

2019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

2020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（N E D O）の委託業務として、国立大学法人 金沢大学，学校法人中部大学 中部大学，名城大学が実施した「戦略的イノベーション創造プログラム（S I P）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」の2019年度成果を取りまとめたものです。

従って、本報告書の著作権は、N E D Oに帰属しており、本報告書の全部又は一部の無断複製等の行為は、法律で認められたときを除き、著作権の侵害にあたるので、これらの利用行為を行うときは、N E D Oの承認手続きが必要です。」

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。

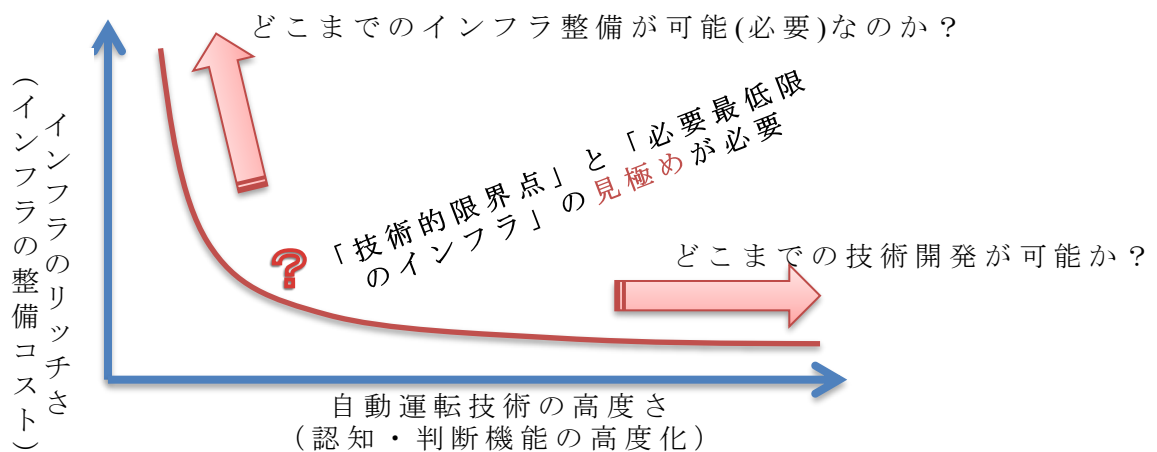


図 1.1-1 インフラのリッチさと自動運転技術の高度差の関係

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。

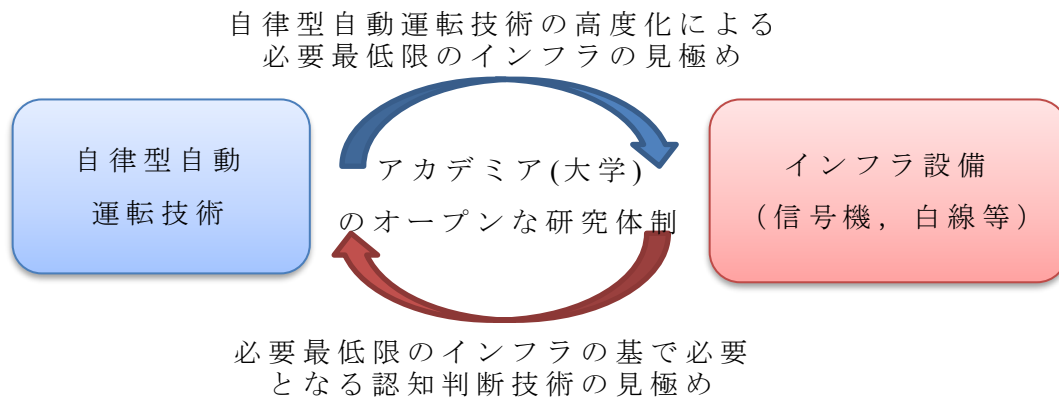


図 1.1-2 必要最低限のインフラの見極めと認知判断技術の見極め

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. 「交通参加者の行動予測推定とそれに基づくパスプランニング技術の開発」
- e. 「複数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」




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通信としてインフラ支援方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2019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る。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%の達成を目指す。非常に厳しい日照条件で視認性の低い状況も含めた実用的な側面からの性能評価も行う。

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で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 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、インフラ支援信号情報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こ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たり風景に溶け込んでいたりする場合や、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、従来の矩形や円形特徴を認識する手法だけで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。

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は学習データセットが不可欠であり、学習したデータと類似する走行シーンや天候において高い精度を再現できる。一方で、様々な道路や町並み、特に天候を網羅した実環境のデータセットを用意することは困難である。このような課題に対して、2019 年度は、セマンティックセグメンテーショ

ンをベースとした信号機認識アルゴリズムによる認識精度が 95%を達成できるかを検証する。

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」

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。従来の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。

以下に実施内容および 2019 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

一般的な車載カメラは視野角 100 度程度であり、画像サイズが 1024x786 の場合、50m

遠距離に存在する歩行者の高さは 37 ピクセル、70m 遠距離に存在する歩行者の高さは 27 ピクセル程度と小さい。また、車載カメラは特定の距離に焦点を当てるため、その距離よりも遠方はピントがずれて物体がぼやけてしまう課題がある。これらの課題に対して、2018 年度は遠距離の物体検知に適した視野角および高画質化機能を有するカメラを評価し、目標達成に必要なカメラの仕様を検討する。

一般的な車載カメラは視野角 100 度程度であり、画像サイズが 1024x786 の場合、50m 遠距離に存在する歩行者の高さは 37 ピクセル、70m 遠距離に存在する歩行者の高さは 27 ピクセル程度と小さい。また、車載カメラは特定の距離に焦点を当てるため、その距離よりも遠方はピントがずれて物体がぼやけてしまう課題がある。これらの課題に対して、2019 年度は遠距離の物体検知アルゴリズムにより、50m 遠距離に存在する歩行者や車両の検知が可能かを検証する。

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、認識距離に改善を試みる。

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。また、道路には様々な状態の白線が存在し、自動運転システムは白線を認識して走行する場合もあるので、白線の状態

が自動運転システムに与える影響について調査を行う。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関し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、③白線の状態が自動運転システムに与える影響の調査に分け、実施内容および2019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年度では信頼度を高く0.3mの位置精度を達成することを目的として、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った。

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する。

具体的には、GNSS/INS とマップマッチング手法を連動して運用しつつ、マップマッチング時の地図の特徴と LiDAR のスキャンデータの関係から、車両位置を推定するだけでなく誤差状態をマッチングの信頼度として同時に推定する。また、この誤差状態の情報を分析してインフラに関する検討を可能にすることを目指す。

これを実現するため、2018 年度に複数方式のマップマッチング手法について調査し、評価ルートを選定を行なった。また、2019 年度においては目標精度 0.1m の位置推定精度を達成することを目的として、複数方式のマップマッチングアルゴリズムの実装・評価を行なった。

③ 白線の状態が自動運転システムに与える影響の調査

高速道路および一般道路には様々な状態の白線が存在し、自動運転システムは白線を認識して走行する場合も存在する。このため、白線の状態が自動運転システムにどのような影響を与えるかについて事前に把握しておくことが必要となる。このため、本事業では車載センサから得られるセンサ情報をもとに、道路上の白線領域を抽出するアルゴリズムの検討を行い、その情報に基づき白線の状態の目安を把握する手法について検討する。

2019 年度は、道路上の白線領域を抽出するアルゴリズムの基礎検討を行う。また、白線の状態を把握する目安の基礎検討を行う。

d. 「交通参加者の行動予測推定とそれに基づくパスプランニング技術の開発」

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大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。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2019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

歩行者や車などの移動体が未来の時刻にどのような経路で移動するかを推定する技術である経路予測において、移動体が経路を決定する要因は、対象物体周囲の環境などの外的要因と予測対象自身が保有している内的要因に分けることができる。外的要因は、例えば歩行者と車がガードレールなどで隔てられていない場所を走行する場合、側道に車が停車していると歩行者は走行路にはみ出して歩く、というような状況である。一方、内的要因は、性別や年齢などの属性情報であり、例えば子供は周辺に注意を向けることなく、急に道路に飛び出す、というような状況である。このような状況において、パスプランニングを実現するためには、移動体の行動を予測することが重要となる。そこで、歩行者の属性を内的要因として推定し、走行の周辺環境を外的要因として理解することで、属性情報を考慮した将来の軌跡を予測する手法を確立する。2019年度は行動予測に必要な歩行者の属性認識アルゴリズムの開発および評価を行う。

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う．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う．

e. 「複数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．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2019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描画する技術、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描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う。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件以上明らかにする。

② 人工知能(AI)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、パスプランニングを行う際、あらかじめ決められたルールに従い、経路計画を行う。しかしながら、実世界では、全てのシーンに対するルールを明確に決めることは困難であり、その場に応じて柔軟な経路計画が求められる。そこで、AIを活用して柔軟な経路計画を立てることができるようにする。特に、実世界で生じるようなデッドロック状態に対して、AIが有効であるかを確認する。2019年度は、実証実験を通じて発生したデッドロック状態を対象として、深層強化学習によりデッドロック回避を行うアルゴリズムを検討する。

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、ウイ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。

2019 年度は公道走行に必要な地図や安全性評価等の事前準備を進めるとともに、石川県金沢市における基礎的な公道走行試験を進める。また、SIP 他事業により整備された通信設備を有する信号機(信号インフラ)を用いて東京臨海部における走行試験を開始する。さらに、準天頂衛星システムみちびきを利用可能なシステム構築を行い、この衛星情報を活用した走行試験を実施する。

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

今年度の実施項目として、昨年度選定した HDR (High Dynamic Range) 機能及び LFM (LED Flicker Mitigation) 機能を有するカメラを利用した東京臨海部での走行データの計測を 2019 年 9 月より開始した。半年以上にわたり継続したデータ計測を実施することで、逆光、雨天、夜間などの異なる条件における信号機認識への技術的課題を分析した。また、その他の実施項目として遠方矢印灯の認識率を改善するための認識アルゴリズムの開発に着手し、デジタル地図情報を活用することで 10 ピクセル以下の小さな矢印灯の認識を実現した。ここで開発してきた認識アルゴリズムを用いて東京臨海部の走行データに対する性能評価を実施し、通常的环境や夜間、雨天時などの条件によらず 95%以上の認識率を確認した。一方、逆光時ではカメラと信号機及び光源が一直線に並ぶときに画像が部分的に飽和する現象を確認している。こうしたハードウェアによる性能限界の発生条件を分析することが今後の課題となる。

また、インフラ支援型信号機から得る信号状態の先読み情報を活用した交差点進入判断アルゴリズムを開発するため、大学内の非公道における検証実験を実施した。ここで、開発した交差点進入判断アルゴリズムを活用した自動運転走行を非公道で実施することで、ジレンマゾーンにおける急減速を回避可能な点を検証した。

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

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について、東京臨海部を走行して撮影したデータを用いて学習・評価した。信号機認識には地図を用いないため、信号機の位置を特定する検知機能と信号機の状態を識別する識別機能が必要となる。検知機能は、DeepLabV3+ベースのセマンティックセグメンテーションにて行う。識別機能は、畳み込みニューラルネットワークベースの手法にて行う。120m 以内において、信号機の検知精度は 96.42%、信号機の識別精度は 95.18%であった。信号機認識の目標である 95%をクリアしている。検知精度を含めた全体精度は 91.78%である。夜間や逆光時に、信号機の検知および識別精度が低下している。これは、識別機能を学習する際のデータに偏りがあるためだと考える。今後は夜間の信号機認識精度向上を検討する。

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

物体検知アルゴリズムには、高精度な手法、高速な手法など様々な手法が提案されている。これらを両立し、かつ遠距離の物体を対象とした手法は現時点ではない。そこで、高精度な Feature Pyramid Network(FPN)をベースとし、ネットワーク構造を探索する MnasNet による高速化を行なった。MnasNet は、高速な MobileNet をベースネットワークとし、FPN ネットワークの長所であるエンコーダ・デコーダの構造自体の仕組みを探索する手法である。これにより、エンコーダとデコーダ内の接続関係を最適化できる。東京臨海部のデータセットを利用して、ネットワーク構造の探索を行うことで、処理速度を FPN よりも高速にしつつ、35 ピクセル程度の 50m 離れた歩行者および 135m 離れた自動車の検出ができていることを確認した。今後は 70m 以上遠方の歩行者および 200m 以上遠方の自動車の検出が可能か検証する。

②. LiDAR およびミリ波レーダに基づく遠方物体認識

今年度の実施項目としては昨年度に評価した 3 次元 LiDAR を用いた遠方物体の認識精度を評価した。評価では 3 次元 LiDAR を搭載した試験車両を用いて金沢市内並びに東京臨海部で走行データを計測し、自動車、二輪車及び歩行者をラベル付けしたデータセットを作成した。さらに、生成した識別器の遠方での物体識別精度を定量的に評価するために距離別に評価データセットを計測し、F 値に基づく識別精度の評価を実施した。評価データセットに対して 2019 年度の目標である自動車 135m 及び歩行者 50m を 90% の認識率を達成した。しかし、遠方物体を認識するに当たり、LiDAR で観測可能な点群のスパースさが課題となる。認識距離を更に改善するには、カメラやミリ波レーダなど他のセンサとのフュージョンした認識アルゴリズムの開発が必要である。

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 年度に確認している。2019 年度の目標は、1.5m を 80% の範囲での達成であり、既に目標は達成することができている。

そこで、2019 年度は 30cm の位置精度を判定する手法の検討を中心に実施した。従来手法では、GNSS 測位結果の信頼性を示す要素として、Kinematic 測位の FIX 解が用いられることが多い。しかし、都市部では誤差の大きい FIX 解が発生する問題があり、そのまま自動車の制御に用いることはできない問題があった。そこで本提案では、FIX 解の中から自動運転に必要な平面 0.3m の精度を判定することを目指し、走行時の高さ変動を利用した、信頼性の高い FIX 解を検出する手法を提案した。具体的には、時系列的な RTK の FIX 解を利用して、車両に搭載された加速度計の誤差を補正することで FIX 解の外れ値除去と加速度計の誤差推定を同時に実現し、その結果から推定した高精度な高さ変動により、FIX 解の信頼性判定を実施した。評価試験により、測位結果は、都市部である東京都お台場付近、東京都新宿付近で、判定の精度が 99%で実現できる可能性を確認した。

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、2018 年度に候補として選出したマップマッチングアルゴリズムの中から、代表的かつ自動運転での実績がある 2 つの方式として①3次元点群を用いた NDT スキャンマッチング ②2次元の路面パターン画像を用いたテンプレートマッチングの 2 つの手法を実装し、位置推定精度と処理コストの観点から各アルゴリズムの評価を行なった。2018 年度に選出した評価ルートの地図データを、2019 年 7 月と 2019 年 12 月の 2 回にわたり計測し、季節の変化による位置推定精度への影響の調査を行なった。評価結果として、各マッチング方式について目標精度である 0.1m を達成可能であることを確認した。季節の変化による影響については、今回計測した地図データから植物の変化による位置推定結果への影響を検証することができたが、その他のシーンについては今後も継続的なデータ収集および評価を続けていく必要がある。また、東京臨海部での実証実験により確認された課題についての整理を行い、精度改善のための対策の検討を行なった。

③. 白線の状態が自動運転システムに与える影響の調査

白線の状態を把握する手段として (1) 道路上の白線領域を抽出するアルゴリズム、および (2) 白線の状態を把握する目安の基礎検討を行った。(1) については、セマンティックセグメンテーションを用いて車載カメラ画像から白線の認識を行うこととする。ただし車載カメラだけでは白線反射率を計測できないので、今後は車載カメラと車載 LiDAR のセンサフュージョンを進める予定である。(2)については、「白線の反射率」「白線と舗装のコントラス

ト」「白線のかすれ具合」の3項目に分けて検討を行った。反射率およびコントラストについては、車載LiDARによる自動計測値と市販の手動計測器（リファレンス）による計測値を比較して同じ傾向があることがわかったので、車載LiDARによる反射率計測は有効であると考えられる。かすれ具合については、リファレンスとなる市販の手動計測器が存在しないのでデジタル一眼レフカメラによる手動計測器を作製し、画像処理を用いて算出した剥離率をかすれ具合の目安とした。作製した手動計測器による剥離率を全国道路標識・標示業協会が定める5段階の目視評価ランクの剥離率と比較することで、作製機器のリファレンスとしての妥当性を検証した。

d. 「交通参加者の行動予測推定とそれに基づくパスプランニング技術の開発」

①.人工知能(AI)に基づく歩行者の行動予測

歩行者の行動予測に向けて、歩行者の属性を認識するアルゴリズム開発を行った。歩行者の性別や年代、鞆の保持など詳細な情報を認識できれば、歩行者が取りうる経路の予測精度向上につながる。歩行者属性認識には、Attention Branch Network (ABN)をベースとした。ABNは、認識する際に注目すべき領域を獲得することができ、認識精度向上が期待できる。一般的な歩行者属性認識のデータベースにおいて、既存手法を上回る精度を達成した。今後は、歩行者属性認識結果を反映した高精度な行動予測手法を実現する。

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

市街地自動運転走行におけるパスプランニングの性能を改善するためには、多種多様な移動物体の運動状態を精密に認識し、物体の種別に応じて将来の運動状態を予測して自車の走行軌道を生成する技術が重要となる。今年度はExtended Object Tracking (EOT)を用いた移動物体の運動状態と形状の同時推定アルゴリズム及び地図に基づく移動物体の行動予測アルゴリズムの開発に着手し、自動運転走行中の周辺状況の予測技術の改善を図った。

また、2019年9月から実施している東京臨海部における実証実験において、開発しているアルゴリズムを順次導入していきながら自動運転走行への寄与を検証している。検証では、自動運転走行におけるシステムが要因となるオーバーライドの発生頻度として平均走行持続距離を算出することで自動運転システムの全体の性能を評価している。この結果、今年度末の自動運転走行の実証実験において、今年度の目標値である平均走行持続距離 2.5km を達成

した．オーバーライドの発生頻度の要因を分析し，平均走行持続距離を改善することが今後の課題である．

e. 「複数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

2019年9月から開始した東京臨海部での自動運転走行実験中，交差点走行において実際の交通ルールにそぐわない駐車車両により，自動運転システムでデッドロックが発生しそうな状況に遭遇した．自動運転車両は交通ルールに厳密に従うようにプログラミングされているものの，交通ルールにそぐわない他車が存在する場合にデッドロックが起これると思われる．このような状況や他の状況で起これうるデッドロック事象を調査・分析するため，複数の自動運転車両を考慮したシミュレータの開発に着手した．開発したシミュレータではユーザによるハンドル入力によって一般ドライバーも加えた走行シミュレーションが可能である．

開発したシミュレータを活用することで，交通ルール違反・譲り合い及び物理的制約を考慮した5種類の環境でデッドロックが発生する状況を考察した．具体的には，交通ルール違反として交差点付近に駐車車両が存在する状況，譲り合いとして幹線道路への合流及び駐車場出入り口，物理的制約として直線路及びカーブにおける見通しの悪い道路での駐車車両の追い越しのそれぞれのシーンに注目してシミュレーションを実施した．これらの5種類の環境でデッドロックが発生しうることを確認し，今年度の目標値である5種類のデッドロックのシーンを発見した．デッドロックの発生要因を詳細に分析することが今後の課題となる．

②. 人工知能(AI)技術を活用したデッドロック回避

東京臨海部における実証実験を通じて，デッドロックが生じるシーンをいくつか抽出し，AIによる自動運転車が走行した場合に，デッドロックの回避可能かを検証した．検証シーンは，1)走行車線に駐車車両があり，対向車を避けて走行するシーン，2)信号待ち時に対向車線に駐車車両があり，右折車が来た時に相手の走行領域を空けるようなシーンである．適切な報酬設計を行い強化学習することで，AIによる自動運転車はこのようなシーンでも衝突を回避する走行ができることを確認した．今後は，その他のデッドロックが生じるシーンへの拡張および深層強化学習の報酬設計の自動化を検討する．

f. 「実証実験」

昨年度検討した試験車両および試験車両に搭載するセンサ, コンピュータ等を購入し, 2 台の試験車両を構築した. また, 東京都臨海部および石川県金沢市の中心部での走行実証に必要な地図の制作等を実施した. さらに, 東京臨海部に設置されている通信機能を有する信号機からの情報取得を可能とするため, ITS 無線機の試験車両への搭載および解析ソフトウェアの構築を進めた. また, 構築した試験車両を用いた公道走行実証実験を安全に遂行するため, 第三者機関による安全性検証を実施し, 2019 年 7 月から石川県金沢市中心部において走行実証実験を開始した. また, 2019 年 9 月から東京臨海部での走行実証実験を開始した. 東京臨海部での走行実証実験に関しては今年度合計 67 日実施し, 自動運転状態で約 850.6km を走破した. また, ITS 無線を活用した実証実験に関しては 32 日間実施し, 当初の目標を達成した.

