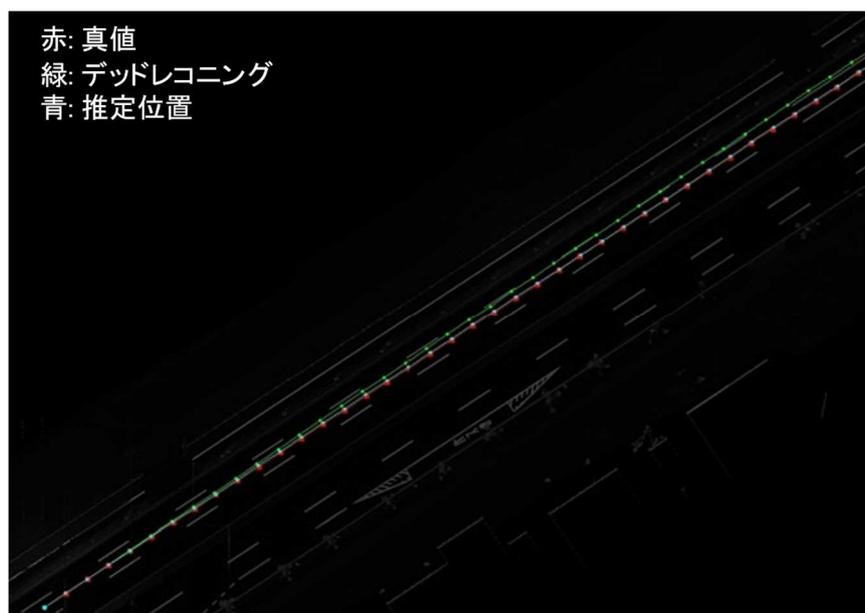


図 2.3.②-10. アスファルト路面における Lv.4 の自己位置推定結果

しかしながら、実環境においてはLv.2程度の濡れ方の路面でも課題となる場合は存在しており、シミュレーションと実環境との差異がある可能性が考えられる。実際の走行データから課題となるシーンの一例を抽出したものを図2.3.②-11に示す。乾いた路面では、LiDAR画像に地図画像と同様の路面パターンが現れており相関の鋭いピークが得られているが、濡れた路面のLiDAR画像では一部の破線が薄くなっており、路面パターンが地図画像と大きく異なることで相関分布に複数のピークが出現している。このように、実走行データでは反射率の低下にばらつきがあるため、反射率の低下が一様であったシミュレーションデータでの評価結果との間に差異が現れていると考察できる。したがって、シミュレーションにおいては反射率の低下のばらつきを再現することが、より詳細かつ多様な性能限界評価にとって重要であることがわかった。

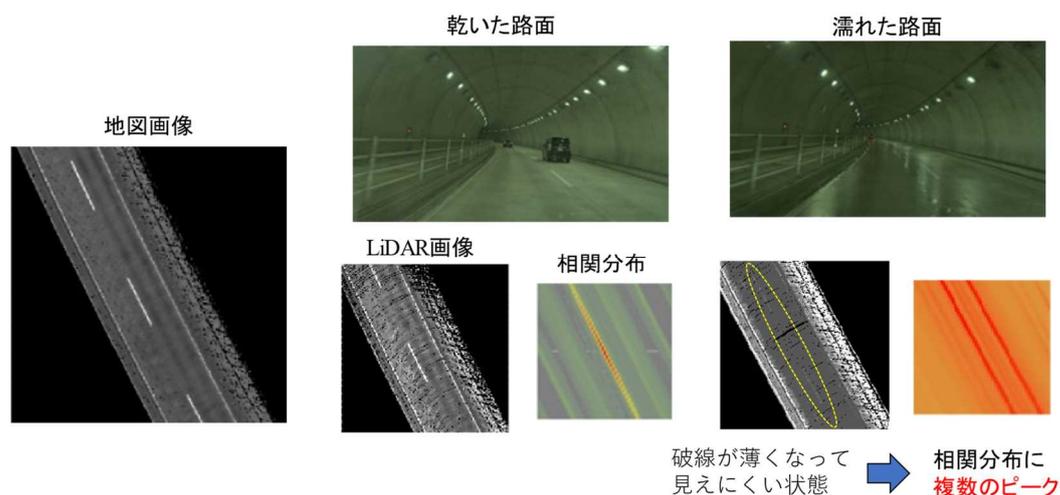


図 2.3.②-11. 実走行データで自己位置推定の課題となるシーン。

【参考文献】

- [1] N. Suganuma, D. Yamamoto and K. Yoneda, “Localization for autonomous vehicle on urban roads”, Journal of Advanced Control, Automation and Robotics, vol. 1, no. 1, pp. 47-53, 2015.
- [2] D. C. Look, “Diffuse Reflection from a Plane Surface”, Journal of the Optical Society of America, 55(12), pp.1628-1632, 1965.

---

---

## 2.4.d. 「SAKURA-DIVP と連携したシミュレータおよびシナリオの検証」

### ① 人工知能(AI)に基づく歩行者の行動予測

パスプランニングの評価は実環境下において検証を行う場合、同等の条件下での検証を繰り返し行うことは困難である。同一条件下での検証を通じて、課題抽出と改善を繰り返し行うためには、実環境と同等の認識ができるシミュレータが必要となる。また、歩行者の行動を予測するためには、各時刻における歩行者の位置を検出する必要がある。そこで、実環境での歩行者の行動を DIVP 事業のシミュレーション環境で再現するために、歩行者の検出精度について、実環境との一致性検証を行う。2021年度は、実環境で課題となっている複数のシーンにおいて、認識アルゴリズムの一致性検証を行い、実環境とシミュレーション環境の差異を明確にする。

#### ・実環境とシミュレーション環境の差異の調査

実環境と同等のパスプランニングを行うためには、まず、シミュレーション環境と現実環境で撮影されたデータに対する相違を明らかにする必要がある。そこで、シミュレーション環境において、鏡面反射成分およびアセットの分解能を変えて、歩行者の検出精度を比較する。また、セマンティックセグメンテーションについても一致性を比較する。

#### ・利用データセット

DIVP プロジェクトで構築しているシミュレーション環境を利用して、実環境で課題となっている複数のシーンを NCAP データセットとして再現し、評価する。評価に用いる物体検出およびセマンティックセグメンテーションの学習には東京都臨海部データセットを用いる。各データセットの構成を表 2.4.①-1 に示す。また、NCAP データセットに含まれる各シーンの詳細を表 2.4.①-2 に示す。本表に示す鏡面反射成分は、実環境で計測した歩行者や道路などに対する分光特性を基準とし、太陽からの入射光をどの程度反射させるか決める係数である。アセットは、歩行者や道路などのシーンに配置したオブジェクトの分解能である。分解能が高いほど詳細な形状表現をしている。背景は、実環境で写るような建物を後方に配置するかどうかの条件となる。トリムは、自車両が写る領域を切り取るかどうかの条件となる。実環境と DIVP シミュレーション環境の画像例を図 2.4.①-1 に示す。ここで、実環境とシミュレーション環境のデータは、カメラを搭載した車両が動き出した時刻から歩行者のダミー人形の一部が画面外に出るまでの時刻に統一しているが、車両の動きに差があるため、データセットの枚数が異なっている。

また、東京臨海部で走行したシーンについてもシミュレーション環境で再現し、評価する。本シーンでは、歩行者が横断歩道付近の道路を横断するシーンであり、シミュレーシ

---

---

ョン環境では、時間帯と天候を変化させる。加えて、歩行者に遮蔽が生じているシーンにおける差異を調査するために、横断する手前に停止車両を配置し、歩行者に遮蔽が生じる状況も作成した。各シーンの詳細を表 2.4.①-3、再現した画像例を図 2.4.①-2 に示す。本シーンでは自車両は停止している状態である。

表 2.4.①-1 各データセットの構成

データセット名	データ種別	枚数
NCAP(DIVP)	実環境 シミュレーション環境	185
東京臨海部物体検出用 データセット(SIP)	実環境	21,401
東京臨海部セグメンテーション用 データセット(SIP)	実環境	580

表 2.4.①-2 NCAP データセットの詳細

シーン	天空光	鏡面反射成分	アセット	背景	トリム	枚数
実環境	-	-	-	-	-	186
CG1	晴れ(14時)	中(1.1)	低	-	-	196
CG2	晴れ(10時)	中(1.1)	低	-	-	196
CG3	晴れ(12時)	中(1.1)	低	-	-	196
CG4	晴れ(14時)	弱(1.05)	低	-	-	196
CG5	晴れ(14時)	強(1.2)	低	-	-	196
CG6	晴れ(14時)	中(1.1)	高	-	-	196
CG7	晴れ(14時)	無し	人 (テクスチャ付加)	-	-	196
CG8	晴れ(14時)	無し	人+道路 (テクスチャ付加)	-	-	196
CG9	晴れ(14時)	無し	高	あり	-	196
CG10	晴れ(14時)	無し	高	-	内装	175
CG11	晴れ(14時)	無し	高	あり	内装	175



(a)実環境



(b)DVIP シミュレーション環境

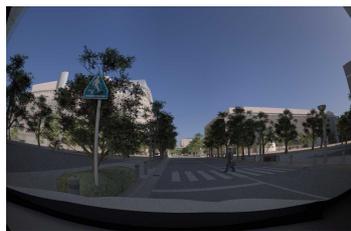
図 2.4.①-1 NCAP データセットの例

表 2.4.①-3 東京臨海部で再現したシーンの詳細

シーン	天空光	天候	停止車両	枚数
実環境	11 時ごろ	晴れ	なし	87
CG1	11 時	晴れ	なし	87
CG2	16 時	晴れ	なし	87
CG3	11 時	曇り	なし	87
CG4	11 時	雨	なし	87
CG5	11 時	晴れ	あり	87
CG6	16 時	晴れ	あり	87
CG7	11 時	曇り	あり	87
CG8	11 時	雨	あり	87



(a)実環境



(b)CG1



(b)CG5

図 2.4.①-2 東京臨海部で再現したシーンの例

・NCAP データセットを利用した現実環境とシミュレーション環境の差異の評価

物体検出用アルゴリズムとして YOLOv4[1],セマンティックセグメンテーション用アルゴリズムとして HRNet[2]を用いて, NCAP データセットを評価する. 各シーンにおける検出率および, 最小検出サイズ(高さ方向)を物体検出の評価指標とする. 一方, 現時点での

