

2020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

2021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2020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。」

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」	10
c. 「高精度自己位置技術の開発」	12
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」	14
e. 「複数自律型自動車が走行する状態での問題点の検討」	16
f. 「実証実験」	17
1.3. 成果の要約	19
a. 「信号機認識技術の開発及び認識が困難な条件の検討」	19
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」	20
c. 「高精度自己位置技術の開発」	21
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」	22
e. 「複数自律型自動車が走行する状態での問題点の検討」	23
f. 「実証実験」	25
2. 研究開発成果	26
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」	26
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	26
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	52
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」	68
① 遠距離向け車載カメラの選定・検知アルゴリズム開発	68
② LiDAR およびミリ波レーダに基づく遠方物体認識	79
2.3. c. 「高精度自己位置技術の開発」	88
① GNSS/INS の開発	88
② マップマッチング技術の開発	97
③ 白線の状態が自動運転システムに与える影響の調査	108
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」	125
① 人工知能(AI)に基づく歩行者の行動予測	125

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	138
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」	153
① ロボティクス技術を活用したデッドロック回避	153
② 人工知能(AI)を活用したデッドロック回避	167
2.6. f. 「実証実験」	184
3. 実施体制	188

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。

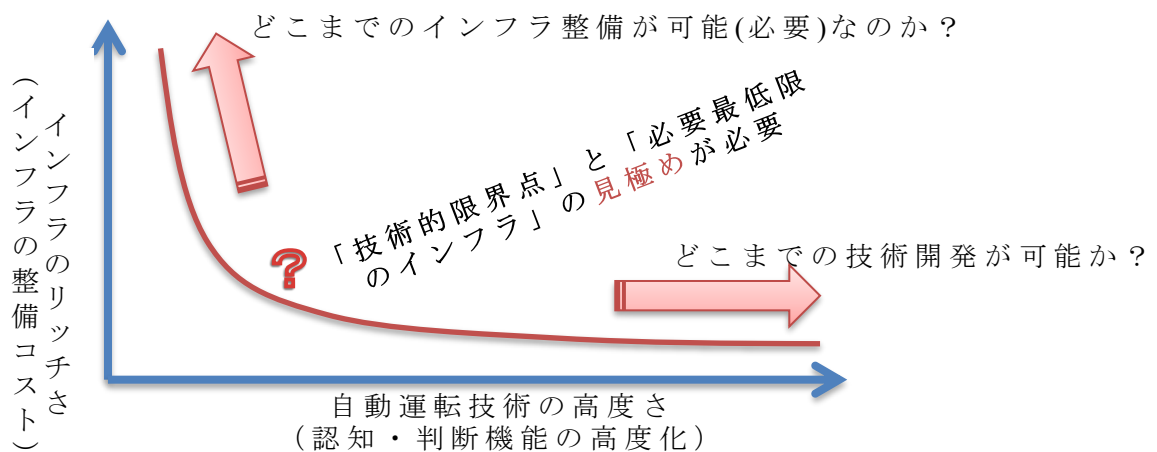


図 1.1-1 インフラのリッチさと自動運転技術の高度差の関係

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。

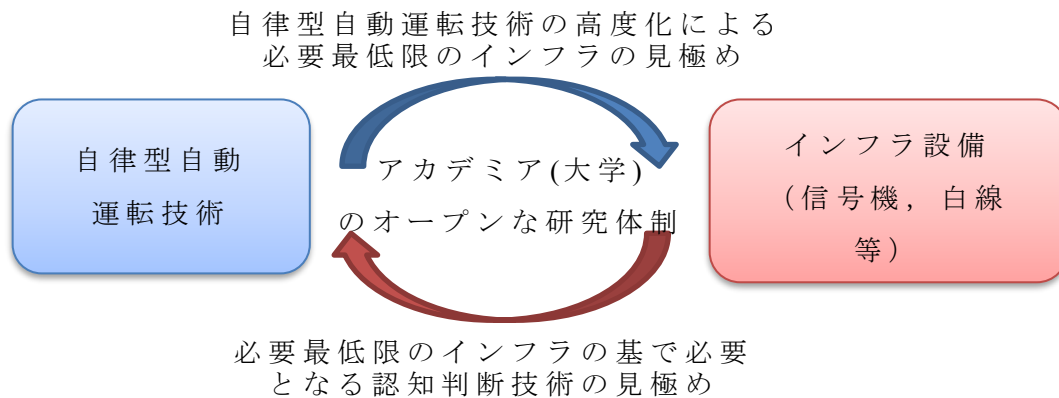


図 1.1-2 必要最低限のインフラの見極めと認知判断技術の見極め

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2020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%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などカメラの性能限界による認識困難な状況を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。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。さらに、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することを目指す。周辺車両への安全性に配慮しながらジレンマゾーンでの急減速回避の効果を評価する。

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、2020年度は、多様な天候の画像を学習データとして利用し、さらに時系列での信号機状態認識を行うことで99%の認識精度を実現する。

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。

以下に実施内容および 2020 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、2020 年度は、最新の物体検知アルゴリズムとその改良により、自動車 200m、歩行者 70m の遠距離の物体を検出する際に生じるピントずれによるぼやけに対応し、小さな物体を正確に検知するアルゴリズムを実現する。

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する。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る。これによって 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かを評価する。

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。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 2020 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。さらに 2020 年度ではみちびきを活用した測位性能の評価、及び手法の改善を行う。

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。

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、評価ルートの選定を行なった。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。

2020 年度に関しては、ローコスト GNSS/INS の利用を前提とした個別方式のマップマッチングアルゴリズム開発を目指し、テンプレートマッチングによる位置および方位角を推定する手法を実装、評価する。

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。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。

2020 年度は、昨年度から検討している白線の状態を把握する手法を基に、白線の状態が白線認識およびマップマッチングに及ぼす影響度の評価を行う。

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 2020 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。2020年度は、属性情報と周辺環境を考慮した歩行者の行動予測アルゴリズムの開発を行う。周辺環境の理解にはセマンティックセグメンテーションを活用する。また、走行実験により有効性を検証する。

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の車線が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での物体認識及びパスプランニングの改善を図る。また、市街地環境における自動運転の平均走行持続可能距離を5.0km以上とするアルゴリズム改善を実施し、自動運転のオーバーライドにおける不調要因を分析する。

e. 「複数自律型自動車が走行する状態での問題点の検討」

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。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2020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。2020 年度では，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。2020 年度は，デッドロックが生じる複数のシーンのシミュレーション環境を構築し，深層強化学習による経路計画を獲得する。実走行車でデッドロックの回避が可能か検証するために，深層強化学習で利用する入力情報の獲得装置と本デッドロック回避アルゴリズムとを接続するシステムを構築する。また，出力情報を車両制御の情報に変換する処理を有するシステムも構築する。

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。

2020年度は、2019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、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

今年度の実施項目として、昨年度より実施している東京臨海部での実証実験を継続実施して信号機認識における環境要因が主となる認識への技術課題の分析及びアルゴリズム評価を実施した。その結果、逆光、順光、隠蔽、背景同化、夜間などの環境条件下では一時的に認識性能が低下する状況を確認している。しかしながら交差点接近における一時的な影響が中心のため、同一交差点の他の信号機を併用するなどの対応により交差点進入判断には致命的な問題は発生しないことを検証した。このように多数の信号機の状況から交差点進入を判断する戦略を導入することで2020年度の目標である120m以内の青・赤・矢印信号を99%以上で認識可能なことを実証した。一方、評価結果より逆光・順光時は認識への影響が大きいことも確認したため、太陽光の影響範囲の定量評価及び逆光影響領域の認識アルゴリズムを開発し、逆光時のカメラの性能限界による視認不可な状況での誤認識を抑制するための対応も補助的な対処方法として検討した。

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を実現するため、昨年度開発した交差点進入判断アルゴリズムを一般道で評価する検証実験を実施した。これにより確定情報として与えられる先読み情報が得られる場合において、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地図情報の有無による精度への影響を評価した。その結果、地図情報を用いることで誤検出を抑制でき、信号機認識精度を向上させることに寄与することを確認した。また、認識精度の課題抽出およびインフラ要件の策定に向けて、信号機認識アルゴリズムに最新手法を導入し、精度向上を図った。信号機認識アルゴリズムの検知機能は、DeepLabV3+またはHRNetをベースとする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、ResNet50, Ghostnet, mobilenet V2, Densenetをベースとする物体認識手法にて行う。これらの組み合わせを評価した結果、HRNetとmobilenet V2による信号機認識アルゴリズムは、20ピクセル以上の信号機に対して97.28%の精度であった。さらに、時系列処理を導入することによって、信号機の認識精度を98.96%まで向上させることができた。昼間だけでなく夜間

や雨天などの悪天候でも信号機を高精度に認識できることを示した。一方で、早朝などの逆光時にセマンティックセグメンテーションにより信号機を検知できないケースがあった。

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。従来手法の比較から YOLO v4 が高精度に検知が可能であることがわかった。そこで、遠距離の物体を検知できるよう入力画像サイズの拡大およびネットワークの内部構造の改良を行った。これにより、200m 遠方に相当する 25 ピクセルの自動車、70m 遠方に相当する 48 ピクセルの歩行者の検知が可能となった。一方で、遠方の歩行者に対する検知精度は十分高いとは言えない。そこで、見通しの良い環境における歩行者検知精度を評価した。その結果、48 ピクセル程度の歩行者の検知精度は 65.2%であった。歩行者の検知精度を 90%程度にするには、歩行者のサイズが 90 ピクセル程度になるよう、さらに入力画像サイズを拡大することが必要となることがわかった。

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、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にデジタル地図を併用した認識アルゴリズムの開発を行った。昨年度の評価結果より、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た。しかし、遠方まで安定して認識を継続するためにはカメラによる認識距離の改善も必要であることが課題として挙げられている。そこで、カメラによる認識距離改善及びリアルタイム化を実現するために、デジタル地図を活用した認識領域の生成方法を検討した。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遠距離認識への効果を評価した。評価結果より限定した領域に対して画像矩形枠の検出距離が改善された。また、開発したアルゴリズムを LiDAR による物体追跡アルゴリズムに統合して性能評価を実施し、2020 年度の目標である 200m 以内の自動車及び 70m 以内の歩行者を 90%の検出率を達成した。

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。

そこで、2020 年度は 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 信号への対応を行った。具体的には、車両運動の拘束を利用した位置推定結果の信頼性判定法が有効に働くような測位解が得られるように CLAS LIB を用いた測位アルゴリズムの改善を行った。さらに、2020 年 11 月から開始された CLAS で放送される補正情報が 17 機に増加することによる性能改善幅の調査の実施を行った。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見られた。そのため、衛星数が減少することが想定される個所においては、インフラを活用したマップマッチング等の補完技術により位置精度を維持するための技術が必要になることが想定される。

②. マップマッチング技術の開発

2020 年度においては、車載グレードの GNSS/INS を使用することを前提としたマップマッチングアルゴリズム開発を行った。マップマッチング方式としては、昨年度までの東京臨海部実証において使用してきた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て、位置および方位角を推定する手法を開発・実装した。車載グレードの GNSS/INS を使用する際、安価なジャイロセンサが内部に搭載されていることから高精度 GNSS/INS と比較して方位角が精度良く得られない。そのため、車載グレードの GNSS/INS の方位角を用いてセンサデータを画像上にマッピングした場合、画像にぶれが発生し位置推定が正しく行えないといった課題がある。そこで、本研究ではセンサデータからリアルタイムにマッピングした観測画像と地図画像との間の路面パターンの傾きから角度差を求めるという考えをもとに、Hough 変換をベースとし

た方位角誤差(オフセット)の推定手法を開発した。精度検証のため、2018年度に選出した金沢市内の評価ルートにおける評価を行い、本手法によって目標精度である 0.1m が達成可能であることを確認した。また、東京臨海部実証において、高精度 GNSS/INS を使用していた場合でも高架下などの GPS 信号の受信が困難となる場所で方位角誤差が増大し、位置推定誤差が大きくなるケースが確認された。そのような状況においても、開発した手法を用いることで正しく方位角および位置推定が可能となることを示した。

③. 白線の状態が自動運転システムに与える影響の調査

本テーマでは白線の状態を「白線の剥離率」「白線の反射率」「白線と舗装の反射率コントラスト」の3項目に分け、各項目が白線認識およびマップマッチングに及ぼす影響の調査を行った。

まず「白線の剥離率」の把握には高い解像度を要するので、車載センサとしてはカメラを使用する。そのため、同じくカメラを用いる白線認識(セマンティックセグメンテーション)への影響度を調査した。その結果、剥離率が高いほど(つまり白線がかすれているほど)認識率が低い頻度が多くなることが確認された。

一方で「白線の反射率」「白線と舗装の反射率コントラスト」の把握には反射率の計測が可能な LiDAR を使用するため、同じく LiDAR を用いるマップマッチングへの影響度を調査した。その結果、白線と舗装の反射率コントラストが高いほど(つまり白線がはっきりと引かれているほど)マップマッチングの確信度が高い頻度が多くなることがわかった。

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

歩行者の行動予測として、自動車視点および俯瞰視点からの経路予測アルゴリズムの評価および分析を行った。自動車視点からの経路予測では、シーン内の全ての移動物体の経路を同時に予測できる手法を評価した。本手法では、全ての移動物体の経路を同時に予測するため高速である一方、自車の移動量によってシーン全体の移動量が大きくなるため、経路予測精度が低い。俯瞰視点からの経路予測では、自車の移動量に関係なく固定したシーンでの移動経路を予測できるため、高精度であった。俯瞰視点からの経路予測において、地図情報(シーンラベル)の有無による地図の有効性を評価した。その結果、地図情報がない場合、建物などの障害物に衝突する経路を予測する一方、地図情報があ

る場合は、障害物を避けるような経路を予測することができた。これより、地図情報が経路予測においても有効であることがわかった。また、移動物体の属性による移動経路について分析した。具体的には歩道から道路への飛び出しをどの程度前から予測できるか分析した。その結果、大人や高齢者の場合は 3m から 5m 程度道路から離れた位置でも飛び出す経路を早期に予測できた。一方、本検討で用いた経路予測手法では、子供の場合は 9m 以上と十分に離れた位置からでないと飛び出す経路の予測が困難であることがわかった。経路予測手法による予測精度の違いがあるため、最新の手法による評価および地図情報のさらなる有効な活用方法を検討する必要がある。

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

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、今年度は移動物の認識方法の改善などを実施して密な交通環境においてスムーズな走行を可能とした。移動物の認識の課題では、昨年度までに開発していた Extended Object Tracking 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を実センサでリアルタイム化できるように改善して実証実験に導入した。この結果、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持続走行距離 5km を達成した。この他、評価結果に基づいてオーバーライドの発生頻度の要因を分析し、オーバーライドに影響のある道路環境の要因の分析を実施した。これにより、道路構造物や他車の存在により死角が発生する交差点での右折走行や矢印信号の点灯時間の短い交差点での右折走行など特定の交通環境下においてオーバーライドに影響のある不調要因を調査した。

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

今年度の実施項目として、昨年度に挙げたデッドロックが発生する 5 件のシーンを解析し、デッドロック発生後に「事後的に対処」できるか、もしくは発生前に「事前に予防」しなければならないか、という観点でタイプ分けをした。前者のタイプに対しては主にロボティクス技術を、後者のタイプに対しては主に e. ②の人工知能(AI)技術を用いて、デッドロック回避の検討を行なった。前者の「事後的に対処」できるタイプのデッドロックシーンの主な原因は、一般的な自動運転システムが“なるべく車線を逸脱せずに走行する”ことを前提に構築されていることである。そこで本研究テーマでは、デ

ッドロック発生時には臨時的に“あえて車線を逸脱して回避する”という柔軟性を自動運転システムに与えることで、デッドロックを回避するアルゴリズムを構築した。なお、本来このようにやむを得ないとは言え、臨時的に交通ルールを遵守せず、デッドロック回避を試みるのが法律上許容されるのかについては議論が必要ではあるが、あえてここではデッドロックのアルゴリズム上の回避策の可能性について検討を実施した。また、本テーマにて検討したデッドロック回避アルゴリズムをシミュレーターおよび非公道における実車試験にて有効性を確認した。検証結果より車線を逸脱して走行可能なスペースが存在する特定の場合においてはデッドロック状態を回避可能であることが確認された。

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)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、2)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、3)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、4)幹線道路に合流するシーン、5)商業施設等の駐車場の出入り口でのシーンである。これらのシーンに対するシミュレーション環境を構築し、深層強化学習によるデッドロック回避が可能かを検証した。なお各シーンにおいて、適切な報酬設計を行った。シーン 3, 5 において、相手を考慮する行動を獲得することで、デッドロック回避を行う行動の獲得を実現した。一方、シーン 1, 2, 4 では、デッドロック回避を行う行動の獲得を実現できなかった。デッドロック回避を行う行動を獲得できたシーンでは、回避行動が一意または限定されており、回避行動の獲得が容易であったと考える。デッドロック回避行動の獲得が困難であったシーンでは、回避行動の選択肢が多い、または複数台が連携して回避行動を取る必要がある複雑な条件であった。これらのシーンで回避可能なシミュレーション環境の再検討、回避行動を獲得するための報酬ルールの見直しなどが必要である。

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，ITS 無線受信機のアンテナの設置位置の見直し，計算機の更新，車載グレードのローコスト GNSS/INS の設置などの装置の更新を実施した．また，石川県金沢市における地図の作成，羽田地域における地図作成等を実施し，東京都臨海部および石川県金沢市の中心部における走行実証を継続的に実施した．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信号現示情報及び残業数情報を活用した公道走行実証実験についても実施した．そして，これらの取り組みを通し，2020 年度は東京臨海部での走行実証実験に関しては今年度合計 54 日実施し，自動運転状態で約 1,287.2km を走破した．また，内閣府が主催して開催した東京臨海部実証実験メディア向けガイドツアー(2020 年 9 月 1 日実施)，SIP-adus 中間成果報告会(2021 年 3 月 24, 25 日実施)などにおいて，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。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 99%の達成を目標とし、評価結果から認識が困難となる環境要因を明らかにする。その結果から、インフラによる支援が求められる状況を整理してまとめる。具体的には以下の研究項目・分析を実施した。

- ・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性能評価
- ・逆光・順光時の信号灯視認性への影響範囲の調査
- ・逆光影響範囲の認識アルゴリズムの検討
- ・インフラ支援信号機を用いた交差点進入判断の評価

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性能評価

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[1-3]、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]。昨年度までに開発してきた信号機認識アルゴリズムの概要を図 2.1.①-1 に示す。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 を算出し、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 画像内に対して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、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．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．しかしながら 120m 以上先の矢印灯を認識する場合，ピクセル数の小さな点灯物を安定して認識することが要求される．本実証実験で使用している画角 60 度を有するフル HD クラスの解像度のカメラを用いた場合，100m 先の矢印灯は 10px 以下の解像度となるため，機械学習アルゴリズムのみで特定の方向をもつ矢印灯を認識することは容易ではない．そこで昨年度の成果として，デジタル地図の情報として信号機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[4]．今年度の評価ではここで開発した信号認識アルゴリズムを用いて性能評価を実施する．




図 2.1.①-1 信号認識アルゴリズムの概要

昨年度まで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．実際に市街地を自動運転走行するときの状況に近い評価を行うため、一連の交差点接近時の画像リストをシナリオとして定義して多数のシナリオデータをまとめて評価する．表 2.1.①-1 に計測した評価データの一覧を示す．評価データは 233 件の交差点接近シナリオとして日中、逆光・順光、夜間、雨天の条件のデータから構成されている．画像データの総フレーム数は 42,603 枚となっており、評価対象となる ROI の総数は 97,985 個である．

表 2.1.①-1 東京臨海部の走行データに関する評価データ

	Type	Number of Data
ROI 数	青信号	46,818
	黄信号	2,926
	赤信号	31,529
	赤信号＋左矢印	212
	赤信号＋直進矢印	3,930
	赤信号＋右矢印	1,847
	赤信号＋複数矢印	2,566
	None（遮蔽）	8,158
	合計	97,985
シナリオ数	日中	140
	夜間	44
	雨天	12
	逆光・順光	37
	合計	233
フレーム数		42,603

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．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 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．

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

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

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


ただし、データ数の都合により矢印灯の認識率の評価では個別の点灯状態に応じて TP/FP/FN を算出しこれらを統合して矢印灯の認識率としてまとめて評価する．本実験では以下の観点に基づいて性能評価を実施する．

- ・ 個別信号機単位の認識性能の評価
- ・ 交差点単位の認識性能の評価
- ・ 望遠レンズカメラ併用による認識性能の評価
- ・ 環境条件別の認識性能の評価


開発した認識アルゴリズムの性能を画像認識の観点から評価する場合は各 ROI に対応する信号機の点灯状態を個別に評価する方法が取られる．しかしながら、多くの場合では同一交差点には複数の信号機が設置されており、あるフレームにおいても当該交差点の複数の信号機を同時に認識する場合では同一交差点として関連付けられた信号機の認識結果から総合的に交差点の点灯状態を決定することが可能である．そこで、個別信号機単位の評価とは別に交差点単位で点灯状態を評価する．この時、同一フレームに複数の信号機がある場合は多数決戦略により点灯状態を決定する．

また、実証実験で使用している自動運転自動車では信号認識の性能評価用に複数画角の車載カメラを搭載している．遠方信号灯に対する貢献を評価するために通常画角（53deg）に加えて望遠画角（27deg）を併用した評価も実施する．具体的な方法としては、通常画角で評価対象となる任意の信号機 ROI に対して望遠画角の画像内に対応する ROI が含まれる場合は望遠画角の ROI 画像を利用するという方法である．その他、日中・夜間などの環境条件別の認識率も評価する．


評価結果として図 2.1.①-2 及び表 2.1.①-2 に全評価データに対する青信号、赤信号及び矢印灯の認識率を示す．評価結果では個別信号機単位及び信号機単位の評価結果と望遠カメラの併用の有無の違いによる距離ごとの認識率と 100m 及び 120m 以内の平均認識率を示している．




(a) 個別信号機評価 (53deg)



(b) 交差点単位評価 (53deg)



(c) 個別信号機評価 (53deg+27deg)



(d) 交差点単位評価 (53deg+27deg)

図 2.1.①-2 全評価データに対する性能評価結果

表 2.1.①-2 全評価データに対する性能評価結果

		青信号	赤信号	矢印灯	平均
個別単位	100m 以内	0.989	0.982	0.933	0.968
	120m 以内	0.984	0.977	0.908	0.956
交差点単位	100m 以内	0.998	0.991	0.976	0.988
	120m 以内	0.996	0.987	0.960	0.981
個別単位 (望遠併用)	100m 以内	0.986	0.979	0.937	0.967
	120m 以内	0.984	0.978	0.928	0.963
交差点単位 (望遠併用)	100m 以内	0.998	0.992	0.983	0.991
	120m 以内	0.997	0.992	0.982	0.990