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。今年度は信号灯及び矢印灯の認識に関して 120m 以内の認識率 95%を目標として以下の研究開発を実施した。

- ・ デジタル地図を活用した信号灯・矢印灯認識アルゴリズムの検討
- ・ 東京臨海部の走行環境における信号認識の性能評価
- ・ 特異環境試験場における信号認識の性能評価
- ・ 取得画像のタグ付け（セマンティックセグメンテーション）
- ・ 先読み情報を活用した交差点進入判断アルゴリズムの基礎検討

以降では具体的な研究開発成果について個別に述べる。

・ デジタル地図を活用した信号灯・矢印灯認識アルゴリズムの検討




図 2.1.①-1 オンボードカメラによる信号機画像(a),(b)と ROI 領域の抽出(c)

画像処理による信号機認識に関する研究として、頑健な認識を可能とするためにデジタル地図を活用した信号機の検出方法がこれまでに多く提案されており[1][2][3], 本研究ではこれまでに単眼カメラと車両位置及びデジタル地図を活用した信号認識アルゴリズムを開発してきた[4]. デジタル地図を活用した信号機認識の主な手順は以下の通りである.

- (1) ROI 抽出 : デジタルマップを用いて, 画像上の信号機領域 (RegionOf-Interest, ROI) を探索する
- (2) 候補検出 : 候補交通信号として ROI 内の照明領域を抽出する
- (3) 状態認識 : 色相の情報や機械学習を用いて信号状態を分類する

車両位置とデジタル地図上の信号機の座標との相対的な位置関係から各信号機の画像上の ROI を算出可能である. しかし図 2.1.①-1(c) に示すように, ROI 内に複数の信号機や背景の照明などが観測される場合がある. そこで我々はこれまでに, ROI 内の信号機位置を表す存在確率を定義し, 他の点灯物の誤検出を低減する方法を提案してその性能を示した[4]. 図 2.1.①-2 に前年度までに基礎検討してきた信号認識アルゴリズムのフローチャートを示す. デジタル地図と自車位置を用いてカメラ画角内の信号灯位置を抽出し, ROI を設定する. この ROI は撮影画像上で信号機が存在する位置を示すため, この領域内で信号機の点灯領域の認識を行う. 一般的に信号灯火は, 周囲より明るい色をもつこと, すなわち高い彩度と明度を持つ特徴があるため, HSV 画像がもつ彩度(S)画像と明度(V)画像の積をとって得られる特徴画像を用いて信号灯領域を強調する. 加えて図 2.1.①-2 のように信号機の点灯色に近い画素を重み付けることで背景の誤認識を抑えた特徴画像(点灯部強調画像)を作成して点灯領域を認識する[5]. 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)や矢印信号(左, 直進, 右)の有無も含まれている. そこで対象の信号機が矢印信号を持つ場合, 矢印信号の状態認識を行う. 矢印認識は事前に機械学習アルゴリズムによって訓練された矢印検出器によって認識される. デジタル地図に登録された矢印信号の向きに合わせて画像を回転させながら任意方向の矢印灯を検出する.




図 2.1.①-2 信号認識アルゴリズム

・ デジタル地図情報を活用した矢印灯認識アルゴリズムの開発

市街地走行環境の信号機認識において 120m 以上先の信号灯及び矢印灯を高精度に認識するためには，ピクセル数の小さな点灯物を安定して認識可能なアルゴリズムを開発することが重要となる．車載カメラとして一般的な 50～60 度程度の水平画角を有するカメラを用いて認識する場合，フル HD クラスの解像度のカメラでも 100m 程度先の信号灯は 10px 以下の低解像度になることが試算可能である．この場合，遠方にある矢印灯の向きを認識することは容易ではなく，人間が見ても画像だけから矢印の向きを識別することが困難な場合も存在する．例えば，図 2.1.①-3 のように 150m 程度離れた信号機の画像では，矢印灯の領域がつぶれてしまい向きを適切に判別することは難しい．図 2.1.①-3 のように遠方の矢印灯の画像において，画像中でつぶれてしまった矢印領域を青信号の点灯領域の候補として誤認識してしまう状況が起こりうる．本研究では，デジタル地図の情報として信号灯と矢印灯の相対位置が与えられた場合に遠方の矢印灯を認識可能な方法を開発した[6]．開発したアルゴリズムでは，ここで検出した赤信号及び青信号（実際には矢印灯）の候補点に対してあらかじめ与えられた相対位置関係から，当該の候補点を矢印灯として検出する方法を導入する．これによって遠距離矢印灯の認識率

改善が期待される。




図 2.1.①-3 矢印等の認識アルゴリズム開発

ここで開発した認識アルゴリズムに対して，一般道で得られるデータを用いた性能評価を実施する．走行データは石川県金沢市及び珠洲市内にて計測したデータを使用しており，データの総数は信号灯及び矢印灯を合わせて 67,171 件ある．各データの内訳は以下の通りである．

表 2.1.①-2 事前評価に用いたデータ数

Label	Number of Data
Green	39,712
Yellow	2,513
Red	22,726
Left	711
Straight	372
Right	1,137

評価指標としては以下に示す，F-value を用いる．車両から信号機までの距離を 10m の区間ごとに分けて各区間での認識率の傾向を評価する．信号認識アルゴリズムにおいて開発した矢印認識アルゴリズムを導入するか否かによる比較，および最新の物体認識アルゴリズムとして YOLOv3[7]を比較手法として認識率を評価する．

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

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

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

ただし，TP は正解数，FP は誤検出数，FN は未検出数である．評価結果として各区間で得られる F 値の傾向を図 2.1.①-4 に，特徴的なシーンでの ROI 画像を図 2.1.①-5 に示す．グラフにおいて実線が信号灯の認識率であり，破線が矢印灯の認識率と対応している．この結果より提案方法の導入により矢印灯の認識率が改善している点を確認できる．遠方の矢印灯に対して同程度の認識率が得られる認識距離は 10～20m ほど増大していることから遠距離の矢印灯の認識への貢献が確認された．




図 2.1.①-4 石川県の市街地走行データにおける信号灯・矢印灯の認識結果

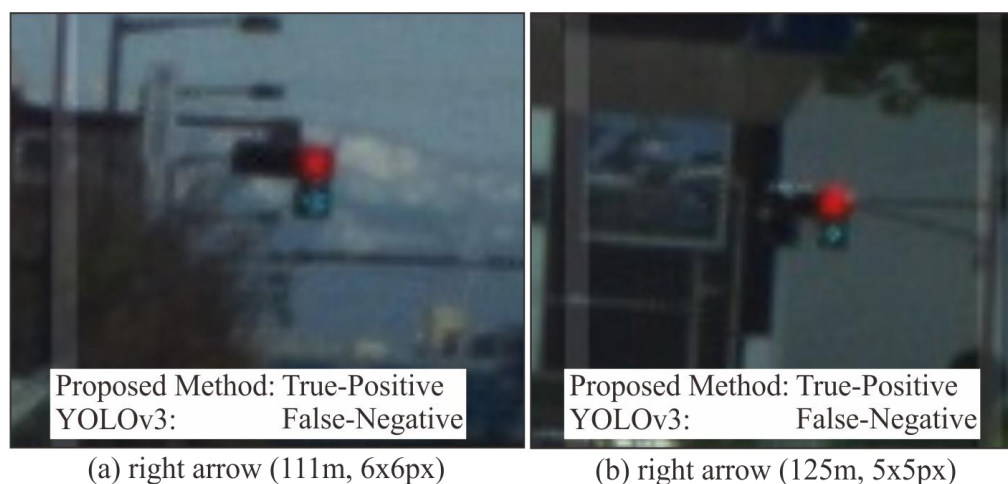


図 2.1.①-5 遠距離矢印灯の認識結果例

・ 東京臨海部の走行環境における信号認識の性能評価

今年度に開発した認識アルゴリズムを用いて、東京臨海部の走行環境における信号灯及び矢印灯の認識性能を評価する。ここでは昨年度選定した HDR 機能及び LFM 機能を持つカメラを使用して得られる走行画像を評価データとする。表 2.1.①-3 に計測した評価データの一覧を示す。総データ数は信号灯の評価データが 106,976 件（青信号、赤信号、黄信号、背景）、矢印灯の評価データが 9,718 件（左、右、直進、右・直進、左・直進）から構成されている。

表 2.1.①-3 東京臨海部の走行データに関する評価データ

	信号灯	矢印灯
昼	64,731	4,137
昼・雨	28,132	3,864
夜	14,113	1,717

上記の評価データに対して 150m 先までの範囲で 10m の区間ごとに Precision, Recall, F-value を算出し、各区間の F-value の平均値を算出して認識率を比較する。ただし、各区間で 30 件以上のデータがない場合は十分なデータ数がないとして無効とした。表 2.1.①-4 及び表 2.1.①-5 に、150m 以内及び 120m 以内の平均認識率を示す。

表 2.1.①-4 東京臨海部の走行データに関する評価データ（150m 以内の平均）

	信号灯	矢印灯	平均
昼	0.965	0.891	0.928
昼・雨	0.971	0.848	0.910
夜	0.968	0.883	0.923
全体	0.967	0.870	0.919

表 2.1.①-5 東京臨海部の走行データに関する評価データ（120m 以内の平均）

	信号灯	矢印灯	平均
昼	0.973	0.961	0.967
昼・雨	0.984	0.917	0.951
夜	0.978	0.948	0.963
全体	0.976	0.940	0.958

全体としては 120m 以内の信号灯を 95%以上で認識できており、矢印灯の認識率は若干低い傾向がある。表 2.1.①-5 における各項目の平均値をとると、天候条件によらず 95%を超える認識率が確認された。ここで得られた各条件の認識率の距離ごとの推移を図 2.1.①-6 に示す。





図 2.1.①-6 東京臨海部の走行データにおける認識率

これらの結果において特徴的な点としては、概ね全体的には Precision と Recall が同程度で推移している点が確認され、遠距離になると Recall が低下（未検出が増加）している結果が得られた。また、矢印灯の認識率を比べると、雨天のデータでは他の条件と比べて遠距離の認識率が低下している結果が得られた。さまざまな条件に対する性能評価を進めていくに当たり、今後も評価データの件数を増やして継続的な評価が必要である。評価に当たり確


認された特徴的なシーンのデータを図 2.1.①-7 に示す.




(a) 昼間の逆光時のシーン（左：右信号が太陽と重なり視認不可）



(b) 早朝の逆光のシーン（信号機が太陽と重なるが信号灯領域は視認可）



(c) 太陽光のビルの反射による逆光（右信号が反射光と重なり視認不可）



(d) 近距離で見上げるときの輝度低下

（左：False Negative，右：True Positive）

図 2.1.①-7 日中の走行データにおける特徴的なシーン

日中の走行データにおける認識への課題は逆光による影響が確認されている．カメラと信号機，太陽が一直線に並ぶときには太陽光周辺の領域が飽和して視認が困難となるケースが確認されているが，HDR 機能の効果により影


響の範囲は限定的でその他の領域では正常に信号灯を認識できている結果が得られた（図 2.1.①-7 (a)など）。その他，図 2.1.①-7 (d)のように近距離で見上げるケースでは点灯領域の輝度が低下するため条件によっては未検出となる問題が確認された。このような場合では画像の明るさを補正して一定のレベルに押し上げるなどの対応が必要と考えられる。

・ 特異環境試験場における信号認識の性能評価

特異環境試験場は，図 2.1.①-8 のように雨・霧・逆光を想定した条件下においてデータ計測が可能な施設である。昨年度は同試験場において，逆光・雨，霧などの条件下で HDR カメラによる効果を検証した。これまで東京臨海部における評価では逆光時にはハードウェアの性能限界により飽和するケースが確認されている。今年度はこうした飽和時の影響を再現するために逆光時の性能評価を特異環境試験場にて実施した。



(a) 試験場の様子



(b) 雨（左），霧（中央），逆光（右）

図 2.1.①-8 日本自動車研究所 特異環境試験場

本実験で実施した試験での対象物体の設置条件を図 2.1.①-9 に示す。ランプ式信号機及び LED 式信号機を車両初期位置（図 2.1.①-9 左側）から約 110m 及び 70m の位置に設置して車両が低速で接近しながらデータを計測する。また，逆光の試験の実施時にはランプ式信号機の後方に投稿器を設置しており，白色・黄色の疑似逆光を発生させて撮影を実施する。




図 2.1.①-9 特異環境試験場での対象物の設置条件例

走行時の信号機の点灯条件は以下の通りである．

- ランプ式：青色，LED 式：青色
- ランプ式：黄色，LED 式：黄色
- ランプ式：赤色，LED 式：赤色

上記の 3 種類の点灯状態に加えて，試験場の照明 ON/OFF，二種類の逆光時の 4 条件でデータを計測する．ある照明条件での走行データは各点灯条件ごとに記録しており，このデータに対する認識率を 10m の区間ごとに評価する．評価結果として各条件の認識率を表 2.1.①-6 に示す．また，図 2.1.①-10 に各距離での認識率の傾向を示す．この評価結果より，照明 ON 及び OFF のときには概ね 100%に近い認識率が得られたことが確認できる．特異環境試験場の疑似逆光ではスポットライトのように特定の地点に強い光を照射する特性があるため，逆光時の認識率では 70～80m 付近で認識率の低下を確認した．

表 2.1.①-6 照明条件の違いによる平均認識率

評価条件	評価条件
照明 ON	0.999
照明 OFF	0.998
逆光（白色）	0.980
逆光（黄色）	0.885






図 2.1.①-10 特異環境試験での異なる照明条件での認識率

得られた特徴的なシーンとして逆光時の撮影画像を図 2.1.①-11 に示す．逆光時では光源と信号灯との相対位置が接近しているときに点灯部の輝度低下が原因となる未検出が確認されている．また黄色の逆光では光源周囲のフレアの境界部を黄色信号の特徴として誤認識する場合も確認された．こうした西日を想定した条件での実走行データの評価は十分ではないため，西日のときに実環境でどのような課題があるかを評価することは今後の課題の一つと言える．



(a) 逆光（白色）



(b) 逆光（黄色）

図 2.1.①-11 逆光時の撮影画像

- ・ 取得画像のタグ付け（セマンティックセグメンテーション）

a②の事業において、セマンティックセグメンテーションの学習及び評価のためのデータセット整備が必要となる。市街地での自動運転では、道路周囲の交通参加者や構造物の種別をカメラから認識することで、柔軟な物体検出及び状況判断が期待される。そこで自動運転の周辺認識で重要となる主要構


造物として表 2.1.①-7 に示す 11 クラスの物体を選定し，撮影画像に対するタグ付け作業を外部業者に発注した．例えば，図 2.1.①-12 に示すような RGB 画像に対してピクセルごとに対応するクラスをタグ付けした画像が得られる．今年度では東京臨海部で計測した画像 200 枚に対してタグ付け作業を完了した．しかしながら，多種多様な走行環境での認識を実現するには多様な天候及び照明条件などの画像を幅広くタグ付けすることが望ましい．そのため，次年度でも継続的なタグ付け作業の発注を進める予定である．

表 2.1.①-7 タグ付けの仕様

クラス名	クラス定義
道路	駐車領域，自転車レーンを含む走行可能領域．線路は含まない．
白線	横断歩道，路面標示，白線，黄色の線．
歩道	歩道に隣接する段差，スロープを含む走行不可領域．
ポール	標識，信号機，街路灯を取り付けるポールや電信柱．
信号機	信号機，矢印信号機，予告信号機．
標識	道路標識とその背面．
植物	街路樹，背の低い草，山．
人	歩行者，二輪車に乗る人．
四輪車	乗用車，トラック，バス，緊急車両等ナンバープレートを持ち公道を走行できるもの．トラクター，ベビーカー等は含まない．
二輪車	自転車，原付，普通二輪車．
背景	空，建物，フェンス，橋，道路工事物品，カーブミラー等，上記以外のクラス．



(a) 車載カメラ画像



(b) クラス分け画像

図 2.1.①-12 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セットのタグ付け

- ・ 先読み情報を活用した交差点進入判断アルゴリズムの基礎検討

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に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。また、自動車が交差点接近中に停止線直前で信号状態が黄色に切り替わり、急減速が発生する条件をジレンマゾーンと呼ぶ。このジレンマゾーンでは、一般車は停止または交差点通過の判断にばらつきが生じることが想定される。これによって、前後の車両間で急減速による追突の危険性があり、自動運転においても同様の危険性が存在する。一方、ITS (Intelligent Transport Systems) 無線を用いた自動車と信号機間の V2I (vehicle-to-infrastructure) 通信によって、信号機の点灯状態及び状態が変化するタイミング（先読み情報）を得ることで、車載センサによる自律認識が困難な状況においても確実な認識を実現する技術が検討されている。現在の信号機の状態に加えて先読み情報を活用することで、ジレンマゾーンにおける不必要な加減速を抑えて乗り心地や省エネに配慮した走行が期待できる。そこで、先読み情報の活用による交差点進入判断アルゴリズムを設計することで、交差点接近時の急減速の回避を検証する。

自動運転自動車が交差点に接近する際には車載カメラで信号機の点灯状態を認識しながら交差点進入の可否を判断する。認識した信号機の状態が赤（または黄）の場合、その時の車両の最大限速度による制動距離が停止線との距離以内であれば減速し、停止できない場合は交差点を通過する。時刻 $t_0[s]$ に速度 $v(t_0)[m/s]$ 及び加速度 $a(t_0)[m/s^2]$ の等加速度運動で走行する自動車が $\Delta T[s]$ の間に移動する距離 $s[m]$ は次式で表される。

$$v(t_1) = v(t_0) + a(t_0)\Delta T \quad (2.1.\textcircled{1}-4)$$

$$s = v(t_0)\Delta T + \frac{1}{2}a(t_0)\Delta T^2 \quad (2.1.\textcircled{1}-5)$$

$$t_1 = t_0 + \Delta T \quad (2.1.\textcircled{1}-6)$$

このときの走行距離は式(2.1.①-4)より ΔT を式(2.1.①-5)に代入することで以下のように示すことができる。

$$\Delta T = \frac{v(t_1) - v(t_0)}{a(t_0)} \quad (2.1.\textcircled{1}-7)$$

$$s = \frac{v^2(t_1) - v^2(t_0)}{2a(t_0)} \quad (2.1.\textcircled{1}-8)$$

ここで、 $v(t_1) = 0.0$ として、最大減速度 a_b ($a_b < 0.0$)で減速するときの経過時間を制動時間 ΔT_b 及び走行距離を制動距離 s_b とすると以下のようなになる。

$$\Delta T_b = \frac{-v(t_0)}{a_b} \quad (a_b < 0.0) \quad (2.1.\textcircled{1}-9)$$

$$s_b = \frac{-v^2(t_0)}{2a_b} \quad (a_b < 0.0) \quad (2.1.\textcircled{1}-10)$$

従って、車載カメラで認識した情報から交差点進入を判断する場合は、赤（または黄）と認識したときの車両と停止線までの距離 s_{stop} が制動距離 s_b 以上のときは減速度 a_b で停止線に停止可能となる。一方、接近している信号機に関する先読み情報が得られていると仮定すると、図 2.1.①-13(b)のように信号機の点灯状態が変化するときの車両位置を見積もることが可能となる。ここで、時刻 t_s において速度 $v(t_s)$ 、加速度 $a(t_s)$ で走行する車両に関して信号機が赤（または黄）に変化するまでの時間 ΔT_{red} としたとき、その間の車両の移動距離 s_{red} は次式で算出可能である。

$$s_{red} = \begin{cases} v(t_s)\Delta T_{red} + \frac{1}{2}a(t_s)\Delta T_{red}^2 & \text{if } \Delta T_{red} < \Delta T_{acc} \\ \frac{v_{lmt}^2 - v^2(t_s)}{2a(t_s)} + v_{lmt}(\Delta T_{red} - \Delta T_{acc}) & \text{otherwise} \end{cases} \quad (2.1.\textcircled{1}-11)$$