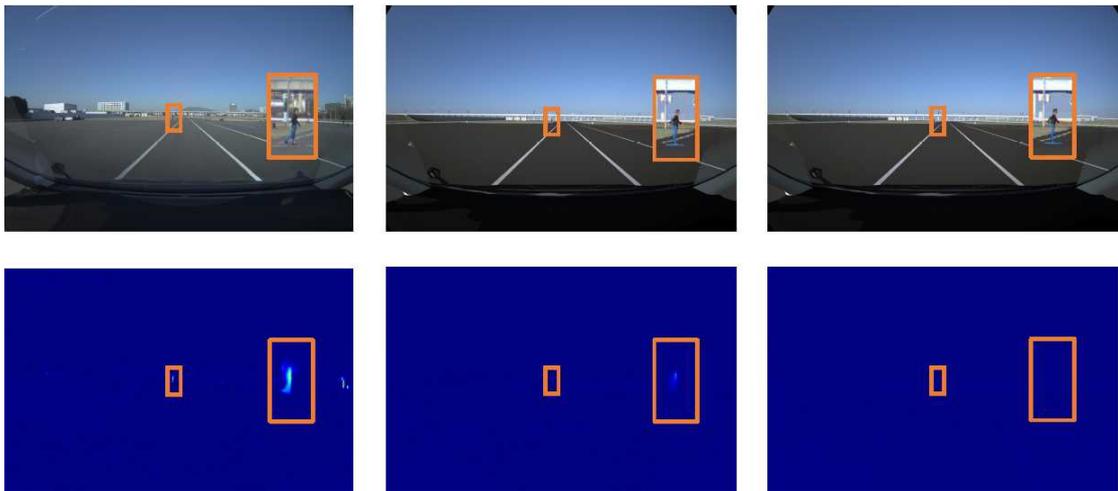
シミュレータにセマンティックセグメンテーションに必要な正解情報を付与する機能が実装されていないため、訂正的な評価のみ行う。表 2.4.①-4 に NCAP データセットのシーン CG1 から CG6 の検出率を示す。これより、実環境と実環境を再現した CG1 を比較すると、精度が大きく低下している。また、CG1 から CG3 を比較すると天空光の違いが検出精度に大きく影響を与えている。一方で、CG1 および CG4, CG5 のように同一天空光において、鏡面反射成分を変更しても検出精度に大きな変化は生じない。CG1 と CG6 のように、同一天空光かつ鏡面反射成分において、アセットの分解能を高くすると検出精度が向上している。実環境とシミュレーション環境において、歩行者の検出精度に差が生じているが、その差異の原因としては鏡面反射成分よりもアセットの分解能に起因することがわかった。

表 2.4.①-4 NCAP データセットでの検出率

シーン	天空光	鏡面反射成分	アセット	検出率[%]	最小サイズ
実環境	晴れ(14時)	-	-	48.4	46
CG1	晴れ(14時)	中(1.1)	低	41.8	58
CG2	晴れ(10時)	中(1.1)	低	46.4	63
CG3	晴れ(12時)	中(1.1)	低	47.4	63
CG4	晴れ(14時)	弱(1.05)	低	42.9	63

次に、歩行者を検出した距離を比較する。ここで、両環境においてカメラから歩行者までの距離情報は計測されていないため、歩行者を検出した際の最小サイズ(歩行者の高さ方向)を比較する。実環境では最小サイズが 46 ピクセルとなっている。実環境を再現したシーンである CG1 では 63 ピクセルとなっており、検出可能な距離に差が生じている。鏡面反射成分を変更したシーンである CG4 および CG5 も同様に最小サイズが大きい。一方、アセットの分解能を高くしたシーンである CG6 では、最小サイズが 52 ピクセルと最も実環境に近くなっている。これより、検出距離においてもアセットの分解能が検出精度に影響することがわかった。

次に、セマンティックセグメンテーション結果について、比較を行う。図 2.4.①-3 および図 2.4.①-4 に実環境、シミュレーション環境のうち CG1 と CG6 の歩行者に対するセグメンテーション結果を示す。ここで、図 2.4.①-3 は最小サイズ付近の時刻、図 2.4.①-4 は車両が接近した時刻の結果であり、歩行者らしさが高いほど赤色、低いほど青色で表している。また、最小サイズ付近の歩行者は小さいため、歩行者がいる領域をオレンジ枠で囲み、本領域を拡大した図も併せて示している。

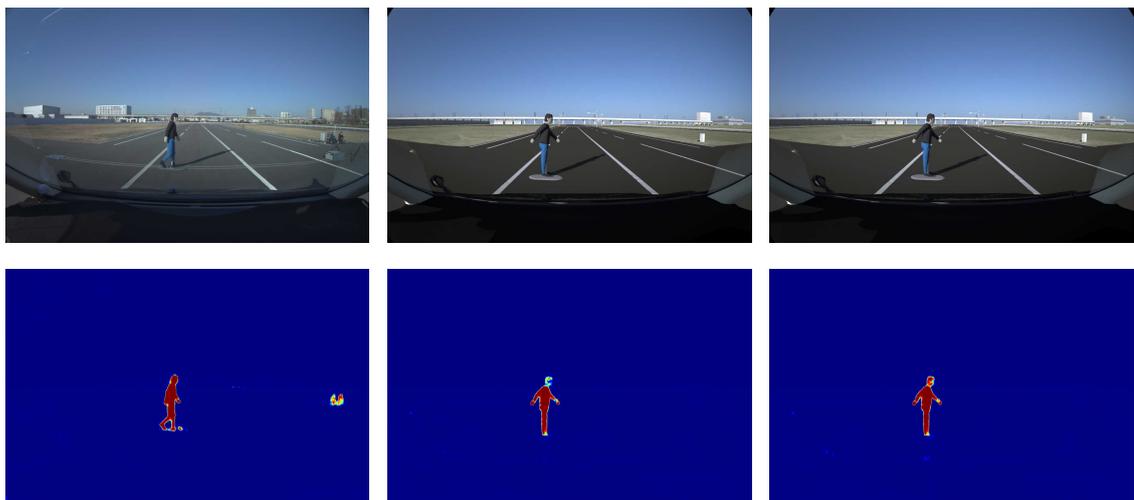


(a)実環境

(b)CG1

(c)CG6

図 2.4.①-3 セマンティックセグメンテーション結果(最小サイズ 46 ピクセル時)



(a)実環境

(b)CG1

(c)CG6

図 2.4.①-4 セマンティックセグメンテーション結果(接近した 490 ピクセル時)

図 2.4.①-3 より、実環境の場合、最小サイズ付近で歩行者らしさが高くなっている。一方で、CG1 や CG6 の場合、歩行者らしさがほとんど現れていない。図 2.4.①-4 のように車両に接近した 490 ピクセル程度のサイズの場合、実環境および CG1, CG6 において歩行者らしさが全体的に高くなっている。CG1 と CG6 を比較すると、頭部付近の歩行者らしさに違いが見受けられる。CG1 では、頭部の歩行者らしさが低くなっており、アセットの分解能の違いにより、テクスチャの凹凸の細かさが CG6 に比べると少ない。

次に、アセットのテクスチャによる影響を調査するために、人および道路に対するテクスチャを付与した場合の物体率を比較する。表 2.4.①-5 に各シーンにおける検出率および最小サイズを示す。表 2.4.①-5 より、歩行者にのみテクスチャを付与すると検出率、

最小サイズともに付与する前よりも低下する。一方で、歩行者と道路の両方にテクスチャを付与すると、実環境と同等以上の検出率になっている。また、最小サイズは実環境に最も近い。図 2.4.①-5 に最小サイズ付近の時刻、図 2.4.①-6 に車両が接近した時刻のセマンティックセグメンテーション結果を示す。ここで、最小サイズ付近の歩行者は小さいため、歩行者がいる領域をオレンジ枠で囲み、本領域を拡大した図も併せて示している。図 2.4.①-5 より、CG7 では最小サイズが実環境と同じものの、歩行者らしさは低い。図 2.4.①-6 より、CG7, CG8 ともに実環境と同様に歩行者らしさが高い。図 2.4.①-4 に示したテクスチャを付与する前の CG6 と CG8 を比べると、頭部付近の歩行者らしさがより実環境に近い。テクスチャを付与することで、より実環境に近い凹凸になっている。これより、テクスチャを付与することが重要であると考えられる。また、CG7 と CG8 を比較すると、道路に対してもテクスチャを付与した方が高い検出率になっている。これより、検出対象だけでなく、周辺の再現性も重要であることがわかる。一方、実環境に比べると歩行者が黒色から灰色に近い色になっている。色の影響については、更なる調査が必要である。

表 2.4.①-5 NCAP データセットでの検出率

シーン	天空光	鏡面反射成分	アセット	検出率[%]	最小サイズ
実環境	晴れ(14時)	-	-	48.4	46
CG6	晴れ(14時)	中(1.1)	高	45.9	52
CG7	晴れ(14時)	無し	歩行者 (テクスチャ付加)	41.3	87
CG8	晴れ(14時)	無し	歩行者+道路 (テクスチャ付加)	55.1	48

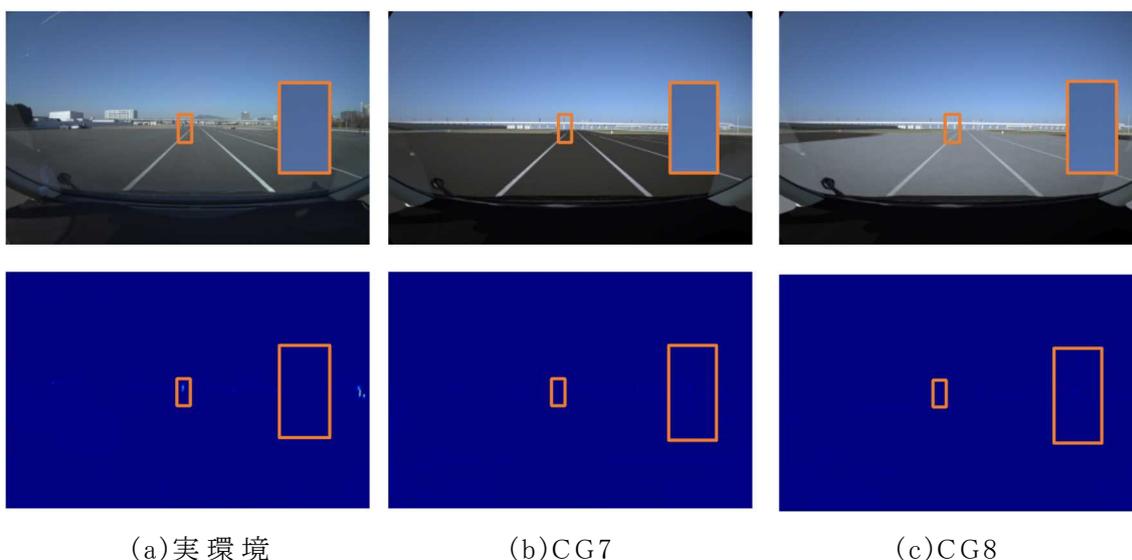
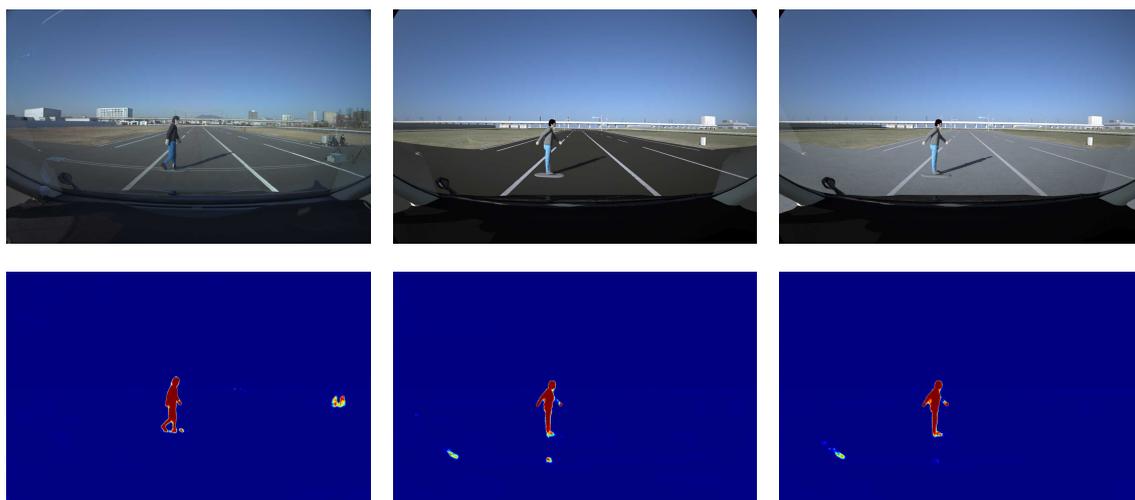