評価結果より以下のことが確認された．

- ・ 交差点単位で信号状態を判断することで全体の認識率が改善
- ・ 望遠カメラを併用することで遠方赤信号灯及び矢印灯の認識率が改善
- ・ 交差点単位の評価で望遠レンズを併用することで 120m 以内の平均認識率が 0.990 となり今年度の目標認識率を達成

交差点単位で評価することで特に赤信号及び矢印灯の認識率の改善を確認した．これは個別信号認識時では，図 2.1.①-3 のように遠方の矢印灯を認識する際に，矢印灯の点灯状態の未検出や点灯状態の誤検出により各 ROI の認識結果にばらつきが確認されている．これが交差点単位の認識として多数決戦略を取ることで適切な状態に出力できるようになったことが要因である．また，望遠カメラを併用することで遠方矢印灯の認識率が 2%程度改善できていることが確認できた．図 2.1.①-4 に通常画角のカメラで認識した信号灯・矢印灯領域の 픽셀数の分布を示す．図 2.1.①-4 より，90m 以降となると矢印灯の 픽셀数が 10px 以下となり，7~10px 程度の矢印灯の向きを正確に認識することは容易ではないことが評価結果より確認された．これに対して画角 1/2 の望遠カメラを利用すると全体の目標値を達成できたことから，矢印灯の画素数が最低 15px 程度は確保されている条件下での認識が望ましいと言える．



図 2.1.①-3 通常画角カメラでの交差点接近時の個別信号機認識の誤認識例
(Dist: 信号機との距離，GT: 正解ラベル，RES: 出力状態)




図 2.1.①-4 通常画角カメラによる信号灯領域のピクセル数

次に，環境条件別の評価結果を表 2.1.①-3 に示す．条件による多少のばらつきはあるものの各条件では矢印灯でも 97%以上の認識率が得られており，平均認識率は 98.5%以上の平均認識率が得られていることから極端に認識率が低下している条件は確認されていない．僅かな差ではあるが，逆光・順光の条件下での矢印灯の認識率が他の条件と比べて低い傾向があることが確認されている．

表 2.1.①-3 環境条件別性能評価結果（交差点単位評価・望遠併用）

		青信号	赤信号	矢印灯	平均
日中	100m 以内	0.999	0.995	0.985	0.993
	120m 以内	0.998	0.994	0.984	0.992
夜間	100m 以内	0.996	0.987	0.990	0.991
	120m 以内	0.995	0.987	0.980	0.987
日中・雨天	100m 以内	1.000	0.987	1.000	0.996
	120m 以内	1.000	0.991	0.997	0.996
逆光・順光	100m 以内	0.998	0.987	0.971	0.985
	120m 以内	0.998	0.987	0.976	0.987

東京臨海部における実証実験で得た評価結果では全体として 120m 以内の信号灯・矢印灯を 99%程度で認識可能であることが確認された．しかしながら条件によっては未検出・誤検出などの状況も確認されている．具体的には隠蔽，


背景同化，夜間及び逆光などのシーンで視認性による課題を確認した．以下に個別で確認された不調シーンに関する特徴的なシーンを述べる．

【隠蔽】：街路樹の遮蔽

東京ビックサイト正門の交差点を走行中に確認された不調シーンである．図 2.1.①-5(a)のように道路中にせり出している街路樹によって信号機が遮蔽されているシーンである．図 2.1.①-5(a)中に赤丸で囲っている領域に信号機の青信号灯が一部確認されているが，このような樹木による遮蔽ではカメラの視点から信号機そのものを確認することは困難となる恐れがある．また図 2.1.①-5(b)に当該交差点接近中の点灯状態を示す．このシーンでは認識開始の数フレームで未検出が確認されるもののその後はすべての信号機を適切に認識できているため致命的な問題とはならないが街路樹による影響のため季節などによって影響の受け方が異なることも想定される．



(a) 不調シーンの画像




(b) 交差点接近時の認識の様子
(点灯状態：青信号)

図 2.1.①-5 環境不調による課題シーンの例（隠蔽）


【背景同化】：背景構造物のエッジによる信号機の境界不鮮明

有明コロシム前の交差点を走行中に確認された不調シーンである．図 2.1.①-6(a)のように画像中で信号機周辺にある背景の建物により対象となる信号機の境界が不鮮明となり未検出となることが確認された．さらに，背景の建物のエッジのパターンを誤認識することも確認されている．図 2.1.①-6(b)より特に遠方の信号灯のみ検出が確認されているが，近距離になると適切に認識可能となっている．



(a) 不調シーンの画像

150m以内から認識開始



(b) 交差点接近時の認識の様子

(点灯状態：青信号)

図 2.1.①-6 環境不調による課題シーンの例 (背景同化)


【夜間】：グレア・ブルーによる矢印灯の形状不鮮明

東京湾岸アンダー出口の交差点を走行中に確認された不調シーンである．夜間の画像では点灯物周辺にグレアやブルーなどの影響を受けることによって点灯物周辺の輪郭が日中に比べると不鮮明になる傾向がある．これによって図 2.1.①-7 のように矢印灯の輪郭が不鮮明になることから矢印灯の未検出や青信号灯への誤検出などの不調が確認されている．このような場合でも近距離になると適切に認識できる状態を確認していることから発生する影響は限定的であると言える．



(a) 不調シーンの画像

150m以内から認識開始



(b) 交差点接近時の認識の様子

(点灯状態：赤+矢印灯)


図 2.1.①-7 環境不調による課題シーンの例 (夜間)

【逆光】：太陽光による逆光領域の飽和

青海一丁目の交差点を走行中に確認された不調シーンである．図 2.1.①-8(a)のように画像中で信号機付近に太陽が存在する場合には逆光の影響により一部が飽和した画像が撮影される．この場合では飽和した領域周辺にある信号機を適切に認識することができなくなるため，未検出，誤検出などの影響を確認している（図 2.1.①-8(b)の traffic light ID=2 が逆光の影響を受けた信号機）．図 2.1.①-8(a)でも確認できるように撮影画像上では飽和領域周辺が黄色に近い色合いになっていることもあり，赤信号や青信号を黄信号と誤認識する場合なども発生している．



(a) 不調シーンの画像



(b) 交差点接近時の認識の様子
(点灯状態：赤信号→青信号)

図 2.1.①-8 環境不調による課題シーンの例（逆光）

以上のように隠蔽・背景同化・夜間・逆光などの環境要因において信号機単体の認識において認識結果が不安定となる場合を確認した．しかしながら，一連の交差点接近において隠蔽は一時的，背景同化や夜間は遠方において確認されており，影響は一時的であるため交差点進入判断に致命的な影響はないと言える．逆光の場合においても，飽和の影響による未検出・誤検出が発生していても図 2.1.①-8のように正常に認識されている他の信号機があることで交差点進入判断が可能となる．一方，上記の検証結果より交差点進入に課題となることが想定される状況としては，以下の2点が考えられる．

- ・ 交差点接近中に対象信号機すべてを認識できない状況が一定時間継続する場合（進入判断不可）
- ・ 交差点先頭に停止時に対象信号機すべてを認識できない場合（発進不可）

1 点目の進入判断不可は前述の課題となるシーンなどにおいても環境要因の認識不調は限定的であることが確認できているため問題の発生頻度は非常に少ないと考えられる。2 点目の発進不可の状況は特に逆光及び順光時に起こりうる課題であり、図 2.1.①-9(a)のように停止線位置停車時に認識対象の信号機が一つしかなく、その信号機が逆光の影響を受けている場合は問題となる。しかしながら、2 個以上の信号機が設置されている交差点では手前側と奥側など離れた位置に信号機が設置されていることから、画像内の逆光の影響が限定的であれば一方が逆光の影響を受けても他方は影響を受けていないことが考えられる。図 2.1.①-9(b)のように前方を広角に捉えることで手前の信号機も視認可能なため、逆光の影響の度合いに応じてどちらの信号機を認識するべきかを判断することも重要である。



(a) 通常画角カメラ (53deg)

(b) 広角画角カメラ (120deg)

図 2.1.①-9 停止線位置での逆光発生時の画像例 (赤丸が信号機)

・ 逆光・順光時の信号灯視認性への影響範囲の調査

前節での評価結果では環境要因により視認性が低下して認識が困難となる状況として逆光・順光・隠蔽・背景同化・夜間などのシーンが確認された。これらの不調要因のうち、逆光などの太陽光による影響が要因となる不調はカメラの性能限界により影響の度合いが左右される。そこで信号機認識における太陽光の影響の程度を調査するために逆光及び順光の影響下の画像を撮影して視認性を評価する。

信号機の視認性を調査する前に逆光・順光時の視認性への影響に関する仮説を検討した。図 2.1.①-10 に示すように、カメラ、信号機及び太陽との相対的な位置関係によって影響の度合いが変化すると考えられる。逆光の場合では、画像内で信号機と太陽の位置が接近しているときに信号機が飽和することで視認性が低下する。したがって、カメラ・信号機間のベクトルとカメラ・太陽

間のベクトルのなす角が特定の範囲にある場合に視認性に影響を受ける（図 2.1.①-10(a)）。しかしながら，画像中の太陽が完全に信号機の裏側にある場合は太陽が遮蔽されるため影響を受けないことも想定される．一方，順光の場合では，自車後方の太陽が前方の信号機を照らすことで信号灯自体が反射光で明るくなることで視認性が低下する．この時照らされた反射光の向きがカメラ・信号機のベクトルに近い場合に強い影響を受け，太陽が高い位置にある場合などでは影響の度合いが小さいと考えられる（図 2.1.①-10(b)）。




図 2.1.①-10 カメラ・信号機・カメラの相対関係による逆光・順光時の影響の仮説

以上の影響の仮説を検証するために，逆光・順光時の評価データの計測は，任意方向の逆光・順光画像を撮影するため十分に開けた場所として，岐阜県高山市の農道離着陸場である「飛騨エアパーク」の滑走路を試験エリアとして利用した．図 2.1.①-11 のように滑走路上に仮設信号機として用意した LED 信号機及びランプ式信号機を設置して太陽方向に向きを変えながら逆光・順光の画像を撮影した．




図 2.1.①-11 逆光・順光の撮影実験の様子


画像の計測では逆光・順光が発生する特定の時間帯で両信号機の点灯状態を変化させながら、影響が想定される範囲内でカメラを移動させて実施する。仮設信号機は約 2m の高さで実際の交差点の信号機の設置高さ（約 5m）と比べて低い位置となる。そこで、撮影用のカメラは自動運転自動車のフロントガラスに設置するのではなく道路面付近の高さから見上げるように固定して撮影する。実験条件として撮影されたフレーム数を表 2.1.①-4 に示す。逆光・順光のそれぞれの条件において、撮影条件の都合により撮影可能な範囲は異なるものの、各点灯状態に対して 200 枚以上の画像を撮影し、これらの画像から視認性を評価する。なお、本実験で使用するカメラは東京臨海部の実証実験で使用している HDR/LFM(High Dynamic Range/LED Flicker Mitigation)機能を持つ車載カメラとしており、カメラの画角は 120deg である。

表 2.1.①-4 逆光・順光の視認性評価における撮影画像数

	逆光(LED)	逆光(ランプ)	順光(LED)	順光(ランプ)
青信号	243	232	1,099	1,128
黄信号	248	282	896	974
赤信号	410	400	1,051	1,047
赤+右信号	589	655	783	826
撮影範囲	数 m～15m 程度の範囲		数 m～60m 程度の範囲	

まず撮影位置の違いによる視認可否を評価するため、撮影された信号機画像を人が確認して適切な点灯状態を判別できるかで撮影範囲全体における視認困難な領域がどのように分布しているのかを調査する。次に信号機画像の点灯/非点灯領域に対して明るさ及び色合いなどの比較することで視認性にどのような影響が発生しているのかを考察する。

逆光時の評価結果として視認困難となる位置のプロットを図 2.1.①-12 に示す。図 2.1.①-12 では、逆光画像を撮影した位置において点灯状態を視認困難と判断した地点を黄点でまとめている。図 2.1.①-12(a)及び(b)より、逆光時の影響は LED 式・ランプ式によらず同程度の範囲で発生していることが確認された。点灯色の違いによる差も確認されておらずそれぞれの状態において視認困難な領域が確認された。



縦軸：東西方向，横軸：南北方向


赤点：信号機位置（原点），黄点：視認不可位置，灰点：視認可能位置

(a) LED 式信号機


(b) ランプ式信号機

図 2.1.①-12 逆光時の視認不可範囲

また，逆光時の特徴的な画像を図 2.1.①-13 に示す．当初の仮説のように太陽位置が信号機の点灯部付近に存在する場合に信号機が飽和することで視認困難となる状況が確認された．また，信号機の裏側に太陽が隠れた場合や点灯部から離れた位置にある場合は視認可能であることも確認された．したがって，逆光の影響を受ける範囲は限定的であり点灯部付近の特定範囲だけで視認困難となる．逆光が影響する範囲は撮影するカメラのダイナミックレンジなどに依存して異なるが本実験では点灯領域の周囲に $5 \sim 10\text{deg}$ 程度の範囲に逆光の影響を受けるスポットが確認された．



(a) 逆光時の画像



(b) 視認困難な影響範囲（円形領域内に太陽がある場合は視認不可）

図 2.1.①-13 逆光時の信号機画像例

逆光により視認性が低下した場合において、ピクセル値レベルで比較したときに点灯領域にどのような変化が起こっているのかを評価する。前述の信号機認識アルゴリズムの開発において、画像中の信号機領域は一般的に彩度及び明度が高い値で色相が特定の範囲にある場合認識しやすい信号機となる。そこで信号機の点灯部の任意の 5 画素を手動で選択してそれらの色相・彩度及び明度の平均値の傾向を比較する。評価に用いた信号機画像及び評価結果を図 2.1.①-

14 及び表 2.1.①-5 に示す．図 2.1.①-14 は信号機周辺に太陽が存在する場合の LED 式信号機及びランプ式信号機を示しており，すべての画像で青信号が点灯している画像である．図 2.1.①-14 の②，③，⑤，⑥は点灯状態を確認可能な画像で，①，④，⑦は逆光による飽和で点灯状態の判別が困難な画像である．これら各画像の青信号灯領域の色相，明度及び彩度の平均値を表 2.1.①-5 に示す．これらの逆光に関する視認性の評価結果に基づき以下の点が確認された．

- ・ 逆光時の視認性への影響は LED/ランプ式信号機によらず点灯領域周辺の限定的な範囲で発生
- ・ 影響範囲は使用するカメラに依存するが本実験では 5～10deg 程度
- ・ 逆光の影響により視認性が低下する場合は点灯部の色相が実際の点灯色と異なる値となる
- ・ 逆光の影響により視認性が低下する場合は点灯部の彩度が低下（視認可能な場合と比較して彩度が最大 89%程度低下）





図 2.1.①-14 逆光時の信号灯視認性評価における信号機画像

表 2.1.①-5 逆光時の信号灯視認性の評価結果

	①	②	③	④	⑤	⑥	⑦
視認可否	×	○	○	×	○	○	×
色相	78.3	162.8	145.6	107.1	161.6	149.2	88.8
彩度	0.056	0.405	0.231	0.047	0.391	0.256	0.076
明度	1.000	0.882	0.899	0.999	0.764	0.807	0.998

次に，順光時における信号灯の視認性を評価結果として逆光時と同様に視認困難となる位置のプロットを図 2.1.①-15 に示す．逆光時における評価結果（図 2.1.①-12）では LED 式・ランプ式によらず影響範囲は同程度であったのに対して，順光時ではランプ式が広範囲に渡って視認不可となる結果が確認された．表 2.1.①-6 に示すように LED 式信号機では黄色信号の点灯に関して一部視認困難が確認されたが青・赤信号に関しては問題なく判別可能であった．一方，ランプ式信号機では点灯状態によらず全体的に高頻度で視認不可なフレームが確認された．順光時の特徴的な画像を図 2.1.①-16 に示す．図 2.1.①-16 より，順光時のランプ式信号では点灯状態によらずすべてのランプが点灯しているかのように撮影されており判別困難となることが確認できる．信号機本体が太陽に照らされる際の影響は信号機本体の形状にも依存するが当初の仮説通り LED 式信号機に対してランプ式信号機に対する影響が非常に大きいことが確認された．



縦軸：東西方向，横軸：南北方向

赤点：信号機位置（原点），黄点：視認不可位置，灰点：視認可能位置

(a) LED 式信号機

(b) ランプ式信号機

図 2.1.①-15 順光時の視認不可範囲

表 2.1.①-6 順光時のデータにおける視認不可なフレームの割合

	LED 式信号機	ランプ式信号機
青信号	0%	95.2%
黄信号	15.5%	84.7%
赤信号	0%	76.7%
赤+右信号	0%	80.6%




図 2.1.①-16 順光時の信号機画像例

順光による影響を受けた場合の視認性の変化を比較するため、逆光時同様に点灯部の色相・彩度・明度を評価する．表 2.1.①-7～2.1.①-10 に評価結果を示す．順光時の画像では本来点灯していないライトが太陽光の反射で点灯しているかのように撮影される影響が確認されていた．そこで各表では点灯しているライトだけでなく青・赤・黄・矢印の各ライトの領域の色相・彩度・明度を調査した．評価結果より、まずランプ式信号機では点灯状態によらず各ライトの色相値が点灯色相当の値を示し、矢印灯を除く青・黄・赤信号の彩度・明度は全体的に同程度の値を示すことが確認された．特に点灯・消灯間で彩度・明度に優位な差が確認されないことから、点灯するライトの判別が困難となるといえる．矢印灯に関しては青信号灯器に矢印型のカバーを取り付けた構造のため明度・彩度が若干低下するが矢印灯の点灯・消灯間では他のライト同様に彩度・明度の変化は確認されないため点灯の判別は困難となる．一方、LED 式信号機に関しては点灯しているライトのみ当該色の色相となり、点灯・消灯間で彩度の値に優位な差が確認された．これによって点灯状態を適切に視認可能となる．しかしながら、黄色信号の点灯に関しては彩度の差が十分に大きくないことが確認された．表 2.1.①-6 による評価結果においても LED 式信号機の黄信号で判別できない状態が確認されたが、本実験の撮影画像においては他の灯色に比べて点灯状態が不鮮明となることが定量的に確認された．

表 2.1.①-7 順光時の信号灯視認性の評価結果（青信号点灯）

	①（ランプ式信号）				②（LED 式信号）			
	青	黄	赤	矢	青	黄	赤	矢
点灯状態	○	×	×	×	○	×	×	×
色相	171.6	40.4	357.0	158.3	140.8	114.4	120.8	119.6
彩度	0.590	0.474	0.637	0.376	0.160	0.096	0.097	0.096
明度	0.710	0.860	0.821	0.496	0.887	0.800	0.786	0.797

表 2.1.①-8 順光時の信号灯視認性の評価結果（黄信号点灯）

	③（ランプ式信号）				④（LED 式信号）			
	青	黄	赤	矢	青	黄	赤	矢
点灯状態	×	○	×	×	×	○	×	×
色相	173.2	46.3	357.6	165.2	110.0	97.1	118.0	116.4
彩度	0.609	0.407	0.616	0.378	0.097	0.104	0.099	0.097
明度	0.692	0.885	0.805	0.467	0.820	0.807	0.785	0.801

表 2.1.①-9 順光時の信号灯視認性の評価結果（赤信号点灯）

	⑤（ランプ式信号）				⑥（LED 式信号）			
	青	黄	赤	矢	青	黄	赤	矢
点灯状態	×	×	○	×	×	×	○	×
色相	172.4	37.2	354.4	166.8	108.4	112.8	30.7	120.4
彩度	0.592	0.524	0.630	0.364	0.089	0.094	0.134	0.094
明度	0.658	0.772	0.817	0.435	0.865	0.836	0.864	0.822

表 2.1.①-10 順光時の信号灯視認性の評価結果（赤＋矢印点灯）

	⑦（ランプ式信号）				⑧（LED 式信号）			
	青	黄	赤	矢	青	黄	赤	矢
点灯状態	×	×	○	○	×	×	○	○
色相	171.6	38.8	354.0	157.9	107.1	110.0	34.8	132.0
彩度	0.607	0.503	0.669	0.447	0.100	0.098	0.136	0.140
明度	0.667	0.821	0.826	0.495	0.820	0.805	0.835	0.842

これらの順光に関する視認性の評価結果に基づき以下の点が確認された。

- ・ 順光時のランプ式信号

- ・ 点灯/消灯によらず色相が灯色に近い
- ・ 点灯/消灯によらず彩度が高い
- ・ 点灯/消灯間の彩度の差が変化しないため灯色の判別が困難

- ・ 順光時の LED 式信号


- ・ 消灯中の色相は灯色と異なる
- ・ 点灯/消灯によらず彩度が低い
- ・ 点灯/消灯間で彩度に差があるが、一部の黄信号では彩度の差が小さく視認困難な状況が確認された

- ・ 逆光影響範囲の認識アルゴリズムの検討

これまでの評価において、逆光・順光などの影響を受ける場合信号機の視認性が低下することが確認されている。このうち順光は旧式のランプ式信号機の視認性に影響を与えるが LED 式信号機に対する影響は僅かである。一方、逆光の場合は LED/ランプ式信号機に関係なく点灯領域の周辺に太陽が撮影される場合に強い影響を受け点灯状態を判別困難となる。交差点接近時にカメラ画像に太陽が写りこむと、画像が白飛びして信号の状態を誤認識してしまうことがあると適切な交差点進入判断ができない場合が発生する。太陽の方角は車両の現在位置と時刻の情報から計算することが可能であるが、雲や建物によって太陽が遮られることがあるため、カメラの画角内に計算した太陽の方角が含まれば必ず逆光が発生するというわけではない。さらに、これまでに実施していた実証実験での評価より、図 2.1.①-17(b)のように太陽光がビルに反射して間接的に逆光の影響を受けることも確認されている。したがって、逆光の影響による誤検出を防ぐためにも車載カメラ画像内の逆光の影響領域を認識することは重要である。そこで本研究では車載カメラ画像において逆光の影響を受けている領域を認識するアルゴリズムの開発を実施した。開発したアルゴリズムでは畳み込みニューラルネットワークにより画像中の逆光による影響を受けた領域を画素レベルで認識するアルゴリズムとなっており、図 2.1.①-18 のように直射日光や反射光により視認性の低下した領域の確率を認識可能となっている。また、図 2.1.①-18(a)のように視認性が低下していない領域は低い確率が出力されるため、この情報を用いることで画像中の任意の信号機が逆光の影響を受けているか否かを判断可能となる。