ただし、 v_{lmt} は制限速度、 ΔT_{acc} は速度 $v(t_s)$ から制限速度まで加速するため

に必要な時間とする． ΔT_{acc} は式(2.1.①-7)を用いて算出可能である．式(2.1.①-11)では，車両の速度が制限速度に達するまでは等加速度運動で走行しており，到達後は等速度運動で走行すると仮定している．ここで， $s_{red} + s_b$ が s_{stop} となるときの最大減速度での減速（ジレンマゾーン）が発生すると予測可能である．




図 2.1.①-13 通信情報を用いた交差点進入

そこで開発した交差点進入判断アルゴリズムでは， ΔT_{red} として与えられる先読み情報と，停止線に停止するために発生する減速度との関係を考慮した事前減速を実現する．図 2.1.①-14 に示すように， ΔT_{red} 秒経過後に減速開始した際の減速度が一定以上となる場合は，一定時刻手前から減速を開始することで発生減速度を低減させる．




図 2.1.①-14 先読み情報の活用による減速度の削減

ここで金沢大学構内の非公道エリアにおいて先読み情報を活用した信号

交差点接近アルゴリズムの検証実験について述べる．検証実験では，図 2.1.①-15 に示すコイト電工社製 LED 式信号機を移動式治具に固定したものを仮設し，市販の Wi-Fi ルータを用いて実験車両と通信を実現する．仮設信号機では，信号機の点灯状態を事前設定された灯色切り替えサイクルに従って制御可能である．また，Wi-Fi ルータを用いて現在の点灯情報及びサイクル開始からの経過秒数，灯色切り替えサイクルのどの段階にいるのかを送信可能な改造をしてあるため，これによって自動運転自動車側で信号機の点灯状態及び先読み情報を受信可能となる．信号機，車両間の通信では図 2.1.①-15(b)及び図 2.1.①-15 (c)に示す市販の Wi-Fi ルータと WiFi 中継機を使用する．これによって 150[m]程度の範囲での通信を可能とし，100[ms]周期で信号制御器の動作情報を通信する．



(a) LED 式仮設交通信号機



(b) WiFi ルータ



(c) Wi-Fi 中継機

図 2.1.①-15 通信機能付き交通信号機

図 2.1.①-16 のように直線道路の横断歩道付近に車両と通信可能な移動式信号機を設置し，仮想の交差点とする．ジレンマゾーンで信号が変わり，急減速が生じるように自動運転で交差点に接近する．あらかじめ停車状態から制限速度（30[km/h]）まで 1.0[m/s²]で加速するのに必要な距離と時間を計算し，発進するタイミングの目安を設ける．実験車両が発進後に発生する加速度は設計値に対してばらつきが想定されるため，このため目安の発進タイミングから調整しながら複数回交差点に接近し，急減速が生じるタイミングを探す．交差点に定速で接近するシチュエーション，加速しな

がら接近するシチュエーションについてそれぞれ発進するタイミングを調整しながら，信号の切り替えを予測する場合としない場合で複数回走行する．調整したタイミング付近で発進している走行データを，信号の切り替わりを予測する場合としない場合で最大減速度を比較しジレンマゾーンでの急減速削減を検証する．






図 2.1.①-16 交差点進入判断の検証エリア

検証結果として，図 2.1.①-17(a)に実験車両の速度変化，及び図 2.1.①-17(b)は実験車両の加速度変化である．先読み情報を活用した事前減速により最大減速度を $-2.97[\text{m/s}^2]$ から $-1.19[\text{m/s}^2]$ と約 40%に削減できた点を確認できる．通信情報を活用しない場合の走行では，信号の点灯色が変わってから 0.5[s]程度の遅れが発生してから減速を開始していることが確認できる．これは車載カメラで認識してから判断をする一連の作業において，カメラの画像取得，信号機認識処理，判断処理，軌道計画の後に車両制御を行うことによる処理の遅延が原因と考えられる．これに対して先読み情報を活用する場合は前半の信号機認識処理までの処理を行う必要がないことから遅延時間を抑えて応答可能となる．以上より，通信信号機による先読み情報の活用により，ジレンマゾーンにおける急減速の削減を検証することができた．



(a) 走行中の速度の傾向



(b) 走行中の加速度の傾向

図 2.1.①-17 先読み情報の活用による交差点進入判断の検証結果

・ まとめ

昨年度評価した HDR 及び LFM 機能を有するカメラを利用した走行データの計測を実施し、東京臨海部では半年以上にわたり継続したデータ計測を実施してきた。実際に計測した画像データに対して評価を行ったところ、通常的环境や夜間、雨天時などの条件によらず 95%以上の認識率を確認した。しかし、逆光時ではカメラと信号機及び光源が一直線に並ぶときに画像が部分的に飽和する現象を確認している。こうしたハードウェアによる性能限界がどのような条件下で発生するのを見積もることが今後の課題といえる。特異

環境試験場や、早朝・夕方などのデータ計測を引き続き継続的に実施することで、ハードウェア及びソフトウェアの両面から認識が困難となる条件をリストアップすることが課題である。

また、インフラ支援型信号機から取得した信号状態の先読み情報を活用した交差点進入判断アルゴリズムを基礎検討し、大学内の非公道においてジレンマゾーンの急減速低減を検証した。今後は東京臨海部で取得可能な先読み情報を活用した自動運転走行を実施して効果の検証を行うことが課題となる。公道でのジレンマゾーンの検証実験は後続車両への影響が想定されるため関係省庁等との調整を進めて、安全管理を行いながら実験実施を検討していきたい。

参考文献

- [1] N. Fairfield and C. Urmson, “Traffic Light Mapping and Detection”, Proceedings of 2011 IEEE International Conference on Robotics and Automation (ICRA2011), May, 2011.
- [2] J. Levinson, J. Askeland J. Dolson and S. Thrun, “Traffic Light Mapping, Localization, and State Detection for Autonomous Vehicles”, Proceedings of 2011 IEEE International Conference on Robotics and Automation (ICRA2011), May, 2011.
- [3] V. John, K. Yoneda, Z. Liu and S. Mita, “Saliency Map Generation by the Convolutional Neural Network for Real-Time Traffic Light Detection Using Template Matching”, IEEE Transactions on Computational Imaging, Vol.1, No.3, pp.159-173, 2015.
- [4] 米陀佳祐, 菅沼直樹, M. Aldibaja, “複数の点灯物による誤検出を考慮した信号機認識”, 自動車技術会論文集, Vol.48, No.2, pp.575-580, 2017.
- [5] A. Kuramoto, J Kameyama, R. Yanase, M. Aldibaja, K. Yoneda and N. Suganuma, “Digital Map based Signal State Recognition of Far Traffic Lights with Low Brightness”, Proceedings of the 44th Annual Conference of the IEEE Industrial Electronics Society (IECON2018), October, 2018.
- [6] 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, 2020.
- [7] J. Redmon and A. Farhadi, “YOLOv3: An Incremental Improvement”, arXiv:1804.02767r, 2018.

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たり風景に溶け込んでいたりする場合や、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、従来の矩形や円形特徴を認識する手法だけで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。2019年度は、セマンティックセグメンテーションと物体検知手法による精度比較および東京臨海部における信号機認識の評価を行う。

・ 信号機認識について

信号機認識には、地図を用いる方法[1]と用いない方法[2]がある。地図を用いることで大まかな信号機の位置を限定できるため、見逃しが少ない。一方で信号機を含むデジタル地図の整備が必要となる。地図を用いない場合、カメラだけで信号機の認識を実現できる。その一方で、信号機の見逃しが発生する恐れがある。本検討では、地図を用いない信号機認識を対象として、信号機認識アルゴリズムの高精度化を検討する。地図を用いない方法は、信号機を検知物体対象として、物体検知で実現する方法と、セマンティックセグメンテーションにより、信号機の位置を特定する方法がある。2019年度は、物体検知手法として、M2Det[3]、セマンティックセグメンテーション手法として DeepLabV3+[4]をベースとする。

・ 物体検知について

物体検出は、画像中に存在する物体の位置を特定する問題であり、歩行者検出や車両検出などへの応用が行われている。また、深層学習により、一般物体検出として、様々な物体を同時に検出できる高精度な手法が提案されている。その一つに M2Det がある。M2Det は、図 2.1.②-1 のように、バックボーンとなるネットワークを複数のエンコーダ・デコーダ構造のネットワークから構成される TUM を含む MLFPN に入力する。各 TUM は異なるサイズの物体に対応して検出することができる。各 TUM に含むカーネル数が多くないため、全体的に処理時間を削減しつつ、高精度化を実現している。本検討では、検出対象を信号機として、M2Det を用いる。




図 2.1.②-2 M2Det の構造

・ 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、歩行者など多クラスの識別を行う。2018年度の検証を踏まえて、DeepLabV3+ [4]をセマンティックセグメンテーションのベース手法とする。DeepLab v3+[4]は、図 2.1.②-2のようにエンコーダ・デコーダのネットワーク構造をしており、エンコーダ側には、Atrous Convolutionを採用している。Atrous Convolutionは、畳み込み処理を行うカーネルが疎な構造をしており、畳み込む要素を一定間隔であけて畳み込み処理を行う。これにより、計算量を増やさずに receptive field を広げることができ、より広い範囲の特徴を捉えて判断することができる。また、Xception モデルの Max Pooling を Depthwise Convolution に置き換えることで、セグメンテーションの精度を保ちつつパラメータの削減を実現している。デコーダでは、低次元の特徴をエンコーダで獲得した特徴マップと結合することにより、オブジェクト境界周りのセグメンテーション精度の向上が期待できる。




図 2.1.②-2 DeepLabV3+の構造

・ 物体検知とセマンティックセグメンテーションの比較

信号機検知において、物体検知手法とセマンティックセグメンテーション手法のいずれが適しているか比較する．比較データセットには、ヨーロッパの街中を走行して撮影されたデータから構成される CityScapes[5]データセットを用いる．本データセットには、信号機が 402 基含まれている．距離別の評価結果を図 2.1.②-3 に示す．これより、セマンティックセグメンテーション手法である DeepLab V3+の検出率が物体検知手法である M2Det よりも高いことがわかる．図 2.1.②-4 に示すように、遠方の信号機に対して、セグメンテーションできており、検出ミスを低減できている．




図 2.1.②-3 距離別の信号機検出精度




図 2.1.②-4 信号機検出結果の比較

- ・ 信号機検知アルゴリズム

上記検証をもとに、図 2.1.②-5 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信号機認識を行う。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を外接矩形で囲い、切り抜きおよび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 2.1.②-5 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

・ 状態識別アルゴリズムの比較

信号機の状態識別は、色の抽出による識別、Haar-like 特徴と Adaboost によるカスケード型分類機、CNN の 3 種類を用いた識別を行う。色の抽出による状態識別は、HSV 色空間を使用して灯火色の赤色と青色を抽出し、円形のテンプレートを用いて色の識別を行う。円形のテンプレート内に赤色と青色の閾値の画素が 30%以上ある場合、灯火領域と判定する Haar-like 特徴と Adaboost によるカスケード型識別器を用いた状態識別では、Cityscapes の学習用データから信号機を検出した画像を学習データに使用する。学習用データと検証用データは 30×60 ピクセルに正規化処理する。赤信号 1357 枚、青信号 974 枚、裏向きや横を向いている信号機をその他クラスに分けて学習する。弱識別器の数は 100 個とする。CNN を用いた状態識別は、ネットワークに ResNet18 を用いる。学習用データと検証用データは、224×224 ピクセルに正規化処理する。学習データには、Adaboost と同じ枚数の赤信号、青信号、その他の信号機のデータを用いる。表 1 に評価結果を示す。これより、CN を用いた場合が最も高精度となっていることがわかる。

表 2.1.②-1 Cityscapes データセットにおける信号機認識精度[5]

識別器	赤信号	青信号
色抽出	51.82	47.61
Adaboost	17.74	29.90
CNN	60.00	52.86

・ 東京臨海部データセットでの評価

東京臨海部で走行して作成したデータセットを用いて、信号機認識アルゴリズムの評価を行う。信号機認識アルゴリズムには、ここまでの検証をもとに、信号機の検出に DeepLab V3+, 状態識別に CNN(ResNet18)を用いる。東京臨海部データセットは、セマンティックセグメンテーション用に 200 枚、信号機識別用に 5748 枚含まれている。そのうち、セマンティックセグメンテーション用のデータを学習に用いる。評価用の信号機は 13147 基である。サイズごとの信号機検出率を表 2.1.②-2 に示す。これより、21 ピクセル以上の信号機に対する検出率は 96.42%となっている。一方で、20 ピクセル以下の信号機検出精度が低い。これは、距離換算すると 120m 以上となる。

表 2.1.②-2 サイズごとの信号機検出率[%]

信号機の幅(ピクセル)	検出率
~10	40.96
11~20	78.98
21~30	93.80
31~40	96.76
41~50	97.08
51~60	97.15
61~70	97.66
71~80	98.04
81~90	98.42
91~	98.42
全体	74.58
20 ピクセル以上	96.42
10 ピクセル以上	90.09


次に、信号機の状態識別結果を表 2.1.②-3 に示す。これより、正解率(recall)では、20 ピクセル以上の時に 91.78%となっている。図 2.1.②-6 に認識結果を示す。これより、遠方の正面の信号機は正しく認識できている。一方で、夜間の赤信号の認識率が低いことがわかった。また、夜間の誤検出も多い。これらは、夜間の学習データが不足していることが原因と考える。今後は、夜間の精度向上を検討する。

表 2.1.②-3 サイズごとの状態識別率[%]

信号機の幅[pixel]	recall	precision	F-score
~10	31.54%	80.60%	0.453
11~20	69.92%	84.01%	0.763
21~30	88.11%	85.67%	0.869
31~40	91.42%	92.97%	0.922
41~50	92.46%	94.59%	0.935
51~60	93.54%	93.71%	0.936
61~70	93.77%	96.52%	0.951
71~80	93.33%	93.70%	0.935
81~90	92.63%	97.78%	0.951
91~	96.19%	97.08%	0.966
全体	67.33%	88.09%	0.763
20 ピクセル以上	91.78%	92.16%	0.920
10 ピクセル以上	83.84%	89.53%	0.866



(a) 信号機認識結果例（青信号）



(b) 信号機認識結果例（赤信号）

図 2.1.②-6 信号機認識アルゴリズムによる認識結果例

- ・ まとめ

2019年度は、セマンティックセグメンテーションによる信号機検知と物体認識による信号機識別を組み合わせた信号機認識アルゴリズムを開発および東京臨海部データセットにて評価を行なった。東京臨海部データセットにおいて、信号機の検出精度は 96.42%、信号機認識精度は 91.78%であった。信号機の検出精度は、目標値である 95%を達成した。信

号機認識精度は、夜間や正面以外の信号機に対して、認識精度が低い。今後は特に夜間の信号機認識精度向上を検討していく。

【参考文献】

- [1] 米陀 他, “複数の点灯物による誤検出を考慮した信号機 認識” 自動車技術会論文
集, Vol.48, No.2, p.575-580, 2017.
- [2] 松尾 他, “学習及び形状・色識別を用いた交通信号機認識” 情報処理学会研究報
告, V ol.2014-CVIM-192, No34, p.1-7, 2014.
- [3] Q. Zhao, et al., “M2Det: A Single-Shot Object Detector based on Multi-Level
Feature Pyramid Network” AAAI, 2019.
- [4] L.-C. Chen et al., “Encoder-Decoder with Atrous Separable Convolution for
Semantic Image Segmentation”, ECCV, 2018.
- [5] M. Cordts, et al., “The Cityscapes Dataset for Semantic Urban Scene
Understanding,” CVPR, 2016.

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

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。特に市街地においては、例えば交差点における右折状況における高い相対速度を持つ対向車両検知や、横断歩行者の検出等の状況において、遠方に存在する移動物体を早期に検知する必要がある。一般的な車載カメラは視野角 100 度程度であり、画像サイズが 1024x786 の場合、50m 遠距離に存在する歩行者の高さは 37 ピクセル、70m 遠距離に存在する歩行者の高さは 27 ピクセル程度と小さい。そこで、2019 年度は遠距離の物体検知アルゴリズムの検討を行う。

・ 物体検知アルゴリズムの比較

物体検知アルゴリズムの研究は盛んに行われており、高精度な手法[1][2]、高速な手法[3][4]、またその両立を目指している手法など多岐にわたる。そこで、まず従来の物体検知手法の精度および処理速度を比較する。車載カメラで撮影されたデータセットとして、Cityscapes[5]、BDD 100K[6]が公開データとしてある。また、2018 年度に本事業で JARI 特異環境にて撮影した SIP データセットがある。Cityscapes、BDD 100K および SIP データセットに含まれるデータ数について、表 2.2.①-1 に示す。BDD 100K は、他のデータセットと比較して大規模なデータセットとなっている。また、検出対象とするクラス数が多く、自動車、二輪車、歩行者についてさらに細分化されたクラスが定義されている。ここでは、表 2.2.①-2 に示すように、他のデータセットに合わせて統合して用いる。

表 2.2.①-1 各データセットのデータ数

	train	val	test
Cityscapes	3000	500	1500
独自データセット	800	400	-
BDD100K	70000	10000	20000

表 2.2.①-2 BDD100K データセットのアノテーションラベル

BDD100K のラベル	統合後のラベル
bike motor	bike
bus car train truck	car
person rider	person
traffic light traffic sign	traffic light

表 2.2.①-3 に各手法の mAP を示す. ここで, 学習においては上記で説明したデータセットを組み合わせて用いて学習している. また, 表 2.2.①-4 に各手法の処理速度を示す. これら結果より, FPN が全てのデータセットにおいて最も高い mAP になっている. 処理時間は 0.08 sec であり, GTX2080Ti の GPU を用いた場合, リアルタイムでの処理が可能である. 処理時間が最も高速な YOLO v3 は, 精度が FPN と比較すると劣る.