図 2.4.①-5 セマンティックセグメンテーション結果(46ピクセル時)



(a)実環境

(b)CG7

(c)CG8

図 2.4.①-6 セマンティックセグメンテーション結果(490ピクセル時)

表 2.4.①-6 NCAP データセットでの検出率

シーン	天空光	鏡面反射成分	アセット	検出率[%]	最小サイズ
実環境	晴れ(14時)	-	-	48.4	46
CG6	晴れ(14時)	中(1.1)	高	45.9	52
CG9	晴れ(14時)	無し	高(背景あり)	48.4	42
CG10	晴れ(14時)	無し	高(内装)	76.5	36
CG11	晴れ(14時)	無し	高(背景+内装)	46.2	36

検出対象の歩行者だけでなく、周辺環境の再現性の重要性を確認するために、図 2.4.①-7 に示すような実環境と同様に遠方に建物を配置したシーン、車内の内装をトリミングしたシーンにおける検出率を調査する。



(a)CG9

(b)CG10

(c)CG11

図 2.4.①-7 背景に建物を配置、内装を切り出したシーンの例

---

---

表 2.4.①-6 に各シーンの検出率，最小サイズを示す．背景を追加した CG9 は，背景なしの CG6 よりも検出率が高く，実環境と同程度になっている．また，最小サイズも実環境と同程度である．これより，歩行者周辺の再現性が重要であることがわかる．次に，内装をトリミングした CG10 の検出率は 76.5%と実環境を大きく上回る結果となっている．CG10 では，画像の一部をトリミングしているため，最小サイズまでの未検出フレーム数が 35 フレームとなっている．CG6 や CG9 では 66 フレームであり，CG6 および CG9 には小さな歩行者が多く含まれていることを意味する．また，歩行者が横断して，画面外に移動するまでのフレーム数も異なる．トリミングした場合，トリミングしない場合よりも早い時刻に画面外に移動するため，CG10 は 21 フレーム分早い．この 21 フレームにおいて，CG6 や CG9 では歩行者を検出できていない．そのため，検出率が低下している．一方，CG10 は検出処理を行わないため，未検出がなく，検出率の低下を抑制できている．しかしながら，背景付与と内装のトリミングを組み合わせた CG11 では，検出率が CG9 および CG10 よりも低下している．トリミングしたことにより歩行者および背景が CG9 よりも大きく写っているフレームが多い．そのため，輪郭付近において背景の特徴を多く捉えているため，歩行者らしさが低下したと考えられる．歩行者の大きさと背景との関係については，今後さらなる調査が必要である．

#### ・東京臨海部のデータを利用した現実環境とシミュレーション環境の差異の評価

NCAP データセットでの実験と同様に物体検出用アルゴリズムとして YOLOv4 を用いて，検出率を比較する．各シーンにおける検出率を表 2.4.①-7 に示す．実環境と CG1 の検出率は実環境 1 よりも低下している．横断歩道を横断中は両シーンとも全ての歩行者を検出できている．一方，横断後の樹木による遮蔽が生じている時刻において，CG1 では検出できないことが多い．歩行者の経路予測としては問題ないとする．時刻が 16 時の CG2 は 11 時の CG1 とほぼ同等の検出率のため，太陽の位置による影響はないと言える．天候が曇りの CG3 も CG1 と同等の検出率である．一方，雨の CG4 では検出率が 51.7%と大きく低下している．この原因は，ワイパーにより歩行者が遮蔽されて写っていない時刻があることである．それらの時刻を除外すると，検出率は 77.0%となり CG1 とほぼ同等である．これより，天候の影響もほぼないと言える．

停止車両があるシーンにおいて，停止車両およびワイパーにより遮蔽された時刻を除いた検出率は，天候が晴れで 11 時の場合の CG5 で 70.0%，16 時の場合の CG6 で 68.5% となっており，停止車両のない場合よりも僅かに検出率が低下している．これは，停止車両により部分的に遮蔽されている時刻において，検出できていない時刻があるためである．一方，CG5 と CG6 を比較するとほぼ同等の検出率であるため，太陽の位置による影響はないと言え

---

---

る．また，天候が曇りの CG7 の場合は 73.2%，雨の CG8 の場合は 72.5%と天候の影響もないと言える．停止車両があるシーンにおける検出結果例を図 2.4.①-7 に示す．

表 2.4.①-7 東京臨海部データでの検出率

シーン	時刻	天候	停止車両	検出率[%]
実環境	11 時ごろ	晴れ	なし	88.5
CG1	11 時	晴れ	なし	75.8
CG2	16 時	晴れ	なし	77.0
CG3	11 時	曇り	なし	78.1
CG4	11 時	雨	なし	51.7(77.0)
CG5	11 時	晴れ	あり	56.3(70.0)
CG6	16 時	晴れ	あり	55.1(68.5)
CG7	11 時	曇り	あり	59.7(73.2)
CG8	11 時	雨	あり	51.7(72.5)

( )内はワイパーまたは停止車両で遮蔽された時刻を除いた場合の検出率



(a)11 時晴れ



(b)16 時晴れ



(c)11 時曇り



(d)11 時雨

図 2.4.①-7 東京臨海部データでの検出結果例(停止車両あり)

---

---

## ・まとめ

2021年度は、パスプランニングに必要な歩行者の行動予測の要素技術となる歩行者検出について、現実環境とシミュレーション環境における認識アルゴリズムの一致性検証を行った。シミュレーション環境の場合、現実環境と同じシーンに対して、時間帯や鏡面反射成分、歩行者などのアセットの分解能など諸条件を変えて再現できる。これらの諸条件を変えて調査した結果、鏡面反射成分の影響は小さく、アセットの分解能が歩行者の検出率に影響することがわかった。次に、歩行者および道路にテクスチャを付与してより再現性を高めた場合、現実環境の検出率と同程度になることがわかった。また、現実環境のように背景に建物を配置して複雑な環境を再現すると、現実環境の検出率と同程度になることもわかった。車内の内装をトリミングし、外界のみを検出領域とした場合、検出率が大きく向上することもわかった。ただし、この条件は歩行者のサイズが大きくなったことに起因することも考えられるため、今後歩行者の大きさと背景の関係について調査する必要がある。一方で、歩行者にテクスチャを付与した場合、歩行者が灰色に近い色になっている。そのため、色とテクスチャの関係についても今後さらなる調査が必要である。

### 【参考文献】

- [1] J. Wang et al., “Deep High-Resolution Representation Learning for Visual Recognition”, CVPR, 2019.
- [2] A. Bochkovskiy et al. “YOLOv4: Optimal Speed and Accuracy of Object Detection”, ArXiv, 2020.

---

---

## ② 時系列追跡による車両の行動予測とパスプランニング

これまでに実施してきた実証実験では、自車周辺の走行環境や天候などの変化により認識及び判断が困難となる不調シーンを検証してきた。具体的には下記の周辺環境認識の課題を確認している。

- 信号機認識：逆光，順光，背景同化，隠蔽，夜間
- 遠距離物体認識：隠蔽，背景同化など（カメラの場合は逆光・夜間も含む）
- 自己位置推定：路面反射のノイズ（路面材質，雨天など）
- パスプランニング：死角による飛び出し時の判断

上記などの認識不調による自動運転継続に課題となるシーンに注目し、シミュレーションを活用して認識技術の高度化が重要である。一方、自動運転の走行環境の安全性を評価するためのプラットフォームとして、SIP 他事業であるDIVP（Driving Intelligence Validation Platform）事業ではカメラやLiDARなどのセンサ情報をシミュレーション可能な環境が開発されている。そこで本研究課題では、認識不調による自動運転継続の課題となるシーンを抽出し、DIVP 事業にて開発されているシミュレーション環境を活用したアルゴリズム改善を目指す。2021年度ではシミュレーション環境と本自動運転システムとの連携を行い、基本的な環境における再現試験を実施する。

図 2.4.②-1 に 2021 年度及び来年度に予定しているシミュレーションを活用した環境不調の検証の概要を示す。ここではカメラ及び LiDAR を用いた認識における環境不調を検証対象とし、それぞれ信号認識，物体認識，自己位置推定における不調の課題を個別に検証する。2021 年度の検証ではシミュレーションと連携した環境構築を行い、各不調要因を再現したシミュレーションの実施及び一貫性評価・検証を実施した。具体的には各認識対象において下記の検証を行った。

- シミュレーション環境全体：多数の交通参加者（自動車，トラック，人など）を任意に配置して，異なる天候（晴れ，曇り，雨天）及び時間帯（昼間，夕方）におけるシミュレーション環境を構築
  - 信号認識：シミュレーション環境内の交差点で異なる点灯色の信号機画像を生成し，異なる天候条件における信号認識の一貫性を検証。逆光時の信号認識への環境不調の再現。（詳細は 2.1.①を参照されたい）
  - 物体認識：遠距離車両に接近するシーンを異なる条件のシナリオを生成し，カメラ及び LiDAR による物体認識における一貫性を検証。（詳細は
- 
-

2.2.①・②を参照されたい)

- 自己位置推定：路面材質及び雨天を想定した異なる条件での LiDAR のシミュレーションデータを生成し，マップマッチングの一致性を検証（詳細は 2.3.②を参照されたい）
- 行動予測・パスプランニング：歩行者横断を想定したシーンのシミュレーションシナリオを生成し，画像認識における一致性を検証（詳細は 2.4.①を参照されたい）