(a) 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）



(b) 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）

図 2.1.①-17 逆光の走行データにおける特徴的なシーン
（2019 年度報告書より抜粋）




図 2.1.①-18 画像認識による逆光状態の認識例

・インフラ支援信号機を用いた交差点進入判断の評価

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では、視点の都合による隠れや逆光等による画像の飽和などの影響下では画像中で信号機を捉えることができないため本質的に認識不可能な状態となる。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、信号認識のタイミングによって交差点通過の判断にばらつきが生じることが想定され、急減速による後続車の追突の危険性がある。一方、V2I 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信号情報の取得が実現可能である。昨年度までの取り組みにおいて、図 2.1.①-19 のように、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し、大学構内の道路においてジレンマゾーンの急減速回避を検証した。今年度の取り組みでは東京臨海部実証実験において整備されているインフラ支援型信号機を用いて公道の走行環境下で開発アルゴリズムの効果を検証する。





図 2.1.①-19 通信情報を用いた交差点進入

東京臨海部実証実験では臨海副都心エリア及び羽田空港エリアにおいてインフラ支援型信号機が整備されている．ここで整備されている信号機では先読み情報の配信方法の異なる3種類の信号機が存在しており，確定的な先読み情報の信号機，幅付きの先読み情報の信号機，先読み情報のない信号機に分けられる．昨年度に開発した交差点進入判断アルゴリズムは確定的な先読み情報が配信されていることを前提とした事前減速アルゴリズムであるため，本検証実験では確定情報を配信している信号機を選定して実施する．そこで，検証実験では確定情報の信号機で十分な加減速が可能な交差点として東京モノレール羽田空港線整備場駅周辺の交差点を選定した．図 2.1.①-20(a)に評価エリアを示す．この直線路での走行データを計測し，先読み情報の利用の有無による交差点急減速の傾向を評価した．ただし，ジレンマゾーンでの急減速発生時の後続車への安全を確保するために自動運転自動車の後続にはサポートカーを配置して実験を実施した．図 2.1.①-20(b)に検証結果として，青信号で交差点接近時に交差点直前で黄信号に変化するシーンの速度のグラフを示す．大学構内での検証結果と同様に先読み情報を利用することで信号灯色が変わるよりも前に事前減速を開始してなめらかに停止している様子が確認できる．以上より公道で整備されたインフラ支援型信号機を用いて交差点進入時の急減速を回避可能である点を検証した．



(a) 検証実験の評価エリア
(東京モノレール羽田空港線
整備場駅周辺)



(b) 信号残秒数情報による急減速低減の検証結果

図 2.1.①-20 確定信号残秒数情報による交差点進入アルゴリズムの検証結果

一方、前述の通り実証実験で整備された信号機には先読み情報が完全には確定していない幅付き残秒数情報を配信している信号機も存在する。この幅付き残秒数情報の信号機に対する開発アルゴリズムの有効性に関して検討する。幅付き残秒数情報は最大・最小の残秒数情報が逐次配信されており、図 2.1.①-21 のように任意の幅のある情報を取得可能である。図 2.1.①-20(b)の検証実験のように青信号の状態で交差点に接近する場合の急減速を回避するためには、早めに事前減速を開始するために安全面を考慮して幅付きの最小残秒数を使用することが望ましい。しかしながら、図 2.1.①-21 のように最小残秒数が 0 秒になっても、信号機は青信号のままとなる状況が発生する場合、参照した残秒数が 0 秒になるタイミングで車両が停止しているにもかかわらず、信号機は青色のままといった危険な現象が発生する可能性がある。残秒数のデータはすべてのシーンで図 2.1.①-21 のような数十秒の差があるわけではなく、最大・最小の残秒数にほとんど差がない場合も存在する。残秒数に差がない場合は確定信号情報と同様に扱うことが可能なため開発アルゴリズムの効果が期待できる。したがって、幅付き信号機に関しては残秒数情報の状況によって有効性が期待できる場合が存在するといえる。




図 2.1.①-21 幅付き信号残秒数情報の例（点灯状態：青）

（潮風公園北 2020 年 11 月 25 日(水)の 11 時 30 分 10 秒～35 秒の信号残秒情報）

・まとめ

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 99%を達成して評価結果から認識が困難となる環境要因を明らかにすることを目的としてきた。東京臨海部の実証実験の評価結果では日中・夜間・雨天・逆光・順光を含む評価データに対して平均 99%の認識率を達成可能し、矢印灯では 15px 程度の解像度を確保できていれば目標値相当の認識が可能な点を確認した。また認識が困難となる環境要因として、隠蔽・背景同化、夜間、逆光の各状況で認識に与える影響を考察し、その結果から隠蔽、背景同化及び夜間に関しては環境不調が一時的であるため交差点進入判断への影響は殆ど発生しないことを確認した。一方、逆光の場合は撮影画像上で信号機自体の視認性が低下することから本質的に認識困難となる状況が起こりうるということが考えられるが、逆光の影響範囲が限定的であるため影響を受けていない他方の信号機を認識することで交差点進入が可能となる。しかしながら信号機が一台しか存在しない交差点などにおいて逆光の影響を受けると車載カメラだけで発進判断をすることが困難となる状況も存在する。そのような交差点で逆光による発進困難となる状況はある特定の信号機配置の交差点における逆光時間帯（停止線・信号機間の方向付近に太陽が存在する特定の時間帯）に限定される。そこで、こうした発進困難となる状況を交差点の条件（視認可能な信号機数）及び車載カメラの設置条件（カメラ取り付け位置・角度・画角）から得られる自車と信号機、逆光領域との相対的な関係から整理することで車載カメラ単独での自動運転に課題となる条件を明らかにすることが課題となる。

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の有効性を検証するために公道でジレンマゾーンの急減速低減を検証した。先読み情報のうち確定信号情報が得られている場合は急減速を回避した滑らかな交差点進入が可能となる結果が得られた。今後は先読み情報を活用した評価を継続的に実施して通信品質や減速改善への効果など多角的な検証を実施することが課題となる。

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] 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.
- [5] 市原直樹, 米陀佳祐, 菅沼直樹, ”自動運転におけるITS 無線を用いたジレンマゾーンでの急減速の削減”, 自動車技術会論文集, Vol.52, No.2, pp. 413-418, 2021.

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。

2020 年度は、2019 年度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認識アルゴリズムを発展させ、信号機の状態を識別する。このとき、地図情報の活用の有効性を評価する。その結果をもとに画像全体に対してセマンティックセグメンテーションを行った後、地図情報で獲得した領域（ROI）のみを状態識別して、信号機認識を行う。評価には、東京臨海部で撮影された車載カメラ画像を使用する。今年度は、信号機の認識に関して、99%を目標として以下の研究開発を実施した。

- ・ セマンティックセグメンテーションと地図情報を活用した信号機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機認識の性能評価
- ・ 時系列情報を用いた信号機認識の性能評価

・ 信号機認識について

2019 年度の検証から、物体検出と比較して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が、遠方にある小さな信号機や、一部が隠れている信号機の検知に有効であることを確認した。2020 年度は、セマンティックセグメンテーションの検出と、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検討する。セマンティックセグメンテーション手法のベースとして DeepLab V3+[1]と HRNetW48 V2[2]を使用し、信号機の検知性能を比較する。状態識別には、ResNet50[3]、GhostNet[4]、mobilenet V2[5]、DenseNet[6]を使用してそれぞれの識別性能を比較する。

・ 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、歩行者など多クラスの識別を行う。使用する手法

として，2019 年度に引き続き DeepLab V3+を用いる．また，新たに HRNet を使用した信号機検出でも評価を行う．

DeepLab v3+

DeepLab v3+[1]は，図 2.1.②-1 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 2.1.②-1 Deeplab v3+の構造

HRNet

セマンティックセグメンテーションの従来手法では，高解像度の特徴マップを残してデコーダで接続することが多い．HRNet[2]は，図 2.1.②-2 のように高解像度の特徴マップも並列で学習を行うことで，高い認識精度を達成している．異なる解像度のサブネットワークを並列で畳み込み処理を行い，それぞれの特徴マップを加算することで情報を共有する．並列処理を行うサブネットワークは，ステージごとに増えていく．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， 1×1 の畳み込み処理を行った後，バイリニア補完を行い，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 3×3 畳み込み処理を行い，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．その後畳み込み処理を行うことで最終的な出力を獲得する．




図 2.1.②-2 HRNet 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認識は，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 2.1.②-3 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


実験に使用する東京臨海部データセットには，セマンティックセグメンター

ション用に 580 枚，信号機識別の評価用に 2237 枚含まれる．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には，昼間，夜間，晴天，雨天といった時間や気候で撮影された車載カメラ画像が含まれる．セマンティックセグメンテーションによって 10 のオブジェクトクラスに画像領域を分割するように学習を行う．

信号機識別の評価用データは，地図情報によって画像上に信号機がある領域 (ROI) が付与されている．この ROI には赤信号や青信号の領域だけでなく，前方車両によって信号機が隠れている ROI も含まれる．評価用データの ROI の例を図 2.1.②-5 に示す．ROI は図 2.1.②-5 のグレーの矩形のような領域である．



(a) 車載カメラ画像



(b) 正解画像

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



図 2.1.②-5 評価データ例

・ 地図情報の有無による比較

デジタル地図がある場合，この情報を活用することで信号機認識の精度を向上させることができると考える．その方法としては，

- 1) 信号機を検出後，地図情報によりフィルタリング
- 2) 地図情報から信号機認識する領域を限定

がある．上記 1) の場合，画像全体に対して，セマンティックセグメンテーションを行い，信号機領域を検出する．そして，その領域が地図情報に含まれて

いる場合は、状態識別処理する．一方で、地図情報に含まれない場合は、状態識別処理を行わず、棄却する．これにより、信号機の誤検出を抑制できる．また、セマンティックセグメンテーションによる信号機に対する信頼度が低い領域も閾値を下げることで検出可能となる．

上記 2) の場合、あらかじめ地図情報から信号機領域を抽出し、その範囲の状態を識別する．地図情報から信号機がある領域に限定できているため、検出処理が不要であり、誤検出を抑制できる．

上記 1), 2) および、地図情報を用いない場合の信号機認識精度を表 2.1.②-1 に示す．ここで、信号機の評価数は 5598 領域であり、青信号は 2748 基、赤信号は 2218 基、その他は 632 領域である．信号機検出アルゴリズムには、DeepLab v3+, 状態識別には ResNet50 を用いる．また、上記 1) を地図情報あり（全体入力）、上記 2) を地図情報あり（限定入力）とする．

地図情報を用いない場合、赤信号および青信号の認識精度が低く、全体認識精度が 72.82% と低い．一方、地図情報（限定入力）では、信号機認識精度が向上しているが、信号機以外の領域（その他）の認識精度が低い．その他は、地図情報から信号機領域を抽出しているが、前方車両などで遮蔽されている状態であり、信号機以外と識別する必要がある．地図情報（限定入力）は、その他の識別精度が低くなっている．一方、地図情報あり（全体入力）の場合、セマンティックセグメンテーションの結果に対して地図情報を反映させることで信号機以外の領域を棄却できるため、その他の誤認識を抑制でき、また、信号機自体の精度を向上させることもできている．これにより、認識精度は 91.12% と最も高くなっている．

表 2.1.②-1 の下部は 120m 以内の信号機（20 ピクセル以内）に限定して評価した結果である．地図情報なしの認識精度は 86.96% と、地図情報あり（限定入力）よりも高い認識精度になっている．地図情報あり（限定入力）の場合は、自己位置ずれを考慮して広い範囲を信号機の位置として状態識別している．一方で、地図情報なしの場合はセマンティックセグメンテーションにより抽出した信号機領域の外接矩形を信号機の位置として状態識別している．120m 以内信号機に対して、セマンティックセグメンテーションにより位置を正確に抽出できているため、青または赤信号の状態識別精度が向上している．地図情報あり（全体入力）はさらにセマンティックセグメンテーションで抽出した誤った信号機領域を抑制できるため、最も精度が高く、93.34% となっている．これ以降の検証では、地図情報あり（全体入力）を用いる．

表 2.1.②- 1 地図情報の有無による信号機認識精度の比較結果 [%]

		地図情報なし	地図情報あり (全体入力)	地図情報あり (限定入力)
全体	赤信号	59.78	89.50	88.64
	青信号	74.98	93.27	81.30
	その他	84.81	87.50	77.22
	全体	72.82	91.12	83.74
20 ピクセル以上	赤信号	86.08	91.02	89.09
	青信号	96.94	96.73	84.78
	その他	84.81	87.50	77.22
	全体	86.96	93.34	85.58

・ 信号機検出アルゴリズムの比較

信号機検出アルゴリズムとして、DeepLab v3+と HRNet の検出性能を比較する。評価対象は、評価データ 2237 枚のうち ROI 内に存在する信号機 4782 基である。信号機の検出率を表 2.1.②-1 および表 2.1.②-2 に示す。これより、Deeplab v3+の信号機検出率が 95.11%、HRNet の信号機検出率は 98.39%となっており、HRNet のセグメンテーション結果を使用した場合の方が高い検出精度であることが確認できる。また、信号機の幅が 20 ピクセル以上の信号機の場合、Deeplab v3+で 97.35%、HRNet で 99.03%の検出である。20 ピクセル以下の信号機は、距離換算すると 120m 以上先の信号機である。

表 2.1.②- 1 Deeplab v3+の信号機検出結果[%]

	検出率
昼間	94.88
夜間	97.83
全体	95.11
昼間(20 ピクセル以上)	97.17
夜間(20 ピクセル以上)	100.0
全体 (20 ピクセル以上)	97.35

表 2.1.②-2 HRNet の信号機検出結果[%]

	検出率
昼間	98.35
夜間	98.92
全体	98.39
昼間(20 ピクセル以上)	98.99
夜間(20 ピクセル以上)	99.59
全体 (20 ピクセル以上)	99.03


図 2.1.②-6 に Deeplab v3+と HRNet の信号機の検出結果を示す．信号機と判断された領域は橙色で表している．図 2.1.②-6 (a)より HRNet は Deeplab v3+に比べて遠方の信号機を検出できていることがわかる．また，図 2.1.②-6 (b)のような夜間のシーンにおいても正しく信号機を検出できている．これは，学習に使用した東京臨海部のセマンティックセグメンテーションのデータには，夜間のデータも含まれているため，昼間と夜間の両方で高い検出が行えていると考えられる．一方で，図 2.1.②-6 (c)では右側の信号機が逆光によって検出できていないことがわかる．



入力画像



Deeplab v3+の結果



HRNetの結果

(a) 昼間の遠方の信号機

図 2.1.②-6 信号機の検出結果



入力画像



DeepLab v3+の結果



HRNetの結果

(b) 夜間の信号機

図 2.1.②-6 信号機の検出結果



入力画像



Deeplab v3+の結果



HRNetの結果

(c) 逆光時の信号機

図 2.1.②-6 信号機の検出結果

・ 状態識別率の比較

次に，DeepLab v3+と HRNet でセマンティックセグメンテーションによって検出した信号機に対して状態識別を行う．状態識別を行うモデルには，ResNet50[3]，Ghostnet[4]，mobilenet v2[5]，Densenet[6]を用いて比較する．評価データには 5039 基の信号機が含まれている．そのうち，夜間が 405 基，昼間が 4904 基の信号機はである．評価には Recall(正解率)を用いる．DeepLab v3+のセグメンテーション結果を使用した状態識別結果を表 2.1.②-3 に示す．また，HRNet のセグメンテーション結果を使用した状態識別結果を表 2.1.②-4 に示す．これらより，Deeplab v3+の識別精度が約 93%であるのに対して，HRNet の識別精度が約 96%となっている．よって，検出の精度が高い HRNet をベースとした状態識別結果の方が，識別精度が高いことがわかる．また，信号機の横幅が 20 ピクセル以上の信号機に対する識別結果は，ResNet を使用した時に 97.41%となっている．Mobilenet v2 を使用した場合でも，97.28%である．Mobilenet v2 のように軽量のモデルを使用した場合においても，高い状態識別精度を達成できている．これらの結果から，信号機認識の精度を向上するには，セマンティックセグメンテーションによる検出精度を向上させることが有効だと考えられる．また，多くの結果で夜間よりも昼間の方が低い状態識別精度になっている．これは，昼間の信号機が逆光の影響により色の判断が難しくなるからだと考えられる．

表 2.1.②-3 Deeplab v3+のセグメンテーション結果を使用した状態識別結果[%]


	Resnet50	Densenet	Ghostnet	Mobilenet v2
夜間	97.28	96.54	95.80	94.57
昼間	93.50	93.13	92.96	93.31
合計	93.78	93.39	93.18	93.41
夜間 (20 ピクセル以上)	99.64	99.64	98.57	97.49
昼間 (20 ピクセル以上)	95.78	95.49	95.18	95.68
合計 (20 ピクセル以上)	96.02	95.75	95.39	95.79

表 2.1.②-3 HRNet のセグメンテーション結果を使用した状態識別結果[%]


	Resnet50	Densenet	Ghostnet	Mobilenet v2
夜間	97.53	97.04	95.84	89.63
昼間	96.47	95.92	96.05	96.15
合計	96.55	96.01	95.86	95.65
夜間 (20 ピクセル以上)	98.92	98.92	98.21	99.28
昼間 (20 ピクセル以上)	97.31	96.81	96.62	97.14
合計 (20 ピクセル以上)	97.41	96.94	96.72	97.28




(a) 昼間



(b) 夜間



(c)逆光



(d)逆光

図 2.1.②-7 信号機の状態識別結果例

図 2.1.②-7 に認識結果画像を示す．画像内の白色矩形は，ROI の領域を示しており，青色と赤色の矩形は信号機の状態識別で判断された灯火色である．図 2.1.②-7 (a)より，昼間のシーンにおいては，遠方の信号機の認識ができていることがわかる．また，夜間シーンの図 2.1.②-7 (b)でも信号機を正しく識別が行えていることがわかる．一方で，図 2.1.②-7 (c)のように逆光の影響でセグメンテーションの時点で検出できていない．しかし，図 2.1.②-7 (c)の結果画像の数フレーム先である図 2.1.②-7 (d)の結果画像では，セグメンテーションで信号機を検出できている．そして，正しく赤信号と状態識別できていることがわかる．

・ 時系列情報を用いた信号機認識

図 2.1.②-7 (c)および図 2.1.②-7 (d)のように、同じ信号機でもタイミングによっては環境光の影響などで信号機を検出できていない場合や、誤識別を行っている信号機がある。実際の走行時は、複数のフレームから信号機の検出、状態識別の結果を見て判断することも可能である。そこで、複数フレームの結果から信号機の認識結果の推定を行う。評価データには連続した画像が含まれており、交差点の場所と信号機ごとに個別の ID が割り振られている。そのため、別フレームでも同一の信号機かどうか判断できる。時系列情報を用いた評価では、同一 ID の信号機に対して半数以上のフレームで正しく認識が出来ているかどうか、また一度でも正しい識別かできているかどうかを評価する。

表 2.1.②-5 および表 2.1.②-6 に半数以上のフレームで正解した場合の結果を示す。これより、Deeplab v3+ベースの場合は、約 96%の正解率となり、HRNet ベースの場合は、約 98%となった。その中でも、HRNet と mobilenet v2 を信号機識別アルゴリズムに用いると正解率は 98.51%を達成した。評価対象の信号機を 20 ピクセル以上にした場合は、Deeplab v3 ベースと HRNet ベースのどちらも 98%を達成している。特に、HRNet と mobilenet v2 を組み合わせた場合、最も正解率が高く、98.96%を達成した。

表 2.1.②-5 時系列を利用した評価(半数以上: Deeplab v3+) [%]

	Resnet50	Densenet	Ghostnet	Mobilenet v2
夜間	98.35	97.93	97.11	94.63
昼間	96.54	96.09	95.98	96.43
合計	96.92	96.49	96.22	96.05
夜間 (20 ピクセル以上)	100.00	99.49	98.98	96.95
昼間 (20 ピクセル以上)	97.68	97.44	97.33	97.68
合計 (20 ピクセル以上)	98.11	97.83	97.64	97.54

表 2.1.②-6 時系列を利用した評価(半数以上: HRNet) [%]

	Resnet50	Densenet	Ghostnet	Mobilenet v2
夜間	98.76	99.17	97.52	98.35
昼間	98.33	98.10	97.66	98.55
合計	98.42	98.33	97.63	98.51
夜間 (20 ピクセル以上)	98.98	99.49	98.48	99.49
昼間 (20 ピクセル以上)	98.72	98.72	98.26	98.84
合計 (20 ピクセル以上)	98.77	98.87	98.30	98.96

次に、複数フレーム内で一度でも正解できているかどうかを評価した。その結果を表 2.1.②-7 および表 2.1.②-8 に示す。これらより、Deeplab v3+と HRNet の両方で状態識別精度が約 98%となり、20 ピクセル以上の信号機に対しては、状態識別精度が約 99%となった。この結果より、時系列データとして複数フレームの結果状態識別することにより、高い認識精度を達成することを確認した。一方で本検討手法では、図 2.1.②-7(c)のような逆光環境、夜間の赤信号をテールランプと間違えるケースなどへの対応も課題となる。

表 2.1.②-7 時系列を利用した評価(1 回以上: Deeplab v3+) [%]

	Resnet50	Densenet	Ghostnet	Mobilenet v2
夜間	98.35	97.93	97.11	94.63
昼間	97.99	97.88	97.66	98.21
合計	98.07	97.89	97.54	97.45
夜間 (20 ピクセル以上)	100.00	99.49	98.98	96.95
昼間 (20 ピクセル以上)	98.61	98.72	98.37	98.95
合計 (20 ピクセル以上)	98.87	98.87	98.49	98.58

表 2.1.②-8 時系列を利用した評価(1 回以上: HRNet) [%]

	Resnet50	Densenet	Ghostnet	Mobilenet v2
夜間	98.35	97.93	97.11	94.63
昼間	96.54	96.09	95.98	96.43
合計	96.92	96.49	96.22	96.05
夜間 (20 ピクセル以上)	100.00	99.49	98.98	96.95
昼間 (20 ピクセル以上)	97.68	97.44	97.33	97.68
合計 (20 ピクセル以上)	98.11	97.83	97.64	97.54

・ まとめ

2020 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の開発および東京臨海部データセットにて評価を行った. 東京臨海部データセットにおいて,信号機の検出精度は 99.03%,信号機認識精度は 97.41%であった. また,時系列情報を用いて信号機の認識を行うことで,98.96%となり信号機認識精度の目標である 99%をほぼ達成した. また,昼間だけでなく夜間の信号機も高精度で認識可能であることを確認した. 今後は,検出精度が低かった,逆光時の信号機検出精度の向上を検討することと,点滅信号の認識を行うアルゴリズムを検討していく.

【参考文献】

- [1] L.-C. Chen et al., “Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation”, ECCV, 2018.
- [2] J. Wang et al., “Deep High-Resolution Representation Learning for Visual Recognition”, CVPR, 2019.
- [3] K. He et al., “Deep Residual Learning for Image Recognition”, CVPR, 2016.
- [4] K. Han et al., “GhostNet: More Features from Cheap Operations”, CVPR, 2020.
- [5] M. Sandler et al., “MobileNetV2: Inverted Residuals and Linear Bottlenecks”, CVPR, 2018.
- [6] G.Huang et al., “Densely Connected Convolutional Networks”, CVPR, 2017.