表 2.2.①-3 各データセットにおける評価結果 (mAP)

手法	学習			評価		
	Cityscapes	SIP (特異環境)	BDD 100K	Cityscapes	SIP (特異環境)	BDD 100K
YOLOv3[1]	✓	✓		0.485	0.715	0.227
	✓	✓	✓	0.566	0.566	0.623
DCFPN[2]	✓	✓		0.320	0.508	0.133
	✓	✓	✓	0.178	0.055	0.191
FPN[3]	✓	✓		0.542	0.728	0.261
	✓	✓	✓	0.638	0.792	0.715
FCOS[4]	✓	✓		0.599	0.699	0.249
	✓	✓	✓	0.571	0.629	0.653

表 2.2.①-4 各手法の処理速度

手法	処理速度(GTX 2080Ti) [s]
YOLOv3[1]	0.016
DCFPN[2]	0.045
FPN[3]	0.080
FCOS[4]	0.125

・ サイズ別の評価結果

物体のサイズ毎に分けた場合の評価を行う．各データセットにおけるサイズ毎の評価データ数を表各手法の mAP を表に示す．表 2.2.①-6 に各手法の mAP を示す．DCFPN, YOLOv3 および FPN の入力画像サイズはそれぞれ 768, 800, 1333 である．全てのサイズにおいて FPN が最も高い mAP となっている．

表 2.2.①-5 各データセットにおけるサイズ毎の評価データ数

データセット	サイズ	bike	car	person	traffic light	計
Cityscapes	0-25	123	434	653	821	2031
	25-35	134	553	588	288	1563
	35-	1067	3915	2734	552	8268
SIP (特異環境)	-25	37	12	74	57	180
	25-35	23	41	50	86	200
	35-	130	298	309	414	1151
BDD100K	-25	235	34096	4497	20826	59654
	25-35	218	16073	2968	3677	22936
	35-	1006	58194	6446	2382	68028

表 2.2.①-6 各データセットにおけるサイズ毎の評価結果

評価データ	サイズ	DCFPN	YOLOv3	FPN
Cityscapes	0-25	0.000	0.124	0.163
	25-35	0.038	0.195	0.235
	35-	0.321	0.665	0.729
	all	0.178	0.566	0.638
SIP (特異環境)	0-25	0.000	0.382	0.544
	25-35	0.066	0.283	0.390
	35-	0.186	0.649	0.795
	all	0.055	0.636	0.792
BDD100K	0-25	0.061	0.308	0.390
	25-35	0.105	0.324	0.365
	35-	0.399	0.668	0.746
	all	0.191	0.623	0.715

・ FPN の高速化アイデア

FPNは高精度であり、GPU上でリアルタイム処理が可能である。しかしながら、自動運転車では、遠距離の物体検知アルゴリズムが全ての計算リソースを占有することはできない。そのため、高速化が必要である。そこで、FPNのアルゴリズムをベースに、軽量化したネットワーク構造にする必要がある。その代表的な方法がネットワーク構造の探索である。FPNのネットワーク構造を探索する手法として、NAS-FPN[7]が提案されており、本件灯では、このアイデアを活用する。

ネットワーク構造の探索には、学習時間と大量のGPUが必要となる。そこで、探索時間を削減するために proxy task を使用する[8]。これは、target task のネットワーク構造を小さくした proxy task を用意する。そして、proxy task を学習するエポック数も短くする。proxy task と target task との関係を表 2.2.①-7 に示す。

NAS-FPN の特徴量マップのスケールは 5 種類、それらのストライドは 8, 16, 32, 64, 128 である。ベースネットワークを ResNet, cell の数を 7 個としてネットワークの構造探索を行う。最後の 5 cell はスケールが被らないようにする。どの cell にも接続されない cell があった場合はそれを出力する特徴量マップに加算する。

表 2.2.①-7 ネットワーク構造探索のための設定

	proxy task	target task
backbone	ResNet-10	ResNet-50
input size	512×512	1000-1333
epochs	10	50
number of pyramids	3	3-7

図 2.2.①-1 にネットワーク構造の探索により得られる接続関係を示す．従来の FPN は，図 2.2.①-1 (a)のように，左側の cell から一つ下の cell に徐々に繋がる構造となっている．NAS-FPN として，ネットワークの構造を探索すると，様々な接続関係が獲得できている．ここで，図 2.2.①-1(b)から図 2.2.①-1(f)は，目標とする精度(AP)を変えた場合の構造である．




図 2.2.①-1 NAS-FPN によるネットワーク構造の探索結果

NAS-FPN のベースネットワークを MobileNet にすることで，さらなる高速化が見込まれる．その手法として，MnasNet[9]が提案されている．MnasNet は，ベースネットワークを MobileNet にすることで高速化を図っている．本検討では，MnasNet をベースとして検討を行う．

・ MnasNet によるネットワーク構造の探索結果

MnasNet によるネットワーク探索中の精度推移を図 2.2.①-2 に示す．学習には，BDD 100K データセットを用いる．これより，ネットワーク構造の探索を進めていくことで，精度が向上していることがわかる．最も精度が高かったパ

ラメータは, 学習率が 0.003, weight decay が 10^{-6} , 入力画像サイズが 800×1333 ピクセル, FPN のチャンネル数が 256, 学習ステップ数が 440000 の時である. その時の BDD100K での mAP は 0.703 である.




図 2.2.①-2 ネットワーク構造の探索における精度推移

その他のデータセットに対する精度について, 表 2.2.①-8 に示す. これより, ネットワーク探索を行っていない FPN と比べると各データセットにおける精度は低下しているが, 処理速度の高速化は実現できている.

表 2.2.①-7 ネットワーク構造探索のための設定


モデル	Cityscapes	SIP (特異環境)	BDD100K	処理時間
FPN	0.638	0.792	0.715	0.080
MnasNet	0.621	0.755	0.703	0.068

・ 東京臨海部データセットにおける精度

MnasNet による遠距離の物体検知アルゴリズムについて, 東京臨海部データセットにより評価を行う. 本データセットには, 表 2.2.①-8 に示すような 11 クラスの物体にアノテーションされている. これまでの検討で用いた Cityscapes, BDD100k, SIP(特異環境)のデータセットと本データセットを合わせて学習および評価を行う. そのため, 表 2.2.①-8 のように, 他のデータセットとクラスラベルを統一する. 図 2.2.①-3 に本データセットの画像例を示す.

表 2.2.①-8 東京臨海部データセットのクラス

東京臨海部データセット のラベル	使用するラベル
Cyclist	bike
Bus	car
Car	car
Truck	car
Pedestrian	person
信号 赤	traffic light
信号 黄	traffic light
信号 青	traffic light
矢印灯 左	traffic light
矢印灯 直進	traffic light
矢印灯 右	traffic light






図 2.2.①-3 東京臨海部データセットの画像例

表 2.2.①-9 に、東京臨海部データセットを学習データに追加した際の各データセットにおける各クラスの精度を示す。これより、他のデータセットと同様の精度が東京臨海部データセットでも達成できている。

表 2.2.①-9 各データセットにおける各クラスの精度

	bike	car	person	traffic light
Cityscapes	0.519	0.799	0.651	0.489
BDD100k	0.543	0.839	0.687	0.729
SIP(特異環境)	0.425	0.913	0.943	0.770
東京臨海部	0.255	0.711	0.600	0.514

表 2.2.①-10 に、東京臨海部データセットにおけるサイズ毎の精度を示す。これより、他のデータセットと同様の精度が東京臨海部データセットでも達成できている。

表 2.2.①-10 各データセットにおける各サイズの精度

サイズ	0-25	25-35	35-
Cityscapes	0.140	0.228	0.708
BDD100k	0.382	0.355	0.738
SIP(特異環境)	0.550	0.368	0.765
東京臨海部	0.206	0.294	0.627

図 2.2.①-4 に、東京臨海部データセットでの検出結果を示す．画面中央の遠方の歩行者や車両を検出できていることがわかる．また，夜間でも遠方の歩行者を検出できていることがわかる．






図 2.2.①-4 東京臨海部データセットでの検出結果の例

・ まとめ

2019年度は、遠距離の物体検知アルゴリズムの検討として、高精度な FPN をベースとし、ネットワーク構造を探索する MnasNet による高速化を行なった。35 ピクセル程度の 50m 離れた歩行者および 135m 離れた自動車の検出ができていたことを確認した。今後は 70m 以上遠方の歩行者および 200m 以上遠方の自動車の検出が可能か検証する。

【参考文献】

- [1] J. Redmon et al., “Yolov3: An incremental improvement.”, arXiv, 2018.
- [2] S. Zhang, et al., “Detecting face with densely connected face proposal network”, Neurocomputing, 2018.
- [3] T. Lin, et al., “Feature pyramid networks for object detection.”, CVPR, 2017.
- [4] Z. Tian, et al., “FCOS: Fully convolutional one-stage object detection”, ICCV, 2019.
- [5] M. Cordts, et al., “The cityscapes dataset for semantic urban scene

understanding.”, CVPR, 2016.

[6]F. Yu, “BDD100K: A Diverse Driving Video Database with Scalable Annotation Tooling”, ArXiv, 2018.

[7]G. Ghiasi, et al., “ Nas-fpn: Learning scalable feature pyramid architecture for object detection”, CVPR, 2019.

[8]B. Zoph, et al, “Learning transferable architectures for scalable image recognition”, CVPR, 2018.

[9]M.Tan, et al., “Mnasnet: Platform-aware neural architecture search for mobile”, CVPR, 2019.

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，今年度は3次元LiDAR及び全方位カメラを搭載した自動運転自動車を用いて石川県金沢市及び東京臨海部での走行データの計測を実施した．ここで得られるセンサデータに対して交通参加者の種別情報をラベル付けしたデータセットの作成に着手した．また，遠距離に特化した物体種別の認識を可能とするため，対象物体の全方位カメラとのセンサフュージョンアルゴリズムの基礎検討を行った．ここで開発した認識アルゴリズムの認識精度を評価するために距離毎の評価データセットを用意し定量評価を行った．今年度は135m以内の自動車及び50m以内の歩行者の認識率90%を目標として研究開発を実施した．

・ LiDAR・カメラのフュージョンによる物体認識の基礎検討

LiDARによる物体識別アルゴリズムでは，観測した物体の点群情報に対して機械学習で識別する方法が一般的であり，形状や運動状態に関する特徴量を設計識別する手法[1][2][3]やディープラーニングによって直接認識する方法[4]などが提案されている．我々の先行研究[3]においても，機械学習の識別アルゴリズムであるReal Adaboostを活用した手法を開発している．処理コストを抑えた識別アルゴリズムのため，1物体あたりの識別処理をCPUで0.1ms以下として認識率95%以上を達成可能である．しかしながら，LiDARの点群情報が疎になる遠方の物体（図2.2.②-1）を認識するには時系列処理の導入やカメラなどの他センサとのフュージョンが重要となる．そこで，今年度の事業ではLiDAR・カメラのセンサフュージョンアルゴリズムの基礎検討を行った．




図2.2.②-1 各物体種別に関するLiDARの観測点群例




図 2.2.②-2 センサフュージョンによる認識アルゴリズム概要

検討したセンサフュージョンアルゴリズムの概要を図 2.2.②-2 に示す．主に以下のステップから構成される．

1. LiDAR 点群のクラスタリング
2. LiDAR による認識：物体点群（Segment）のクラス確率を出力
3. カメラ画像による認識：画像全体から交通参加者の矩形枠を認識
4. Segment・矩形枠の対応付け：Segment の点群を画像上に投影して矩形枠と対応付けする
5. 時系列処理による事後確率計算：Segment のクラス確率をバイナリベイズフィルタによる時系列処理で事後確率を計算する．このとき画像矩形枠と対応付けられている場合は画像矩形枠認識時のクラス確率も追加することで時系列処理によるフュージョンを行う．

なお，Segment の認識結果を時系列処理するためには時系列データ間での物体の関連付け（Track データの抽出）が必要となる．本研究では，カルマンフィルタによる状態推定アルゴリズムを先行研究として開発している [5]．この状態推定アルゴリズムを活用することで時刻間の Segment を同一 Track の物体として関連付けながら処理を行う．また，カメラ画像から交通参加者を認識する処理はディープラーニングによる物体認識モデルの YOLOv3 [6] を活用する．すでに配布されている学習済みモデルを活用することで効率的なアルゴリズム検討を行う．

・ 遠距離物体の認識性能評価

前述の認識アルゴリズムの認識性能を定量評価する．本実験では，図 2.2.②-3 に示す金沢大学の直線構内道路を移動する交通参加者を対象として評

価用データを計測した．データ計測では自動運転自動車を停止させた状態で，評価対象となる自動車・二輪車（バイク・自転車）・歩行者を前後に（歩行者は左右にも）移動させることで，様々な距離における対象物体のデータを計測した．評価に用いるセンサデータは自動運転自動車上部に設置された全方位 LiDAR（Velodyne VLS-128）及び LiDAR 下部に設置された全方位カメラを 10Hz で記録している．全方位カメラは画角 60 度のカメラを 8 台設置しており全周を撮影可能である．














図 2.2.②-3 遠距離定量評価の撮影環境と対象物体の様子

また図 2.2.②-4 に自車両から見た対象物体の例を示す．自動車および二輪車（バイク・自転車）は最初に自車両から遠ざかる様に前進し，次にある程度の距離まで到達したら U ターンをして今度は自車両へ近づく様に前進させた．歩行者は自動車や二輪車と同様の前後の動きに加え，ある一定の距離にて自車両から見て左右に横切る様な動きも計測している．本実験における学習データは 78 個の Track データ（Segment 総数 8,240 個）及び評価データは 336 個の Track データ（Segment 総数 23,671 個）で構成されておりデータの内訳は表 2.2.②-1 に示す通りである．評価データに含まれる自動車，二輪車及び歩行者の物体点群の様子を図 2.2.②-4 に示す．評価データの距離ごとの分布を図 2.2.②-5 に示す．遠方になるにつれてデータ数が減少しているが，100m 以内の区間では 1,000 件以上のデータが記録さ






れている．なお，LiDAR の Segment と画像矩形枠間の対応付けは両者の時刻差が 100ms 以内のときに実施する．各セグメントと対応付けられた画像矩形枠の物体数は図中の Image objects と対応しており総数は 11,521 個である．

表 2.2.②-1 学習・評価データの実験条件

クラス	Train Data		Test Data	
	Segment 数	Track 数	Segment 数	Track 数
自動車	1,426	16	3,464	40
二輪車	4,942	24	6,277	45
歩行者	1,726	28	6,552	40
背景	146	10	7,378	211

カメラ画像	20m	40m	60m	80m	100m
					
					

(a) 自動車・二輪車の物体点群

カメラ画像	20m	30m	40m	50m	60m
					

(b) 歩行者の物体点群

図 2.2.②-4 特徴的な物体点群の様子




図 2.2.②-5 評価データの距離ごとのセグメント数


評価指標は以下に示す F-value を用いる．車両から対象物までの距離を 10m の区間ごとに分けて各区間での認識率の傾向を評価する．

$$Precision = \frac{TP}{TP + FP} \quad (2.2.②-1)$$


$$Recall = \frac{TP}{TP + FN} \quad (2.2.②-2)$$

$$F-value = \frac{2Precision \cdot Recall}{Precision + Recall} \quad (2.2.②-3)$$


ただし，TP は正解数，FP は誤検出数，FN は未検出数である．評価結果として各区間で得られる F 値の傾向を図 2.2.②-6 に示す．



(a) 自動車の認識率



(b) 二輪車の認識率



(c) 歩行者の認識率

図 2.2.②-6 評価結果

図 2.2.②-6 において、各グラフは自動車、二輪車及び歩行者の認識結果を示している。またグラフ中の青色が Segment 単体で認識した識別結果、緑色が LiDAR の認識結果だけで時系列追跡した際の識別結果、黄色が時系列追跡に画像矩形枠をフュージョンした識別結果である。ただし、各グラフにおいて認識率の算出に必要な TP, FP, FN の和が 100 件以下の場合は無効な評価結果としてプロットしていない（二輪車の 100m 以降、歩行者の 110m 以降）。また、表 2.2.②-2 に各条件の有効区間内の平均認識率を示す。これらの結果より、全体的に時系列追跡することで認識率が 15%以上改善している傾向が確認された。本評価で用いた学習データは十分なデータ数を与えないで学習しているため Segment の認識率が 60~80%程度と低い傾向であるが、時系列追跡による識別結果への貢献が確認できた。また、画像矩形枠とフュージョンすることで LiDAR 単体では見分けが難しくなる歩行者・二輪車の識別結果が改善されていることが確認できる。今回用いた画像矩形枠の認識では既存のモデルを直接使用しただけであり遠方に特化したモデルではないため、センサフュージョンの効果が確認できたのは 80m 以内の中距離にとどまっている。しかし、今後遠方に特化した認識モデルを活用することで LiDAR の点群がより疎になる遠方の認識への貢献も期待できる。表 2.2.②-2 の評価結果より各交通参加者の物体種別を 90%以上で認識可能であることが示された。これによって今年度の目標値である 135m 以内の自動車及び 50m 以内の歩行者に対する認識率 90%以上が達成された。

評価データに対する典型的な認識結果のデータを図 2.2.②-7 に示す。また、金沢市内の市街地走行データに対する認識結果の様子を図 2.2.②-8 に示す。図 2.2.②-7(b)のように 130m 以上離れた車両でも適切に物体種別を識別しながら追跡している様子が確認できる。

表 2.2.②-2 評価結果（有効区間内での平均認識率）

	Vehicle	Bicyclist	Pedestrian
評価区間	20m-140m	20m-100m	20m-110m
Segment	0.810	0.573	0.699
Tracking (LiDAR)	0.962	0.904	0.854
Tracking (LiDAR w/ Image)	0.962	0.918	0.900



(a) バイクと歩行者が接近するシーンの認識結果



(b) 自動車が離れていくシーンの認識結果

図 2.2.②-7 特徴的な認識結果の様子




図 2.2.②-8 市街地走行中の認識結果の様子（金沢市内）

・ まとめ

3次元LiDARと全方位カメラのセンサフュージョンによる物体認識アルゴリズムの基礎検討を行い，自動車・二輪車・歩行者の遠距離データをまとめた評価データに対して性能評価を実施した．評価実験では，LiDARによる時系列追跡及び画像矩形枠とフュージョンしたクラス確率の時系列処理の導入により認識率の改善を検証した．評価結果より各物体種別を90%以上で認識可能であることを示し，今年度の目標値である135m以内の自動車及び50m以内の歩行者に対する認識率90%以上が達成された．今後は認識距離をさらに改善するために，遠方に特化した画像認識手法やミリ波レーダの導入など他センサとのフュージョンした物体認識アルゴリズムを開発すること必要である．先行研究として開発した画像ベースの物体追跡アルゴリズム[7]の活用を検討や2.2.①にて検討した遠距離認識モデルの活用を検討するなど既存の成果を生かした効率的な開発を予定する．

参考文献

- [1] A. Teichman, J. Levinson, S. Thrun, “Towards 3D object recognition via classification of arbitrary object tracks,” Proceedings of IEEE International Conference on Robotics and Automation, pp. 4034-4041, 2011.
- [2] L. Spinello, K. O. Arras, R. Triebel, R. Siegwart, “A Layered Approach to People Detection in 3D Range Data”, Proceedings of the Twenty-Fourth AAAI Conference on Artificial Intelligence, pp.1625-1630, 2010.
- [3] N. Suganuma, M. Yoshioka, K. Yoneda and M. Aldibaja, “LIDAR-based Object Classification for Autonomous Driving on Urban Roads”, Journal of Advanced Control, Automation and Robotics, Vol.3, No.2, pp.92-95, 2017.
- [4] C. R. Qi, L. Wei, C. Wu, et al., “Frustum PointNets for 3D Object Detection from RGB-D Data”, arXiv preprint arXiv:1711.08488, 2017.
- [5] 永野聖巳，菅沼直樹，米陀佳祐，M. Aldibaja，岸田正幸，松元利裕，“全方位ミリ波レーダを用いた自動運転自動車のための周辺移動車両追跡に関する研究”，自動車技術会論文集，vol.48, no.2, pp.411-418, 2017.
- [6] J. Redmon and A. Farhadi, “YOLOv3: An Incremental Improvement”, arXiv:1804.02767r, 2018.
- [7] 倉元昭季，柳瀬龍，米陀佳祐，M. Aldibaja，菅沼直樹，“単眼カメラを用いた遠方車両の3次元位置トラッキング”，第25回ロボティクスシンポジア，2020.