AD-URBAN/DIVP連携		FY2021(認識観点での評価)		FY2022(システム観点へ)
評価対象		ステップ① (事前評価)	ステップ② (不調シーンの再現性評価)	ステップ③ (サクセスケースの提示)
センサ	機能	評価観点: 仮想環境で評価できるレベルになっているのか?	評価観点: 実証実験で実際に発生した不調シーンが再現できるのか?	評価観点: 仮想空間を活用して自動運転システムを改善可能か?
カメラ	信号認識	Semantic Segmentationによる評価 (認識クラスの正しさ) ・正しい認識結果となるのか? ・一致しない具体例は何か?	信号灯色の色相・彩度の評価  ・比較評価@飛騨エアパーク	 不調シーン例: 逆光・隠蔽・背景同化・夜間など
	物体認識		距離ごとの物体認識率  ・比較評価@JARI特異環境試験路	 不調シーン例: 逆光・隠蔽・背景同化・夜間など
LiDAR	物体認識	地図生成による評価 (地図の歪み, 路面模様再現性) ・3次元環境が再現できているか? ・反射率がどれくらい一致するか? ・一致しない具体例は何か?	距離ごとの物体認識率  ・比較評価@JARI特異環境試験路	 不調シーン例: 隠蔽・背景同化(近接物体)・雨天・反射物など
	自己位置推定		自己位置推定状態評価 (相関分布, ピーク)  ・比較評価@お台場+JARI特異環境試験路	 不調シーン例: 遮熱性塗装路, 雨天, 高架下, 路面表示のかすれなど

図 2.4.②-1 DIVP 事業との連携による認識不調の評価計画

上記のような各要素技術の認識不調の再現・検証を進めていくことで，複合的な不調の課題を改善して自動運転の平均持続可能距離の改善が期待できる。実証実験において確認しているパスプランニングの不調シーンとして，前述した死角のある環境での飛び出しに関する判断が挙げられる。例えば，交差点の右折走行時において右折待ち車両や周辺構造物による物理的遮蔽が発生すると，対向車両の認識が遅れてしまう課題が想定される（図 2.4.②-2）。こうした不調シーンを解決するには，物理的遮蔽の程度による認識アルゴリズムの改善や対向車両の存在を想定した判断技術の構築などが必要となる。このような

死角の存在する環境における交差点進入時の走行データの生成例を図 2.4.②-3 及び図 2.4.②-4 に示す。図 2.4.②-4 などのように実際の交差点走行を想定したシナリオの構築を進めて、認識・判断などの観点から不調シーンの再現及びアルゴリズム改善に取り組んでいく。今後の検証においてはシミュレーション可能なシーンの拡張に伴い継続的な評価を進める予定である。



図 2.4.②-2 右折時の死角による対向車未検知（2020 年度報告書より）

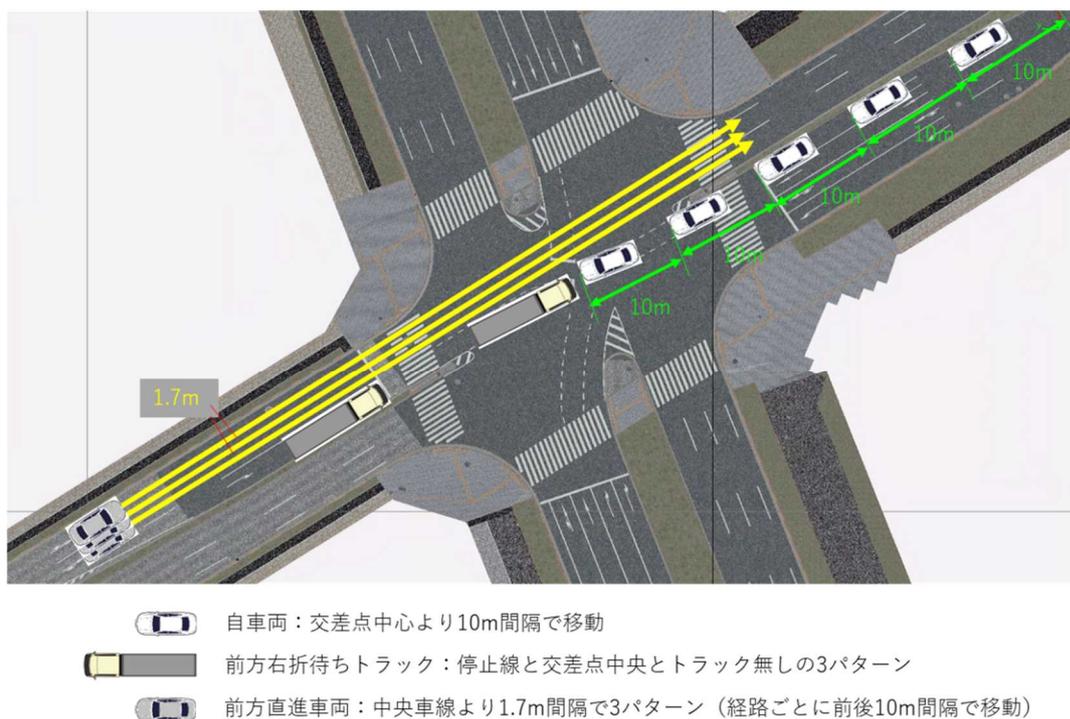


図 2.4.②-3 異なる隠れを想定した対向車の走行のシミュレーションシナリオ例（青海一丁目交差点）

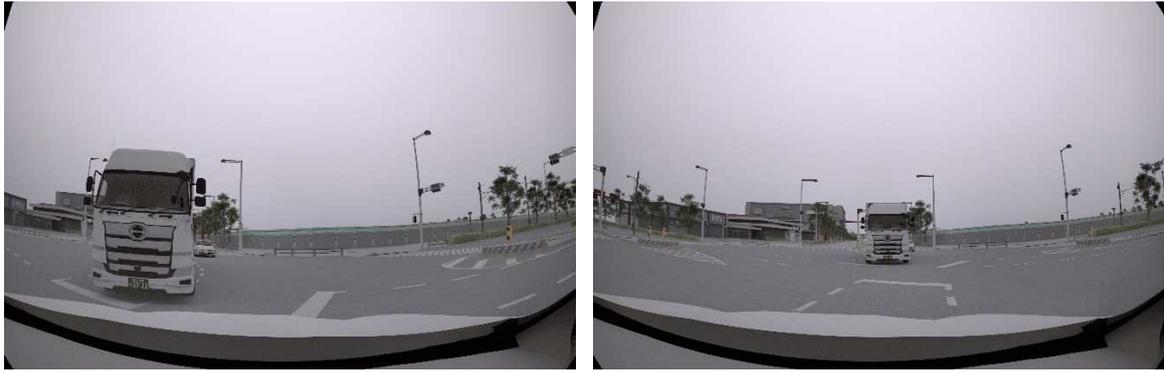


図 2.4.②-4 異なる隠れを想定した対向車の走行シーンの生成画像例

---

---

## 2.5.e. 「自律型自動車が走行する状態での問題点の検討」

### ① ロボティクス技術を活用したデッドロック回避

自動運転システムにおいて、自動車の振る舞いを決定するパスプランニング技術には、大きく分けて自動運転自動車が目的地に到達可能なルートを計画する技術、交通ルール等に基づいて大まかな車両の振る舞いを決定する技術、そして細かい障害物への回避や先行車両の追従などの細かい挙動を計画する技術に大別可能であると考えられる。本研究課題では、こうした自動運転の基本的な意思決定をシミュレーションソフト上で再現するための環境を構築し、自動運転車が走行する環境下でデッドロックが発生しやすい状況を明らかにする。2020年度までは複数の自動運転自動車が走行する状況を想定したデッドロックシーンを中心にシミュレーション及び非公道エリアによる実証などを実施してきた。交通ルールを厳密に遵守する自動運転自動車に対して、交通ルールに対して曖昧な運転行動をとる一般車両が存在する場合、デッドロックにより走行不能となる状況が起こりやすいことを検証した。このような交通ルールに対する曖昧さが発生しやすい状況として緊急車両の走行時が挙げられる。緊急車両が接近した場合は緊急車両の安全な走行の妨げにならない運転行動をとる必要があるため通常の走行時とは異なる状況判断が要求される。2021年度は、緊急車両に対するデッドロック回避の有効性を評価するため、開発済みの試験車両に緊急車両を認識するための車載センサやV2X通信装置を搭載し、センサフュージョンによる緊急車両の認識アルゴリズムを開発する。また、緊急車両の接近に伴うデッドロックの回避シーンを検討してシミュレーション環境への反映を目的とした環境構築を進める。

緊急車両は、道路交通法第39条より「消防用自動車、救急用自動車その他の政令で定める自動車で、当該緊急用務のため、政令で定めるところにより、運転中のものをいう。」とされており、道路交通法施行令第14条より緊急自動車の要件として、一部の例外を除きサイレンを鳴らして、赤色の警光灯をつけなければならないとされている。道路交通法施行令第13条より、緊急自動車としては車両の所有機関や用途を細かく区別してみると20種類ほどあるがサイレンの違いを見ると救急車、パトカー、消防車、白バイの4つが代表的なものとしてあげられる。これらの車両は非緊急時に遭遇する場合は運転行動の配慮が必要ないため、対象車両を認識してかつ当該車両が緊急状態であることを認識する必要がある。車載センサおよびV2X通信により緊急車両を認識する場合には対象車両との接近状態に応じて下記のような処理が必要となる。

- 
- 
- 画像による接近車両の認識（近距離～中距離において緊急車両の存在及び警光灯の点灯・点滅を認識）
  - 音による接近車両の認識（中距離から緊急車両のサイレンを認識）
  - 遠方からの接近情報の取得（V2X通信により緊急車両の位置情報を取得）

上記の要素技術に関して，2021年度の検討では車載されたマイクを用いて走行中の車外の走行音から緊急車両のサイレン音の走行データ収集及び認識アルゴリズムの基礎検討を実施した[1]．また，東京臨海部の実証実験において実施されたV2N通信による緊急車両の位置情報の配信実験に参加して得られる情報の傾向を調査した．なお，画像認識による緊急車両認識の検討状況については2.5.②節を参照されたい．

#### ・車載マイクを利用した緊急車両のサイレン音の認識アルゴリズムの検討

緊急車両のサイレン音の認識を実現するに当たり，基礎検討として認識対象を救急車及びパトカーに限定して検討を進める．サイレン音の周波数は法律上定められていないが，実際のサイレン音の周波数傾向より救急車のサイレン音は960[Hz]と770[Hz]を1.3秒周期で繰り返す音[2]であり，パトカーのサイレン音は最高吹鳴周波数が870[Hz]ということがわかっている．実際にこれらの車両のサイレン音を認識する場合は自車両，緊急車両ともに走行中なため，ドップラー効果の影響を受ける．音源と観察者が互いに近づくととき周波数は実際の周波数よりも高くなるため，それを考慮して処理する必要がある．