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で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。画像サイズが 1920×1080 ピクセルの場合、70m 遠距離に存在する歩行者の高さは 48 ピクセル、200m 遠距離に存在する自動車の高さは 24 ピクセル程度と小さい。2020 年度は遠距離の物体検知アルゴリズムの精度検証および課題抽出を行う。

・ 物体検知アルゴリズムの検討

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[4]、またその両立を目指している手法など多岐にわたる。高速な手法として代表的な手法は、You Only Look Once(YOLO)[1]である。YOLO は、畳み込みニューラルネットワークに画像を入力し、物体検知に関する情報を一度にまとめて出力する処理を採用しており、非常にシンプルな構成となっている。出力した物体検知に関する情報は、入力画像をグリッドに分割した各グリッドに対する物体らしさ、物体のサイズ情報、物体のクラス情報となる。これらの出力を後処理することで物体検知情報に変換している。YOLO が登場して以降、YOLO と同様の 1 段階の手法が多く提案されているが、YOLO をベースとした YOLOv2 や YOLOv3[2]、YOLOv4[3]が代表的な手法である。各 YOLO は、初期の YOLO の問題点を解決している。具体的には、小さな物体に対する検知精度の向上が挙げられる。YOLOv4 では、入力画像サイズの拡大、ベースとする畳み込みニューラルネットワーク構造の改良、学習方法の改良などがなされている。ここで、YOLOv4 の構造を図 2.2.①-1 に示す。YOLOv4 の構造は、backbone, neck, head の 3 つの部分に分かれている。backbone には、CSPDarkNet53[5]というネットワーク構造の畳み込みニューラルネットワークを用いている。CSPDarkNet53 は、畳み込み層で獲得した特徴マップの一部をコピーして次の層に連結する構造を採用している。neck は、backbone で縮小した特徴マップを拡大して畳み込み処理を行い、特徴マップサイズを拡大していく。このとき、backbone で獲得した特徴マップをコピーして再利用する。head では、各特徴マップのスケールにおいて、物体検知の情報を出力する。特徴マップの大きさを小さくするだけでなく、拡大処理が含まれる構造を導入することで小さな物体にも対応してい

る．各スケールでの物体検知した情報を統合して，小さな物体から大きな物体までサイズの異なる物体を検知している．




図 2.2.①-1 YOLOv4 の構造

本事業では，2019 年度に物体検知アルゴリズムの比較を行い，Feature Pyramid Netork(FPN)[4]が検知精度と処理時間のバランスが良い手法であった．本比較検討以降，YOLOv4 が発表されたため，FPN と YOLOv4 を比較した．比較には東京臨海部で撮影したデータセットを用いる．東京臨海部データセットは，5747 枚の画像で構成されている．本データセットでは，11 クラスの物体クラスをあらかじめアテノーションしている．ここでは，表 2.2.①-1 に示すように，矢印灯は 1 つのクラスとして，全 7 クラスとした．各物体クラスに対するデータ数を表 2.2.①-2 に示す．

表 2.2.①-1 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
Car	自動車
Bus	自動車
Truck	自動車
Pedestrian	歩行者
Cyclist	バイク
信号 赤	信号機(赤)
信号 青	信号機(青)
信号 黄色	信号機(黄色)
矢印灯 左	矢印灯
矢印灯 直進	矢印灯
矢印灯 右	矢印灯

表 2.2.①-2 東京臨海部データセットにおける各クラスの個数

クラス	データ数
自動車	22,006
歩行者	5,832
バイク	291
信号機(赤)	3,405
信号機(青)	3,328
信号機(黄)	171
矢印灯	423

評価には、mAP(mean Average Precision)を評価指標として用いる。mAPは、各クラスに対する Average Precision(AP)を算出し、その平均値である。APは、まず物体検知した際の信頼度をもとに Precision と Recall を以下のよう

$$Precision = \frac{\text{正解したデータ数}}{\text{検知した数}}$$

$$Recall = \frac{\text{正解したデータ数}}{\text{正解データ数}}$$

そして、Precision を平均する。これは、各 Recall(r)における Precision を積分した面積に相当する。

$$AP = \int_0^1 Precision(r)dr$$

本東京臨海部データセットにおける FPN と YOLOv4 の検出精度を表 2.2.①-3 に示す。表 2.2.①-3 より、mAP は、YOLOv4 の方が高いことがわかる。これより、本年度の検証には、YOLOv4 を用いることとする。

表 2.2.①-3 東京臨海部データセットにおける mAP

データセット名	FPN	YOLOv4
東京臨海部	0.627	0.649

・ YOLOv4 の高解像度画像対応

遠方の物体を検知するためには，入力画像として高解像度の画像が必要となる．従来の YOLOv4 では，高解像度の入力画像を想定していない．そこで，YOLOv4 の入力画像サイズ変更および内部構造の改良を行う．表 2.2.①-4 に距離ごとの自動車および歩行者のサイズを示す．

表 2.2.①-4 距離ごとの物体サイズ[ピクセル]

距離[m]	50	70	100	120	135	150	200
自動車	96	68	48	40	35	32	25
歩行者	68	48	34	28	25	22	17

これより，200m 遠方の自動車は 25 ピクセル，70m 遠方の歩行者は 48 ピクセルである．これらのサイズに対応するために，入力画像サイズを 416×416 ピクセルから 992×992 ピクセルに変更した．また，各スケールで検出する物体サイズを決めるアンカーパターンを歩行者および自動車を対象とするため，縦横比 1:1，1:2，2:1 を基準にその間を埋めるよう設定した．

・ YOLOv4 の学習

YOLOv4 による物体検知モデルを学習するにあたり，東京臨海部および金沢市街地で撮影したデータセットを用いた．データ数は 16938 枚である．学習時の設定を表 2.2.①-5 に示す．

表 2.2.①-5 学習時の設定

項目	設定
更新回数	500,000
ミニバッチサイズ	64
学習率	0.001
学習率変更タイミング	400,000および450,000

・ 東京臨海部データセットにおける精度

各クラスのサイズ別検知精度(mAP)を表 2.2.①-6 に示す．これより，200m 遠方に相当する 25 から 35 ピクセルの自動車に対して，mAP が 0.375，70m 遠方に相当する 50 から 70 ピクセルの歩行者に対して，mAP が 0.134 と検出できている．

表 2.2.①-6 各クラスのサイズ別精度 (mAP)

サイズ	0-25	25-35	35-50	50-70	all
自動車	0.231	0.375	0.498	0.548	0.768
歩行者	0.008	0.084	0.134	0.238	0.590
バイク	0.010	0.033	0.138	0.371	0.456

物体検知結果例を図 2.2.①-2 から図 2.2.①-5 に示す．また，各図の矩形の色と物体クラスの関係を表 2.2.①-7 に示す．

表 2.2.①-7 各クラスの色

クラス	色
自動車	ピンク
歩行者	緑
バイク	黄緑
信号機(赤)	赤
信号機(青)	青
信号機(黄)	黄色
矢印灯	水色

図 2.2.①-2 より縦列駐車している自動車や近距離からやや遠方の自動車を検知できていることがわかる．



図 2.2.①-2 遠方の物体検知結果例 1

図 2.2.①-3 から 200m ほど遠方の自動車を検知できていることがわかる。また、図 2.2.①-4 から、70m ほど遠方の歩行者を正しく検知できていることがわかる。



図 2.2.①-3 遠方の物体検知結果例 2




図 2.2.①-4 遠方の物体検知結果例 3

図 2.2.①-5 から悪天候（雨天）の場合でも遠方の自動車や保億者を検知できていることがわかる．また，信号機の検知も正しくできていることがわかる．




図 2.2.①-5 遠方の物体検知結果例 4

検知が失敗している例を図 2.2.①-6 から図 2.2.①-7 に示す．ここで未検知の物体は白色の矩形で示している．図 2.2.①-6 より，登り坂で遠方の自動車の上部だけが見えている場合に検出できていない．



図 2.2.①-6 遠方の物体検知結果例 5(失敗例)

また，図 2.2.①-7 のように，背景の茂みと同じ色の服装をした遠方の歩行者を検知できていないケースもある．




図 2.2.①-7 遠方の物体検知結果例 6(失敗例)

・ 見通しの良い環境での精度

前述の実験では，東京臨海部を走行した際の一般的なシーンを対象として評価を行った．歩道を歩いている際に植物で身体が隠れている場合や駐車場に停車中の自動車なども評価対象として多数含まれている．そこで，見通しの良い環境における物体検知精度を評価した．評価データは，未来館前で撮影した 3000 枚の画像を用いる．図 2.2.①-8 に歩行者のサイズ別の検知精度を示す．これより，70m 相当の 48 ピクセル歩行者について 65.2% の検知率である．50m 相当の歩行者となる 68 ピクセル程度で検知率が 80%，30m 相当の歩行者となる 90 ピクセル程度で検出率が約 90% である．これより，遠方の歩行者を検出する場合，検知率を 90% とするためには，入力画像サイズを 2 倍程度拡大することが望ましいと言える．




図 2.2.①-8 見通しの良い環境での歩行者のサイズ別検知精度

検出結果例を図 2.2.①-9 および図 2.2.①-10 に示す．図 2.2.①-9 のように見通しの良い環境において，遠方の横断歩道を歩く歩行者を正しく検知できている．一方で，図 2.2.①-10 のように，近距離でも歩行者通しが並んでいる場合，誤って 1 人として検知しているケースもある．



図 2.2.①-9 見通しの良い環境での検知結果例 1




図 2.2.①-10 見通しの良い環境での検知結果例 2

・ まとめ

2020 年度は，遠距離の物体検知アルゴリズムとして，YOLOv4 をベース手法とし，入力画像サイズおよびネットワーク構造の改良を行い，遠方の物体への対応を行った．東京臨海部で撮影したデータセットにおいて，200m 遠方の自動車および 70m 遠方の歩行者を検知することがわかった．一方で，検知精度は近距離と比べて十分高いとは言えない．見通しの良い環境における歩行者のサイズ別検知精度の比較を行ったところ，70m 相当 (48 ピクセル) の歩行者について検知率は 65.2% であった．検知率を 90% 程度にするには，歩行者のサイズが 90 ピクセル程度になるよう，さらに入力画像サイズを拡大することが必要となる．

【参考文献】

- [1] J. Redmon et al., “You Only Look Once: Unified, Real-Time Object Detection”, CVPR2016.
- [2] J. Redmon et al., “Yolov3: An incremental improvement.”, arXiv, 2018.
- [3] A. Borchkovskiy et al., “YOLOv4: Optimal Speed and Accuracy of Object Detection”, arXiv, 2020.
- [4] T. Lin, et al., “Feature pyramid networks for object detection.”, CVPR, 2017.
- [5] C.-Y. Wang, et al., “CSPNet: A new backbone that can enhance learning capability of CNN”, arXiv, 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，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．昨年度の評価結果では，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た．しかし，遠方まで安定して認識を継続するためにはカメラによる認識距離の改善も必要であることが課題として挙げられていた．

今年度は遠距離に特化した物体種別の認識を可能とするため，全方位カメラによる認識においてデジタル地図などから抽出される画像内の道路領域に注目して対象物を認識するアルゴリズムを検討する．また，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見通しの良い環境において 200m 以内の自動車及び 70m 以内の歩行者の認識率 90%を達成することを目標として性能評価を実施する．これらの評価結果より認識に課題のある道路環境を分析する．

・ LiDAR ・ カメラのフュージョンによる物体認識

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，先行研究[1]において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．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，昨年度の事業において，図 2.2②-2 のように LiDAR ・ カメラのセンサフュージョンアルゴリズムを検討した．




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

時系列処理及びセンサフュージョンによる物体認識アルゴリズムは以下の処理で構成される。

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. LiDAR/カメラフュージョン事後確率計算：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。
6. 時系列処理による移動物体推定：時系列フレーム間のSegmentの関連付け（Trackデータの抽出）を行い移動物体として運動状態を推定する

・ デジタル地図を活用した画像認識による遠距離物体認識の基礎検討

前述のセンサフュージョンによる物体追跡アルゴリズムにおいて連続的に認識する移動物体の種別を安定して認識することが期待される。しかしながら、LiDARの物体にカメラの矩形枠情報をフュージョンするにあたり、画素数の小さな対象物を適切に認識しなくては遠方に存在する物体の認識改善を実現することはできない。一方、市街地の走行において遠距離の対象物の認識が要求されるシチュエーションは交差点の対向車や横断する歩行者など特定の道路

領域に限定される．そこで，図 2.2.②-3 のようにデジタル地図から状況に応じて注目領域を抽出し，画像内で認識すべき領域を ROI として算出してその領域内の対象物を認識する方法を導入する．DNN（Deep Neural Network）で画像内の物体を認識する場合，処理時間などの制約により入力画像を一定サイズの解像度にリサイズしてから処理をすることが一般的である．そのため，元画像を入力サイズにリサイズして処理するのに対して限定された ROI 画像を入力サイズにリサイズすることで画像内の物体が相対的に大きなサイズで処理可能となる．物体認識では画像全体領域の認識と ROI 画像の認識の双方の物体認識を実施することで，入力画像の解像度を確保して効率的な遠距離物体の検出が期待される．





図 2.2.②-3 デジタル地図を活用した遠方領域の物体認識

ここで，基礎検討した物体認識による効果を検証するために，直進走行時の駐車車両及び横断歩道通過中の歩行者の認識距離を評価する．評価用の走行画像は，東京臨海部の日本科学未来館周辺の直線道路（図 2.2.②-3）で計測し，画像中の対象物との検出距離を評価する．評価対象の物体は特定の横断歩道を移動中または計測中に駐車している車両としており，絶対位置を特定可能な物体とする（歩行者の場合は横断歩道領域の位置を特定可能とする）．したがって，データ計測中の自動運転自動車との位置関係から対象物の距離を計測可能となる．


実験条件としては，地図から抽出した ROI 領域に対して異なる解像度の入力画像で検出物体数を評価する．本評価では，ROI 未使用，ROI 解像度として元画像の 1/2 倍，1/3 倍の条件で評価を実施した．物体検出には YOLOv3[2]の DNN モデルを利用し，DNN の入力解像度は 608x608 とする．入力画像はアスペクト比を維持しながら DNN の入力解像度にリサイズして処理するため，ROI の範

囲が小さいほど遠方物体の解像度を落とすことなく処理可能となる．なお，評価に用いた画像枚数は 1,965 枚とする．


評価結果として，対象物との距離ごとに検出された物体数のグラフを図 2.2.②-4 に示す．各条件の評価結果より ROI 解像度を小さくすることで遠距離に存在する物体の検出が達成されていることが確認できる．ROI 解像度を元画像の 1/2 または 1/3 とすることで目標距離である 200m 以内の自動車や 70m 以内の歩行者の検出数を増大することが実現された．また図 2.2.②-4(d)に ROI の解像度を 1/3 倍としたときに検出された物体矩形枠幅の平均ピクセル数を示す．60～70m 付近で検出物体数及びピクセル数が変化しているが，これは評価エリアの横断歩道と車両との位置関係により特定区間で歩行者によるオクルージョンが多くなり車両のデータ数が少ないこと，さらに当該区間の対象車両にトラックが偏って存在しているためである．対象物の姿勢の違いにより多少のばらつきがあるが，100m 先の歩行者として約 15px の物体，200m 先の自動車として約 25px の物体を検出可能な点が確認された．これによって移動物体追跡とのフュージョンにおいても認識精度の改善が期待される．




(a) ROI 未使用



(b) ROI 解像度 (元画像の 1/2 倍)



(c) ROI 解像度 (元画像の 1/3 倍)



(d) (c)の検出物体幅のピクセル数

図 2.2.②-4 画像認識における遠距離物体の検出距離・ピクセル数

・遠距離物体の認識性能評価

前述の遠距離物体の検出方法の効果を検証するための評価を実施する。本実験は昨年度の事業における評価同様に見通しの良い環境での評価として図 2.2.②-5 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。評価用データは、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を計測したデータである。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．

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 350 個の Track データ（Segment 総数 24,265 個）で構成されており，昨年度同様の評価データに一部遠方の車両データを追加したものである．データの内訳を表 2.2.②-1 に示す．評価データにおいて歩行者および二輪車は 100m 以内の範囲のみに存在し，その他の物体は 200m 以内の存在する．この物体に対して画像認識結果である矩形枠情報を統合することで物体種別の識別性能を評価する．なお，ROI を利用した画像に対する物体矩形枠認識は前述の検証結果を踏まえて元の解像度の 1/3 の領域と設定する．




図 2.2.②-5 遠距離定量評価の撮影環境と対象物体の様子
(2019 年度と同様の評価条件)

表 2.2.②-1 学習・評価データの実験条件（LiDAR の物体数）

クラス	Train Data		Test Data	
	Segment 数	Track 数	Segment 数	Track 数
自動車	1,426	16	4,058	54
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
合計	8240	78	24,265	350


認識率の評価において評価指標は以下に示す **F-value** を用いる．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．

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

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

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

ただし，TP は正解数，FP は誤検出数，FN は未検出数である．評価データの距離ごとの **Segment** 数及び LiDAR/カメラ間の対応付け数の傾向を図 2.2.②-6 に示す．図 2.2.②-6 において **Image objects** は画像認識によって検出された物体と LiDAR の **Segment** 間の対応付けが成功した物体数を示している．評価結果より，ROI 情報を使用することで LiDAR による追跡物体と画像矩形枠との対応付け数の割合が高くなり，特に遠方の画像情報の貢献を改善可能な点が確認できる．図 2.2.②-6 において，50～100m 付近における対応付の割合が低下している区間が確認できるが，これは当該区間で遠方歩行者・二輪車が多く存在するためである．評価データにおいて遠方の物体数が少ないため継続的な評価が必要ではあるが，見通しの良い環境であれば目標距離相当の自動車を十分に認識可能であるといえる．本評価では ROI の利用により対応付けられた物体矩形枠数が 11,632 個から 15,876 個へと約 1.36 倍に改善した．




(a) Segment 数/矩形枠数


(b) 対応付けされた矩形枠の割合

図 2.2.②-6 評価データにおける距離ごとの Segment 数/矩形枠数


また，評価データに対する認識率を図 2.2.②-7，各条件の有効区間内における平均認識率を表 2.2.②-2 に示す．評価結果より，時系列追跡することで全体的な認識率が改善し，画像情報とのフュージョンによりさらに改善している傾向が確認できる．これによって LiDAR 単体では点群が疎になり認識が困難となる遠方の物体に対して画像情報を与えることで識別精度が改善された．以上より，今年度の目標値としている 200m 以内の自動車及び 70m 以内の歩行者の認識率 90%が達成された．しかしながら，図 2.2.②-6(a)にも示しているように特に遠方の評価データが不足していることから，より詳細に認識アルゴリズムの評価を実施するためには今後市街地環境でのデータも含めて評価データの追加が必要である．



(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 2.2.②-7 評価結果

表 2.2.②-2 平均認識率

	Vehicle	Bicyclist	Pedestrian
評価区間	20-200m	20-100m	20-100m
Segment	0.853	0.573	0.710
Tracking (LiDAR)	0.973	0.904	0.868
Tracking (LiDAR w/ Image)	0.973	0.918	0.920
Tracking (LiDAR w/ Image+ROI)	0.977	0.922	0.933

・まとめ

遠距離に特化した物体認識を可能とするため、全方位カメラによる認識においてデジタル地図などから抽出される画像内の道路領域に注目して対象物を認識するアルゴリズムを検討して有効性を評価した。評価結果より画像中で15px程度（100m先相当）の歩行者及び25px程度（200m先相当）の自動車の検出を可能とした。また、LiDAR・カメラによるセンサフュージョンアルゴリズムに開発した物体認識手法を統合することで、遠距離物体の識別精度の改善を評価した。評価結果より、見通しの良い環境において今年度の目標値である200m以内の自動車及び70m以内の歩行者の認識率90%を達成した。しかしながら、特に遠方の評価データが不足していることから、今後評価データの追加が必要である。また、ここで開発した物体認識アルゴリズムを市街地の走行環境にて評価して認識に課題のある道路環境を分析することが課題となる。多くの構造物や交通参加者が混在する環境ではオクルージョンなどによりLiDAR/カメラともに対象物の認識が困難となる状況が想定される。多様な道路環境における不調要因を評価するためシミュレーションなどを活用した性能評価及びアルゴリズム改善が必要であると考えられる。

参考文献

- [1] 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.
- [2] J. Redmon and A. Farhadi, “YOLOv3: An Incremental Improvement”, arXiv:1804.02767r, 2018.