2.3.c. 「高精度自己位置技術の開発」

① GNSS/INS の開発

(1) 高さ方向の変動を利用した位置の信頼度判定

自動運転支援システム，および，自動運転車両では，高い車両位置精度と信頼性が求められる．ここで，都市部などの遮蔽物が多い空間では，GNSS の測位精度が劣化する場合がある問題が知られており，測位精度の信頼性が重要となる．そこで，GNSS 測位結果の信頼性を示す要素として，Kinematic 測位の FIX 解が用いられることがある．しかし，都市部では無視できない誤差を持つ FIX 解が発生する場合があります，FIX 解であるか否かの判定では，自動車の制御には十分でない問題がある．そこで，2019 年度の GNSS/INS の開発では，車両の高さ変動が小さいことに注目する．特に，GNSS/IMU を利用した際の車両の相対的な高さの変動を利用し，信頼性の高い FIX 解を検出することで，FIX 解の中から自動運転に必要な平面 0.3m の精度を判定する手法を提案する．

(2) 提案手法の概要

提案手法では平面ではなく，高さ方向の軌跡に注目し，相対的な高さの変動を利用して FIX 解の性能を判定する手法を提案する．GNSS 測位結果の誤差は，衛星と受信機の幾何学的要因により，高さ方向に発生する誤差は，平面の誤差よりも大きい傾向があることが知られている．そのため，位置の信頼性を検討する際，高さ方向の精度に注目することで，より確度が高い判定をできる可能性がある．ただし，提案手法を実現するためには，FIX 解を判定するために十分な精度で，相対的な高さの変動を推定する必要がある．一般的に相対的な高さの変動は気圧高度計を用いるか，もしくは車速とピッチ角を利用して推定がされる．気圧高度計は相対的な高さ変動を直接計測できるセンサであるが，気圧や気温の変化に弱く，ドリフト誤差が避けられない．そこで，提案手法では車速とピッチ角を利用する手法に注目をする．ここで，式(1)に，車速とピッチ角を利用して相対的な高さの変動を推定する式を示す．車速は車輪測計から計測ができ，その補正方法が数多く提案されている．そのため，式(1)から提案手法には正確なピッチ角の推定が必用であるといえる．

$$\Delta H = \int V \cdot \sin(\theta) dt \quad (1)$$

ここで、ピッチ角に注目をするすると、加速度計と車速の時間変動から推定できることが知られている[4]．式(2)にピッチ角 θ と加速度計 δG_x^{imu} ，車速 V の関係を示す．また，図 2.3. ①-1 にその概要を示す．なお，式(2)においては，加速度計の誤差を δG_x ：オフセット誤差と仮定している．

$$\theta = \sin^{-1} \left(\frac{(G_x^{imu} - \delta G_x) - \frac{dV}{dt}}{g} \right) \quad (2)$$




図 2.3. ①-1 ピッチ角推定の概要

式(2)において，未知のパラメータとなるのは加速度計の誤差 δG_x となる．つまり，提案手法における課題は，加速度計の誤差推定であるといえる．ここで，加速度計の誤差の補正方法としては，GNSS，IMU や車輪測計をカルマンフィルタ[5]や，オブザーバ[6]で統合する手法が知られている．しかし，GNSS にはマルチパスの問題があるため，入力される GNSS の位置・速度に大きな誤差がある場合は，推定結果にも大きな影響を与える問題もある．そのため，GNSS のマルチパスを判定することが重要となる．

そこで提案手法では，入力として GNSS の Kinematic 測位の FIX 解を利用し，FIX 解の誤差判定と加速度計の誤差を同時に推定する手法を提案する．図 2.3.2 に提案手法の概要を示す．提案手法では，そもそも入力となる FIX 解にマルチパスに代表される誤差が含まれる問題を，繰り返し演算により解決をすることを目指す．




図 2.3. ①-2 提案手法の概要

提案手法では、FIX 解を用いて加速度誤差 δG_x を推定する。具体的には、一定時間の FIX 解と加速度、車輪測を利用して、FIX と式 (1)、式 (2) による加速度・車輪測から推定した相対高さの整合性を検証することで、加速度誤差を推定する。図 2.3. ①-2 にその概要を示す。提案手法では、図 2.3. ①-3 に示す残差の二乗和が最小となるように加速度誤差 δG_x を決定する。




図 2.3. ①-3 加速度誤差推定の概要

図 2.3. ①-4 に提案手法の FIX 解の信頼度判定部の概要を示す。提案手法では、加速度誤差が補正された状態で推定された相対的な高さを利用して、FIX 解の信頼性を判定することで、FIX 解の中から自動運転に必要な平面 0.3m の精度を判定する。具体的には、推定した絶対高さと FIX 解を比較し、差が閾値以上の場合は棄却する処理を行っている。以上の処理により、高さの変動に一致しない FIX 解が除去されるため、信頼性が高い FIX 解が残ることが期待できる。

ただし，入力される FIX 解にはマルチパスの誤差に代表される誤差がある問題がある．そこで提案手法では，加速度誤差の補正と，FIX 解の信頼性の判定を繰り返し実施することで，最終的に出力する FIX 解の精度を向上させている．




図 2.3. ①-4 高さ方向を利用した信頼度判定の概要

(3) 評価試験

提案手法の有効性を確認するため，車両で評価試験を行った．ここで本手法では，リファレンスとの差が平面で 0.3m 以下の FIX 解を信頼性の高い FIX 解とする．試験は，誤差の大きい FIX 解が発生する可能性の高い環境として，東京都お台場周辺，及び東京都新宿周辺で試験を行った．表 2.3. ①-1 に試験に用いた機材を示す．GNSS アンテナは測量用，GNSS 受信機，IMU は数万円程度のものを使用した．リファレンス機材には Applanix 社製の高精度位置計測システム POSLV220 で計測した位置を用いた[7]．また，提案手法ではオープンソースである RTKLIB を使用し Kinematic 測位を行った[8]．この際，衛星は，GPS, BeiDou, QZSS を使用し，アンビグイティ決定は瞬時 AR を採用し，Ratio Test の閾値は 3 を採用した．

表 2.3. ①-1 評価試験に利用した機材一覧

Equipment	Manufacturer	Model (cycle)
GNSS antenna	Aero	AT1675-540T
GNSS receiver	U-blox	C099-F9P-0-01 (5Hz)
IMU	Tamagawa	AU7684 (50Hz)
Reference	Applanix	POSLV220

図 2.3. ①-5 にお台場での試験コースを示す．走行距離は 13km である．なお，図 2.3. ①-5 の桃色線部分は，ゆりかもめや高速道路の高架などがあり，

マルチパスによって測位誤差が発生しやすい環境である．図 2.3.①-6 に，提案手法で推定した加速度誤差を用いて算出したピッチ角と高さの誤差分布を示す．図 2.3.①-6 より，ピッチ角は標準偏差 0.25deg ，高さは標準偏差 0.08m で推定できている．



図 2.3.①-5 お台場の評価コース




図 2.3.①-6 お台場での評価結果（ピッチ角，高さ）

ここで，図 2.3.①-7 a)に図 2.3.①-5 の赤線で囲った部分における Kinematic 測位の FIX 解を，図 2.3.7 b)に提案手法で信頼性が高いと判定された FIX 解を示す．図 2.3.①-7 a)ではリファレンスの軌跡に対して，マルチパスの影響により，誤差の大きい FIX 解が多いことが確認できる．一方，図 2.3.①-7 b)では誤差の大きい FIX 解を除去できていることが分かる．次に，図 2.3.①-8 に判定を実施した FIX 解の平面及び高さの誤差を示す．図 2.3.①-8 の緑円は，提案手法で信頼性が高いと判定された FIX 解である．信頼性が高いと判定した FIX 解の総エポック数が 6369 のうち，リファレンスとの差が平面で 0.3m 以上の数は 4 個となり，提案手法の判定精度は 99.9% であった．残存する誤差として，図 2.3.①-8 の A 部など，高さ方向では誤差が小さいが，平面方向では誤差が大きい FIX 解が存在する場所がある．しかし，図 2.3.①-8 の A 部では誤差が大きいため，[2]の手法を用いて平面の走行軌

跡を使用することで、除去することが可能であると考える。




図 2.3. ①-7 お台場における信頼度を判定した後の測位結果例




図 2.3. ①-8 お台場における提案手法の適用結果

次に図 2.3. ①-9 に新宿での試験コースを示す．走行距離は 6.5km である．なお，このコースには，高さ 200m を超える東京都庁舎や，高さ 100m を超える高層ビルが建っており，マルチパスによって測位誤差が発生しやすい環境である．図 2.3. ①-10 に，提案手法で推定した加速度誤差を用いて算出したピッチ角と高さの誤差分布を示す．図 2.3. ①-10 より，ピッチ角は標準偏差 0.34deg，高さは標準偏差 0.42m で推定できている．図 2.3. ①-6 b) のお台場

の高さと比較すると，高さの推定精度が悪くなっていることが分かる．ここで，図 2.3. ①-11 a) に，図 2.3. ①-10 の赤線で囲った部分における Kinematic 測位の FIX 解を，図 2.3. ①-11 b) に提案手法で信頼性が高いと判定した FIX 解を示す．図 2.3. ①-11 a) ではお台場の環境である図 2.3. ①-7 a) と比較して，誤差の大きい FIX 解が多いことが確認できる．一方，図 2.3. ①-11 b) では誤差の大きい FIX 解を除去できていることが分かる．




図 2.3. ①-9 新宿の評価コース




図 2.3. ①-10 新宿での評価結果（ピッチ角，高さ）




図 2.3. ①-11 新宿における信頼度を判定した後の測位結果例

次に, 図 2.3. ①-12 に判定を実施した FIX 解の平面及び高さの誤差を示す. 図 2.3. ①-12 の緑円は, 提案手法で信頼性が高いと判定された FIX 解である. 信頼度が高いと判定された FIX 解の総エポック数は 5370 となる. その内, リファレンスとの差が平面で 0.3m 以上のエポック数は 14 とあり, 提案手法の判定精度は 99.7% であった. 以上の結果より, 提案手法は新宿においても 99% 以上の判定精度を達成していることが確認できる. しかし, 提案手法においても図 2.3. ①-12 の A 部のように連続してオフセット的な誤差がある FIX 解に対しては, FIX 解の信頼性の判定に相対的な高さの変動を用いているため誤判定をしてしまう課題が確認できる. この問題に対しては, 判定を実施するために蓄積するデータの間の調整や, 平面方向の軌跡も活用することで対応することを予定している.




図 2.3. ①-12 新宿における提案手法の適用結果

【参考文献】

- [1] P. J. G. Teunissen, S. Verhagen; “On GNSS Ambiguity Acceptance Tests”, Proceedings of IGNS Symposium 2007, Dec. 4-6, 2007, Sydney
- [2] H. Kuusniemi, G. Lachapelle, and J. H. Takala: “Position and velocity reliability testing in degraded GPS signal environments”, GPS Solutions, vol. 8, p. 226-237 (2004)

-
-
- [3] 荒川拓哉,他:”GNSS ドップラを活用した都市部におけるレーンレベル位置推定の実現”,計測自動制御学会論文集 55 卷 11 号,pp,754-761,2019
- [4] H. Eric Tseng, Li Xu and DavorHrovat: “Estimation of Land Vehicle Roll and Pitch Angles”, Proceeding of AVEC’ 06, p.445-449,2006
- [5] Siavash Hosseinyalamdary, “Deep Kalman Filter: Simultaneous Multi-Sensor Integration and Modelling;A GNSS/IMU Case Study”, sensors,2018,4,24
- [6] Kanwar, Bharat, Singh, “Vehicle Sideslip Angle Estimation Based on Tire Model Adaptation”, electronics 2019,8(2),119
- [7] POSLV(<https://www.applanix.com/products/poslv.htm>)
- [8] RTKLIB(<http://www.rtklib.com>)

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。

2019年度は複数方式のマップマッチングアルゴリズムをそれぞれ実装し、処理コストや位置精度（目標精度0.1m）の面から安定した性能を持つアルゴリズムの評価を行なった。本年度においては高精度なGNSS/INSを使用して実装することで、姿勢角を既知としたマッチングアルゴリズムの実装および評価を行なった。

また、東京臨海部での走行実験の認識状況と、実験を通して得られた自己位置推定の課題とその対策についても報告する。

複数マップマッチングアルゴリズムの実装・評価

2018年度において調査したマップマッチングアルゴリズムの中から、NDTスキャンマッチング・テンプレートマッチングの2つの手法を選定し実装・評価した。NDTは主に3次元点群のマッチング手法であり、建物や電柱など




図 2.3.②-1. 評価ルート

の立体構造物の特徴を用いる．それに対して，テンプレートマッチングは 2 次元の画像をマッチングする手法であり，白線や横断歩道などの路面パターンを特徴として用いる．

2019 年度は，前年度に選定した評価ルートについて 2019 年 7 月と 2019 年 12 月の異なる季節における地図データ計測を行なった．評価ルートは図 2.3.②-1 に示す金沢市内における片道約 20km の経路である．図 2.3.②-2～3 に計測した 3 次元点群地図と路面パターン地図（以下，2 次元オルソ地図）の例を示す．




図 2.3.②-2. 3 次元点群地図の例




図 2.3.②-3. 2 次元オルソ地図の例

・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 2.3.②-4 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 $\mathbf{x}_{t-1,DR}$ ，速度 $\mathbf{v}$ とデータ取得周期 Δt から現時刻のデッドレコニング位置 $\mathbf{x}_{t,DR}$ は $\mathbf{x}_{t,DR} = \mathbf{x}_{t-1,DR} + \mathbf{v} \Delta t$ 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 $\mathbf{x}_{t,DR}$ に対する誤差 $\Delta \mathbf{x}_{t,DR}$ 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 2.3.②-4. 自己位置推定アルゴリズム概要

・ NDT スキャンマッチング [1]

NDT (Normal Distributions Transform) スキャンマッチングでは，図 2.3.②-5 に示すように点群地図をグリッド状に区切り，各グリッド内の点群を正規分布で近似する．この正規分布によって表された地図とセンサデータの各点について対応要素の探索および変換の推定を繰り返すことで，図 2.3.②-6 のように 2 つの点群間の位置・角度のずれを求める．全ての点の対応を計算する ICP と比較して，NDT は近侍により高速に計算可能であり，自動運転で用




図 2.3.②-5. NDT スキャンマッチングの外観図

いられている実績がある[2].




図 2.3.②-6. NDT スキャンマッチングによる 3 次元点群マッチングの例

・ テンプレートマッチング

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 2.3.②-7 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と捉えることができる．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[3]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．




図 2.3.②-7. テンプレートマッチングの外観図

・マッチング手法の性能評価

評価ルートの中から立体構造物・路面パターンそれぞれの特徴を含む区間を選出し、各マッチング手法の位置精度・処理時間を評価した。図 2.3.②-8～9 に選出した評価区間の 3 次元点群地図および 2 次元オルソ地図の例を示す。

この評価区間において、各方式による自己位置推定の精度および処理時間を表 2.3.②-1～2 に示す。

NDT スキャンマッチングにおいては、マッチングに用いる LiDAR の点数によって精度が変化する可能性が考えられるため、Autoware で実際に使用されているパラメータである 1000 点の場合と、リアルタイム処理が可能である範囲で点数を多くしたときの 3000 点の場合での比較を行った。ただし LiDAR 点群のダウンサンプリング手法は、使用点数の調整を行うために Autoware にオプションとして用意されているランダムフィルタリング手法 [4] を用いた。表 2.3.②-1 より、どちらのパラメータについても車両縦方向・横方向ともに 0.1m の推定精度を達成し、公道走行実験で使用実績のある使用点数 1000 点というパラメータが目標精度とリアルタイム処理を達成可能であることがわかった。

次に、テンプレートマッチングについては、LiDAR 画像（テンプレート画像）のサイズが処理時間に寄与するが、テンプレート画像のサイズが大きければマッチングに使用する路面パターンもより広範囲に使用できるため、精度やロバスト性に寄与する可能性がある。試験車両に使用している LiDAR は




図 2.3.②-8. 評価区間の 3 次元点群地図




図 2.3.②-9. 評価区間の 2 次元オルソ地図

取り付け位置の関係から半径約 20m 付近のレーザ密度が高くなっているため、車両を中心として 48m×48m の領域を LiDAR 画像のサイズとして設定した。また、1/2 の距離である 24m×24m の LiDAR 画像でマッチングを行い、処理時間と精度を比較した。48m×48m の LiDAR 画像を用いた場合、処理時間は NDT スキャンマッチングと同様にリアルタイムでの処理が十分に可能であり、目標精度の 0.1m を達成可能であった。また、24m×24m の LiDAR 画像を使用した場合、今回選定した評価区間では 48m×48m の場合と比較して推定精度に有意な差は見られなかったが、目標精度を達成しつつより高速に処理可能であることが確認された。

表 2.3.②-1. 評価区間における NDT スキャンマッチング性能

	LiDAR 使用点数:3000	LiDAR 使用点数:1000
車両縦方向 RMSE [m]	0.082	0.081
車両横方向 RMSE [m]	0.066	0.066
平均マッチング時間 [ms]	74	24

表 2.3.②-2. 評価区間におけるテンプレートマッチング性能

	LiDAR 画像 サイズ:48m×48m	LiDAR 画像 サイズ:24m×24m
車両縦方向 RMSE [m]	0.085	0.076
車両横方向 RMSE [m]	0.056	0.057
平均マッチング時間 [ms]	36	7.9

・季節による認識性能の変化に関する調査

地図データは 2019 年 7 月と 2019 年 12 月の 2 回外注にて計測した。季節の変化が位置推定精度に影響を及ぼす要因として、植え込み・街路樹などの植物の変化や路面の書き換えなどが挙げられる。今回計測した 2 つの地図からは植物の枯れ具合による道路形状の変化，建物の建て替えがあった場所が確認されたため，その区間を抽出し，各手法について精度評価を行なった。

・植物の変化した区間①

調査シーンの 3 次元点群地図を図 2.3.②-10～11 に示す。7 月の地図では道路脇に植物が存在していることが確認できるが，12 月の地図ではそれらが草刈りや枯れた影響で無くなっており道路形状の変化が見られる。図 2.3.②-12～13 に同シーンの 2 次元オルソ地図を示すが，こちらに関しては路面パターンに大きく変化がないことがわかる。

評価に際しては 2020 年 3 月の走行データを使用した。したがって，路面は 12 月の地図にかなり近い状態であった。




図 2.3.②-10. 2019 年 7 月の 3 次元点群
地図




図 2.3.②-11. 2019 年 12 月の 3 次元点群
地図




図 2.3.②-12. 2019 年 7 月の 2 次元
オルソ地図




図 2.3.②-13. 2019 年 12 月の 2 次元
オルソ地図

この区間での各方式による自己位置推定の精度および処理時間の表 2.3.②-3～4 に示す．また，図 2.3.②-14～15 にそれぞれの場合の位置推定誤差のグラフを示す．テンプレートマッチングにおいてはどちらの地図を使用した場合でも評価区間全体の RMSE としては目標精度を達成している．しかしながら，NDT スキャンマッチングの場合，7 月の地図を用いたときの推定誤差が大きくなっており，図 2.3.②-14 に示すように植物の変化のある部分において 1m 以上の車両横方向の誤差が発生していることが確認できる．

表 2.3.②-3. 植物の変化した区間①における NDT スキャンマッチング性能
(LiDAR 使用点数 3000)

	7 月 地図	12 月 地図
車両縦方向 RMSE [m]	0.092	0.082
車両横方向 RMSE [m]	0.657	0.066
平均マッチング時間 [ms]	93	74

表 2.3.②-4. 植物の変化した区間①におけるテンプレートマッチング性能
(LiDAR 画像サイズ:48m×48m)

	7 月 地図	12 月 地図
車両縦方向 RMSE [m]	0.087	0.085
車両横方向 RMSE [m]	0.057	0.056
平均マッチング時間 [ms]	38	36




図 2.3.②-14. 植物の変化した区間①における NDT スキャンマッチング
推定誤差 (7 月地図)




図 2.3.②-15. 植物の変化した区間①における NDT スキャンマッチング推定
誤差 (12 月地図)




図 2.3.②-16. 植物の変化した区間①におけるテンプレートマッチング推定誤差（7月地図）





図 2.3.②-17. 植物の変化した区間①におけるテンプレートマッチング推定誤差（12月地図）


・植物の変化した区間②

図 2.3.②-18 に示すように(a)7 月地図と(b)12 月地図を重ね合わせて比較すると，(c)のように道路脇の樹木の形状が変化していることが確認できる．それに対し，図 2.3.②-19(a)～(b)に示すオルソ画像については，路面パターンに大きな変化がないことがわかる．


表 2.3.②-5～6 に NDT スキャンマッチングとテンプレートマッチングの位置推定性能を示し，図 2.3.②-20～23 にそれぞれの場合の位置推定誤差のグラフを示す．テンプレートマッチングに関しては，7 月地図と 12 月地図で推定性能及び誤差にあまり大きな差異は見られないが，NDT スキャンマッチングの場合，7 月地図を用いたときの推定精度が低下し，推定誤差が 12 月地図を用いたときと比較して不安定になっていることがわかる．



(a) 7 月地図



(b) 12 月地図



(c) 2 つの点群地図の重ね合わせ

図 2.3.②-18. 植物の変化した区間②の 3 次元点群地図



(a) 7 月地図



(b) 12 月地図

図 2.3.②-19. 植物の変化した区間②の 2 次元オルソ画像地図

表 2.3.②-5. 植物の変化した区間②における NDT スキャンマッチング性能
(LiDAR 使用点数 3000)

	7 月地図	12 月地図
車両縦方向 RMSE [m]	0.122	0.065
車両横方向 RMSE [m]	0.153	0.037
平均マッチング時間 [ms]	244	113

表 2.3.②-6. 植物の変化した区間②におけるテンプレートマッチング性能
(LiDAR 画像サイズ:48m×48m)

	7 月地図	12 月地図
車両縦方向 RMSE [m]	0.090	0.109
車両横方向 RMSE [m]	0.059	0.087
平均マッチング時間 [ms]	34	35




図 2.3.②-20. 植物の変化した区間②における NDT スキャンマッチング推定誤差
(7 月地図)




図 2.3.②-21. 植物の変化した区間②における NDT スキャンマッチング推定誤差
(12 月地図)




図 2.3.②-22. 植物の変化した区間②におけるテンプレートマッチング推定誤差
(7月地図)





図 2.3.②-23. 植物の変化した区間②におけるテンプレートマッチング推定誤差
(12月地図)


・ 建物の建て替わった区間

次に，7月と12月で建物の建て替わりがあったシーンについて調査した．図 2.3.②-24 に 3 次元点群地図を示す．(a)の 7 月地図と (b)の 12 月地図を重ねると，(c)のように 7 月にはなかった建物が 12 月では新しく建てられていることがわかる．図 2.3.②-25 に示すオルソ画像地図では季節によって路面パターンには大きな変化がないことがわかる．