一般的な音認識では，音データから統計的手法により抽出された特徴量を用いた認識処理が行われる．本検討ではサイレン音にフィルタバンク分析を適用してサイレン音信号の持つ次元数を削減する．フィルタバンク分析とは縦軸を振幅，横軸を周波数としてグラフ化した振幅スペクトル，または縦軸を振幅の絶対値の2乗，横軸を周波数としてグラフ化したパワースペクトルの次元数を削減する方法で，一定の範囲ごとに周波数成分の値を集約することで周波数成分の数を削減するというものである．この周波数成分を集約する関数であるフィルタバンクを作成するにあたり，メル尺度と呼ばれる定義で周波数を変換することでメルフィルタバンクを作成することができる．メル尺度とは音認識でよく用いられるモデルで，人間の聴覚特性が考慮された尺度のことである．図2.5.①-1のように多数の三角窓としてフィルタバンクを定義し，このフィルタバンクを畳み込むことで異なる周波数成分に注目した次元削減が可能となる．異なる周波数成分に応じて注目する三角窓の幅を

---

---

変化させることで分解能を調整している．これは，人間の聴覚特性は音の低周波数成分の変化には敏感で，高周波数成分の変化には鈍感であるというものである．これらの処理によって音データから特徴量を抽出する．

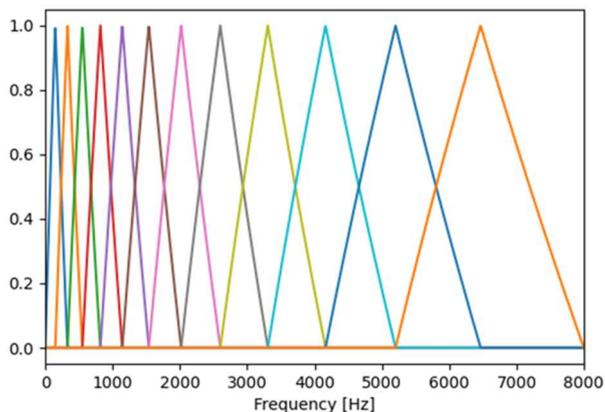
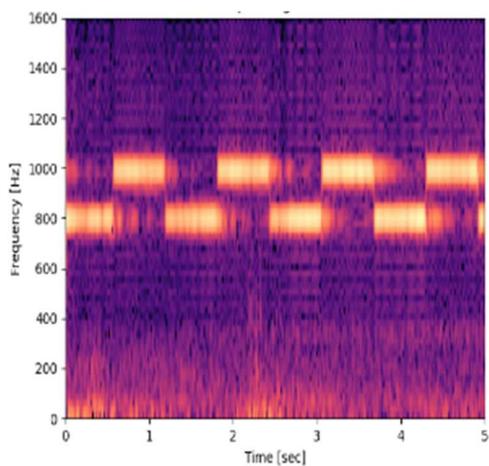
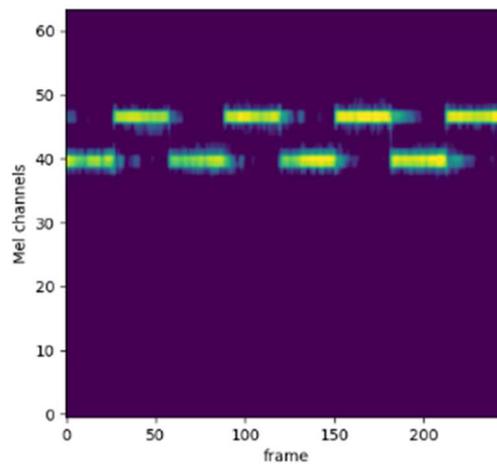


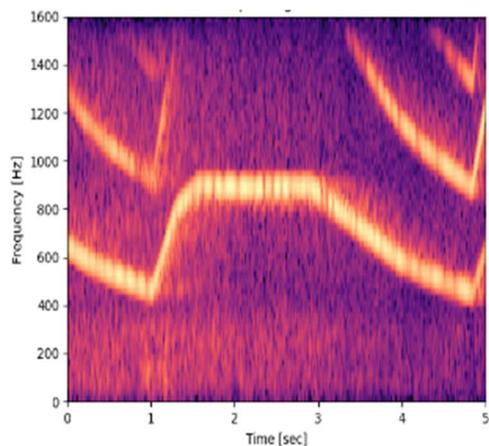
図 2.5.①-1 メルフィルタバンクの例



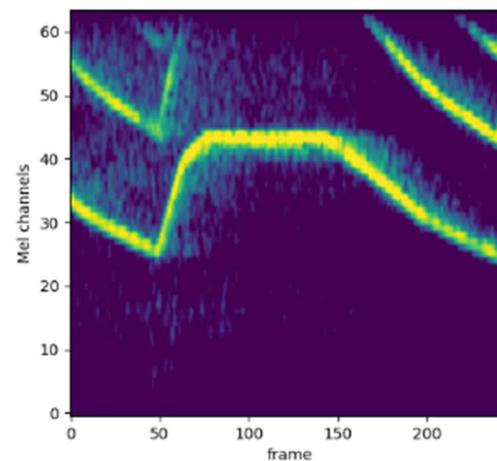
(a) 救急車音（次元削減前）



(b) 救急車音（次元削減後）



(c) パトカー音（次元削減前）



(d) パトカー音（次元削減後）

図 2.5.①-2 緊急車両音の特徴量例

図 2.5.①-2 に救急車及びパトカーのサイレンに関して次元削減前後の特徴量の様子を示す。サイレン音に関する周期的なパターンの特徴は維持しながら図中縦軸の特徴次元数は削減できていることが確認できる。本研究では音声にフィルタバンク分析により抽出された音の特徴データを用いて機械学習アルゴリズムによってサイレン音データの検出を試みる。

サイレン音データの認識では特定時間範囲の音声の特徴量を入力データとしてサイレン音の状態を識別する。学習データにはオンラインでスクレイピングした音データ、音識別用の環境音データセットである ESC-50、自動運転自動車の車外に搭載されたマイクで録音された走行音データを用いる。音データの特徴量は、20~1600[Hz]の範囲をフィルタバンクの作成区間として、フィルタバンクの次元数は 64 とした。データセットに収録する音データは、すべて 5[sec]ごとに分割して特徴量抽出を行った。

学習・評価に用いたデータセットの概要を表 2.5.①-1、表 2.5.①-2 及び表 2.5.①-3 に示す。本検討では初期検討として救急車・環境音の識別、パトカー・環境音の識別として単純化した 2 クラス問題を対象として識別性能を評価する。また、車載マイクを搭載した走行データで遭遇した救急車の緊急車両走行時のデータに対して評価する。

表 2.5.①-1 サイレン音識別の学習データ

Class	Number of Data
Ambulance	940
Police Car	640
Environmental Sound	980

表 2.5.①-2 サイレン音識別の評価データ

Class	Number of Data
Ambulance	321
Police Car	216
Environmental Sound	351

表 2.5.①-3 サイレン音識別の評価データ（実走行データ）

Class	Number of Data
Ambulance	19
Environmental Sound	2,977

学習にはサポートベクターマシン（Support Vector Machine, SVM）を用いて識別器を構築した。表 2.5.①-4 に評価結果として各データセットの分類結果を示す。ただし、実走行データに関しては救急車に対して環境音のデータ数の割合が非常に高いため Accuracy の評価は行っていない。

表 2.5.①-4 救急車・環境音，パトカー・環境音の識別評価結果

	Ambulance/Env. Sound	Police Car/Env. Sound	Actual Driving Data
Accuracy	0.964	0.945	---
Precision	0.966	0.930	0.938
Recall	0.960	0.926	0.789

表 2.5.①-4 より、サイレン音と環境音との識別に関しては概ね高い認識率が得られていることが確認できた。特徴的な課題としては、サイレン区間の直前・直後などの十分に周期的なパターンが確認できないようなシーンやサイレンに雑音が付与されたようなシーンでの未検出が確認されている。こうした課題は継続してデータを追加することで改善が期待できる。一方、実走行データでは未検出の割合が高くなり Recall が低下する結果が得られた。十分なデータ数がないため参考値としての結果ではあるものの、遠方で音声小さい場合や図 2.5.①-3 などのように救急車と同程度の周波数に風切り音が観測された場合などが課題として確認された。図 2.5.①-3 のような課題は、単純にデータを増やすだけではなく、識別器に入力する特徴量の工夫なども検討しながら改善を進める必要がある。今後はこれらの課題改善のほか、多クラス識別問題としてモデル化しながら認識性能の評価を継続して進める予定である。

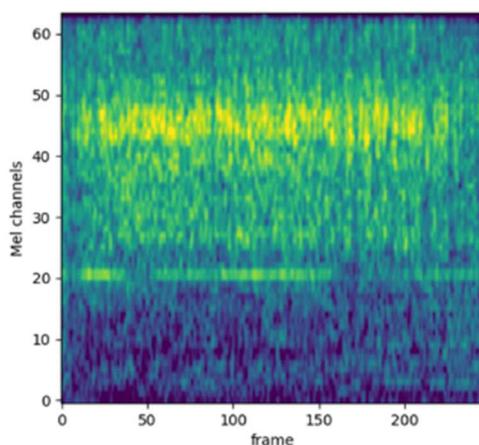


図 2.5.①-3 実走行データにおける特徴的な誤認識シーン（風切り音）

## ・ V2N 通信による緊急車両の位置情報取得

緊急車両の情報を得る手段としてセルラー通信を用いた情報配信である V2N 通信も検討されている。カメラ及びマイクなどの車載センサによる認識に対する多重系としての活用や、車載センサではカバーできない遠距離に存在する緊急車両の情報を事前に得ることも期待できる。2021 年度の東京臨海部実証実験では図 2.5.①-4 に示すように模擬緊急車両に搭載した GNSS の情報を V2N 通信により試験車両に配信する実証実験を 2022 年 1 月 10 日から 21 日までの 12 日間実施された。本事業では実験期間のうち 9 日間の実験に参加してお台場のエリアで得られる配信データの特徴を調査した。