2.3.c. 「高精度自己位置技術の開発」

① GNSS/INS の開発

(1) みちびきの信号を活用した測位とINS複合の両立

a GNSS/INSに適切なGNSS測位誤差

GNSS/INS を開発する際に、その入力となる GNSS, INS の誤差傾向を把握することが重要である。例えば、従来開発されている GNSS/INS では、Kalman Filter に代表される誤差がホワイトノイズと仮定できるフィルタが活用される場合が多く、それ以外のカラーノイズに対しては単純なフィルタ設計では対応が難しいのが実情である。ここで GNSS, INS の誤差に注目をする、時間的に支配的な誤差はホワイトノイズであるが、誤差の大きさに影響が大きいのはマルチパスに代表されるカラーノイズであることが知られている。そのため、GNSS/INS の設計の際には、マルチパスに代表されるフィルタで対応が難しい誤差を、事前に棄却することが大切となる。

一方、みちびきから放送されている補正情報 (CLAS) を利用した高精度測位を実施する場合、従来の RTK-GNSS と比較して衛星数の制限があるため、マルチパス等のホワイトノイズではない測位誤差の影響を受けやすい問題がある。そのため、CLAS を活用した測位の段階でマルチパスの影響を排除した位置推定を実施するか、もしくは後段の INS 複合でマルチパスの影響を排除しやすいように誤差をコントロールする必要がある。本プロジェクトでは、後段に INS 複合をすることを前提としている [1] ため、CLAS を利用した測位ではマルチパスの影響は残りつつも、GNSS/INS の複合で除去を行う [2] 方針を採用する。

b CLAS LIBの改善による測位手法の適切化

CLAS を利用した測位を行うためには、みちびきの L6E 帯から放送される補正情報のデコードを行ったうえで、測位演算を実施する必要がある。そこで本プロジェクトでは内閣府から公開されている CLAS LIB [3] の活用を行う。ただし、2020 年時点で公開されている CLAS LIB ver0.72 では、時系列的な情報を利用した測位がベースとなっているため、都市部のようなマルチパス環境下ではオフセット的な測位誤差が発生する問題がある。そこで、CLAS LIB を改良し、瞬時解を算出可能にすることで GNSS/INS に適した測位解を利用可能にした。

ここで、図 2.3. ①-1(a) に名城大学付近のコースを示す。このコースにおいて改良前の CLAS LIB (時系列的な測位解：図 2.3. ①-1(b)，瞬時解：(c)) と、瞬時解が算出できるように改良した CLAS LIB の測位解 (図 2.3. ①-1(d)) の比較を行った。なお、本評価では GNSS 受信機に Septentrio 社の mosaic-x5 を利用した。図 2.3. ①-1(b)(c)(d) により、CLAS LIB の改良により、改良前と同等

の FIX 率を維持しつつも GNSS/INS に適した瞬時解を得られていることが確認できる。




図 2.3. ①-1 CLAS LIB の評価概要

また，図 2.3. ①-2 に本評価の衛星数と Ratio の値を示す．ここで Ratio は FIX 解の信頼性の指標であり，その値が高いほど測位解が信頼できる可能性が高いことを示す．図 2.3. ①-2 より，改良前の CLAS LIB では十分な衛星数があったとしても瞬時解を算出している際に Ratio が大きくなり FIX 解が得られていないが，改善により瞬時解でも FIX 解が得られていることが確認できる．



図 2.3. ①-2 CLAS LIB の評価の際の衛星数と Ratio

c CLASに適したGNSS受信機の選定

CLAS を利用した測位の課題として、利用する衛星数、周波数帯、コードがマルチ GNSS と比較して限定されることが知られている。さらに、近年比較的安価で車載が可能なレベルの GNSS 受信機の商用化が行われているが、そのような受信機では利用できる周波数帯、コードが限定されてしまう問題がある。GNSS 測位においては、利用できる信号の冗長性は重要であり、可能な限り多くの信号が受信できることが望ましい。そこで、本プロジェクトで利用する GNSS 受信機を選定するため、測量用の GNSS 受信機 (Trimble 社 Alloy), Ublox 社 F9P, Septentrio 社の mosaic-x5 で CLAS LIB を用いて測位を行った際の性能評価を行った。

ここで図2.3.①-3に比較を行った結果を示す。比較を行った3つのGNSS受信機 (Alloy:高価な測量用受信機, mosaic-x5, F9P:比較的安価な汎用受信機)はそれぞれL1/L2/L5の周波数帯を受信可能であるが、対応しているコードが異なる。具体的には、最も安価なF9PはL2P/L5には対応をしていない。一方, Alloy と, mosaic-x5はL2P/L5に対応をしている。現状の衛星ではL2Cに対応をしているものは一部にとどまるため, F9Pで受信した信号をCLASで測位を行う場合には, 限定された衛星数となる (図2.3.①-4)。そのため, 図に示すようにFIX率が他の受信機と比較して減少していると考えられる。そこで, 本プロジェクトでは将来的に車載可能な価格となる受信機として mosaic-x5 を選定し, GNSS/INSでの評価を行うことにする。




図 2.3.①-3 CLAS LIB で利用する受信機による測位性能の比較




図 2.3.①-4 CLAS LIB で利用する受信機による衛星数，Ratio の比較

d 名古屋市の市街地における性能評価

ここで改善したCLAS LIBと選定したmosaic-x5を利用したCLASを活用した測位の性能検証を実施するため，図2.3.①-5に示す名古屋市の市街地にて評価試験を実施した．図2.3.①-6に測位結果を，図2.3.①-7にPOSLV220[4]で計測した真値と比較した結果を示す．図2.3.①-7より，マルチパス等の影響により，各所で大きな誤差が発生しているが，GNSS/INSに入力する情報として避けるべきである，一定方向に著しくオフセットが発生する傾向は見受けられないことが確認できる



図 2.3.①-5 名古屋市の市街地の評価コース




図 2.3.①-6 評価試験における測位結果




図 2.3. ①-7 評価試験における測位誤差

さらに、図2.3. ①-8にCLASを活用した測位を行った結果の信頼性を判定した結果を示す。また図2.3. ①-9に、その誤差を示す。図2.3. ①-9、表2.3. ①-1より、99%の割合で30cm以下の測位結果のみ抽出することが可能となり、提案する信頼性判定法がCLASを活用した測位にも有効であることが確認できる。




図 2.3. ①-8 信頼性判定結果




図 2.3. ①-9 信頼度が高いと判定した場所の位置推定誤差

表 2.3. ①-1 測位解の信頼性判定結果

総数	9274
FIX	4760
30cm以下と判定	2944
判定した中で30cm以下の誤差の数	2942

(2) CLAS17機体制におけるみちびき対応GNSS/INSの性能評価

次に，2020年11月から開始されたCLASに含まれる補正情報の17機への増加に関する効果の検証を行う．測位に利用可能な衛星数が従来の11機から17機に増加がされるため，冗長性が確保されることで結果的に測位精度が改善されることが期待される．ここで，図2.3. ①-10に東京臨海部のお台場における評価コースを示す．また，図2.3. ①-11に改良したCLAS LIBによる測位結果を，図2.3. ①-12に測位精度を示す．図2.3. ①-11，図2.3. ①-12より，CLAS11機体制で評価をした名古屋市の結果と同じように，連続したオフセット的な誤差が見受けられず，GNSS/INSの入力に適した位置推定結果が得られていることが確認できる．




図 2.3. ①-10 お台場における評価コース




図 2.3. ①-11 お台場における改良した CLAS LIB の測位結果




図 2.3. ①-12 お台場における改良した CLAS LIB の測位誤差

また、図2.3. ①-13に提案する信頼性判定法により、30cm以下の測位解が得られていると判定した場所を、図2.3. ①-14、図2.3. ①-15、表2.3. ①-2にその精度を示す。これらの結果より、みちびきから放送されるCLAS信号を活用することで、30cmの位置推定の信頼性を99%で判定ができることを確認できる。加えて、図2.3. ①-16にこれらの測位解をGNSS/INSに入力した場合の結果を示す。図2.3. ①-16より、みちびきを活用したGNSS/INSにより、1.5mの位置精度97%を達成していることが確認できる。しかし、30cmの位置精度はみちびきの信号が受信している箇所においては信頼性が確保されつつも、INSで補完している場所を含めると30cmの位置精度は70%程度の場所では達成できていないことが確認できる。この要因として、受信可能な衛星数が減少する場合には、みちびきの補正情報を受信していたとしても測位性能が劣化するためであると考えられる。そのため、衛星数が減少することが想定される個所においては、インフラを活用したマップマッチング等の補完技術により位置精度を維持するための技術が必要になることが想定される。2021年度においては、衛星数を始めとしたGNSSの性能劣化要因とGNSS/INSの性能の関係、及びその位置精度の劣化からインフラを活用した位置推定がどの程度の割合で必要であるか検討を行う予定である。




図 2.3.①-13 お台場における信頼性判定結果




図 2.3.①-14 お台場における信頼性判定した結果の測位精度




図 2.3.①-15 お台場における信頼性判定した結果の測位精度(2D, 高さ)




図 2.3.①-16 みちびきを活用した GNSS/INS の位置推定性能評価結果

表 2.3.①-2 測位解の信頼性判定結果

		判定結果	
		信頼性が高い	信頼性が低い
実際の誤差	誤差 $\leq 0.3\text{m}$	2682	382
	誤差 $> 0.3\text{m}$	1	452

【参考文献】

- [1] 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 巻 11 号,pp,754-761,2019
- [2] Aoki Takanose, Yoshiki Atsumi, Kanamu Takikawa, Junichi Meguro, Improvement of Reliability Determination Performance of Real Time Kinematic Solutions Using Height Trajectory, Sensors, 21, 2
- [3] CLAS LIB (https://qzss.go.jp/technical/dod/clas/clas_test-library.html)
- [4] POSLV(<https://www.applanix.com/products/poslv.htm>)

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。

2020 年度は車載グレードの GNSS/INS を使用することを前提としたマップマッチングアルゴリズムを開発し、位置精度(目標精度 0.1m)の評価を行なった。2019 年度においては高精度な GNSS/INS を使用し、姿勢角を既知としたマッチングアルゴリズムの開発を行ったが、車載グレードの GNSS/INS を使用する場合には姿勢角を高精度に得られないことが考えられるため、本年度においては、車両の方位角を含めたマップマッチングアルゴリズムを開発した。

(1) 方位角推定を含めたマップマッチングアルゴリズムの開発

・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 2.3.②-1. 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(LiDAR 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




図 2.3.②-2. テンプレートマッチングの外観図

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。

車載グレードの GNSS/INS を使用する場合、安価なジャイロセンサが用いられているために高精度 GNSS/INS と比較して車両方位角が精度良く得られない。そのため、図 2.3.②-3 に示すように、センサの車両方位角を使って LiDAR 画像のマッピングを行うと画像にぶれが発生し位置が正しく推定できない可能性が大きくなる。そこで、2020 年度は上記の位置推定手法に方位角推定を組み込むことで、方位角の精度が低下した場合や車載グレード GNSS/INS を使用した場合においても正しく位置推定を可能とするマップマッチングアルゴリズムを開発した。方位角推定手法を以下に述べる。




図 2.3.②-3. 方位角精度の LiDAR 画像マッピングに対する影響

ここでは、文献[2],[3]で示されるような Hough 変換をベースとした方位角推定手法を参考に開発を行った。処理の流れを図 2.3.②-4 に示す。LiDAR からリアルタイムに得られたデータを用いてマッピングされた観測画像と、LiDAR 地図画像それぞれについて、エッジ抽出・Hough 変換を行い方位角方向のスペクトラム(Hough スペクトラム)を計算することで、各画像に対する路面パターンの傾きの分布を知ることができる。2つの画像の Hough スペクトラムに対しテンプレートマッチングなどにより相関分布を計算することで、2つの画像の間の角度差、すなわち方位角オフセットの尤度分布が得られる。したがって、この尤度分布のピークから方位角オフセットを求めることが可能である。また、Hough 変換は図 2.3.②-5 に示すように半径方向 ρ と角度方向 θ のパラメータを用いて直線を表すものであるため、位置ずれの影響を受けにくいといった特徴がある。そのため、位置推定と方位角推定を切り分けて考えることができるのでこれらを同時に実行することが可能であり、リアルタイムでの処理が可能

である。




図 2.3.②-4. 方位角推定手法




図 2.3.②-5.Hough 変換における位置ずれの影響

・ マッチング手法の性能評価

方位角推定を含めたマップマッチング手法の性能評価のため、車両の走行データを用いて検証を行なった。誤差の計算に位置および方位角の真値が必要となるため、高精度 GNSS/INS のデータに人工的にノイズを付加し、車載グレード GNSS/INS のセンサデータをシミュレーションすることにより推定位置および方位角の精度評価を行った。ここでは、1 時間走行したとき角速度の積算により求めた方位角の誤差が 5 度発生するようなガウシアンノイズを付加している。精度評価には、以下の 2 つのルートの走行データを使用した。

[評価ルート 1]

図 2.3.②-6 に走行ルート 1 を示す。このルートは、図 2.3.②-7 に示すような高層ビルが立ち並ぶ、交通量の多い市街地を含んでいる。

図 2.3.②-8 に方位角の推定誤差のグラフを示す。センサの角速度(ヨーレート)を時間積分することによって求められるデッドレコニングの方位角は、時間の経過につれて誤差が増大しているが、方位角の推定を行うことによって、デッドレコニングの誤差を抑制できていることがわかる。図 2.3.②-9 に示した位置推定誤差を見ると、車両縦方向・横方向ともに概ね $\pm 0.5\text{m}$ 以内に誤差が抑制されており、表 2.3.②-1 に示す通り、2 次元位置誤差の RMS は目標精度となる 0.1m を達成している。



図 2.3.②-6. 評価ルート 1



図 2.3.②-7. 高層ビルの多い市街地




図 2.3.②-8. 評価ルート 1: 方位角誤差




図 2.3.②-9. 評価ルート 1: 位置推定誤差

[評価ルート 2]

表 2.3.②-1. 評価ルート 1: 位置・方位角推定誤差

車両縦方向 RMSE [m]	車両横方向 RMSE [m]	2次元位置 RMSE [m]	方位角 RMSE [deg]
0.12	0.06	0.08	0.12

図 2.3.②-10 に走行ルート 2 を示す．本ルートは，図 2.3.②-11 のような複数車線をもつ，交通量の多い駅周辺の道路や，図 2.3.②-12 のような長距離のトンネル区間などを含む経路である．この評価ルートは，ルート 1 が比較的にオープンスカイなエリアを走行しているのに対して，長距離のトンネル区間と




図 2.3.②-10. 評価ルート 2

いった GPS 信号の取得が困難となる場所を走行している．また，ルート 1 では直線区間を多く走行しているのに対してルート 2 では大きくカーブする区間，すなわち方位角の変化が大きい区間を含んでいる．そういった区間においても本手法によって位置や方位角の推定が問題なく行えることを検証した．




図 2.3.②-11. 車線数の多い区間




図 2.3.②-12. 長距離トンネル区間

図 2.3.②-13 および図 2.3.②-14 に推定方位角誤差と推定位置誤差のグラフを示す。図 2.3.②-13 のグラフより、トンネル区間やその他の区間においても、デッドレコニングの誤差が増大しているのに対して方位角推定による結果ではその誤差が抑制されていることが確認でき、図 2.3.②-14 から位置についても GPS 信号を取得可能な区間と同等の精度で推定できていることがわかった。また、表 2.3.②-2 に示すように 2 次元位置の RMS 誤差からも、ルート 1 と同様に目標精度 0.1m を達成可能であることが確認できた。




図 2.3.②-13. 評価ルート 2: 方位角誤差




図 2.3.②-14. 評価ルート 2: 位置推定誤差

表 2.3.②-2. 評価ルート 2: 位置・方位角推定誤差

車両縦方向 RMSE [m]	車両横方向 RMSE [m]	2 次元位置 RMSE [m]	方位角 RMSE [deg]
0.08	0.09	0.08	0.12

・ 東京臨海部における方位角推定の有効性検証

東京臨海部における自動走行試験を実施する中で、高精度 GNSS/INS を使用していたとしても方位角の誤差が増大し、推定位置誤差が拡大してしまうケースが確認された。図 2.3.②-15 の右に示した高架下の約 1km の区間が、実際に GNSS/INS の位置および方位角の誤差が増大した場所となる。高架下のような状況では、GPS 信号の受信が困難となる場合があり、衛星からの情報が得られないために車両の方位角誤差が増大したものと考えられる。図 2.3.②-15 左に GNSS/INS 位置、方位角推定を行わなかった場合のマップマッチングによる推定位置、そして方位角推定を含めたマップマッチングの推定位置の軌跡をプロットしている。また、車両はこの区間において直進レーンの右側車線を走行し、区間の最後で右折レーンに進入し停止した。GNSS/INS 位置は実際の車両の軌跡を大きく外れた車道外の場所を指しており、20m 以上の誤差が現れている。それに対して、デッドレコニングおよびマップマッチングによるデッドレコニングのオフセット推定によって、推定誤差の抑制が確認できる。加えて、方位角推定を行った場合には実際の車両の軌跡と一致するのに対し、方位角推定を行わない場合には一番左の直線・左折レーンを車両位置として推定しており、数車線分の車両横方向の誤差が発生していることがわかる。これらのことから、高精度 GNSS/INS を使用している場合においても、方位角推定の有効性が確認できた。




図 2.3.②-15. 高架下における方位角推定の有効性

今年度においては車載グレード GNSS/INS についての検討はシミュレーションによって行ったため、車載グレードセンサを搭載した実車での走行データによる精度検証も次年度以降の課題である。また、c-①や c-③での検討結果を統合し、マップマッチング併用によるみちびきの有効性評価についても今後の課題として挙げられる。

【参考文献】

- [1] N. Suganuma et al., “Localization for Autonomous Vehicle on Urban Roads,” Journal of Advanced Control, Automation and Robotics (JACAR), 2016.
- [2] A. Censi, L. Iocchi and G. Grisetti, “Scan Matching in the Hough Domain,” Proceedings of the 2005 IEEE International Conference on Robotics and Automation (ICRA)
- [3] Stefano Carpin, “Merging maps via Hough transform,” 2008 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)

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) 車載センサによる白線状態の把握手法の検討

まず白線状態の各項目「白線の剥離率」「白線の反射率」「白線と舗装の反射率コントラスト」[1]について，車載センサによる自動推定値（車載カメラで撮影した画像で，セマンティックセグメンテーションによる白線認識を行うことで推定される白線剥離率）とリファレンス機器による手動計測値（白線を真上からデジタル一眼レフカメラで撮影した画像に，二値化などの画像処理を行うことで得られる白線剥離率）が同じ傾向であることを確認する必要がある．そこで金沢大学構内にて自動推定値と手動計測値の両方のデータを取得し，両者の比較を行った．

・剥離率

昨年度，リファレンス機器として白線を真上からデジタル一眼レフカメラで撮影する装置を作製した．図 2.3.③-1 に作製した手動計測器の外観を，表 2.3.③-1 に使用したデジタルカメラおよび周辺機器の詳細を示す．




図 2.3.③-1 剥離率のリファレンス機器として作製した装置の外観

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

今年度は上記のデジカメ装置を用いて、金沢大学構内の計 50 箇所の白線において自動推定値と手動計測値のデータ取得を行い、両者を比較する。図 2.3.③-2 に剥離率の自動推定と手動計測の様子を、図 2.3.③-3 に剥離率の自動推定値と手動計測値の関係性を示す。



図 2.3.③-2 剥離率の自動推定値（左図）と手動計測値（右図）の比較




図 2.3.③-3 剥離率の自動推定値と手動計測値の関係性

上図より、自動推定値と手動計測値には同じ傾向があることが確認できる。剥離率が中間程度（自動推定値では約 40%，手動計測値では約 60%）の辺りににおいて自動推定値は手動計測値より低めの値となっているが、これはデジカメ装

置が間近から白線を撮影しているのに対し、車載カメラは白線から離れた位置から撮影していることが原因だと考えられる。また、参考文献[2]も同様の結果を報告している。

・ 反射率およびコントラスト

LiDAR 点群を自車が移動するに従ってマッピングすることで、衛星写真のように天空から見下ろした形の地図画像（反射率オルソ画像）を作成することができる。反射率オルソ画像の各画素の明るさはその地点での反射率の強さを表しているが、画像内のどのピクセルが白線部分なのかを自動的には特定しづらいというのが昨年度の課題であった。そこで今年度は LiDAR 点群とセマンティックセグメンテーション画像をフュージョンすることで、画像内のどのピクセルが白線部分なのかを自動で検出することを可能にし、「白線の反射率」および「白線と舗装の反射率コントラスト」の自動推定値を計算できるようにした。金沢大学構内においてそのようにして算出した自動推定値と、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 を用いて計測した手動計測値を比較することで、両者の関係性を確認する。図 2.3.③-4 に反射率の自動推定と手動計測の様子を示す。図 2.3.③-4 の右側に示すようなミロラックス 7 を用いた白線反射率の手動計測値の算出にあたっては、機器的な制約から、白線とその周辺のアスファルトのみの反射率を用いられている。これと条件をそろえる目的で、図 2.3.③-4 の左側に示すような LiDAR 点群とセマンティックセグメンテーションを用いた白線反射率の自動推定値の算出においても、白線とその周辺のアスファルトのみの反射率を用いることとした。そのため図 2.3.③-4 の左側に示すように、反射率オルソ画像から白線部分（赤）と白線周辺の舗装部分（アスファルト：青）のみを抽出して評価に用いた。ただしここで用いる白線部分には、横断歩道も含まれている。この理由は、セマンティックセグメンテーションでは横断歩道も白線として扱われてしまい、これらの分離が難しいからである。そのためここでの白線反射率の数値評価にあたっては、横断歩道と白線の両方を用いることとした。また舗装部分は上記で白線とみなした領域の周辺のみを画像処理により抽出した。



図 2.3.③-4 白線反射率および反射率コントラストの
自動推定値（左図）と手動計測値（右図）の取得の様子

車載 LiDAR で計測できる反射率と、ミロラックス 7 で計測できる反射輝度値は単位が異なるため、先のカメラによる剥離率のように両者の値同士を直接的に比較することができない。そこで金沢大学構内の白線がかすれたエリアと綺麗なエリアの 2 つのエリアで自動推定値と手動計測値のデータ取得を行い、白線がかすれたエリアに対して綺麗なエリアの反射率は何倍になるかというエリア間の変化率を比較することで、両者の関係性を確認することとした。図 2.3.③-5 に白線反射率の自動推定値と手動計測値の関係性を、図 2.3.③-6 に反射率コントラストの自動推定値と手動計測値の関係性を示す。図 2.3.③-5 と図 2.3.③-6 より、白線がかすれたエリアに対する綺麗なエリアの変化率が

- ・ 白線反射率については自動推定値および手動計測値ともに約 1.7 倍
- ・ 反射率コントラストについては自動推定値および手動計測値ともに約 1.5 倍

となっているので、自動推定値と手動計測値には同じ傾向があることが確認できる。




図 2.3.③-5 白線反射率の自動推定値と手動計測値の関係性




図 2.3.③-6 反射率コントラストの自動推定値と手動計測値の関係性

(2) 白線状態が白線認識およびマップマッチングに及ぼす影響度の評価

車載センサを用いることで白線状態をリファレンス機器と同じ傾向で自動推定できることが確認できたので、次は白線状態が自動運転システム内の特に白線認識およびマップマッチングにどのような影響を及ぼすのかについて調査を行った。白線認識に及ぼす影響を評価する理由は、白線認識が自動運転システムの中で白線を最も直接的に取り扱う部分だからである。またマップマッチングに及ぼす影響を評価する理由は、白線状態がマップマッチングに用いる反射率オルソ画像の鮮明度に関わるからである。

また、白線状態が自動運転システムに与える影響を調査するにあたり、白線

状態以外の条件を可能な限り一致させるために、同一地域における白線補修工事の実施前後でのデータを比較することが望ましい。そこで自治体からの協力を頂き、石川県かほく市（全長約 6 km の走行コース）および富山県富山市（全長約 35 km の走行コース）の公道における白線補修工事の予定を事前に情報提供頂いた。これらの事前情報を基に、当該地域の白線補修工事の実施前と後でそれぞれ複数回データ取得を行なった。このように白線補修工事の前後でデータ取得を行い比較することで、自動運転システムに及ぼす環境要因を可能な限り白線状態のみに限定することができた。

・ 白線認識に及ぼす影響度の評価

白線を認識する技術として、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を利用する。車載カメラ画像から自動推定した剥離率を因果関係の原因側、セマンティックセグメンテーション画像の白線部分の認識率を因果関係の結果側として、影響度の評価を統計的に行った。車載カメラ画像は 20 m おきに撮影したものを使用し、剥離率および認識率ともに人手によりアノテーションされた正解画像、つまり白線の元の姿を表す画像を 100% として算出した。図 2.3.③-7 に剥離率が認識率に及ぼす影響度の評価方法の流れを示す。