表 2.3.②-7～8 に NDT スキャンマッチングとテンプレートマッチングの位置推定性能を示し，図 2.3.②-26～29 にそれぞれの場合の位置推定誤差のグラフを示す．結果として，このシーンにおいては建物の建て替わりが NDT スキャンマッチング及びテンプレートマッチングの位置推定精度には大きく寄与していないことがわかる．NDT スキャンマッチングに関しても大きく精度が低下しない原因としては，LiDAR 点群と地図点群との対応付けを行う際に距離が大きく離れているペアを回転・並進を求める際に省く処理が入っているためであると考えられる．したがって，変化していない他の建物や街路樹などの特徴が支配的となり推定精度に影響がないと考察される．



(a) 7 月地図



(b) 12 月地図



(c) 2 つの点群地図の重ね合わせ

図 2.3.②-24. 建物の建て替わった区間①の 3 次元点群地図



(a) 7 月地図



(b) 12 月地図

図 2.3.②-25. 建物の建て替わった区間①の 2 次元オルソ画像地図

表 2.3.②-7. 建物の建て替わった区間における NDT スキャンマッチング性能
(LiDAR 使用点数 3000)

	7 月地図	12 月地図
車両縦方向 RMSE [m]	0.097	0.099
車両横方向 RMSE [m]	0.032	0.030
平均マッチング時間 [ms]	96	91

表 2.3.②-8. 建物の建て替わった区間におけるテンプレートマッチング性能
(LiDAR 画像サイズ:48m×48m)

	7 月地図	12 月地図
車両縦方向 RMSE [m]	0.028	0.022
車両横方向 RMSE [m]	0.052	0.070
平均マッチング時間 [ms]	41	35




図 2.3.②-26. 建物の建て替わった区間における NDT スキャンマッチング推定誤差 (7 月地図)




図 2.3.②-27. 建物の建て替わった区間における NDT スキャンマッチング推定誤差 (12 月地図)




図 2.3.②-28. 建物の建て替わった区間におけるテンプレートマッチング推定誤差 (7 月地図)




図 2.3.②-29. 建物の建て替わった区間におけるテンプレートマッチング推定誤差 (12 月地図)

以上の3つのシーンより、植物の変化や建物の建て替えなどが各マッチング手法に与える影響を調査した。テンプレートマッチングについては、立体構造物の変化が位置推定精度にはあまり寄与しないことが確認できた。それに対して、NDT スキャンマッチングは建物の建て替わりといった地図内の一部の点群が変化するような場合は位置推定精度に大きな影響は見られなかったが、植物の変化のように広範囲にわたって形状が変化するような場合には位置精度の低下が見られた。このような広範囲の植物の変化は今回計測したルートの中でも特に地方部に見られ、地方部での自動運転における課題となり得ることを確認した。今後は都市部を含め、植物等の変化がどのような範囲で起きたとき推定位置精度に影響を及ぼすのかについても継続的に検討を行う必要がある。また、NDT スキャンマッチングは収束計算により回転・並進の行列が1つだけ求まる。それに対して、テンプレートマッチングはマッチングの結果として相関値の2次元の分布を得ることができるため、この相関値の分布は尤度分布とみなし、ヒストグラムフィルタなどを用いて確率論的にフィルタリング処理が可能である。そのため、テンプレートマッチングを用いた位置推定手法は、図 2.3.②-16~17 に見られるようにロバスト性の高いオフセット推定が可能であると考えられる。NDT スキャンマッチングの場合、よりロバスト性を高めるためにはカルマンフィルタなどを用いてマッチング結果に対しフィルタリング処理や棄却検定などを積極的に行う必要があることがわかった。また、路面パターンの変化などテンプレートマッチングの推定精度が低下する可能性のあるシーンなどについては今回取得した地図データでは確認できなかったため、今後も継続的にデータ取得・評価を行っていく必要がある。

東京臨海部実証実験での認識状況および課題

東京臨海部における実証実験での認識状況について報告する．また，実験を通して確認された課題とそれらについて行なった対策についても報告する．ここでは，金沢大学が公道での実証実験を通して開発を行い，実際に走行実績のあるテンプレートマッチングをベースとした自己位置推定手法を使用し実験・検証を行なった．

・東京臨海部での認識状況

現在，東京臨海部での実証実験において衛星測位の難しい環境での位置推定を行い，自動走行に大きな支障がないことを確認している．例として，図 2.3.②-30 に有明コロシアムから東京ビッグサイトへ向かうゆりかもめ高架下を走る道路を走行中の位置推定結果を示す．赤い点が走行中に得られた GNSS/INS の位置であり，青い点がマップマッチングによる推定位置であることを示している．このとき，実際の走行経路はマップマッチングの推定位置と概ね一致していたが，GNSS/INS が示す位置は 1 車線～2 車線ほどずれた状態が約 1km の区間にわたって続いている．したがって，衛星測位が困難な環境においてもマップマッチングにより自動走行を実現する位置推定が可能であることが確認できた．

しかしながら，東京臨海部での走行から得られた位置推定における課題と




図 2.3.②-30. 衛星測位の難しい環境での位置推定結果

して、遮熱性塗装の施された路面や降雨時における位置推定精度の低下が確認された．これらの問題と行なった対策を以下で述べる．

・遮熱性塗装の路面

遮熱性塗装の施された路面は赤外線反射率が高く，LiDAR による観測では白線と路面のコントラストが低いために地図画像と LiDAR 画像の相関のピークが出にくい場所が確認されていた．図 2.3.②-31 に実際に課題となった場所の一例を示す．カメラ画像からは白線とアスファルト部分のコントラストがあることを確認できるが，LiDAR のデータから作成された地図画像やリアルタイムの LiDAR 画像からは白線を認識しづらいことがわかる．結果として，地図画像と LiDAR 画像のマッチングから得られる相関分布には鋭いピークが現れていない．しかしながら，道路脇のゼブラゾーン部分は比較的コントラストが高いことが確認できる．そこで，地図から遮熱性塗装が施されている部分にマスク処理を行い，マッピングの際に当該箇所を無視するようにすることで，図 2.3.②-32 のように鋭いピークをもつ相関分布を結果として得られることを確認した．したがって，今後はこのように路面のコントラストが高い部分に着目してマッピングを行うようなアルゴリズムの検討が必要である．




図 2.3.②-31. 遮熱性塗装の路面における課題




図 2.3.②-32. 地図のマスク処理によるマッピング結果の改善

・ 降雨時における位置推定

降雨時において、路面が濡れている影響で LiDAR の赤外線反射が得られない場合がある．例えば，図 2.3.②-33 に示すように，晴天時は LiDAR のレーザ 照射点が多くマッチングの相関分布も鋭いピークをもっているが，降雨時には照射点が少なくマッチング結果の相関分布は晴天時と比較してあまり鋭いピークが得られず，また正しい位置にピークが現れない場合がある．その対策として，複数の LiDAR を活用することでマッチング結果の改善が見られた．従来は，1 台の LiDAR (VLS-128) のみを自己位置推定に用いていたが，車両には計 5 台の LiDAR を搭載しており，それぞれがセンサの死角を補うような形で取り付けられている．これら全ての LiDAR を使用し，なるべく多くの点を LiDAR 画像の生成に用いることで，図 2.3.②-34 に示すようにマッチング結果として晴天時と同様に鋭いピークをもつ相関分布が得られることを確認できた．




図 2.3.②-33. 降雨時の課題




図 2.3.②-34. 複数 LiDAR を用いた場合の降雨時の相関分布


【参考文献】

- [1] P. Biber et al., “The Normal Distributions Transform: A New Approach to Laser Scan Matching,” Proceedings of the 2003 IEEE International Conference on Intelligent robots and Systems, 2003.
- [2] S. Kato, et al., “An Open Approach to Autonomous Vehicles,” IEEE Micro, 2015.
- [3] N. Suganuma et al., “Localization for Autonomous Vehicle on Urban Roads,” Journal of Advanced Control, Automation and Robotics (JACAR), 2016.
- [4] Autoware - random_filter.cpp (https://gitlab.com/autowarefoundation/autoware.ai/core_perception/-/blob/master/points_downsampler/nodes/random_filter/random_filter.cpp)

③ 白線の状態が自動運転システムに与える影響の調査

(1) 道路上の白線領域を抽出するアルゴリズムの基礎検討

自動運転車両を走行させながら車載センサのみで白線の状態を把握するためには，まず白線が道路上のどこに存在するかを特定する必要がある．そこで研究テーマ a.「信号機認識技術の開発及び認識が困難な条件の検討」にも用いられているセマンティックセグメンテーション技術を利用して車載カメラ画像から白線を抽出し，白線が道路上のどこに存在するかを特定する．図 2.3.③-1 に車載カメラ画像およびその時のセマンティックセグメンテーションによる周辺環境の認識結果を示す．



(a) 車載カメラ画像 (b)セマンティックセグメンテーション結果

図 2.3.③-1 車載カメラ画像とセマンティックセグメンテーションの結果

ここで赤く塗り潰されている箇所が白線領域である．この認識結果および車載カメラの取り付け位置などの情報から，自動運転車両から見て道路上のどこに白線が存在するかを算出することができる．ただしカメラ画像からだけでは次節で述べる反射率を計測できないので，車載カメラと車載 LiDAR の情報を統合するセンサフュージョン技術が必要になる．このセンサフュージョンは今後の課題である．

(2) 白線の状態を把握する目安の基礎検討

高速道路および一般道路には様々な状態の白線が存在し、自動運転システムは白線を認識して走行する場合もあるので、白線の状態が自動運転システムに与える影響について調査を行う必要がある。そこで今年度は白線の状態を表す目安として「白線の反射率」「白線と舗装のコントラスト」「白線のかすれ具合」[1][2]を把握する手法の基礎検討を行った。

評価方法

- ・反射率およびコントラスト：外乱光の影響を受けにくくするために、赤外線反射率を計測できる車載 LiDAR を用いて白線自体の反射率を計測する。また白線に隣接する舗装部分の反射率と白線部分の反射率との比をコントラストの目安とする。車載 LiDAR による自動計測値を市販の手動計測器（リファレンス）による計測値と比較することで、車載方式による白線状態把握手法の妥当性を検証した。

- ・かすれ具合：市販の装置が存在しないので、リファレンスとなる手動計測器の製作から検討を行う。高い解像度が必要となるのでカメラ画像を用いて白線の剥離率を計測し、かすれ具合の目安とする。作製した手動計測器のカメラ画像による計測値を全国道路標識・標示業協会が定める 5 段階の目視評価ランク [3] と比較することで、作製した手動計測器のリファレンスとしての妥当性を検証した。

反射率およびコントラスト

テストコース内にて車載 LiDAR を用いて白線および隣接する舗装部分（アスファルト）の反射率を計測し、その反射率の平均値と手動計測器による計測値の比較を行った。それぞれ反射率特性の異なる 4 種類の白線（(a)一般的な白線、(b)ビーズ入り白線、(c)テープ式白線、(d)黒縁付きテープ式白線）を用意し、手動計測器には路面標示の反射輝度値を測定する機器として普及している [3] ミロラックス 7 を使用した。図 2.3.③-2 に手動計測器の外観（製品マニュアルより抜粋）および反射輝度値の測定の様子を、図 2.3.③-3 に反射率およびコントラストを計測する処理の流れを示す。



図 2.3.③-2 手動計測器（ミロラックス 7）の外観および反射輝度値の測定の様子




図 2.3.③-3 白線の反射率および白線と舗装のコントラストを計測する処理の流れ

まず，車載 LiDAR での自動計測値と手動計測器での計測値を比較調査するために車載 LiDAR による反射率の計測を行った．図 2.3.③-4 に計測した白線の平均反射率と，手動計測器での反射輝度値を示す．車載 LiDAR を用いて計測した白線の平均反射率は，概ね手動計測器による計測値と同じ様な傾向があることを確認できた．




図 2.3.③-4 車載 LiDAR での平均反射率と手動計測器での反射輝度値

次に、路面状態によって車載 LiDAR での自動計測値と手動計測器での計測値の傾向がどのように変化するかを調査するために、路面に水を撒く前と撒いた後で車載 LiDAR による計測を行った。図 2.3.③-5 に水を撒く前および撒いた後で計測した白線の平均反射率と、手動計測器での反射輝度値を示す。車載 LiDAR での自動計測値および手動計測器での計測値ともに、水を撒いたことで「(a)一般的な白線」と「(b)ビーズ入り白線」の値が下がり、「(c)テープ式白線」と「(d)黒縁付きテープ式白線」の値は殆ど変化がなかった。このことから車載 LiDAR を用いて計測した白線の平均反射率は、路面状態によらず概ね手動計測器による計測値と同じ様な傾向があることを確認できた。




図 2.3.③-5 水を撒く前および撒いた後で計測した白線の平均反射率と手動計測器での反射輝度値

最後に、白線と舗装（アスファルト）のコントラストについての検討結果を述べる．図 2.3.③-6 に白線とアスファルトの反射率比を示す．車載 LiDAR での自動計測値および手動計測器での計測値ともに、「(a) 一般的な白線」の値が低くその他の値が高いという点で同じ様な傾向が得られた．従って反射率比を白線と舗装のコントラストの目安とすることができると考えられるが、今後も計測データ数を増やして引き続き検討を行う．




図 2.3.③-6 白線とアスファルトの反射率比

かすれ具合

リファレンスとなる手動計測器として，道路上の白線の写真を真上からデジタル一眼レフカメラで撮影する装置の製作から検討を行った．図 2.3.③-7 に作製した手動計測器の外観を，表 2.3.③-1 に使用したカメラおよびカメラ周辺機器の詳細を示す．毎回同じ高さから撮影するためにアルミフレームで構築した直方体の骨組の上部にカメラアームおよび雲台を用いてカメラを固定し，理想的な照明条件の下で撮影するために骨組の側面を板で囲う構成とした．撮影時は更に上から暗幕をかけ完全に外部からの光を遮断した状態で，リング状のストロボによるフラッシュを付けて撮影した．




図 2.3.③-7 かすれ具合のリファレンスとして作製した手動計測器の外観

表 2.3.③-1 カメラおよびカメラ周辺機器の詳細

機器	メーカー	型番
カメラ本体	Canon	EOS RP
レンズ	Canon	RF 35mm F1.8 MACRO IS STM
ストロボ	Canon	MR-14EX II
カメラアーム	Manfrotto	244 Variable Friction Magic Arm
雲台	Manfrotto	MHXPRO-3WG

製作した手動計測器のリファレンスとしての妥当性を検証するために、撮影した白線写真を画像処理で二値化して白線の剥離率をかすれ具合の目安として算出し、全国道路標識・標示業協会が定める5段階の目視評価ランクと比較を行った。金沢大学の構内道路および駐車場にて目視評価ランク5（最も良い）～1（最も悪い）に相当する白線写真を各ランクにつき3枚ずつ撮影し、3枚の剥離率の平均値を最終的な値として採用した。図 2.3.③-8 に剥離率を計測する処理の流れを示す。



図 2.3.③-8 白線の剥離率を計測する処理の流れ

図 2.3.③-9 に計測した白線の剥離率，および比較対象の参考として全国道路標識・標示業協会が定める 5 段階の目視評価ランクの参照画像を示す．また計測に使用した白線写真の中から各ランクごとに 1 枚ずつ，二値化画像とともに例示した．目視評価ランクが下がるにつれ，作製した手動計測器により計測した剥離率が増加する傾向が得られた．従って作製した手動計測器はリファレンスとしての妥当性があると考えられるが，今後も計測データ数を増やして引き続き検討を行う．




図 2.3.③-9 目視評価ランク 5（最も良い）～1（最も悪い）に相当する白線の剥離率

(3) まとめ

今年度は道路上の白線領域を抽出するアルゴリズムおよび白線の状態を把握する目安の基礎検討を行った結果、それぞれの目標を達成することができた。白線領域を抽出するアルゴリズムについてはセマンティックセグメンテーションによる認識結果およびカメラの取り付け位置などの情報から、白線の位置を算出することができることがわかった。白線の反射率および白線と舗装のコントラストの目安についてはそれぞれ、車載 LiDAR による自動計測値と市販の手動計測器による計測値で同じ様な傾向があることを確認できた。白線のかすれ具合の目安については市販の手動計測器が存在しないため手動計測器の製作を行い、リファレンスとしての妥当性を確認できた。来年度はこれらの計測データ数を更に増やし、リファレンスとの相関を確認する。また今年度実施した基礎検討の結果とともに、将来的には車載センサのみを用いて自動運転車両を走行させるだけで半自動的に白線状態の目安を把握できるようにし、白線状態の目安が認識性能（精度・信頼度）に及ぼす影響の調査を行う。

【参考文献】

- [1] 木下雅央，浅田拓海，本多誠司，亀山修一，川端伸一郎，“道路区画線の剥離評価と夜間視認性評価に関する研究”，土木学会第65回年次学術講演会，2010
- [2] 浅田拓海，本多誠司，亀山修一，“画像特徴量を用いた道路区画線剥離率推定法の開発”，土木学会論文集E1（塗装工学），2011.
- [3] 一般社団法人 全国道路標識・標示業協会，“路面標示と交通安全”，2017.

2.4.d. 「交通参加者の行動予測推定とそれに基づくパスプランニング技術の開発」

① 人工知能(AI)に基づく歩行者の行動予測

歩行者や車などの移動体が未来の時刻にどのような経路で移動するかを推定する技術である経路予測において、移動体が経路を決定する要因は、対象物体周囲の環境などの外的要因と予測対象自身が保有している内的要因に分けることができる。外的要因は、例えば歩行者と車がガードレールなどで隔てられていない場所を走行する場合、側道に車が停車していると歩行者は走行路にはみ出して歩く、というような状況である。一方、内的要因は、性別や年齢などの属性情報であり、例えば子供は周辺に注意を向けることなく、急に道路に飛び出す、というような状況である。このような状況において、パスプランニングを実現するためには、移動体の行動を予測することが重要となる。そこで、歩行者の属性を内的要因として推定し、走行の周辺環境を外的要因として理解することで、属性情報を考慮した将来の軌跡を予測する手法を確立する。

2019年度は、内的要因である歩行者の属性認識アルゴリズムの開発を行う。歩行者の属性は、性別や年代、カバンの保持の有無、服装など、多岐にわたる。これらを同時に認識する方法としてマルチタスク学習がある。従来の属性認識手法である DeepSAR や DeepMAR は[1],各属性を個別に認識しているため、処理時間がかかる。そこで、本検討では、マルチタスク学習が可能な Attention Branch Network(ABN)[2]をベースとして、属性認識を行う。ABNは、一般物体認識手法の1つであり、認識する際にどこに着目したかをアテンションマップとして獲得できる。そのため、属性認識において、重要な場所を視覚的に把握することができる。

•Attention Branch Network による属性認識アルゴリズム

ABN は、Class Activation Mapping (CAM) の構造をベースとし、Attention branch を用いて、推論時におけるネットワークの注視領域を Attention map として獲得する。その後、Attention branch で獲得した Attention map を Feature extractor で抽出した特徴マップに反映する。最終的に、Perception branch で認識結果を出力する。ABNをマルチタスクに応用する場合、図 2.4.①-1 に示すように Perception branch をタスク数分配置し、特定の属性に属しているか否かを複数認識する。




図 2.4.①-1 ABN による属性認識のネットワーク構成

・評価データセット

評価には, Pedestrian Attribute (PETA) dataset [3]を用いる. PETA dataset は, 既存の小規模なデータセットを統合して構成しており, 多様なカメラ角度, 解像度の画像が含まれるため, 汎化性能の高いモデルを学習することができる. 属性には, 関心の高い性別や年齢層, 外観, 上半身及び下半身のスタイル, アクセサリーなど 61 種類があり, 各属性に対して yes/no の2値判定を行う. 本実験では学習に 11,400 枚, 評価に 7,600 枚を用いる. なお, 既存手法と同様の比較を行うため, 使用した属性は 61 属性中 35 属性である.

・評価結果

従来手法と ABN による属性認識の評価結果を表 2.4.①-1 に示す. ここで, odd は従来手法に対して ABN が幾つの属性で認識精度が優っているかを表している. これより, 従来手法と比較して認識精度が向上していることがわかる. また, 認識精度が向上している属性数は半数を超えていることがわかる.