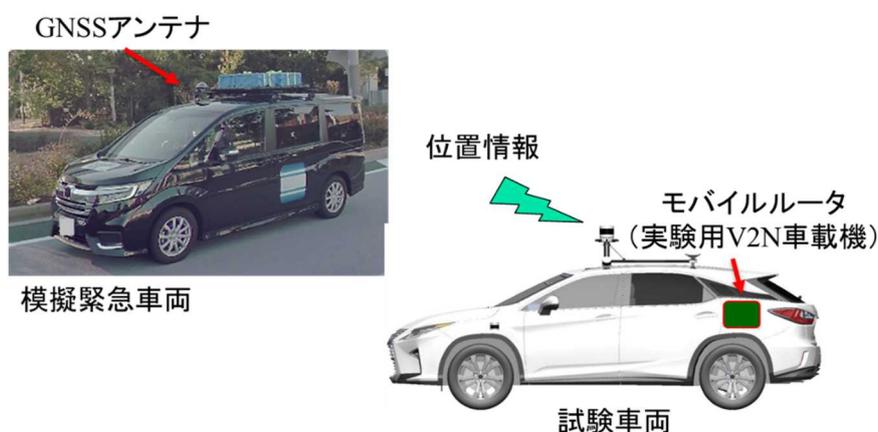


図 2.5.①-4 V2N 通信による模擬緊急車両の位置情報配信実験の概要

本走行試験では、実際の緊急車両との遭遇を想定したデータ計測や配信データの品質などを中心に検証した。データの品質としては、図 2.5.①-5 のように模擬緊急車両停車時や遮蔽物の多いエリアでは一時的に数メートル～20m 程度の誤差が起り得ることを確認した。近距離にいる場合は大きな誤差であるが、図 2.5.①-6 のように自車からの距離に対して想定される車両位置の方位誤差を試算すると遠距離にいる場合は 10[deg]以下となる。したがって、配信情報から緊急車両の存在方向を把握するには十分な精度で位置情報を取得可能である。特に市街地の環境では多くの遮蔽物により車載カメラからの認識が遅れてしまうことが想定されるため、配信情報により対象物の大まかな位置を取得できるのは有効である。実用的な運用としては近距離時に正確な位置情報を得る必要があるため、配信情報によって認識範囲の絞り込み、車載センサで細かい挙動を認識するなどの協調的な利用も考えられる。

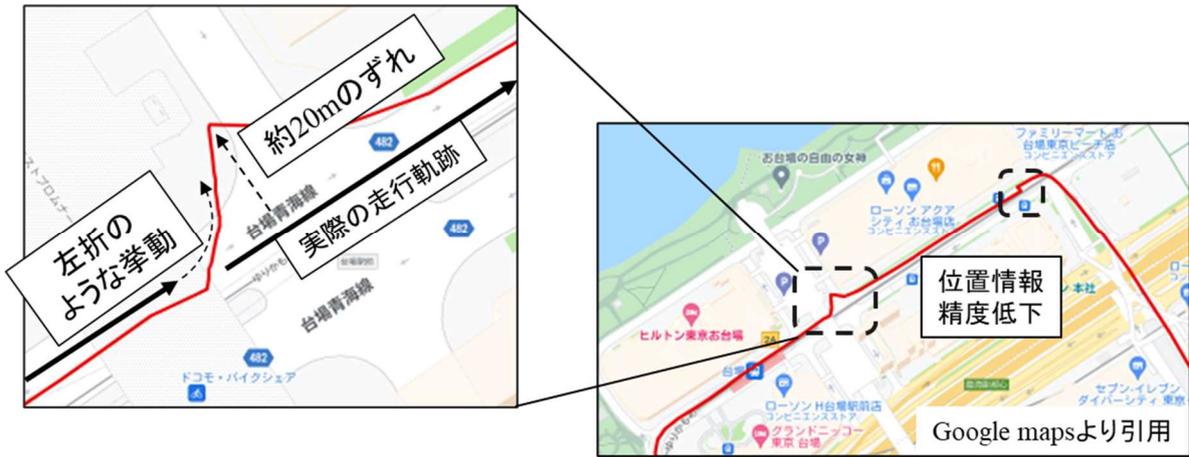


図 2.5.①-5 模擬緊急車両の走行試験における車両走行軌跡  
(2022年1月13日13時半ごろ)

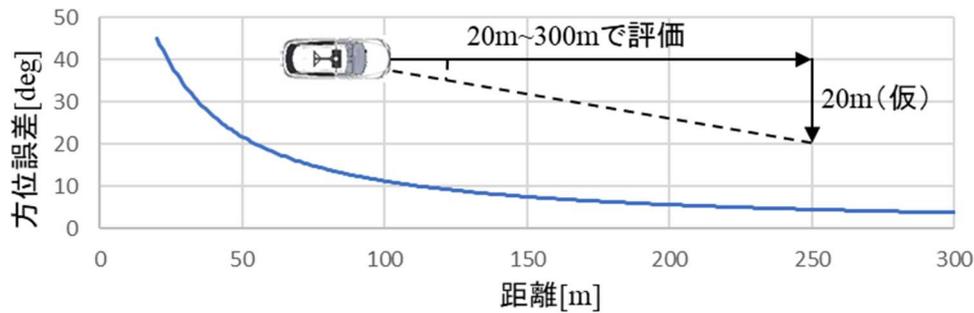


図 2.5.①-6 位置誤差 20[m]を仮定した場合の方位誤差

#### ・ 緊急車両遭遇時のデッドロックシーンの検討

緊急車両を想定したデッドロックシーンを検証するために評価対象とする走行環境を検討する。緊急車両が接近する場合には自車を含む周辺車両全体が譲るための回避行動を取るため道路脇に対比してスペースを確保する運転行動が考えられる。これまでに本事業にて実施している一般道の公道実証実験においても東京臨海部並びに金沢市の走行において実際に緊急車両と遭遇するシーンのデータを計測している。図 2.5.①-7 及び図 2.5.①-8 にお台場及び金沢市内で計測した緊急車両の遭遇シーンを示す。どちらのシーンにおいても緊急車両を譲るために周辺車両が一時的に停止して通過可能なスペースを確保している走行が確認されている。このように実走行で実際に確認されたシーンをベースとしてシミュレーション環境に落とし込んでいけるようにモデル化を進めていく。走行中に計測した LiDAR のデータについては図 2.5.①-9 のようにフレームごとに得られたデータに対して交通参加者を 3 次元の