図 2.3.③-7 剥離率が認識率に及ぼす影響度の評価方法

影響度の評価を統計的に行うために、各剥離率における認識率の頻度を集計した。ただし認識率の頻度の様子をヒストグラム図ではなく、ヒストグラム中の認識率の高い方から順に累積した累積頻度図として表している。このようにヒストグラム図から累積頻度図へ変換することで、頻度の“推移”が読み取りやすくなり、各剥離率同士での比較が容易となる。ただし、ヒストグラム図では横軸の左側ほど認識率が低く、右側ほど高いことを示しているのに対し、累積頻度図では横軸が反転しており、横軸の左側ほど認識率が高く、右側ほど低いことを示していることに注意されたい。図 2.3.③-8 にヒストグラム図から累積頻度図への変換の詳細を示す。




図 2.3.③-8 ヒストグラム図から累積頻度図への変換

本累積頻度図は、グラフが左上に凸なほど「認識率の高い頻度が多い」ことを、右下に凸なほど「認識率の低い頻度が多い」ことを表す。剥離率を 20% 区切りで 5 つにグループ分けし、各剥離率グループでの認識率の累積頻度図を比較したものを図 2.3.③-9 に示す。図 2.3.③-9 より、剥離率が低いほど（つまり白線が綺麗なほど）認識率が高い頻度が多くなり、一方で剥離率が高いほど（つまり白線がかすれているほど）認識率が低い頻度が多くなる傾向にあるとわかる。




図 2.3.③-9 各剥離率グループにおける認識率の累積頻度図

・マップマッチングに及ぼす影響度の評価

事前に作成してある地図用オルソ画像と、走行中のリアルタイムデータから作成される反射率オルソ画像をマッチングすることで、自車の現在位置の特定（自己位置推定）をセンチメートルオーダーで行なっている場合もある．白線の状態が劣化していて白線反射率や反射率コントラストが低下していると、走行中にリアルタイムで作成する反射率オルソ画像の鮮明度も低下するため、地図用オルソ画像とのマッチングが曖昧になってしまう恐れがある．そこで車載LiDARから自動推定した反射率コントラストを因果関係の原因側、マッチング相関分布のピーク位置の誤差およびピークの鋭さ（標準偏差）を因果関係の結果側として、影響度の評価を統計的に行った．相関分布のピーク位置の誤差は高精度GNSSの後処理補正位置を真値として計算しており、相関分布の標準偏差はピーク位置周りで計算している．実際の自動運転システムでは、このマップマッチングの結果に加えて高精度GNSSからの情報等も織り交ぜて時系列的に処理したものを最終的な自己位置推定結果としているが、GNSS等の白線状態とは関係のない影響要因を可能な限り省くために、本調査では単一フレームでのマップマッチングについてのみに着目した．図 2.3.③-10 に反射率コントラストがマップマッチングに及ぼす影響度の評価方法の流れを示す．




図 2.3.③-10 反射率コントラストがマップマッチングに及ぼす
影響度の評価方法

富山県富山市の公道での走行データを用いて、白線補修工事が行われる前（白線がかすれている状態）と行われた後（白線が綺麗な状態）でマップマッチングの結果を比較することで、白線の状態がマップマッチングへ及ぼす影響度の評価を行った。ただしマッチングの品質には、走行中のリアルタイムデータから作成される反射率オルソ画像（観測画像）の鮮明度だけでなく、地図用オルソ画像（地図画像）の鮮明度も影響するため、全部で以下の4つの組み合わせが考えられる。

- ① 地図中の白線は綺麗だが、走行時は白線がかすれている
→ 地図データ取得後に現実の白線が経年劣化してしまったケースに相当
- ② 地図中の白線も綺麗で、走行時も白線が綺麗
→ 地図データおよび現実の白線ともに良くメンテナンスされているケースに相当
- ③ 地図中の白線もかすれていて、走行時も白線がかすれている
→ 地図データは更新されているが現実の白線はメンテナンスされていないケースに相当

④ 地図中の白線はかすれているが，走行時は白線が綺麗

→ 白線補修工事が行われたが地図データはまだ更新されていないケースに相当

各ケースにおける，観測画像の反射率コントラストに対するマッチング相関分布のピーク位置の誤差を図 2.3.③-11 に示す．プロット点が縦軸の 0 付近から上下に離れるほどマップマッチングの誤差が大きいことを表し，青いほど頻度が少なく，赤いほど頻度が多いことを示している．図 2.3.③-11 より，①と④のケース，つまり地図画像と観測画像で白線の状態が大きく異なるケースでは，マップマッチングの車両横方向の誤差が大きくなる場所が点在していることがわかる．これは自動運転を行うにあたり理想的ではないものの，時系列処理（誤差の大きい場面では観測情報よりも過去の情報を信じるような処理）を行うことでカバーできる可能性があり，自動運転として全く成立しないレベルとまでは言えないので，図 2.3.③-11 中では△と表記した．一方で②と③のケース，つまり地図画像と観測画像で白線の状態が近いケースでは，白線状態の良し悪しに関わらず，概ねすべての状況でマップマッチングの車両横方向の誤差は小さいことがわかる．誤差が大きい場所もみられるもののその頻度は非常に少なく，自動運転への影響はかなり限定的と考えられるため図 2.3.③-11 中では○と表記した．




図 2.3.③-11 観測画像の反射率コントラストに対する
マッチング相関分布のピーク位置の誤差

ただし②のケースと③のケースにおける同一箇所でのマッチング相関分布を比較してみると、両ケースともピーク位置自体は正しいが、②のケースよりも③のケースの方が相関ピークの鋭さが低いことが確認された。このことを図 2.3.③-12 に示す。図 2.3.③-12 は、観測画像（赤色）を相関ピーク位置に従って地図画像（緑色）上に重ね合わせ、そのときの相関分布をグレースケール（黒いほど相関値が低く、白いほど相関値が高い）で示したものである。また、このときの地図画像は真値を中心として切り出しているため、相関ピーク位置が画像中央であればピーク位置は正しいということになる。図 2.3.③-12 より、左側の②のケースは相関分布のピークがより鋭く、③のケースは相関分布のピークがなだらかであることがわかる。これは、②のケースよりも③のケースの方がマッチングの確信度が低いことを意味している。そこで以降、「マッチングの確信度」を「相関分布のピーク位置周りの車両横方向の標準偏差の小ささ」で評価する。




図 2.3.③-12 同一箇所でのマッチング相関分布の比較

ここで②と③のケースにおける、観測画像の反射率コントラストに対するマッチング相関分布の標準偏差を図 2.3.③-13 に示す．縦軸の標準偏差の値が低いほど相関分布のピークが鋭い、つまり確信度が高いことを表す．また図 2.3.③-11 と同様に、プロット点の色は青いほど頻度が少なく、赤いほど頻度が多いことを示している．図 2.3.③-13 より、②のケースでは、反射率コントラストが大きくなるにつれて標準偏差が小さくなる、つまり相関分布のピークが鋭くなり、確信度は高くなる傾向があることがわかる．一方で③のケースでは、同じ反射率コントラスト（横軸の値が 1.0 ～ 2.0 の辺り）でも標準偏差が小さいときもあれば大きいときもある、つまり相関分布のピークが鋭かったり鋭くなかったりと、不安定であることがわかる．また③のケースでは、反射率コントラストが高くなっても（横軸の値が 2.0 以上の範囲でも）標準偏差は②と比較して大きいままであり、全体的に相関分布のピークは鋭くなく、確信度が低い傾向にあることがわかる．




図 2.3.③-13 観測画像の反射率コントラストに対する
マッチング相関分布の標準偏差

ここで影響度の評価を統計的に行うために、各反射率コントラストにおけるマッチング相関分布の標準偏差の頻度を集計した。ただし図 2.3.③-9 と同様に、ヒストグラム図ではなく累積頻度図で各反射率コントラスト同士での比較を行う。本累積頻度図は、グラフが左上に凸なほど「標準偏差が小さい（ピークが鋭い）頻度が多い」ことを、右下に凸なほど「標準偏差が大きい（ピークが鋭くない）頻度が多い」ことを表す。反射率コントラストを 1.5 区切りで Lv.1 から Lv.5 までの 5 つにグループ分けし、各反射率コントラストグループでの標準偏差の累積頻度図を比較したグラフを図 2.3.③-14 に示す。図 2.3.③-14 より、反射率コントラストが高いほど標準偏差が小さい（ピークが鋭い＝確信度が高い）頻度が多くなり、一方で反射率コントラストが低いほど標準偏差が大きい（ピークが鋭くない＝確信度が低い）頻度が多くなる傾向にあるとわかる。









図 2.3.③-14 各反射率コントラストグループにおけるマッチング
相関分布の標準偏差の累積頻度図

各反射率コントラストグループにおける観測画像と、その画像における相関分布の標準偏差の具体例を図 2.3.③-15 に示す。一般にマップマッチングでは、白線の反射率データだけでなく、周辺環境（建物のエッジなど、道路管理者の管理が及ばないところ）などの反射率データも同時に用いられる。しかし反射率コントラストが低いグループの観測画像（Lv.1）では道路の白線が確認しにくく、相関分布の標準偏差も大きい。このような環境では、マッチングにおいて道路の白線よりも周辺環境が重要視されていると考えられる。一方で、反射率コントラストが高いグループ（Lv.4 や Lv.5）では、白線が観測画像上でも視認しやすく、また相関分布の標準偏差も小さくなっていることが確認できる。こちらでは、マッチングにおいて道路の白線が重要な役割を担っていると考えられる。

	Lv.1	Lv.2	Lv.3	Lv.4	Lv.5
反射率コントラストの範囲	0.0 ~ 1.5	1.5 ~ 3.0	3.0 ~ 4.5	4.5 ~ 6.0	6.0 ~
観測画像					
反射率比	0.53	1.98	3.43	5.51	6.56
相関分布の標準偏差 (進行方向) [m]	1.47	1.30	1.28	1.41	1.44
相関分布の標準偏差 (横方向) [m]	0.88	0.75	0.61	0.42	0.21

相関分布は鋭くない(標準偏差が大きい)

相関分布は鋭い(標準偏差が小さい)

※人間の目で見えた印象は、観測画像から得られる数値的な特徴と必ずしも一致しない

図 2.3.③-15 各反射率コントラストグループにおける
観測画像とマッチング相関分布の標準偏差

ところで、マッチング相関分布の相関値は、白線部分のみに由来する成分と、その他の領域（周辺領域）が由来の成分とに分けることができる。反射率コントラストの大きさマッチングで白線と周辺領域のどちらが重要視されているのかを調べるために、マッチング相関分布のピーク値（最大相関値）のうち白線部分のみに由来する成分の比率（以下、白線の相関値比）を集計した。各ケース①～④において、白線の相関値比の累積頻度図を比較したものを図 2.3.③-16 に示す。図 2.3.③-16 の中央図が全体での比較、左図は中央図のうち横軸の値（白線の相関値）が負の領域を拡大したグラフ、右図は地図画像と観測画像で白線の状態が近い場合の結果を中央図から抽出して比較したグラフである。これらの図に共通して、横軸の値（白線の相関値）が負の領域は、マッチングが行われた際に白線部分の相関値が負であったこと、すなわちマッチングにおいて白線領域が悪影響を及ぼしていたことを表している。

図 2.3.③-16 の左図をみると、①と④のケースでは横軸が負の領域からグラフが立ち上がっていることから、マッチングにおいて白線領域が悪影響を及ぼしている場所があったことが確認される。①は地図データ取得後に現実の白線が経年劣化してしまったケース、④は白線補修工事が行われたが地図データはまだ更新されていないケースであり、どちらも地図上の白線の状態が実際と乖離した場合に相当する。一方で、②や③のケースのように地図画像と観測画像で白線の状態が近い場合は、横軸が負の領域ではグラフが立ち上がっておらず、マップマッチングで白線が悪影響を及ぼした場所はみられない。以上の

ことから、白線がマップマッチングに悪影響を及ぼさないようにするためには少なくとも、地図データの更新を継続的に行うことで地図データ上の白線の状態を実際の状態と近いものに保つことが望ましいと考えられる。

また、②と③のケース、つまり地図画像と観測画像で白線の状態が近い場合について、白線状態の良し悪しがマップマッチングにおける白線の相関値比にどの程度影響するかを比較する。そのために、図 2.3.③-15 に示したグラフのうち、②と③の結果に着目する。③のグラフは白線の相関値比が小さい正の値のところ（0.25 以下）で立ち上がっている。つまり、③のように地図データの更新はされているものの現実の白線はメンテナンスされていないケースでは、マッチングにおいて白線は悪影響を及ぼしてはいないもののあまり効果的ではなく、むしろ周辺環境（道路管理者の管理が及ばないところ）の影響度が相対的に高い、ということがわかる。これは、「白線の相関値比が低い場所で周辺環境が突然変化すると、マップマッチングの精度や、ひいては自動運転の安全性が担保できなくなる危険性」につながると考えられる。一方で、②のグラフは白線の相関値比が比較的高いところ（0.25 以上）で立ち上がっている。つまり、②のように地図データおよび現実の白線ともに良くメンテナンスされているケースでは、マッチングにおいて白線が効果的に使われており、周辺環境の影響度が相対的に低くなっている。したがって、周辺環境の変化がマッチングに及ぼす影響を抑制するためには、白線のメンテナンスをできるだけ継続的に行う必要があると考えられる。




図 2.3.③-16 各ケースのマッチングにおける白線相関値比とその累積頻度

左：横軸の値（白線の相関値）が負の領域のグラフの拡大図

中央：全体図

右：地図画像と観測画像で白線の状態が近い場合の比較

【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”，土木計画学研究・講演集，Vol.42，Paper ID:158，2010.
- [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），Vol. 67，No. 1，pp. 10-21，2011.
- [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。

2020年度は、歩行者の属性および周辺環境を考慮し、歩行者の経路予測を行う。その際、入力画像として自動車視点の場合と俯瞰視点の場合のいずれが適切であるか比較検討する。また、歩行者の経路予測結果をもとに、道路への飛び出しまでの時間を評価し、インフラとしてどのような対策が必要となるか検討する。

・自動車視点からの経路予測

自動車視点での経路予測は、研究開発が急速に進む自動運転において、運転手の判断を支援する Advanced Driver Assistance System の1つとして注目されている。自動車視点における経路予測では、周囲に映る歩行者や自動車の未来の経路を予測することが重要となる。特に、歩行者の未来の経路を予測する場合、周囲の環境や歩行者同士の相互関係、その歩行者自身の判断など、歩行者の潜在的な状態を予測しなければならない。しかし、シーン内の歩行者や自動車など複数の移動物体を予測するためには、対象毎に予測する必要があり、計算コストが課題となる。そこで、シーン内の移動物体の情報をまとめて埋め込んだコンテキスト画像を入力することで、複数の移動物体の未来の経路を同時に予測する[1]。

コンテキスト画像

複数の移動物体の経路を同時に予測するために、コンテキスト画像を用いた経路予測手法を用いる。ここで、コンテキスト画像とは、1時刻前の画像と現

在の画像間におけるオプティカルフロー画像から作成した各移動物体の移動量を1つにまとめて表現した画像である．コンテキスト画像の作成例を図 2.4.①-1 に示す．コンテキスト画像作成にあたり，オプティカルフロー画像は FlowNet2.0[2]で求めている．そして，シーン内に映る移動物体の矩形領域のみ残してマスク処理する．この時，オプティカルフロー画像を HSV 色空間の 3 チャンネルで表現したコンテキスト画像を入力に用いる．




図 2.4.①-1 コンテキスト画像の作成例

経路予測モデル

経路予測モデルの構造を図 2.4.①-2 に示す．本モデルは，過去のコンテキスト画像を入力する Encoder と未来の位置を予測する Predictor で構成されている．Encoder は，入力画像を ConvLSTM の 1 層目に入力し，3 層目まで逐次順伝播する．すべての観測時刻のコンテキスト画像を入力した後，Predictor へ遷移する．Predictor では，現時刻以降の数時刻先までのコンテキスト画像を逐次出力する．その後，コンテキスト画像における各物体の位置から経路情報に変換して，各移動物体の経路として予測する．




図 2.4.①-2 自動車視点からの経路予測モデルの構造

データセットの内訳

東京臨海部で撮影した歩行者データセットを用いて自動車視点における経路予測手法の精度を評価する．本データセットの内訳を表 2.4.①-1，データセットの画像を図 2.4.①-3 に示す．シーンは全部で 10 シーンある．属性として，歩行者や自動車の移動物体の種類だけでなく，赤信号や矢印灯などの静的物体も含まれている．



図 2.4.①-3 自動車視点からの経路予測モデルの評価データ例

表 2.4.①-1 データセットの内訳

シーン数	10 (中に複数シーンあり)
データ数	60 (1 シーンあたり 6 つの視点あり)
画像サイズ	1920x1080, 1920x1208
属性	トラック，歩行者，一般自動車，バス，自転車，赤信号，矢印灯右，no target
アノテーション情報	物体矩形の座標 (左上，左下，右上，右下)

評価実験

経路予測には 8 時刻分を観測データとして入力し，その後の 8 時刻分の経路を予測する．コンテキスト画像のサイズは 240×135 ピクセルである．

予測結果例を図 2.4.①-4 に示す．図 2.4.①-4 より，真値と比較して予測が十分正しくできていないことが確認できる．これは，1 時刻間での移動量が大きすぎるためと考えられる．また，自車の動きも考慮しなければならないため，自動車視点での予測は多くの課題がある．




図 2.4.①-4 自動車視点からの経路予測結果例

・俯瞰視点からの経路予測

自動車視点から経路予測は、自車や時刻間の移動量に大きく依存するため、予測が困難である。そこで、経路予測において、成功している俯瞰視点で経路予測を検討する[6, 7, 8]。従来の経路予測手法は、高い予測精度を達成できる一方で、道路や横断歩道へ飛び出す歩行者を何秒前から予測できるか十分に分析されていない。これは、既存のデータセット[9, 10, 11]には横断歩道や車道のようなセマンティックなシーンラベルや、歩行者の年齢のような属性ラベルがついていないためであると考えられる。また、現実シーンで撮影されたデータに経路情報だけでなくこれらシーンラベルや属性ラベルを付与するのはコストがかかる。そこで、データを容易に収集し、属性ラベルを付与できるよう CARLA シミュレータ[12]でデータセットを作成する。収集したデータを従来手法[13]に組み込むことで、車道や横断歩道の飛び出しの何秒前に予測ができるかを分析する。

CARLA データセット

CARLA シミュレータ上で作成したデータの内訳を表 2.4.①-2 に示す。収集したシーン例と付与したシーン例を図 2.4.①-5 に示す。ここで、シーン例の青線は移動対象が実際に辿った経路例を示す。それぞれ異なる 15 シーンで撮影し、自動車、自転車及び、歩行者の経路データを作成した。歩行者には、大人、子供及び高齢者の 3 種類の異なる属性が含まれている。データには道を歩く人、直交する人及び、急な方向転換をする人など様々な状態の歩行者のデータを作成した。また、CARLA では歩道や車道のようなシーンラベルを自動で付与できるが、Minoura らの条件に合わせるために人手によるアノテーションを行った。シーンラベルは以下の 6 種類とした。

また、全シーンにおける各対象が位置するラベルマップの占有率を図 2.4.①-

6 に示す．これより，歩行者は歩道を主に歩き，他は車道を渡っていることが確認できる．

表 2.4.①-2 CARLA データセットの内訳

シーン数	15
1 シーンあたりのフレーム数	1,800
画像サイズ	720x576
属性	歩行者(大人,子供,高齢者),自動車,自転車
対象数	大人(600),子供(110),高齢者(111),自動車(111),自転車(41)




図 2.4.①-5 シーンラベル付与したシーン例




図 2.4.①-6 収集した各対象が位置するラベルマップの占有率

経路予測モデル

経路予測モデルには Minoura ら[13]が提案した属性と環境情報を考慮した経路予測手法を用いる。経路予測モデルの概要を図 2.4.①-7 に示す。本モデルの入力として、移動対象の属性、移動対象周囲の環境、過去の移動対象の位置座標の3つの情報を用いる。移動対象の属性は、大人、子供及び、高齢者といった情報であり、one-hot vector で表現する。環境情報では、シーンラベルを CNN へ入力し、環境に関する特徴ベクトルを抽出する。過去の移動対象の位置情報は、各時刻における移動対象の座標である。これらの情報を LSTM に入力し、ネットワークの出力として次の時刻の位置情報を得る。予測時には、ネットワークの出力を次の時刻の入力として逐次的に入力することで、過去の情報を考慮した予測を実現する。これにより、移動対象の移動速度の違いや移動する領域の違いを考慮した経路予測を実現できる。




図 2.4.①-7 属性と環境情報を考慮した経路予測モデルの概要。文献[13]より改変。




図 2.4.①-8 評価実験における歩行者の飛び出しの具体例

評価実験

大人，子供及び，高齢者が歩道から何秒前に車道，または横断歩道に飛び出す経路を予測できるかを検証する．評価実験の具体例を図 2.4.①-8 に示す．図 2.4.①-8 より，観測時刻で歩道にいる歩行者が横断歩道に飛び出す何秒前に経路を予測できるかを分析する．同時に飛び出すまでの距離についても分析する．

経路予測モデルには 8 時刻分の観測値を入力し，その後の 12 時刻分の経路を予測して出力する．画像サイズは 720×576 ピクセルである．評価は，15 シーンの内 1 シーンを評価用，それ以外を学習用データセットとして交差検証を行う．

実験結果

歩行者が進行方向の車道に向かうシーンにおいて，歩行者が横断歩道または，車道に入るまでの秒数とその移動対象数を表したグラフを図 2.4.①-9 に示す．このシーンでは，移動対象が横断歩道または，車道に入る経路を 0.4 秒前から 2.8 秒前に予測している．具体的な予測結果を図 2.4.①-10 に示す．図 2.4.①-10 の(a), (b)は，左図のヒストグラムに属する大人の予測結果例を示す．図 2.4.①-10 (a)より，移動速度が速いかつ車道までの距離が 1m と近い場合，0.4 秒前とほぼ直前で予測できる．また，図 2.4.①-10 (b)のように車道まで 8.5m と遠い距離の場合でも車道に飛び出す 3.2 秒前から予測できている．




図 2.4.①-9 横断歩道または，車道に入った対象数と入るまでの秒数を表したグラフ




図 2.4.①-10 進行方向の車道に向かうシーンでの予測結果例

歩行者が進行方向を変えて車道に向かうシーンでの予測結果を図 2.4.①-11 に示す．図 2.4.①-11 の(a)および(b)はどちらも大人の例である．歩行者が車道に沿って歩くシーンでは，歩行者が進行方向を変えて車道に飛び出す経路を 2.4 秒から 3.2 秒前から予測できている．図 2.4.①-11 の(b)のように，緩やかに進行方向を変えている場合は，4.8 秒前から予測ができていないケースもある．これらのシーンにおいて，実際には歩行者は車道に飛び出してはいないが，その危険性を予測することができている．