表 2.4.①-1 属性認識の比較結果

手法	認識精度	odd
Deep SAR	81.3%	27/35
Deep MAR	82.6%	22/35
ABN	84.6%	-

各属性の認識精度について, 表 2.4.①-2 に示す. 属性には, 年代, 服装, カバンの保持の有無などがあり, ABN は高齢者(above61)で 97.3%と高い認識率にな

っている．これより，属性認識は，年代などを考慮した行動予測に利用できる
と考える．

表 2.4.①-2 属性別の認識結果

Attribute	DeepSAR	DeepMAR	ABN
Age16-30	82.9	85.8	80.6
Age31-45	79.4	81.8	77.6
Age46-60	83.3	86.3	94.1
AgeAbove61	92.0	94.8	97.3
Backpack	78.8	82.6	76.3
CarryingOther	73.0	77.3	84.1
Casual lower	81.6	84.9	91.6
Casual upper	81.1	84.4	91.2
Formal lower	81.9	85.2	92.1
Formal upper	81.6	85.1	92.4
Hat	89.2	91.8	95.3
Jacket	77.5	79.2	94.2
Jeans	80.2	85.7	78.6
Leather shoes	84.2	87.3	86.3
Logo	76.1	68.4	95.8
Long hair	83.2	88.9	85.5
Male	85.1	89.9	79.2
MessengerBag	77.4	82.0	79.7
Muffler	94.4	96.1	97.1
No accessory	81.5	85.8	88.5
No carrying	78.8	83.1	80.7
Plaid	84.9	81.1	94.3
Plastic bag	82.9	87.0	95.3
Sandals	81.3	67.3	98.0
Shoes	75.8	80.0	76.1
Shorts	81.9	80.4	96.4
ShortSleeve	84.6	87.5	87.7
Skirt	83.2	82.2	95.6
Sneaker	77.3	78.7	76.1
Stripes	72.8	66.5	98.2
Sunglasses	79.1	69.9	92.8

Trousers	78.4	84.3	71.8
T-shirt	80.0	83.0	91.3
UpperOther	83.4	86.1	81.1
V-Neck	75.5	69.8	98.8
average	81.3	82.6	84.6

【参考文献】

- [1] D. Li et al., "Multi-attribute Learning for Pedestrian Attribute Recognition in Surveillance Scenarios, ACPR, 2015.
- [2] H. Fukui, et al., "Attention Branch Network: Learning of Attention Mechanism for Visual Explanation", CVPR, pp.10705-10714, 2019.
- [3] Y. Deng, et al., "Pedestrian Attribute Recognition At Far Distance", ACM MM, 2014.

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

市街地には、車、バイク、自動車、歩行者などの多種多様の移動物体が多数存在する。このような移動物体に衝突せず安全に走行を行うためには、移動物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。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を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するため、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。したがってこのような環境の中で、どのように移動物体の運転状態やその形状を精度よく求めるかが課題である。また、自動運転自動車の走行計画では、現在地点から目標地点に向けてどのように走行すべきかを計画するのは非常に重要な技術である。自動運転自動車のより安全な走行を計画していくためには自動運転自動車の周辺移動物体を検出・識別し、数秒後の周辺移動物体の走行を予測することが必要である。

(1) 移動物体の運転状態と形状の同時推定

オクルージョンが頻繁に存在する環境下では、各時刻にセンサから得られる物体の形状が不安定となり、時刻間の物体の対応付け（Data Association）が困難となりそもそも移動物体の航跡自体を求めることが難しくなる問題が生じる。この問題に対しては、物体の形状も含めて剛体として追跡する Extended Object Tracking(EOT)[1]技術を導入し、追跡のロバスト化を目指す。

従来、移動物体の追跡手法として、追跡物体を仮想的に質点と仮定として時系列的に追跡する手法（以降質点追跡と述べる）が一般的に良く用いられてきた。この場合、追跡物体の時系列的な追跡によって運動状態の推定を行うことはできるが、形状の時系列的な推定は別問題として取り扱われるため、移動物体の形状推定に対するロバスト性に課題があった。一方今回導入する EOT では、追跡物体を直接剛体として取り扱い状態推定を行う。このため、LiDAR 等から得られる密なセンサ情報の活用が可能となり、追跡物体の外形に対応する複数の観測値を用いて時系列的に運動状態と形状情報を推定することが可能となる。このため、質点追跡に比べて移動物体の追跡における信頼性の向上が期待できる。なお、本事業では移動物体の状態推定に、Interacting Multiple Model (IMM)法[2]を用いた。

本事業では、シミュレーションによってこのアルゴリズムの定量的評価を行った。また東京臨海部において得られた実データから、アルゴリズムの有効性について評価した。

仮想的な環境での検証.

実装した EOT の定量的な評価のため，シミュレーションによる評価を行った．シミュレーションでは，図 2.4.②-1 に示すように追跡物体を矩形枠で近似できると仮定し，矩形枠の角 4 点とそれぞれ隣り合う角の midpoint 4 点の計 8 点をセンサから計測可能な観測値として仮定した．そして，これらの観測値にノイズを加えた値を EOT に基づき時系列的に追跡し，追跡物体の中心位置，方位及び，サイズの真値との差を求めることで，EOT の妥当性を検証した．




図 2.4.②-1 真値の矩形枠上の点を用いた状態の更新

なお観測値に与えたノイズは，実際の実験環境で使用する LiDAR の分解能 $0.02[\text{m}]$ に合わせて平均 $0[\text{m}]$ ，標準偏差 $0.02[\text{m}]$ の正規分布に従う観測ノイズを与えてシミュレーションを実施した．図 2.4.②-2 (a) に追跡物体の中心位置 x, y の真値との差の推移を示す．また，図 2.4.②-2 (b) にサイズ s^x, s^y はそれぞれ進行方向のサイズ及び，それに直交する方向サイズの推定結果を示す．なお横軸の Update Number は，時間経過のステップ数を示す．これらの結果から，観測値に与えた誤差に対して十分に高い推定精度で時系列的な追跡および物体形状の推定が行えていることが分かる．




図 2.4.②-2 EOT のシミュレーション結果

市街地走行で得られた実環境データによる検証。

次に、東京臨海部において得られた実データから、アルゴリズムの有効性についてオフラインで評価した。

EOT において、物体形状推定のロバスト性向上が見られた場面があったので、その場面について述べる。図 2.4.②-3 に一つの対象物体の観測情報の時間的な変化を示す。対象物体と LiDAR の位置関係の変化から、LiDAR から照射されるレーザが当たる領域が小さくなり、得られる輪郭情報が少なくなっている。この対象物体を質点追跡した結果及び、EOT により追跡した結果を比較したものを図 2.4.②-4 に示す。質点追跡ではサイズを追跡していないため、サイズはそのフレームにおいて LiDAR から得られる観測情報のみで求めている。よって、サイズが小さくなったと誤って判断されている。一方、EOT ではサイズも追跡しているため、ここで示したような観測情報が上手く得られない場合においても、時系列的に更新してきた追跡情報を用いることで、ロバストな追跡が行えている。今後はより多くのシーンで本アルゴリズムの更なる評価を行うとともに、実際の自動運転システムに導入し評価を実施する予定である。




図 2.4.②-3 対象の観測情報の変化





図 2.4.②-4 観測情報が変化した時の追跡結果

(2) 地図に基づいた移動物体の将来軌道の予測

自動運転自動車の軌道計画は、現在地点から目標地点に向けてどのように走行すべきかを計画する非常に重要な技術である。より安全な自動運転自動車の走行を計画するためには自動運転自動車の周辺移動物体を検出・識別し、数秒後の周辺移動物体の軌道を予測することが必要である。

周辺移動物体の走行を予測する手法として、周辺移動物体のセンサから識別された速度や加速度、位置情報を用いて予測するものがある。この手法では周辺移動車両が単一の経路（例えば、直進）しか作成していない。その結果、自車の走行にとって問題を生じる可能性がある。図 2.4.②-5 に予測の動

作と実際の動作が異なったとき時車両に影響を及ぼす主なシーンを示す．周辺移動車両（黄色）が直進すると予測したとき，自車（白色）は交差点に進入できずその周辺移動車両が通過するまで停止し続ける状態となる．もし周辺移動車両が直進するのを事前に判断できれば自車を待つことや，移動車両がウィンカーを出して減速するなどあらかじめ右左折することが分ければ，安全に考慮して早く交差点に進入できるといった走行計画が可能になる．したがって周辺移動車両が直進か右左折を判断することは非常に重要であることが分かる．そこで，周辺移動車両の走行する経路を直進だけでなく全ての経路を考慮し，その移動物体の取りうる行動の候補を確率的に探索しながら，将来の予測軌道を求める手法を構築した．さらに計算された経路を用いてどの経路を走行するか事前に判断する手法を提案した．



(a) 自車が右折する際に他車が
接近している場合

(b) 自車が交差点に進入した際に他車と
交差すると考えられる場合

図 2.4.②-5 交差点での周辺車両の将来軌道の予測の必要性




図 2.4.②-6 交差点近辺地図の例.

移動車両の取りうる全ての走行経路の作成.

移動車両の直進や右左折を判断するために、地図を使用した．使用するデジタル地図の情報としては、図 2.4.②-6 に示すようにノード，リンクで表されるベクトル地図（有向グラフ）を用いる：

- **ノード (WayPoint)**：道路の中心座標を表す緯度経度や道幅
- **リンク (Link)**：ノードの集合．ノード間のつながりとその方向を示し，直進・右左折といったリンクの種別や，制限速度，破線や黄色線などの白線種別情報が付加情報として記載されている．
- **グループ (Group)**：ノードとリンクの集合．通常の道路や交差点などの道路の分類情報を持つ．

これらの情報を用いて走行可能なルート予測を行う．まず，グループの中にあるリンクの中から最も近い距離のリンクを探索する．探索アルゴリズムの概要を図 2.4.②-7 に示す．リンク始点から自車の位置までの距離 K を求める．距離 K の計算に Levenberg-Marquardt(LM)法を用いている．




図 2.4.②-7 最近傍リンク探索アルゴリズムの概要

図 2.4.②-8 に周辺移動車両の走行全ての経路のアルゴリズムのフローチャートを示す．図 2.4.②-9 に示すように最近傍リンクを用いて走行する経路に分岐点があるか探索し，分岐点があれば，最近傍リンクを複製し直進経路 A と左折経路 B を作成する．作成した経路は経路内のノード数がある閾値になるまで拡張を行う．




図 2.4.②-8 辺移動車両の走行全ての経路のアルゴリズムの概要



図 2.4.②-9 交差点で移動車両経路の判断

地図ベースによる移動車両の走行経路の判断．

経路をスプライン曲線で補間した際にノード間の距離の長さによってうねりが生じ経路の曲率が正しく計算できない場合がある．そこで，作成した経路について曲率を正しく計算するためのリサンプリング方法について説明する．リサンプリングでは周辺移動車両の現在地点から 1m 間隔で行う．またリサンプリングを行った点には位置や制限速度などの情報を付与する．制限速度は経路の曲率と最大横加速度から求められる経路走行の最大速度である．図 2.4.②-10 に示すように自車以外の周辺移動車両が走行する経路を確率として表現する．周辺移動車両が直進か右左折かを判断する要素に速度，加速度がある．そこで前述で取得した経路情報と周辺移動車両の情報を用いて走行する経路の確率を求める．求めた確率に Binary Bayes Filter[3]を用いて時系列処理を行い信頼性のある確率にしていく．そして図 2.4.②-10 に示すように得られた各径路の走行確率を正規化し，周辺移動車両がどの経路を走行するか判断する．




図 2.4.②-10 走行経路の確率

実環境で走行する周辺移動車両には車間距離維持のための加速度が存在する．そこで周辺移動車両が追従している先行車両を探索し車間距離保持のための加速度を Intelligent Driver Model(IDM)[4]を使用して求める．IDM は，走行する経路において先行車両に追従する車両が最低車間距離を保持して走行するために必要な加速度を計算するモデルである．求められた加速度を走行経路の確率を求める時に使用し，実環境にも対応した周辺移動車両の走行する経路の判断を行う．

作成した経路中心と移動車両の横方向距離を取得する．予測時間後には経路中心に戻り走行する仮定とし，横方向距離が 0 になるように経路に沿った周辺移動車両の位置を計算する．

シミュレーションおよび実験データを用いた検証。

提案手法を実装し、シミュレーションを行った。図 2.4.②-11 は図 2.4.②-10 に示す状況下で、自動運転車両周囲の移動車両が左折すると仮定して提案したアルゴリズムを評価した結果を示している。このシミュレーションでは図 2.4.②-11 に示すように周辺移動車両は減速を継続的に行ったため、提案したアルゴリズムを用いることで事前に左折する判断ができた。




図 2.4.②-11 シミュレーションの確率の結果

次に実走行データによる評価を行う図 2.4.②-12 はシミュレーションと同様に自動運転車両周囲の移動車両が左折する状況下で取得したデータを用いて検証を行った結果を示す。図 2.4.②-12 に示すように周辺移動車両が継続的な減速を行ったため、停止線 5m 前から正しく左折経路を走行する判断できた。




図 2.4.②-12 シミュレーションの確率の結果

提案手法は早く継続的な減速を行うことが走行経路を事前に判断するための決め手となることが分かった。今後は、提案した手法をより多くの状況下で検証を行う予定としている。

(3) 公道走行による総合評価

2019年9月より、東京都臨海地区で自動運転自動車の公道実証実験を実施している。走行ルートとして、お台場周辺の約5km程度のルートを選定した。図2.4.②-13に走行ルートの例を示す。選定した走行ルートにおいて、自動運転状態での平均走行持続可能距離は2019年度の目標値である2.5kmを達成した。以下に公道走行実験の評価結果を述べる。

今回の総合評価では2020年3月中旬から3月末までの期間に実施し、7日間で合計261kmの距離を走行した。また、収集したデータの容量は6TB以上となった。走行実験は、主に朝9時から午後5時までの時間帯に晴天、雨天の状態で行ったが、一部早朝、夜間での走行検証のため、朝4時から夜10時までの時間帯での走行データも含まれている。

平均走行持続可能距離を計算するにあたって、自動運転モードの状態を以下の3つに分ける。

- ・制御ON
- ・制御OFF
- ・マニュアルオーバーライドによる制御OFF

制御ONは自動走行を行なっている状態を表す。制御OFFは目的地に到着した際や実験終了時など正常に自動運転モードを解除したことを表す状態である。マニュアルオーバーライドによる制御OFFは、自動運転システムが意図しない挙動を示した場合などにドライバが介入することによって自動運転モードが解除された状態を表す。



図 2.4.②-13 お台場走行ルートの例(日付:2019年11月14日)

自動運転自動車の自動走行に対する評価指標は様々なものがあるが、その中の「走行距離」、「累積走行距離」、「平均走行持続距離」と「自動運転割合」に注目する。

- ・ **走行距離**：走行ルートを走行した距離（手動運転・自動運転のどちらも含む）。
- ・ **累積走行距離**：走行ルート上を自動運転により走行した距離。つまり、自動運転モードが制御ONから制御OFFもしくはマニュアルオーバーライドによる制御OFFになるまでの走行距離を合計したものである。
- ・ **平均走行持続距離**：累積走行距離をマニュアルオーバーライドの発生回数で割った距離。すなわち、ドライバによる介入1回あたりにおける自動運転での平均走行距離である。また、走行中に1度もマニュアルオーバーライドが発生しなかった場合には平均走行持続距離は累積走行距離と等しくなる。
- ・ **自動運転割合**：自動走行距離のうち累積走行距離が占める割合。走行ルート上を自動走行した割合を意味する。

表 2.4.②-1 に各実験日における走行距離、累積走行距離と自動運転割合を示す。7 日間の合計で 171.81km の距離を自動走行した。また、7 日間の自動運転割合は 65.85% となり、6 割以上を達成した。表 2.4.②-2 に、オーバーライドの発生回数を示している。この数値より、平均走行持続距離は次の式で求めることができる。

$$\text{平均走行持続距離} = \frac{\Sigma \text{累積走行距離}}{\Sigma \text{オーバーライドの発生回数}}$$

ただし今回の検証データは、単純に自動運転車両の評価を行うための走行データとはなっておらず、取得したデータの中にはアルゴリズムの評価・検証を実施していた日のデータも含まれている。このため、オーバーライド発生回数が日によって大きな増減している。このため平均走行持続距離の計算には、走行距離および累積走行距離が一定以上のデータを抽出して、平均走行持続距離の算出を行った。その結果、7 日間の平均走行持続距離は 2.82km となった。ただし、本来正確な平均走行持続距離の算出には、アルゴリズムの評価・検証時のデータと平均走行持続距離の算出に用いるデータを分けて収集する必要がある。例えば、今回評価に用いた期間以外の日程で、持続走行距離が 7km を超える場合も確認されている。一方、平均走行持続距離は交通量や天候などの交通環境によっても大きな影響を受けると考えられる。このため、今後はデータの収集、整理方法についても検討を行う必要がある。

表 2.4.②-1 1 日間ごとの走行距離，累積走行距離と自動運転割合

	走行距離 (km)	累積走行距離 (km)	自動運転割合 (%)
3 月 16 日	43.88	35.64	81.22
3 月 17 日	21.88	18.35	83.87
3 月 18 日	17.28	16.16	93.52
3 月 24 日	11.07	9.44	85.38
3 月 26 日	79.14	33.37	42.17
3 月 27 日	43.62	20.39	46.74
3 月 31 日	44.02	38.46	87.37
合 計	260.89	171.81	65.85

表 2.4.②-2 7 日間のオーバーライドの発生回数

	オーバーライドの発生回数
3 月 16 日	10
3 月 17 日	4
3 月 18 日	6
3 月 24 日	5
3 月 26 日	15
3 月 27 日	5
3 月 31 日	16
合 計	61

表 2.4.②-3 7 日間の平均走行持続距離

	平均走行持続距離 (km)
3 月 16 日	3.56
3 月 17 日	4.59
3 月 18 日	2.69
3 月 24 日	1.89
3 月 26 日	2.23
3 月 27 日	4.08
3 月 31 日	2.40
合計	2.82

【参考文献】

- [1] H.Kaulbersch, J.Honer, M. Baum, A Cartesian B-Spline Vehicle Model for Extended Object Tracking.In *International Conference on Information Fusion*, pp. 1-5, 2018.
- [2] Y. Bar-Shalom, W.D.Blair, *Multitarget-Multisensor Tracking: Applications and Advances Vol. III*.MA: Artech House, 2000.
- [3] S. Thrun, W. Burgard, D. Fox, *Probabilistic Robotics*.Cambridge: MIT Press, 2005.
- [4] M. Treiber, A. Hennecke, D. Helbing, Congested Traffic States in Empirical observations and Microscopic Simulations. *Physical Review E*, vol. 62(2), pp. 1805–1824, 2000.