矩形枠としてタグ付けする作業も進めている。今後はモデル化対象のシーンについても一定フレームのデータのタグ付けを進めていく予定である。



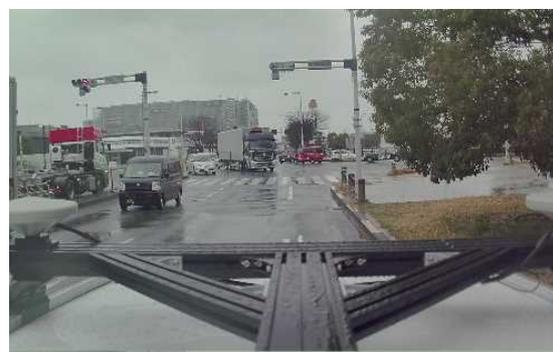
(a) 前方カメラ



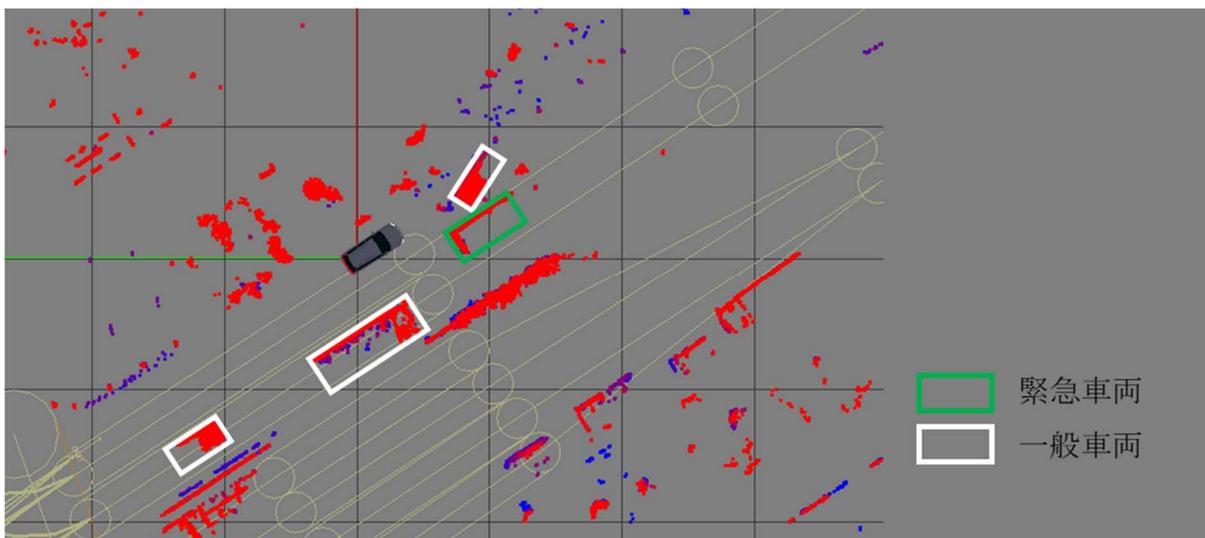
(b) 右側カメラ



(c) 左側カメラ



(d) 後方カメラ



(e) LiDAR データ

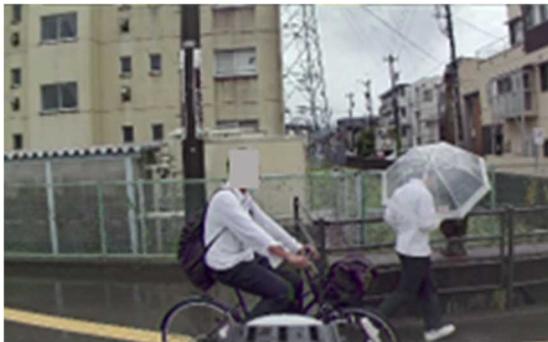
図 2.5.①-7 お台場の走行における緊急車両の遭遇シーン



(a) 前方カメラ



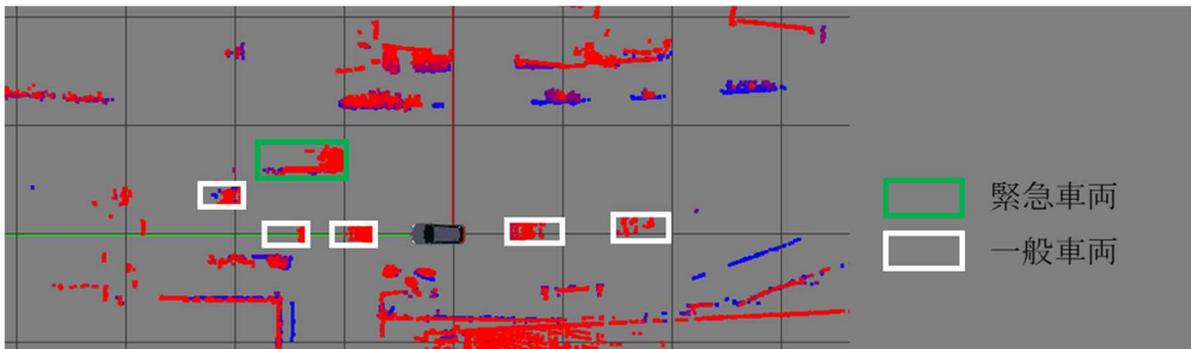
(b) 右側カメラ



(c) 左側カメラ



(d) 後方カメラ



(e) LiDAR データ

図 2.5.①-8 金沢の走行における緊急車両の遭遇シーン



(a) 前方カメラ



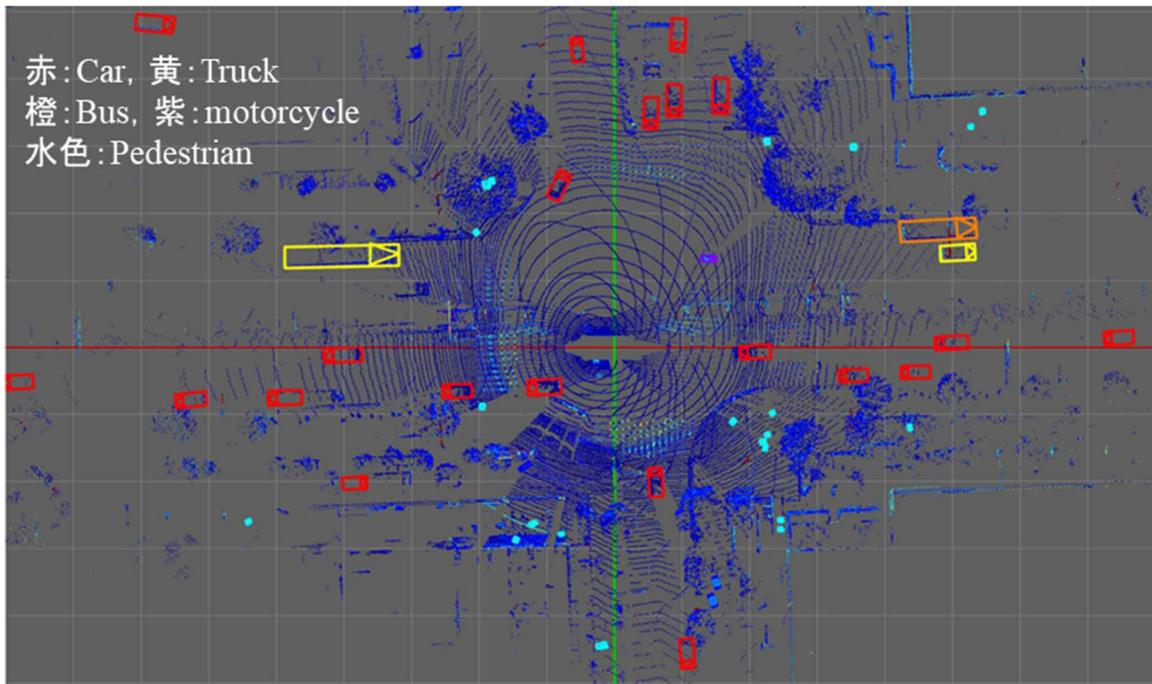
(b) 右側カメラ



(c) 左側カメラ



(d) 後方カメラ



(e) LiDAR データに対するタグ付けデータ

図 2.5.①-9 お台場の走行データに対するタグ付け結果の様子

---

---

【参考文献】

- [1] 高津知里, 米陀佳祐, 菅沼直樹, 車載マイクロフォンを用いた緊急車両の認識, 自動車技術会春季学術講演会, 2022年5月発表予定, 2022.
- [2] 消防庁, 救急自動車に備えるサイレンの音色の変更について, 消防防第337号通知, 1970.
- [3] K. J. Piczak, ESC: Dataset for Environmental Sound Classification, Proceedings of the 23rd Annual ACM Conference on Multimedia, Brisbane, Australia, pp.1015-1018, 2015.

---

---

## ② 人工知能(AI)を活用したデッドロック回避

デッドロックを回避するシーンとして、緊急車両を優先して走行させるために、自動運転自動車が避ける制御を行うことも想定される。特に、緊急車両が自動運転自動車から遠方に存在する場合、デッドロックが生じる前に回避を行うことが可能である。2021年度は、画像認識による緊急車両の認識アルゴリズムを開発する。また、緊急車両を優先して走行させるためのデッドロックシーンを検討し、シミュレーション環境を構築する。

### ・緊急車両のデータ収集

緊急車両の認識アルゴリズムを開発するために、緊急車両の学習データが必要である。まず、金沢市内を走行し、緊急車両を含む走行映像を収集した。その際、緊急車両が写っている時刻を記録しておく。後日、その時刻を基準として画像データに変換する。表 2.5.②-1 に収集したデータ数および緊急車両の種類を示す。緊急車両として、消防車、救急車、パトカーが含まれる。ここでは、まず救急車とパトカーを対象クラスとする。各シーンに映るこれらの緊急車両と収集枚数から、No.3, No.6, No.8 および No.9 を学習用データとした。これらの学習用データに対してアノテーションを行った。実際に緊急車両が写っているフレーム数は、253 枚で、うち救急車が 96 枚、パトカーが 157 枚である。緊急車両が写っているシーン例を図 2.5.②-1 に示す。

表 2.5.②-1. 緊急車両データの収集

シーン	収集枚数	クラス	アノテーション
No. 1	183 枚	消防車	なし
No. 2	685 枚	消防車	なし
No. 3	475 枚	救急車	あり(38 枚)
No. 4	410 枚	パトカー(バン)	なし
No. 5	248 枚	パトカー(セダン)	なし
No. 6	227 枚	救急車	あり(58 枚)
No. 7	306 枚	パトカー(セダン)	なし
No. 8	220 枚	パトカー(ミニパト)	あり(94 枚)
No. 9	204 枚	パトカー(ミニパト)	あり(63 枚)



(a)No.3

(b)No.6

(c)No.8

図 2.5.②-1 緊急車両が写っているシーン例

### ・ 緊急車両の認識アルゴリズム

緊急車両の認識アルゴリズムとして、遠方の物体検知で利用している YOLOv4[1]を用いる。まず、東京臨海部で収集した物体検出用データセットを用いて、YOLOv4 を学習する。東京臨海部のデータセットは、一般車両、歩行者、自転車、信号機の各種状態を含む 7 クラスを検出対象としている。東京臨海部のデータセットで学習後、緊急車両のクラスを追加して 9 クラスにより追加学習を行う。最初に 7 クラスで学習することで、車両に搭載したカメラから取得した映像を入力とする物体検出に適した特徴を獲得する。そして追加学習することで緊急車両に適した特徴を追加して獲得できるようにする。追加学習する際、緊急車両のデータのうち、No.6 と No.9 を学習に利用する。

### ・ 緊急車両の検出結果

緊急車両の検出結果を図 2.5.②-2 に示す。一般的な車両や信号機など従来対象としていたクラスに加えて、救急車やパトカーを検出することができていることがわかる。



(a)救急車

(b)パトカー

図 2.5.②-2 緊急車両の検出例

図 2.5.②-2(a)のシーンにおいて、各フレームの検出結果を確認する。図 2.5.②-3 に前後のフレームでの検出結果を示す。救急車のライトが消灯している時刻では、car(一般的な車両)として検出している。一方、救急車のライトが点灯している時刻では救急車として検出している。これより、救急車の特徴として、ライトが点灯していることを学習できていることがわかる。図 2.5.②-4 にパトカーが映る複数フレーム間での検出結果を示す。パトカーも同様に、ライトが消灯している時刻では、car として検出しており、ライトが点灯している時刻ではパトカーと検出している。これより、パトカーもライトが点灯していることを特徴として学習していることがわかる。



図 2.5.②-3 救急車が通過するシーンにおける検出結果例

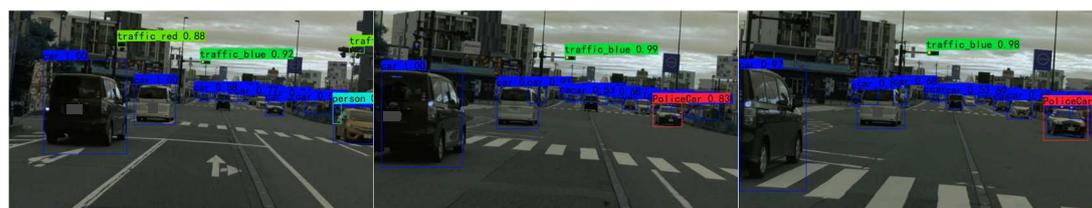


図 2.5.②-4 パトカーが通過するシーンにおける検出結果例

#### ・ シミュレーション環境の構築

緊急車両の走行を妨げずに優先するシーンとして、渋滞しているシーンが考えられる。まず、緊急車両が後方から来るシーンを想定し、複数の他車両と連携して、緊急車両が通過できるスペースを空けるように経路計画できるか検討するシミュレーション環境を構築する。構築したシミュレーション環境を図2.5.②-5に示す。今後、本環境において、AIを活用した経路計画を行うことができるよう、深層強化学習モデル[2]および学習時の報酬などの諸条件を検討していく。

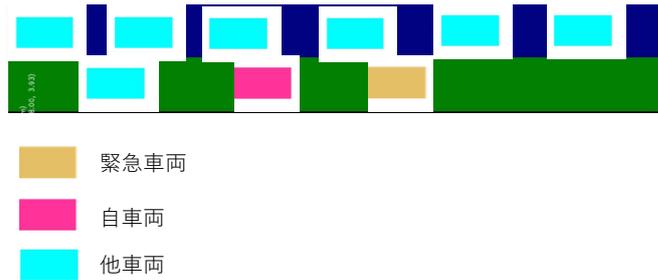


図 2.5.②-5 緊急車両とのデッドロック回避を検討するシミュレーション環境

・まとめ

2021年度は、緊急車両とのデッドロックを回避するために、緊急車両のデータ収集および認識アルゴリズムの検討を行った。データは金沢市内で9シーン収集することができた。緊急車両として、救急車とパトカーを対象とし、物体検出アルゴリズムを学習および評価した。2つの評価シーンにおいて、緊急車両のランプが点灯している際、それぞれ正しく認識できている。一方、ランプが消灯している際、一般車両と認識することがある。今後、距離による認識精度の限界を確認するとともに、時系列での緊急車両の認識を検討する。

また2021年度は、AIを活用して緊急車両とのデッドロック回避を検証するためのシミュレーション環境を構築した。構築した環境は、渋滞時に後方から緊急車両が走行するシーンとした。今後、本環境において、他車両と連携し、スムーズに緊急車両が走行できるスペースを空けることができるか検討する。

【参考文献】

[1] J. Wang et al., “Deep High-Resolution Representation Learning for Visual Recognition”, CVPR, 2019.  
 [2] 五藤ら, “複数車両の情報を考慮する深層強化学習を用いたデッドロック問題の解決”, 自動車技術会, 2020.