図 2.4.①-11 進行方向を変えて車道に向かうシーンでの予測結果例

交差点で進行方向を変えて道路に向かうシーンでの予測結果を図 2.4.①-12 に示す．図 2.4.①-12 (a)および(d)は，子供が走っているような移動速度が速い移動対象の結果である．子供の場合，道路から離れていると飛び出す経路を飛び出す 2.0 秒前に予測できている．一方で，道路に近い場合は 0.4 秒前という直前にならないと予測できていない．図 2.4.①-12 の(b)および(e)は，子供より移動速度の遅い大人に対する結果である．また，図 2.4.①-12 (b)および(e)は同じ移動対象の予測結果である．図 2.4.①-12 (b)より，道路から離れている場合は，道路に飛び出す 3.6 秒前に飛び出す経路を予測し，道路に近い場合でも 2.0 秒前に予測できている．図 2.4.①-12 (c)および(f)は，移動速度の遅い高齢者に対

する結果である．高齢者の場合，道路に近い場合でも飛び出す 2.8 秒に飛び出すような経路を予測できている．これより，交差点に近い場合，子供の飛び出す経路の予測は直前でないと予測できないものの，交差点からある程度離れている場合は 2.0 秒以上前から飛び出す経路の予測が可能である．




図 2.4.①-12 交差点で進行方向を変えて道路に向かうシーンでの予測結果例

横断歩道を渡るシーンでの予測結果を図 2.4.①-13 に示す．図 2.4.①-13 (a)および図 2.4.①-13 (d)に子供のような移動速度が速い場合の経路を示す．図 2.4.①-13 (a)より，横断歩道に近い場合は，道路に飛び出す 0.4 秒前でないと飛び出す経路を予測できていない．また，図 2.4.①-13 (d)のように急な方向転換をする場合，経路を予測することが困難である．次に，図 2.4.①-13 (b)のような大人の場合，図 2.4.①-13 (a)と同じ場所から横断歩道に進入するが，子供と比べて歩く速度が遅いため，道路に飛び出す 2.4 秒前から経路を予測できている．図 2.4.①-13 (e)のように移動対象の移動量が小さい場合も道路に飛び出す前に余裕を持って経路予測できている．図 2.4.①-13 (c)および図 2.4.①-13 (f)に示すように，移動速度がさらに遅い高齢者の場合は，横断歩道を渡る経路を 3.6 秒から 4.8 秒前から予測できている．これより，横断歩道を渡るシーンにおいて，大人や高齢者の場合は 2.4 秒前から経路の予測が可能であるが，子供の場合は 0.4 秒前と直前でないと予測が困難である．

シーンラベルの有効性の確認

AI ベースの経路予測について、シーンラベルの有効性を確認するために、シーンラベルの有無および、従来のモーションベースによる経路予測を比較する。ここで、モーションベースは等速直線運動とし、経路予測を行う。これらの予測結果を図 2.4.①-15 に示す。図 2.4.①-15 の上図は、歩行者がラウンドアバウト周辺を歩くシーンである。このシーンにおいて、モーションベース（等速直線運動による予測）では、前方のガードレールを超えて道路に飛び出している。一方で、シーンラベルを考慮した AI ベース経路予測では、道路へ飛び出さず、歩道に沿って移動する経路を予測できている。

図 2.4.①-15 の中央は、建物に向かって移動するシーンである。モーションベースおよび、シーンラベルを考慮しない場合、建物に衝突するような経路となっている。一方で、シーンラベルを考慮した場合は、建物や塀への衝突を避けるような経路を予測できている。これより、シーンラベルを考慮することで、周囲の障害物との衝突を避ける経路予測が可能となる。




図 2.4.①-15 モーションベースと AI ベースによる予測結果例

・まとめ

自動車視点と俯瞰視点からの経路予測を評価した．その結果，俯瞰視点からの経路予測が飛び出しを予測するのに適していることがわかった．俯瞰視点からの経路予測において，属性および周辺環境を導入した手法をもとに，属性による飛び出しまでの時間および道路までの距離を分析した．その結果から，大人や高齢者の場合は，3m から 5m 程度と比較的道路に近くても飛び出す経路を早期に予測できる．一方で，子供の場合は 9m 以上と十分に離れている必要がある．

一方，地図情報（シーンラベル）の有効性について確認した．経路予測において，障害物の回避などにとって，地図情報が重要であることがわかった．また，AI ベース（本検討手法）とモーションベース（等速直線運動）の経路予測手法についても比較した．その結果，AI ベースの手法は，道路への飛び出しなどの誤った経路の予測を抑制できており，有効であることがわかった．

経路予測について，シーンラベルのさらなる有効な活用方法や AI ベースの手法に最先端な手法をベースとするなどの改良により，子供の経路を早期に予測できるか検討が必要である．

【参考文献】

- [1] H. Iesaki, T. Hirakawa, T. Yamashita, and H. Fujiyoshi, “Simultaneous Visual Context-aware Path prediction,” 15th International Conference on Computer Vision Theory and Applications, 2020.
- [2] E. Ilg, N. Mayer, T. Saikia, M. Keuper, A. Dosovitskiy, and T. Brox, “FlowNet 2.0: Evolution of optical flow estimation with deep networks,” In Computer Vision and Pattern Recognition, 2017.
- [3] K. P. Diederick and B. Jimmy, “Adam: A method for stochastic optimization,” In International Conference on Learning Representations, 2015.
- [4] M. Cordts, M. Omran, S. Ramos, T. Rehfeld, M. Enzweiler, R. Beneson, U. Franke, S. Roth, and B. Schiele “The cityscapes dataset for semantic urban scene understanding,” In Computer Vision and Pattern Recognition, 2016.
- [5] H. Adam and L. Jules, “Megapixels: Origins, ethics, and privacy implications of publicly available face recognition image datasets,” 2019.
- [6] A. Alahi, K. Goel, V. Ramanathan, A. Robicquet, L. Fei-Fei, and S. Savarese, “Social Lstm: Human Trajectory Prediction in Crowded Spaces,” In Computer Vision and Pattern Recognition, 2016.
- [7] A. Gupta, J. Johnson, L. Fei-Fei, S. Savarese, and A. Alahi, “Social gan: Socially

acceptable trajectories with generative adversarial networks,” In Computer Vision and Pattern Recognition, 2018.

[8] B. Ivanovic and M. Pavone, “the trajectron: Probabilistic multi-agent trajectory modeling with dynamic spatiotemporal graphs,” In International Conference on Computer Vision, 2019.

[9] S. Pellegrini, A. Ess, K. Schindler, and L. V. Gook, “You’ll never walk alone: modeling social behavior for multi-target tracking,” In International Conference on Computer Vision, 2009.

[10] A. Lerner, Y. Chrysanthou, and D. Lischinski, “Crowds by example,” Computer Graphics Forum, 2007.

[11] A. Robicquet, A. Sadeghian, A. Alahi, and S. Savarese, “Learning social etiquette: Human trajectory understanding in crowded scenes,” In European Conference on Computer Vision, 2016.

[12] A. Dosovitskiy, G. Ros, F. Codevilla, A. Lopez, and V. Koltun, “CARLA: An Open Urban Driving Simulator,” 1st Annual Conference on Robot Learning, 2017.

[13] H. Minoura, T. Hirakawa, T. Yamashita, and H. Fujiyoshi, “Path prediction using object attributes and semantic environment,” 14th International Conference on Computer Vision Theory and Applications, 2019.

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。

今年度は昨年度までに開発していた認識アルゴリズムから移動物体の状態推定アルゴリズムの性能改善を図り自動運転自動車での運用を行った。その他、金沢市及び東京臨海部での実証実験から総合的な性能評価を実施した。

・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、追跡物体を質点と仮定して追跡する手法（以降質点追跡と述べる）が一般的によく用いられてきた。この場合、物体の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。

今年度は、東京臨海部を走行する自動運転自動車に開発アルゴリズムを導入した性能評価を実施した。実証実験で計測したセンサデータを用いて、EOTと質点追跡をそれぞれ行い、ロバスト性とリアルタイム性の評価を実施した。

まず、形状変化に対するロバスト性の評価を行う。評価は、図 2.4.②-1 に示すような、自車の対向車を追跡する場面で行う。この追跡物体は、オクルージョンによって形状が変化している。初めは、オクルージョンによって点群が得られない領域が存在することで、対象が 2 つの物体として追跡されているが、その後はオクルージョンがなくなり 1 つの物体として追跡される。この過程で、図 2.4.②-2 のように観測サイズ（形状）が変化する。ここでは、普通乗用車に比べて細長いトレーラを追跡対象としているため、形状変化がかなり大きい。




図 2.4.②-1 評価に用いる追跡物体






図 2.4.②-2 評価に用いる追跡物体の観測サイズ


図 2.4.②-3 に実際に追跡を行った結果を示す．図 2.4.②-3(a)は方位の推定値である．ここでは，自車と対向車はほぼ平行に運動しているため，自車方位を目安として用いている．質点追跡では，約 30 フレーム目まで自車方位とかけ離れた推定値が得られた．一方，EOT では，方位の推定値が自車方位と大きく異なるということとはなかった．図 2.4.②-3(b)，(c)はそれぞれ長さ，幅の推定値である．まず，長さに注目する．図 2.4.②-2 から分かるように，今回考える対象は最初，長さが約 16[m]まで拡大し続けている．しかし，質点追跡による長さの推定値を見ると，10[m]を超えたところで拡大がストップし，その後は急に小さくなっている．一方，EOT では，長さが約 16[m]に達するまで拡大し続けている．次に，幅に注目する．質点追跡では，幅の推定値が 20 フレームを超えたところで約 6[m]となった．一般的なトレーラの最大幅は 2.5[m]程度であることから明らかに大きな値である．一方，EOT においても，最初の 40 フレームは想定される車両幅を超えている．これは，トレーラが旋回中で車体が「く」の字になっているものを矩形枠で近似して形状推定しているためである(図 2.4.②-3(d))．なお，40～60 フレームで EOT 及び質点追跡ともに推定幅が小さくなっているのは，追跡物体が自車の真横にいるため側面のみが観測される状態のためである(図 2.4.②-3(e))．以上より，EOTの方が現実には即した推定が行えていると言える．また，追跡継続性という観点で見ると，質点追跡では，追跡が途中で 2 回中断されて推定値が不連続な変化をしているが，EOTにおける追跡中断は 1 度もなかった．よって，追跡継続性に関しても EOTの方が優れていると言える．




(a) 追跡物体の方位




(b) 追跡物体の矩形枠の長さ



(c) 追跡物体の矩形枠の幅



(d) 「く」の字の車両



(e) 側面のみ観測

図 2.4.②-3 追跡結果

次に、リアルタイム性の評価を行う．約 1 時間 30 分の東京臨海部の走行データについて処理時間を計測した．ここで、使用した LiDAR のフレームレートは 10[Hz]であるため、1 フレームあたりの処理時間が 100[ms]以内に収まっていればリアルタイムであると言える．EOT と質点追跡の処理時間を図 2.4.②-4 に示す．これを見ると、両者の差は小さいことが分かる．実際、平均処理時間

は EOT が 33.4[ms]，質点追跡が 28.3[ms]であり大差はない．一般的に EOT の方が処理時間は長くなるが，その差が小さく抑えられていることから，今回導入した EOT の有用性が確認できる．また，EOT の最大処理時間が 73.1[ms]であり，100[ms]以内に収まっていることから，全フレームでリアルタイムな処理を実現できたと言える．




図 2.4.②-4 EOT と質点追跡の処理時間

このように，形状変化に対するロバスト性とリアルタイム性を両立した，実環境での走行にも適用可能な EOT を実現することができた．

・公道走行による総合評価

本事業での実証実験を継続的に実施するに当たり，周辺物体の追跡，予測，パスプランニングの各種アルゴリズムを改善し，自動運転状態での平均走行持続可能距離として 5.0[km]を達成することを目標値として設定している．今年度は新型コロナウイルスの感染拡大に伴う出張制限などの影響により東京臨海部での実験中断の対応を取る時期が発生していたことから石川県金沢市内を中心に総合評価を実施した．

石川県金沢市内で性能評価に用いたルートを図 2.4.②-5 に示す．本ルートでは，金沢大学から市内の幹線道路を通りながら金沢駅を經由して金沢港へ向かう片道 18[km]のルートである．幹線道路のトンネル及び分合流や金沢駅周辺の片道 3 車線の道路など郊外・市街地の走行環境を含む評価ルートである．本実験では 2020 年 6 月より 2 週間に 1 回の程度のペースで評価ルートの往復走行する性能評価を実施してアルゴリズムの課題抽出及び平均走行持続可能距離の評価を行った．



図 2.4.②-5 石川県金沢市内における評価用ルート（片道 18km）

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。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「自動走行距離」、「平均走行持続可能距離」に注目する。

- ・ 自動走行距離：走行ルートを自動運転で走行した距離
- ・ オーバーライド数：ドライバによるマニュアルオーバーライドにより制御 OFF となる回数
- ・ 平均走行持続可能距離：ドライバによるオーバーライド1回あたりにおける自動運転での平均走行距離である。

評価結果を表 2.4.②-1 に示す。評価が進むにつれて平均持続可能距離が改善し、2020 年 9 月末の時点では約 5.8[km]と本年度の目標値が達成されていることが確認できる。継続した評価をすすめるにつれて認識・予測・パスプランニングの各機能の技術的課題が改善されオーバーライド数の削減が達成された。

前述の EOT による移動物体の追跡アルゴリズムの実車導入などの昨年度までに検討・開発していた機能を徐々に導入していくことで総合的な性能が改善されている。

表 2.4.②-1 石川県金沢市の自動運転評価における平均走行持続可能距離

評価時期	自動走行距離[km]	オーバーライド数	平均走行持続可能距離 [km]
2020/06	32.452	12	2.704
2020/07	97.446	42	2.320
2020/08	72.825	13	5.602
2020/09	41.018	7	5.860

・東京臨海部実証実験において確認された環境不調による課題

前述の性能評価に加えて東京臨海部においても実証実験を継続的に実施しているが、アルゴリズムが主要因となるオーバーライドだけでなく道路周辺の構造物や他車両、交差点の状態などに応じた道路環境の条件が要因となる不調シーンも確認されている。特徴的なシーンとしては以下のものが挙げられる。


- ・右折時の死角による対向車未検知によるオーバーライド
- ・信号機の右折矢印灯の点灯時間秒数による交差点進入時のオーバーライド
- ・交差点接近中に信号状態が黄色に変わるときの急減速

これからのシーンにおける課題は認識アルゴリズムの技術的な改善のアプローチだけでなくインフラによる支援及び調整などによっても改善が期待できる。各課題の詳細な状況に関して以下に述べる。

【シーン1】右折時の死角による対向車未検知によるオーバーライド

自車両が安全に右折するためには、対向車を検知することが必要不可欠である。もしも検知できなければ、対向車に衝突してしまう恐れがある。交差点周辺の構造物や右折待ち車両などによって死角が発生し、対向車の認識に遅れる場合を確認している。例えば、東京湾岸警察署前の交差点（図 2.4.②-6(a)）では、高架橋を支える柱や対向車によって死角となることがある。図 2.4.②-6 に示すようにカメラ画像(図 2.4.②-6(b))において、右折中待ちしている車両が存在している間は死角に入り込んでいる対向車の検知が困難となり対向車への反応が遅れることが考えられる。このような死角による対向車検知の課題は、

類似課題として中央分類帯の草木などによる対向車の死角が影響を及ぼす場合も確認されている。




(a)東京湾岸警察署前の交差点




(b)カメラ画像

図 2.4.②-6 右折時の死角による対向車未検知


図 2.4.②-7 に、このシーンにおける自車両の速度の変化、加速度の変化、ヨー角の変化、自動運転の状態を示す。グラフ第 2 縦軸は自動運転状態を表し、1 は自動運転、0 は手動運転であることを示している。最初は、速度、加速度が大きくなり、ヨー角も変化していることから右折しようとしていることが読み取れる。その後、対向車との衝突を防ぐため、オーバーライドを行い、手動で停止させた。このようなシーンでは自車からの視点だけでは対向車の状況を把握することが困難であると考えられるため、解決するためには、V2I 及び V2V などの通信で死角補助等のインフラによる支援や、対向車の死角の状況に応じて徐々に前進するなどのプランニング側の改善が必要である。



(a)速度の変化



(b)加速度の変化



(c)ヨー角の変化

図 2.4.②-7 シーン 1 の実験車両の状態の変化

【シーン2】信号機の右折矢印灯の点灯時間秒数による交差点進入時のオーバーライド

自車両が右折専用車線で先頭から2車両目に位置するときに、右折待機状態から信号機の右折矢印灯を確認して発進するが、矢印灯の点灯時間が短く、矢印灯点灯中に交差点から抜け出すことが出来ずにオーバーライドを行った例である。具体的な交差点位置としては図 2.4.②-8 に示す「有明コロシム東」の交差点で矢印の方向に右折をする状況でオーバーライドが発生した。図 2.4.②-9 にこの交差点でオーバーライド発生時の車両の状況を示す。一般的な交差点では信号機の点灯サイクルが「青信号→黄信号→赤+右矢印→黄信号→赤信号」と変化するため右折走行を行う場合では青信号の段階から交差点に進入して対向車の状況に応じて右折を開始する。しかしながら、当該交差点では「赤+左・直進矢印→黄信号→赤信号→赤+右矢印→黄信号→赤信号」と信号サイクルが変化するため、右折を開始する矢印が点灯してからはじめて交差点に進入することになる。そのため、右矢印の点灯時間によっては交差点進入が困難となる場合が発生する。




図 2.4.②-8 有明コロシム東の交差点






図 2.4.②-9 右折矢印灯の点灯時間が短いことによるオーバーライド


図 2.4.②-10 に，このシーンにおける自車両の速度変化，加速度の変化，ヨー角の変化，自動運転の状態と信号の状態を示す．グラフ第 2 縦軸は自動運転状態を表し，1 は自動運転，0 は手動運転であることを示している．グラフの背景の色は信号の状態を表しており，信号の状態は「赤＋左・直進矢印→黄→赤→赤＋右矢印→黄→赤」の順番で変化している．このシーンは，赤信号状態で停車中から始まり，時刻 18 秒付近で右折矢印灯が点灯し，車両は右折のために発進を始める．その後，時刻 26 秒付近に黄色信号に切り替わるタイミングでは自車両はまだ交差点の内部にいたため，交差点から抜け出すために手動運転で加速をしており，オーバーライドが発生している．自動運転自動車では滑らかに加速して発進するように設計する場合もあることから発進時の加速を抑えていることがあるが，そのような場合に交差点進入時の遅れが懸念される．発進時の加速を強く設計することで一般車同様に交差点進入が可能となるが乗り心地とのトレードオフの問題も検討する必要がある．このようなオーバーライドをインフラ側から防ぐためには矢印灯の点灯時間の調整も一案として想定される．したがって，交差点の階梯パターンの検討においても自動運転車が通過しやすいパターンの調整についても検討の余地があると考えられる．



(a)速度の変化



(b)加速度の変化



(c)ヨー角の変化


図 2.4.②-10 シーン 2 の信号の状態と実験車両の状態の変化

【シーン 3】：交差点接近中に信号状態が黄色に変わるときの急減速


自動車が交差点接近中に停止線直前で信号状態が青色(緑色)から黄色に変わる場合、ジレンマゾーンと言われる状況において急減速が発生する。例えば、図 2.4.②-11 及び図 2.4.②-12 は「お台場中央（北側）」の交差点接近中に発生したジレンマゾーンの例である。ジレンマゾーンは交差点進入直前のタイミングで発生しうる問題のため一般的にはどの交差点でも発生する可能性がある。



図 2.4.②-11 お台場中央（北側）の交差点



信号状態が黄色に変わった時



停止線で停車した時

図 2.4.②-12 信号状態が黄色に変わった時と停止線で停車した時の車両の状況

図 2.4.②-13 に、このシーンにおける自車両の速度変化，加速度の変化，自動運転の状態と信号の状態を示す．グラフ第 2 縦軸は自動運転状態を表し，1 は自動運転，0 は手動運転であることを示している．グラフの背景の色は信号の状

態を表しており、信号の状態は「青色→黄色→赤色」の順番で変化している。このシーンは、青信号状態で交差点接近中の状態から始まり、黄色信号に切り替わるタイミングでは急減速が発生し、停車している。図 2.4.②-13 の結果ではオーバーライドせず自動運転走行を継続しながら交差点で停止しているが、中には停止線直前で停止できないと判断してオーバーライドする場合も確認されている。このような急減速を回避するためには、2.1 で検証しているようなV2I 通信等による残秒数（先読み情報）の配信によるインフラからの支援が一案であると考えられる。





図 2.4.②-13 シーン 3 の信号の状態と実験車両の状態の変化

・まとめ

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、今年度は移動物の認識及び自車の走行軌道の生成方法の改善を図り密な交通環境においてスムーズな走行を可能とした。移動物の認識の課題では、昨年度までに開発していた Extended Object Tracking 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を実センサでリアルタイム化できるように改善して実証実験に導入した。

開発したアルゴリズムの性能を評価するため、今年度は石川県金沢市の市内の道路を対象として自動運転走行の平均走行持続可能距離を評価し、パスプランニングアルゴリズムなどの改善を進めながら今年度の目標値である平均持続走行距離 5km を達成した。この他、東京臨海部での実証実験の評価結果に基づいてオーバーライドの発生要因を分析し、オーバーライドに影響のある道路環境の要因の分析を実施した。評価結果より密な交通環境下では状況に応じて死角の補助や信号残秒数（先読み）情報の提供などによる V2I 通信で円滑な走行が期待される。また物理的なインフラの導入だけでなく、交差点の信号パターンを調整して矢印灯の点灯時間を長くするなどの対応によっても円滑な交差点走行が期待される。このような市街地走行における不調要因の分析はシミュレーションの活用によっても効率的にすすめることが可能である。したがって、今後はシミュレーションと連携した評価・分析が課題となる。

【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.