2.5.e. 「複数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

ロボティクス技術の高度化によるデッドロック回避を検討するために、まずはシミュレーションソフト上で複数の自動運転車が走行する環境を再現させ、自動運転システムにおいてデッドロックが発生しやすい状況をシーン別に5つ確認した。

・複数台の自動運転車両を考慮したシミュレータの開発

自動運転システムにおいてデッドロックが発生しやすい状況を走行実験以外でも明らかにするため、複数車両で自動運転のシミュレーションができる環境を開発した。また開発したシミュレータでは、今後様々な自動運転システムの評価にも使用可能とするため、ユーザによるハンドル入力によって一般ドライバを加えた走行シミュレーションも可能とした。本シミュレータの概要を図 2.5.①-1 に示す。




図 2.5.①-1 開発したシミュレータの概要

・デッドロックが発生するシーン

2019 年 12 月 26 日の東京臨海部での自動運転走行実験中，交差点走行において実際の交通ルールにそぐわない駐車車両により，自動運転システムにおいてデッドロックが発生しそうな状況に遭遇した．(以降で述べるシーン 1 に相当する状況)．その時の状況を図 2.5.①-2 に示す．



図 2.5.①-2 実際に遭遇したデッドロックが発生しそうな状況

上記のシーンも含め東京臨海部における実証実験を通じて遭遇したシーンおよび地形を基に，複数の自動運転車両をシミュレータ上で走行させ，デッドロックが発生するシーンを 5 つ確認した．これらの状況は以下の 3 つ状況に場合分けできると考えられる．

- 交通ルールを順守していない一般車両が存在する場合
- 見通しが悪い場合
- 譲り合いが必要な場合

シミュレータ上でデッドロックが発生することを確認できたシーンについて，以下でそれぞれ詳しく見ていく．なお，自動運転車は 2 台とも交通ルールを順守し，後続車がいるためバックはできないと仮定する．また 2 台の自動運転車はともに自律型の自動運転システムであり，お互いに車間通信はしないものとする．

【シーン 1】 交通ルールを順守していない一般車両が存在する場合… 交差点付近に路駐車両が停車しているシーン

- ・ 1 台目：交差点にて信号待ちをしていたところに，2 台目の自動運転車両が交差点で右折してきた．
- ・ 2 台目：交差点にて右折したところ，路駐車両が停車していたので，回避するために少し右側に膨らみながら走行しようとした．





図 2.5.①-3 交差点付近に路駐車両が停車しているシーン

- ・ デッドロック状況：2 台目の自動運転車両が路駐車両を回避しようと少し右側に膨らみながら走行しようとしたところ，反対車線に信号待ちの 1 台目の自動運転車両がいたため，車幅の関係でこれ以上進めない．一方で 1 台目も 2 台目によって前方を塞がれてしまったので，信号が青になったとしてもこれ以上進めない．

図 2.5.①-4 及び図 2.5.①-5 にこのシーンでのデッドロックの様子を示す．




(a) 1 台目視点




(b) 2 台目視点

図 2.5.①-4 【シーン 1】デッドロック直前の様子




(a) 1 台目視点




(b) 2 台目視点

図 2.5.①-5 【シーン 1】デッドロック直後の様子

図 2.5.①-6 にこのシーンにおける自動運転車両の車速プロファイルを示す。上記の状況が発生後、2 台とも車速が 0 から変化しないので、デッドロックになっていることが分かる。ただし 1 台目は信号待ちを想定しているため、デッドロック発生前から車速が 0 である。



(a) 1 台目



(b) 2 台目

図 2.5.①-6 【シーン 1】車速プロファイル

【シーン 2】 見通しが悪い場合…片側一車線の道路に路駐車両が停車しているシーン

- ・ 1 台目：自車線に路駐車両が停車していたので、回避するために少し右側に膨らみながら走行しようとした。
- ・ 2 台目：反対車線に停車している路駐車両を乗り越えそうとするタイミングで、1 台目の自動運転車両が路駐車両を追い越してきた。




図 2.5.①-7 片側一車線で見通しの悪い道路に路駐車両が停車しているシーン

- ・ デッドロック状況：1 台目の自動運転車両が路駐車両を回避しようとして少し右側に膨らもうとしたところ、ちょうど 2 台目の自動運転車両が反対車線を走行していたため車幅の関係でこれ以上進めない。一方で 2 台目も 1 台目によって前方を塞がれてしまったので、これ以上進めない。

図 2.5.①-8 及び図 2.5.①-9 にこのシーンでのデッドロックの様子を示す。






図 2.5.①-8 【シーン 2】デッドロック直前の様子




(a) 1 台目視点




(b) 2 台目視点

図 2.5.①-9 【シーン 2】デッドロック直後の様子

図 2.5.①-10 にこのシーンにおける自動運転車両の車速プロファイルを示す．上記の状況が発生後，2 台とも車速が 0 から変化しないので，デッドロックになっていることが分かる．



(a) 1 台目



(b) 2 台目

図 2.5.①-10 【シーン 2】車速プロファイル

【シーン 3】 見通しが悪い場合…片側一車線の道路に路駐車両が 2 台停車しているシーン

- ・ 1 台目：自車線に路駐車両が停車していたので、回避するために少し右側に膨らみながら走行しようとした。
- ・ 2 台目：1 台目と同様に、自車線に路駐車両が停車していたので、回避するために少し右側に膨らみながら走行しようとした。




図 2.5.①-11 片側一車線の道路に路駐車両が 2 台停車しているシーン

- ・ デッドロック状況：1 台目の自動運転車両が路駐車両を回避しようと少し右側に膨らみながら走行しようとしたところ、ちょうど 2 台目の自動運転車両も同様に右側に膨らもうとしたため、車幅の関係でこれ以上進めない。一方で 2 台目も 1 台目によって前方を塞がれてしまったので、これ以上進めない。

図 2.5.①-12 及び図 2.5.①-13 にこのシーンでのデッドロックの様子を示す。





図 2.5.①-12 【シーン 3】デッドロック直前の様子




(a) 1 台目視点




(b) 2 台目視点

図 2.5.①-13 【シーン 3】デッドロック直後の様子

図 2.5.①-14 にこのシーンにおける自動運転車両の車速プロファイルを示す．上記の状況が発生後，2 台とも車速が 0 から変化しないので，デッドロックになっていることが分かる．



(a) 1 台目



(b) 2 台目

図 2.5.①-14 【シーン 3】車速プロファイル

【シーン 4】譲り合いが必要な場合…複数台の自動運転車両が走行する幹線道路に合流するシーン




図 2.5.①-15 幹線道路に合流するシーン

幹線道路を走行している複数台の自動運転車両は，ある一定の間隔および速度を維持し続けるので，新たに合流するのが難しい間隔および速度の組み合わせだと，いつまでも合流できず合流地点の先端で停止してしまう．図 2.5.①-16 にこのシーンでのデッドロックの様子を示す．




図 2.5.①-16 【シーン 4】デッドロックの様子

図 2.5.①-17 にこのシーンにおける自動運転車両の車速プロファイルを示す．上記の状況が発生後，車速が 0 から変化しないので，デッドロックになっていることが分かる．




図 2.5.①-17 【シーン 4】車速プロファイル

【シーン 5】譲り合いが必要な場合…商業施設等の駐車場の出入り口でのシーン

本シーンにおいては，東京臨海部での地形を基に商業施設の出入り口の状況を想定したシミュレーションを実施した．ただし，日本全国を想定した場合，様々な大きさの出入り口が存在することが考えられる．このため，実際の商業施設の出入り口よりも幅が狭いことを想定したシミュレーションを実施している．

- ・ 1 台目：駐車場へ進入しようとした．
- ・ 2 台目：同時に駐車場から退出しようとした．






図 2.5.①-18 商業施設等の駐車場の出入り口でのシーン

- ・ デッドロック状況：駐車場の出入り口の幅が狭い中，1 台目と 2 台目の自動運転車両が同時に進入及び退出しようとしたため，車幅の関係でお互いこれ以上進めない．

図 2.5.①-19 及び図 2.5.①-20 にこのシーンでのデッドロックの様子を示す．




(a) 1 台目視点




(b) 2 台目視点

図 2.5.①-19 【シーン 5】デッドロック直前の様子




(a) 1 台目視点




(b) 2 台目視点

図 2.5.①-20 【シーン 5】デッドロック直後の様子

図 2.5.①-21 にこのシーンにおける自動運転車両の车速プロフィールを示す．上記の状況が発生後，2 台とも车速が 0 から変化しないので，デッドロックになっていることが分かる．



(a) 1 台目



(b) 2 台目

図 2.5.①-21 【シーン 5】车速プロフィール

・まとめ

複数台の自動運転車が走行できるシミュレータを開発し、東京臨海部で実際に遭遇したシーンおよび地形を基に今年度の目標値である 5 件のデッドロックのシーンを発見した。これら 5 件のシーンは、交通ルールを順守していない一般車両が存在する場合、見通しが悪い場合、譲り合いが必要な場合の 3 つの状況に場合分けされると考えられるが、今後はデッドロックの発生要因を詳細に分析することが課題となる。

② 人工知能(AI)を活用したデッドロック回避

自動運転車のパスプランニング技術では、観測した情報をもとにルールまたは数式に基づく軌道を計画している。これらのパスプランニングには限界があり、突発的なルールなどに落とし込めず、デッドロックが生じるシーンが実世界には存在する。そこで、本検討では、デッドロックが生じるようなシーンを想定し、深層強化学習によりデッドロック回避の行動を獲得できるか、検証を行う。

・デッドロック回避が必要なシーン

東京臨海部における実証実験を通じて、デッドロックが生じるシーンをいくつか抽出した。本検討では、

- 1) 走行車線に駐車車両があり、対向車を避けて走行するシーン
- 2) 信号待ち時に対向車線に駐車車両があり、右折車が来た時に相手の走行領域を空けるようなシーンを対象とする。

・深層強化学習

強化学習は、エージェントが試行錯誤を通じて価値を最大化するような方策を見つける問題である。また、教師あり学習とは異なり、事前に正解が与えられるのではなく、自身の行動の良し悪しをもとに最適な行動を見つけ出す手法である。強化学習は教師信号の作成が困難なロボット制御[1]やゲーム攻略[2]など様々なタスクに応用されている。近年では、コンピュータ囲碁プログラムである AlphaGo[3] に強化学習が用いられ、プロの棋士に勝利している。また、強化学習に深層学習を組み合わせた深層強化学習が主流となっており、強化学習の代表的な手法である Q 学習と畳み込みニューラルネットワークを組み合わせた Deep Q-Network(DQN)[4]は、Atari2600 のゲーム攻略において人間を上回る性能を実現している。また、Actor Critic 法と worker と呼ばれる並列で経験を収集する機構を用いた分散学習を組み合わせた手法である Asynchronous Advantage Actor-Critic (A3C)[5] は、膨大な数の状態数を持つ連続空間の問題においても有効性を示している。本検討では、A3C をベースネットワークとして用いる。

・デッドロック回避に向けたアイデア

実問題へ深層強化学習を適用する際、環境に複数のエージェントが存在するケースが多く、エージェント同士の相互作用を考慮する必要がある。その

方法として、マルチエージェント強化学習がある。マルチエージェント強化学習は、複数のエージェントを同時に学習する手法である。しかし、複数のエージェントが存在する場合、自己利益のみを優先してしまい、エージェント同士が衝突することで、学習の停滞や局所解への陥りなど効率的な学習が困難となる。そのため、エージェント同士の衝突を避けて学習を行う仕組みが必要である。本検討では、マルチエージェント強化学習に深層学習を導入する際に、ネットワークを単一としてエージェントごとに複数のブランチを分けて同時学習する手法とする。




図 2.5. ②-1 デッドロック回避の行動獲得のための深層強化学習ネットワーク構造

本検討に用いるネットワーク構造を図2.5. ②-1に示す。ネットワークには、車両の鳥瞰画像、速度と曲率を入力する。ネットワーク構造は、単一ネットワークでエージェントごとに方策と状態価値の出力層をブランチ分けし、全てのエージェントが畳み込み層を共有するようなネットワークとする。各エージェントはそれぞれ対応したブランチからの出力を制御値とする。これにより、他エージェントの学習を自分の学習に反映し、他エージェントとのインタラクションを考慮した学習が可能となる。また、デッドロックが発生した場合、デッドロックを回避する行動獲得の促進を図る。

・技術検証の環境

技術検証を行う自動運転環境は図 2.5.②-2 に示すように、2 台の車を配置し、走行シーンに障害物がある。走行レーンを正しく走行し、障害物または他車に衝突すると失敗となる。障害物は車両が 2 台以上通れない程度の間隔を空けてランダムに設置する。エージェントの行動は速度増減及び曲率増減変化なしの組み合わせで合計 9 通りであり、最大速度が 3m/s、最低曲率が

0m/s, 最大曲率が 0.25, 最低曲率が-0.25 とする. 1 回のエピソードの終了条件はエージェントが道路外, 障害物及び他車両に衝突した場合と 1.0×10^5 ステップ経過で終了とする.



図 2.5. ②-2 深層強化学習の自動運転環境

衝突を回避する行動を獲得するためには, エージェントに対して報酬を与える必要がある. 本検討では, 表 1 に示す報酬ルールをもとに学習を行う. 報酬には, 良い行動をした時の正の報酬と, 良くない行動をした時の負の報酬がある. ゴールした場合には大きな報酬を与え, 前進また正しい走行レーンを走行していると正の報酬を受け取ることができる. 一方で, 障害物や他車両に衝突した場合は負の報酬が与えられる. また, 速度を急に变化させたり, 他者との間隔が狭い場合にも負の報酬となる.

表 2.5. ②-1 報酬ルール

報酬の種類	報酬値
ゴール報酬	+10
車両の前進	+0.5
左側通行	+1.5
衝突ペナルティ	-10
速度変化によるペナルティ	-0.5
車間距離によるペナルティ	-3

・評価指標

自動運転環境において, ステップ数ごとの累積報酬の推移と評価環境における 1000 試行での衝突回数を比較することで, 検討手法の有効性を確認する. 比較手法として独立したネットワークを用いて学習する場合(ネットワーク共

有なし), 提案手法(ネットワーク共有あり) の2 通りで学習を行う. A3C の worker 数は7 とし, 各手法を 1.0×10^7 ステップ学習する.

・評価結果

自動運転環境における共有なし agent 1, 2 及び共有あり agent 1, 2 のステップ数ごとの累積報酬の推移を図4 に示す. 図4から, 共有ありは共有なしと比較してより高い累積報酬を獲得した. このことから, デッドロック状態を回避する学習が可能であり, マルチエージェント環境における検討手法の有効性が確認できる. また, 共有なし agent1, 2 の累積報酬は両エージェント共に約500 で差がないのに対し, 共有あり agent1, 2 での累積報酬の差は約100 となり, agent1 が高い累積報酬を獲得している. これは, agent2 が agent1 を考慮した学習を行い, デッドロック状態における相手を優先する行動を取ったことによる累積報酬の低下であると考えられる. このことから, 検討手法を用いることにより相手を考慮し, より高い利益を獲得する行動の学習を実現した.




図 2.5. ②-3 学習ステップごとの累積報酬の推移

デッドロックを誘発する自動運転環境における共有なしagentと共有ありagentの衝突回数を表2.5. ②-2に示す．表2.5. ②-2から，共有なしagentと比較し共有ありagentの衝突回数が395回少ないことが確認できる．このことから，提案手法を用いることでデッドロックによる衝突を回避するエージェントの獲得を実現した．

表 2.5. ②-2 衝突回数の比較

	衝突回数
共有なし(従来手法)	997
共有あり(検討手法)	602

シーン1)において，検討手法により獲得した行動の推移を図2.5. ②-4に示す．ここでピンク色の車両がagent1，青色の車両がagent2である．図2.5. ②-4から，agent2が $t+1$ から $t+2$ まで停止してagent1が障害物を通り過ぎた後動き出している．これはデッドロックを回避するためにagent2はagent1が通り過ぎるのを待つという行動を獲得できているためと考えられる．このことから，相手を考慮してデッドロックによる衝突を回避するエージェントの獲得を実現した．




図 2.5. ②-4 シーン 1) におけるデッドロック回避行動

・バックによるデッドロック回避検証

デッドロックの回避行動として、バック行動を追加し、より困難なデッドロック状態を回避できるか検証する．学習する際の行動の最低速度を -1m/s に変更し，報酬にバック行動によるペナルティ -3 を加える．バック行動によるペナルティは緊急時のみにバック行動を起こすようにするためである．学習回数は 1.0×10^7 ステップまで行う．

シーン 2)において，バック行動を追加したモデルにより獲得した行動を図 2.5. ②-5 に示す．ここでピンク色の車両がagent1 で青色の車両がagent2 である．図2.5. ②-5より， $t+1$ から $t+6$ までの間にデッドロックが発生し，agent2 が $t+4$ から $t+5$ でバック行動を行なってデッドロックによる衝突を回避してい

ることがわかる．このことから，バック行動を追加しても相手を考慮した学習を行うことができ，より衝突を避けるエージェントの獲得を実現した．




図 2.5. ②-5 シーン 2) におけるデッドロック回避行動

【参考文献】

- [1] S. Gu, et al., “Deep reinforcement learning for robotic manipulation with asynchronous off-policy updates, ICRA, 2017.
- [2] V. Oriol, et al., “StarCraft II: A New Challenge for Reinforcement Learning”, CoRR, 2017.
- [3] D. Silver, et al., “Mastering the game of Go with deep neural networks and tree search”, Nature, 2016.
- [4] V. Mnih, et al., “Playing Atari with Deep Reinforcement Learning”, NIPS, 2013.
- [5] V. Mnih, et al., “Asynchronous Methods for Deep Reinforcement Learning” ICML, 2016.

2.6.f. 「実証実験」

昨年度選定した試験車両（LEXUS RX450hL）を購入し，車載コンピュータからの指示でハンドル，アクセル，スロットル，ウィンカーを制御可能とするため，車両の改造を実施した．

車両の改造にあたっては，マニュアルオーバーライド機能を搭載し，自動運転中にドライバの操作介入があった場合に安全に手動運転状態に移行できる機能を実装した．具体的には，ハンドルに一定以上のトルクを加えた場合，スロットルやブレーキを人間が踏んだ場合に，自動運転状態から手動運転状態に即座に切り替えが行えることができる仕様とした．また図 2.6-1 に示すように，運転席付近に緊急用の手動運転切り替えスイッチを設置し，人間による手動運転状態と自動運転システムによる自動運転状態を明確に区別可能な仕様とすることで，二重の安全対策を実施した．



図 2.6-1 試験車両内に設置した手動運転・自動運転切り替えスイッチ

また試験車両に搭載するセンサを購入し，試験車両へ搭載した．図 2.6-2 にセンサを搭載した試験車両の外観を示す．また，図 2.6-3 にセンサの搭載概要を示す．



図 2.6-2 センサ搭載済みの試験車両内の外観




図 2.6-3 試験車両に搭載したセンサの搭載概要

試験車両には、LiDAR (Light Detection and Ranging), ミリ波レーダ, GNSS/INS GNSS(Global Navigation Satellite System) / INS(Inertial Navigation System)等のセンサを設置した。このうち LiDAR (Light Detection and Ranging) に関しては、天井部に Velodyne 社の VLS-128 を 1 台搭載し、車両全方位を中距離から遠距離まで監視可能とした。また、同じ天井部には、Velodyne 社の VLP-16 を 2 台搭載することで、車両側方部の近距離において VLS-128 から死角となる領域の監視も可能とした。また車両側方の前輪付近には、交差点進入時の死角を減らす目的に Velodyne 社の VLP-32 を 2 台搭載している。またミリ波レーダに関しては、デンソーテン社製のミリ波レーダ 9 台がバンパー内に埋め込まれており、これら 9 台のミリ波レーダを組み合わせることで概ね全方位の物体検知を可能としている。さらに、車両天井部および車室内のルームミラー付近に合計 11 台のカメラが設置されており、これらのカメラを組み合わせることで全方位の物体検知や信号認識等が可能となっている。また GNSS/INS に関しては、図 2.6-4 に示す三菱電機社の AQLOC-Light を搭載し、準天頂衛星を利用した衛星測位を可能とした。また、自己位置推定精度の検証用および自動運転システムの初期検討用として、Applanix 社の POS-LV220 も搭載した。



図 2.6-4 試験車両に搭載したセンサの搭載概要

また東京臨海部に整備されている ITS 無線路側器からの信号情報等のインフラ情報を取得可能とするため、図 2.6-5 に示すように ITS 無線受信機等も設置した。

なお本事業では、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実施するため、効率的かつ安全な運用を行う観点から上記で説明した試験車両を 2 台構築した。また、自動運転システムに関しては、金沢大学が本事業実施前までに開発してきた独自のソフトウェアを用いて開発を進めることで効率的な事業の実施を行った。



図 2.6-5 試験車両に搭載した ITS 無線受信機を用いて ITS 無線路側器と通信を行っている様子

（２）公道走行実証実験実施

上記で述べた試験車両を使用した公道走行試験に先立ち、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を実施した。具体的には、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した。また図 2.6-6 に示すように、日本自動車研究所が実施している自動運転車の公道実証実験に向けた「事前テストサービス」を活用して、第三者機関による安全性評価を実施し、試験車両及び試験車両に搭乗するドライバの双方により安全性を担保して公道走行試験が実施可能であること確認した。その後、2019 年 7 月から石川県金沢市中心部において走行実証実験を開始した。また、2019 年 9 月から東京臨海部での走行実証実験を開始した。

図 2.6-7 に東京臨海部において公道で自動運転を実施している様子を示す。東京臨海部での走行実証実験に関しては今年度合計 67 日実施し、自動運転状態で約 850.6km を走破した。また、ITS 無線を活用した実証実験に関しては 32 日間実施し、当初の目標を達成した。



図 2.6-6 日本自動車研究所テストコースにおいて安全性評価を実施している様子



図 2.6-7 東京臨海部において公道で自動運転を実施している様子

3. 実施体制