### 2.6.f. 「実証実験」

2020年度に引き続き、2019年度に構築した2台の試験車両を用いて東京都臨海部および石川県金沢市の中心部等における走行実証を継続的に実施した。図2.6-1および図2.6-2に2019年度に構築した車両の概要を示す。



図 2.6-1 センサ搭載済みの試験車両内の外観

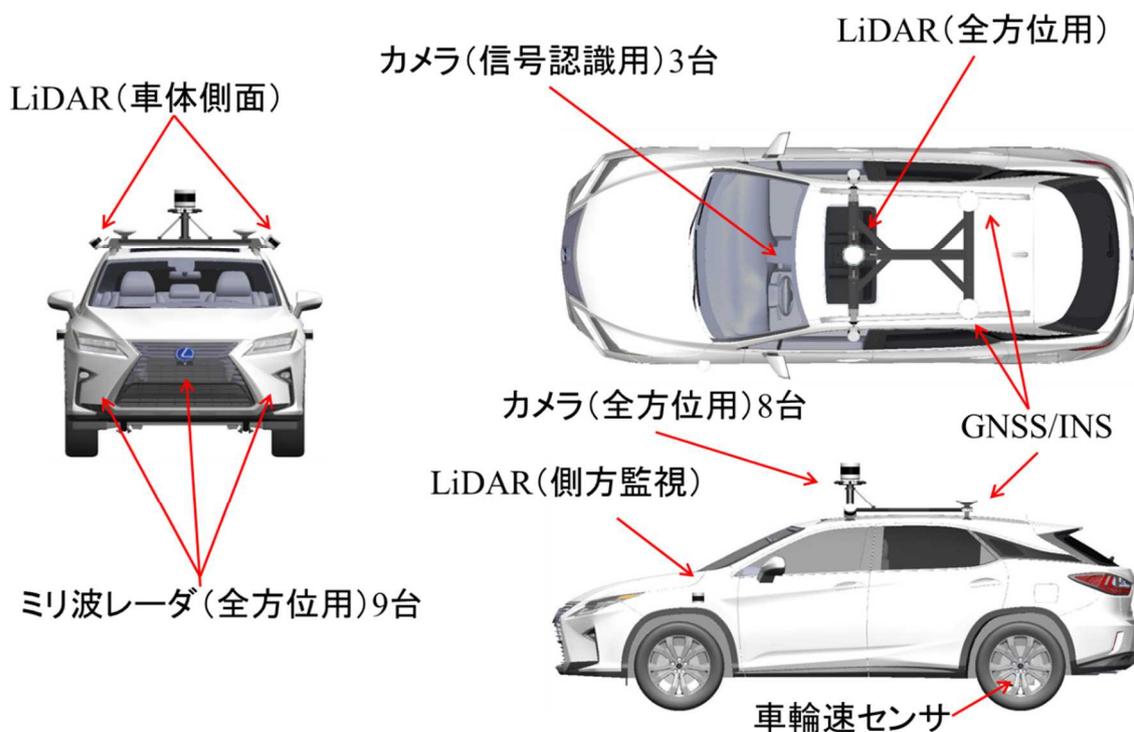


図 2.6-2 試験車両に搭載したセンサの搭載概要

図 2.6-2 に示すように、2020 年度までは自律型の自動運転機能を構築するため、自動車の周辺環境認識用センサとして、カメラ・LiDAR といった光を使用して周辺環境認識を認識するセンサと、ミリ波レーダといった電波を使って周辺環境認識を認識するセンサのみが搭載していた。一方、2021 年度は 2.5.e「自律型自動車が走行する状態での問題点の検討」節でも述べたように緊急車両のサイレン音の認識も可能とするため、図 2.6-3 に示すように新たに自動運転自動車の周辺環境の環境音を計測可能なマイクも新たに追加し、走行環境音を含めた走行環境情報の収集を可能とした。



図 2.6-3 試験車両に搭載した環境音計測用マイク

さらにインフラ協調型の自動運転機能の構築のため、SIP 別施策として実施されている東京臨海部実証実験において、2021 年度から実施された V2N (Vehicle to Network) を使用した実証実験に参加すべく、2020 年度まで使用していた実証実験用車載機に加え、セルラー通信によってインフラからの情報を取得可能な車載機を新たに搭載し、実証実験を実施した。図 2.6-4 に車両に搭載したセルラー通信を行うルータ、および車載機を示す。

V2N 実証実験では、降雨情報、車線別道路交通情報、緊急車両位置情報、信号予定情報といった 4 項目に関する情報がセルラー通信経由でネットワークから配信され、これを受信することで自動運転車両の自動運転を支援することが可能となる。各配信情報の概要を下記に示す。



(a) セルラー通信のルータ



(b) V2N 情報受信用車載機

図 2.6-4 V2N 実証実験用の機材

- ・ 降雨情報

気象庁から配信される降水量予報をネットワークによって配信し、自動運転車両が V2N を介して情報を受信することで、例えば降水量に応じた自動運転車両の ODD (Operational Design Domain) を踏まえた、自動運転の継続性の判断等に反映させることなどが可能となる。

- ・ 車線別道路交通情報

主に高速道路等において収集されたプローブ情報等から生成された、渋滞の発生個所、時刻等の情報を、V2N を介して受信することで、例えば渋滞区間を回避した適切なルート選択や車線を選択することなどが可能となる。

- ・ 緊急車両位置情報

---

---

緊急車両の位置情報を，V2Nを介して受信することで，例えば自車周辺に緊急車両が接近している際に，自動運転状態から手動運転状態への遷移要求や，緊急車両の走行を妨げない運転行動の選択をすることなどが可能となる．

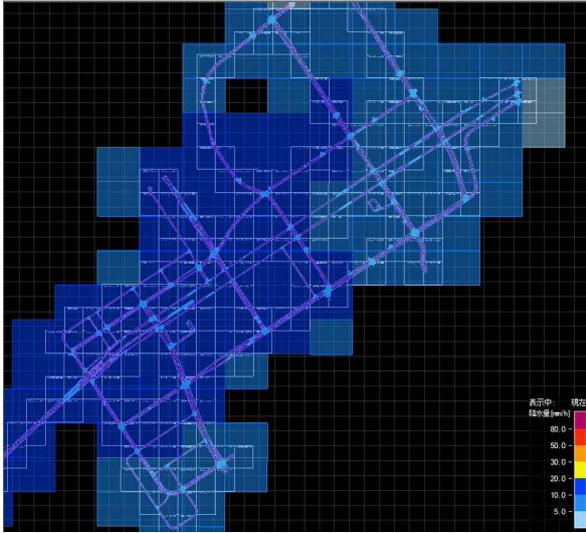
・ 信号予定情報

2020年度まで実施されていたV2I（Vehicle to Infrastructure）と同様に，セルラー通信を使って信号機の情報（現時情報や残秒数情報など）を取得することで，例えばカメラによる信号認識やV2Iに加えV2Nといった多重系による信号譲歩の取得とそれに基づく，安全円滑な交差点進入を実現することなどが可能となる．

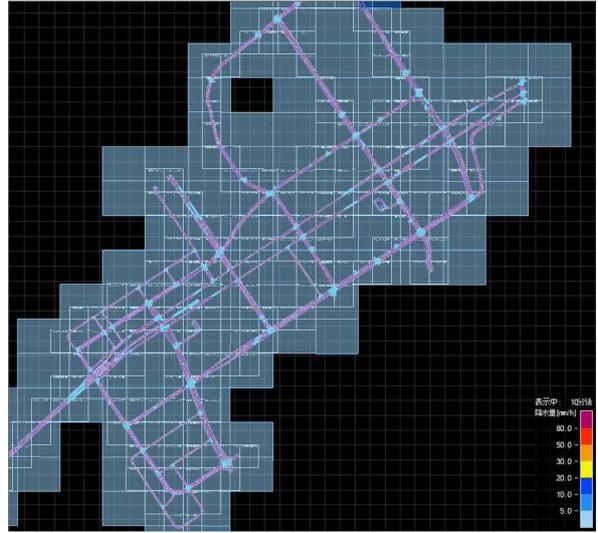
これらの情報のうち，本プロジェクトでは一般道向けの情報が配信されている降雨情報，信号予定情報，緊急車両情報を中心としたデータ配信を受け，データ収集を行った．図2.6-5にこれらの情報のうち降雨情報の配信例について示す．また緊急車両位置情報の配信概要については2.5.e.「自律型自動車が走行する状態での問題点の検討」説の項目を参照されたい．なお，信号予定情報に関しては，2022年度にこの情報を用いた実証実験を実施予定としている．

また図2.6-6に示すように，2021年4月20日，21日に東京臨海部において実施されたメディア向け試乗会に参加し，試験車両の展示，試乗機会の提供等を実施し，社会受容性向上に資する取り組みについても実施した．

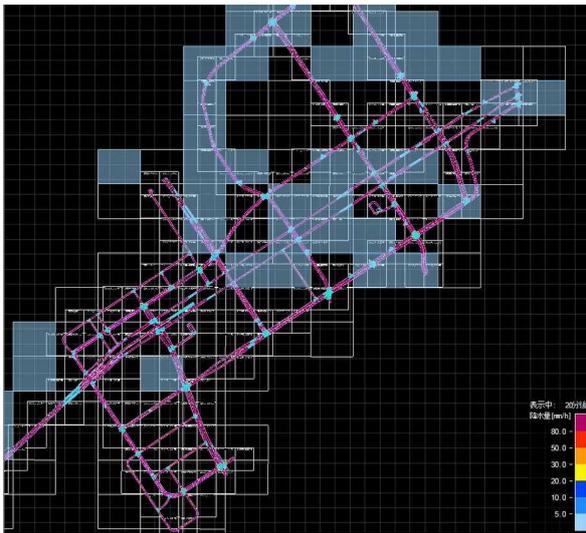
そしてこれらの取り組みを通し，2021年度は東京臨海部での走行実証実験に関しては合計61日間実施し，自動運転状態で約1,075.4kmを走破した．



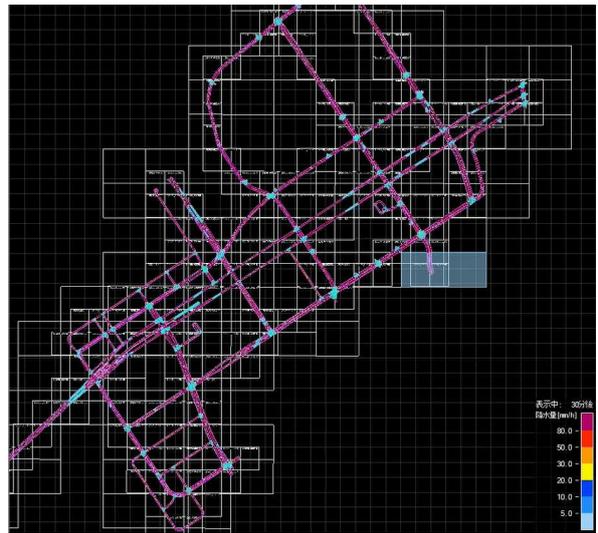
(a) 現在時刻の降水量



(b) 10分後の予想降水量



(c) 20分後の予想降水量



(d) 30分後の予想降水量

図 2.6-5 降雨情報の配信例 (2021年12月14日正午ごろのお台場の様子)



図 2.6-6 メディア向け試乗会における車両展示の様子

### 3. 実施体制