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

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を回避可能であるか否かの検討を進める。

昨年度では、複数台の自動運転車を走行させることのできるシミュレーションソフトを構築し、そのシミュレーションソフト上でデッドロックの発生するシーンを5つ確認した。自動運転自動車同士が交通ルールに対して厳密に走行するため、周囲の一般車や構造物の状況によってデッドロックが発生する場合を確認している。今年度はデッドロックシーンについて回避策を検討する。また、ロボティクス技術を活用したデッドロック回避アルゴリズムを構築し、シミュレーターおよび実車試験にて有効性を評価する。まず昨年度報告した5つのデッドロックシーンを以下に示す。

【シーン1】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 2.5.①-1 交差点付近に路駐車両が停車しているシーン

【シーン 2】片側一車線の道路に路駐車両が停車しているシーン

この道路はカーブの区間となっているため、2 台目の左側にはガードレールが設置されており、2 台目の車両は道路左側の空間を利用して 1 台目の車両を避けることは出来ない状況である。

- ・ 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通り越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 2.5.①-2 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

【シーン 3】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 2.5.①-3 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

【シーン 4】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

・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 2.5.①-4 幹線道路に合流するシーン

【シーン 5】商業施設等の駐車場の出入り口でのシーン

駐車場の出入口の左右には壁があるため，2台目の車両は道路左側の空間を利用して1台目の車両を避けることはできない状況である．

- ・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 2.5.①-5 商業施設等の駐車場の出入り口でのシーン

・デッドロックシーンのタイプ分け

上記の 5 つのデッドロックシーンは、デッドロック発生後に車両 1 台分が通り抜けられるスペースがまだ残っている場合と、通り抜けられるスペースがもう残っていない場合の 2 タイプに大別される。前者のタイプはデッドロック発生後に「事後的に対処」できるが、後者のタイプはデッドロック発生前に「事前に予防」しなければならない。後者の事前予防タイプに対応するためには、片方の車両がもう片方の車両の通過を待ってあげるなど、“複数台の間での譲り合い”が必要となるので、マルチエージェント強化学習等を行える人工知能(AI)技術を活用して対応するのが適切だと考えられる。従って、主に前者の事後対処タイプに対してロボティクス技術を活用してデッドロック回避の検討を行った。上記の 5 つのデッドロックシーンは、具体的には以下のように分けられる。


< 事後対処タイプ > → ロボティクス技術を活用

- ・シーン 1 ... 1 台目は左折・直進レーンも含めると自車左側に回避スペースが残っている。
- ・シーン 3 ... 1 台目は歩道も含めると自車左側に回避スペースが残っている。

< 事前予防タイプ > → 人工知能(AI)技術を活用

- ・シーン 2 ... 2 台目が通り過ぎるまで 1 台目は追い越しせずに待ってあげる必要がある。
- ・シーン 4 ... 合流車線側の車両が入れるように本線側の車両が車間をあけてあげる必要がある。
- ・シーン 5 ... 2 台目が出庫するまで 1 台目は入庫せずに待ってあげる必要がある。

＜事後対処タイプ＞ → ロボティクス技術を活用



＜事前予防タイプ＞ → 人工知能（AI）技術を活用




図 2.5.①-6 デッドロックシーンのタイプ分け

・事後対処タイプの回避策

前者の事後対処タイプのデッドロックシーンが起きてしまう主な原因は、自動運転システムが“交通ルールを順守し、なるべく車線を逸脱せずに走行する”ことを前提に構築されているからである。例えばシーン1では、交通ルール上本来ならば路上駐車してはならない交差点付近に一般車両が路上駐車しているのが根本的な発端であり、そのような状況に対して1台目の自動運転車両が交通ルールを順守するために通常通り右折レーンから逸脱せずに交差点を右折しようと試みるのが原因である。人間の運転手であればこの場合、自車左側にある左折・直進レーンに他車両がないことを確認してから、臨時的に右折レーンを逸脱して左折・直進レーンに侵食しながら（左に膨らみながら）デッドロックを回避するだろう。同様にシーン3では、自車左側の歩道に歩行者や自転車がないことを確認した上で、臨時的に少し歩道に侵食することでデッドロックを回避するだろう。

そこで本研究テーマでは、このような事後対処タイプのデッドロック発生時には“臨時的に交通ルールを順守せず、あえて車線を逸脱して回避する”という柔軟性を自動運転システムに追加することで、デッドロック回

避を行う．なお，本来このようにやむを得ないとは言え，臨時的に交通ルールを順守せず，デッドロック回避を試みるのが法律上許容されるのかについては議論が必要ではあるが，あえてここではデッドロックのアルゴリズム上の回避策の可能性について検討を実施した．

本自動運転システムでは，目的地に到達可能な走行ルートを探索する「経路計画技術」，交通ルール等に基づいて大まかな振る舞いを決定する「意思決定技術」，そして障害物への回避などの細かい挙動を計画する「軌道計画技術」という三層の階層構造型のパスプランナを採用している．この二層目の「意思決定技術」の直後にロボティクス技術を活用したデッドロック回避アルゴリズム（大まかな回避行動の提案）を追加することで，交通ルールを順守しながら計画した経路をベースにしながらも，臨機応変にスペースを見つけてデッドロックを回避することが可能となる．また，回避行動の経路探索には，A*ベースのアルゴリズム[1]を応用している．図 2.5.①-8 にシーン 1 におけるアルゴリズムの適用前と適用後の目的地への走行ルートの違いを示す．アルゴリズムを適応することで新たな経路探索を行い，デッドロックを回避する走行ルートが生成されていることが確認できる．




図 2.5.①-7 三層階層構造型パスプランナ




図 2.5.①-8 A*ベースの経路探索アルゴリズム

・デッドロック回避アルゴリズムの有効性の評価

事後対処タイプのデッドロックシーン（シーン 1，シーン 3）において，上記の枠組みによる回避策が有効かどうか，シミュレーターおよび非公道における実車試験にて評価を行う．評価する観点とは，デッドロックシーンを回避可能かどうかという点と，回避経路の計画にかかる処理時間のリアルタイム性の 2 点とする．シミュレーターは Intel Core i7-8700K 3.70GHz CPU 上で行い，実車試験は金沢大学構内の駐車場にて行った．また，路駐車両は段ボールで再現し，2 台目の自動運転車両は静止しているものとする．

【シーン 1】交差点付近に路駐車両が停車しているシーン

まずシミュレーターにて検証した結果を図 2.5.①-9 に示す．左から，デッドロックの発生，回避行動の提案，回避行動の遂行を表している．





図 2.5.①-9 シーン 1 をシミュレーターにて検証

図 2.5.①-9 より，臨時的に右折レーンを逸脱して左折・直進レーンに侵食しながらデッドロックを回避できていることがわかる．また，このときの回避経路計画にかかる処理時間は 63 [ms] であった．このシミュレーション結果を受けて，次は実車試験を行った．実車試験にて検証した結果を図 2.5.①-10 に示す．




図 2.5.①-10 シーン 1 を実車試験にて検証


図 2.5.①-10 より，実車試験においてもシミュレーターでの結果と同様に，臨時的に右折レーンを逸脱して左折・直進レーンに侵食しながらデッドロックを回避できていることがわかる．検証により得られた 1 台目の自動運転車両の速度変化，加速度の変化，ヨー角の変化と自動運転の状態を図 2.5.①-11 に示す．グラフ第 2 縦軸は自動運転状態を表し，1 の間は自動運転，0 の間は手動運転であることを示している．実験開始後 15[s]～25[s]の間で 1 台目の自動運転車両が直進し，2 台目の自動運転車両と向かい合わせになると，車両速度が 0[m/s]の状態が続き，デッドロックが発生する．そして，30[s]経過の時点でデッドロック回避アルゴリズムを適用することで 30[s]～40[s]の間に臨時的に左折・直進レーンに侵食して左側に膨らみながら 2 台目の自動運転車両を回避し，その後右折を行っていることが確認できる．図 2.5.①-12 にデッドロック発生後から回避経路を作成し，回避行動を遂行している様子を示す．



(a) 速度の変化



(b) 加速度の変化



(c) ヨー角の変化

図 2.5.①-11 シーン 1 の実験車両の状態の変化




図 2.5.①-12 シーン 1 の実験車両のデッドロック回避の様子

【シーン 3】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

まずシミュレーターにて検証した結果を図 2.5.①-13 に示す．左から，デッドロックの発生，回避行動の提案，回避行動の遂行を表している．





図 2.5.①-13 シーン 3 をシミュレーターにて検証

図 2.5.①-13 より，臨時的に少し歩道に侵食することでデッドロックを回避できていることがわかる．また，このときの回避経路計画にかかる処理時間は 19 [ms] であった．このシミュレーション結果を受けて，次は実車試験を行った．実車試験にて検証した結果を図 2.5.①-14 に示す．




図 2.5.①-14 シーン 3 を実車試験にて検証


図 2.5.①-14 より，実車試験においてもシミュレーターでの結果と同様に，臨時的に少し歩道に侵食することでデッドロックを回避できていることがわかる．検証により得られた 1 台目の自動運転車両の速度変化，加速度の変化，ヨー角の変化と自動運転の状態を図 2.5.①-15 に示す．グラフ第 2 縦軸は自動運転状態を表し，1 の間は自動運転，0 の間は手動運転であることを示している．実験開始後 15[s]～25[s]の間で 1 台目の車両が右側に膨らみながら 1 台目側の路駐車両を回避するが，その後 2 台目の自動運転車両と向かい合わせになると車両速度が 0[m/s]の状態が続き，デッドロックが発生する．30[s]経過の時点でデッドロック回避のアルゴリズムを適用すると，30[s]～70[s]で歩道側に侵食することでデッドロックを回避し，元の車線に復帰している．図 2.5.①-16 にデッドロック発生後から回避経路を作成し，回避行動を遂行している様子を示す．



(a) 速度の変化



(b) 加速度の変化



(c) ヨー角の変化

図 2.5.①-15 シーン 3 の実験車両の状態の変化




図 2.5.①-16 シーン 3 の実験車両のデッドロック回避の様子

シミュレーターおよび実車試験の両方にて，本アルゴリズムによる事後対処タイプのデッドロックの回避が可能であることが確認できた．またシーン 1 とシーン 3 とともに，回避経路の計画にかかった処理時間は自動運転システムに搭載した L i D A R の計測周期である 100 [ms] を下回っているため，リアルタイム処理できている．これらのことから，事後対処タイプのデッドロックシーンに対して，本アルゴリズムは有効性があると考えられる．

・まとめ

デッドロックシーンをデッドロック発生後に「事後的に対処」できるか，もしくは発生前に「事前に予防」しなければならないか，という観点でタイプ分けをし，前者の事後対処タイプについてロボティクス技術を活用したデッドロック回避アルゴリズムを構築した．本アルゴリズムは，デッドロック発生時には臨時的に“あえて車線を逸脱して回避する”というアイデアに基づいており，シミュレーターおよび実車試験にて有効性があることを確認した．このようなアイデアによる回避行動は，人間の運転手が日常的に行っている回避行動と近い．従って自動運転車両についても人間の運転手と同様に，通常は交通ルールを順守しながら走行しつつも，デッドロックのような例外的なシーンにおいては臨時的に交通ルールを順守しないといった，柔軟性を持たせるべきか議論する必要がある．このような例外的に交通ルールが変化させる必要のある状況として緊急車両の接近時が挙げられる．緊急車両接近時では周辺車両が道を譲るためにスペースを空けるなどの柔軟な対応が求められる状況が発生するが，通常時の交通ルールに厳密に従う自動運転自動車では状況の把握及び柔軟な譲り合い行動が困難である．このような状況に対してどのように周辺状況を認識して対処す

るべきかを検討することは重要な課題である。

【参考文献】

- [1] C. Chen, M. Rickert, and A. Knoll, “Path planning with orientation aware space exploration guided heuristic search for autonomous parking and maneuvering”, Proc. IEEE Intelligent Vehicles Symposium, 2015.

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。2020年度は、2019年度に抽出したデッドロックが生じる複数のシーンのシミュレーション環境を構築し、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

2019年度の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)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

2)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

3)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

4)幹線道路に合流するシーン

5)商業施設等の駐車場の出入り口でのシーン
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[6]。

・デッドロック回避のための深層強化学習手法

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手法

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、車両の俯瞰画像、速度と曲率を入力する。ここで、俯瞰画像は車両を中心とした一定範囲の領域を切り出した画像である。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。

・各シーンにおける技術検証

検証を行うデッドロックが発生するシーンをシミュレーション環境として作成し、シーンごとに発生するデッドロックの回避を図る。

【シーン 1】 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

シーン 1 のシミュレーション環境

図 2.5.②-2 に示すように 2 台の自動運転自動車を配置し，走行レーンに路駐車両がある環境である．本シミュレーション環境では，走行レーンを正しく走行するように学習する．そのとき，走行レーンを逸脱したり，他車に衝突したりすると失敗となる．交差点における青信号と赤信号は道路の色で表現する．具体的には，青色の自動運転自動車は道路の色が緑色であれば走行可能，ピンク色の自動運転自動車は道路が赤色なら走行可能とする．道路の色が青色の場合は，走行できない状態である．自動運転自動車の行動は，速度及び曲率の増減，変化なしの組み合わせ合計 9 通りとし，その行動を自動運転自動車の制御値に変換する．変換する際，最大速度を 3m/s，最低速度を-1m/s，最大曲率を 0.25，最低曲率を-0.25 とする．速度は，デッドロックを回避するシーンでは徐行するとして仮定し，時速 10km から換算している．また，急激なハンドル操作を行わないと仮定して曲率の範囲を算出している．1 回のシミュレーション（エピソード）の終了条件は自動運転自動車が道路外，障害物及び他自動運転自動車に衝突した場合，または 1.0×10^5 ステップ経過とする．




図 2.5.②-2 シーン 1 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，自動運転自動車の走行に対する報酬を与える必要がある．本検討では，表 2.5.②-1 に示す報酬ルールをもとに学習を行う．報酬には，良い行動をした時に正の報酬，良くない行動をした時に

負の報酬を与える．具体的には，ゴールした場合に+10 という大きな報酬を与える．また，正しく走行レーンを走行できるように，走行パスを指定し，中間地点に向かうことでプラス 2 の正の報酬を与える．一方で，障害物や他自動運転車に衝突した場合はマイナス 10 の負の報酬を与える．また，自動運転自動車が信号無視した場合は走行ゾーン離脱としてマイナス 10 の負の報酬，他自動運転自動車との間隔が狭い場合にもマイナス 10 の負の報酬を与える．ここで，これらの報酬については，文献[6]で検討した最も良い組み合わせをもとに，いくつかの報酬ルールのパターンを事前実験し，その中で最良の組み合わせを採用している．

表 2.5.②-1 報酬ルール

報酬の種類	報酬値
ゴール報酬	+10
中間地点に近づく	+2
衝突ペナルティ	-10
走行ゾーン離脱ペナルティ	-10
車間距離によるペナルティ	-3

シーン 1 のシミュレーション環境における走行パスと中間地点の設計を図 2.5.②-3 に示す．




図 2.5.②-3 シーン 1 での自動運転自動車ごとの走行パスと中間地点

学習条件

シーン1のシミュレーション環境において、agent1とagent2それぞれの累積報酬の推移と獲得した行動を確認し、検討手法を用いることでデッドロックを回避する行動が獲得可能か確認する．ここで、A3Cを学習する際の並列処理数(worker 数)を8とし、 4.0×10^7 ステップ学習する．

評価結果

シーン1のシミュレーション環境における累積報酬の推移を図2.5.②-4に示す．図2.5.②-4から、agent1とagent2ともに累積報酬が安定せず、デッドロックを回避するような学習ができていないことが分かる．シーン1において、最も高い累積報酬を獲得したモデルにおける行動の推移を図2.5.②-5に示す．ここで、ピンクの自動運転自動車がagent1、青色の自動運転自動車がagent2である．図2.5.②-5から、t+3からt+5までに路駐車両の前後でagent1とagent2が停滞していることが確認できる．デッドロックを回避する行動を獲得するに至らなかった原因としては、回避するパターンが一意に定まらないことが挙げられる．具体的には、前方から右折車が進入してきた際、信号待ちの自動運転自動車は、左に避ける、右に避ける、後退する、前進して先に行く行動を取ることができる．いずれの場合でも、走行ゾーンを離脱するため、報酬としてマイナスになる．また、車間距離が近づくため、さらにマイナスの報酬が加算される．このようなマイナスの報酬の累積を防ぐために、ピンク色のagent1は、t+2の段階で走行レーンの端で停滞する行動を選択したと考えられる．これを回避するためには、背反する報酬ルールの見直しやシミュレーション環境に回避可能な領域を一時的に設けるなどの改善が必要であると考えられる．




図 2.5.②-4 シーン 1 での学習ステップごとの累積報酬の推移





図 2.5.②-5. シーン 1 における各自動運転自動車の行動

【シーン 2】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
シーン 2 のシミュレーション環境

図 2.5.②-6 に示すように片側 1 車線のカーブ道路に 2 台の車を配置し，走行レーンに路駐車両がある環境をシミュレーション環境として構築した．走行す

自動運転自動車 道路 路駐車両 障害物&道路外

シーン 2 のシミュレーション環境における走行パスと中間地点の設計を図 2.5.②-7 に示す.



シーン1のシミュレーション環境と同様の報酬ルールにより学習を行う．その際， 5.0×10^7 ステップ学習する．

評価結果

シーン2のシミュレーション環境における累積報酬の推移を図2.5.②-8に示す。図2.5.②-8から、agent1とagent2ともに累積報酬が一定で停滞していることが確認できる。また、シーン2において、検討手法により獲得した行動の推移を図2.5.②-9に示す。ここで、ピンクの自動運転自動車をagent1、青色の自動運転自動車をagent2とする。図2.5.②-9から t+2からt+5までに、デッドロックが発生し、agent2がデッドロックを回避しようとして道路外へ出てしまい、デッドロックを回避できていない。このシーンにおいては、デッドロックが発生する手前で、ピンクの自動運転自動車が停止し、譲る行動を獲得することを意図している。しかしながら、そのような行動を獲得できていない。その理由として、検討手法に入力する切り出し領域の範囲が狭く、他の自動運転自動車が十分に写っていないケースが考えられる。また、シミュレーション環境のカーブの構築が不完全で、これまでに発見できていないマイナスの報酬にならないホットスポットがあることも考えられる。本検討手法による1回の学習は、高性能GPUサーバ（NVIDIA DGX-1）を用いて3週間以上要するため、本シーンにおけるデッドロック回避が可能かどうかは時間をかけて再検討が必要である。




図 2.5.②-8 シーン 2 での学習ステップごとの累積報酬の推移




図 2.5.②-9 シーン 2 における各自動運転自動車の行動

【シーン 3】 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

シーン 3 のシミュレーション環境

図 2.5.②-10 に示すように，2 台の自動運転自動車を配置し，走行レーンに障害物があるシミュレーション環境を構築した．障害物は自動運転自動車が 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．走行する条件や行動の選択肢はシーン 1 と同様である．




図 2.5.②-10 シーン 3 の自動運転環境

学習条件

シーン1のシミュレーション環境と同様の報酬ルールにより学習を行う．その際、 2.0×10^7 ステップ学習する．

評価結果

シーン3のシミュレーション環境において検討手法を学習した際の累積報酬の推移を図2.5.②-11に示す．図2.5.②-11から、agent1とagent2ともに学習が進むごとに累積報酬が高くなっており、 2.0×10^7 ステップ時点で収束していることが確認できる．また、シーン3において、検討手法により獲得した行動の推移を図2.5.②-12に示す．図2.5.②-12からピンク色のagent1がt+1からt+2まで待機し、青色のagent2が障害物を通り過ぎた後に動き出している．これより、デッドロックを回避するために、agent1がagent2の通過を待つという譲る行動を獲得できたと考えられる．路駐車両の位置を変えた場合でも、デッドロックが発生する場合に、同様の行動を安定して獲得できていることも確認できた．これより、シーン3においてデッドロックを回避する行動の獲得が可能であると言える．ただし、デッドロック状態においては、回避できないこともある．その条件について、さらなる解析が必要である．




図 2.5.②-11 シーン 3 での学習ステップごとの累積報酬の推移




図 2.5.②-12. シーン 3 での各自動運転自動車の行動

【シーン 4】 幹線道路に合流するシーン

シーン 4 のシミュレーション環境

図 2.5.②-13 に示すように，複数台の自動運転自動車を配置し，片方の自動運転自動車が合流するようなシミュレーション環境を構築した．合流を行う側は自動運転自動車 1 台とし，合流される側は自動運転自動車 6 台を制御する．走行する条件や行動の選択肢はシーン 1 と同様である．




図 2.5.②-13 シーン 4 のシミュレーション環境

シーン 4 の環境における走行パスと中間地点の設計を図 2.5.②-14 に示す。




図 2.5.②-14 シーン 4 の走行パスと中間地点

学習条件

シーン1のシミュレーション環境と同様の報酬ルールにより学習を行う。その際、 1.0×10^7 ステップ学習する。

評価結果

シーン4のシミュレーション環境で、検討手法を学習した際の累積報酬の推移を図2.5.②-15に示す。図2.5.②-15から、agent1の累積報酬が250、agent2の累積報酬が550程度で停滞していることが確認できる。また、シーン3において、検討手法により獲得した行動の推移を図2.5.②-16に示す。図2.5.②-16から、 t から $t+5$ まで合流される側の自動運転自動車が譲る行動を取らず、合流することができていないことが確認できる。本シーンでは、合流する自動運転自動車により、他の複数台の自動運転自動車が譲る行動を取らなければならないシーンである。譲る行動は、加速または減速することが必要となる。このいずれかを合流する付近の自動運転自動車が同じ行動を取るという単純な行動と考えることもできるが、譲る行動を取る自動運転自動車同士が衝突しないよう、複数台が連携を持って同じ行動しなければならないという高度な行動である。特に、本シーンでは、合流される側に6台配置しているため、複雑な行動選択が必要となる。今後、一定間隔に配置する台数やその間隔を変えて、どの程度の合流であれば、デッドロックを回避可能かなど更なる検討が必要である。




図 2.5.②-15 シーン 4 での学習ステップごとの累積報酬の推移




図 2.5.②-16 シーン 4 における各自動運転自動車の行動

【シーン 5】 商業施設等の駐車場の出入り口でのシーン

シーン 5 のシミュレーション環境

図 2.5.②-17 に示すように、2 台の自動運転自動車を配置し、細い道からの出入りするシーンのシミュレーション環境を構築した。細い道は 2 台以上通れな

い程度の道路幅としている．走行する条件や行動の選択肢はシーン 1 と同様である．




図 2.5.②-17 シーン 5 のシミュレーション環境

シーン 5 の環境における走行パスと中間地点の設計を図 2.5.②-18 に示す．




図 2.5.②-18 シーン 5 の各自動運転自動車の走行パスと中間地点

学習条件

シーン 1 のシミュレーション環境と同様の報酬ルールにより学習を行う．
その際， 5.0×10^7 ステップ学習する．

評価結果

シーン5のシミュレーション環境における検討手法の累積報酬の推移を図2.5.②-19に示す．図2.5.②-19から，agent1とagent2ともに安定して高い累積報酬を得ることができていることを確認できる．agent1とagent2に大きな累積報酬の差があるのは，それぞれスタート地点が異なり，異なる動きを行うためである．また，シーン5において，検討手法により獲得した行動の推移を図2.5.②-20に示す．図2.5.②-20から，ピンク色のagent1が $t+1$ から $t+3$ までバックや停止の行動を選択し，青色のagent2が細い道から出てくるまで待機している．そして，agent2が通り過ぎた後に動き出している．これより，デッドロックを回避するためにagent1がagent2の通過を待つという行動を獲得できている．このように，デッドロックが発生するシーンにおいて，自動運転自動車が取りうる行動の選択肢が一意に決まるまたは限定されている場合は，累積報酬を安定して獲得でき，デッドロックを回避することが可能である．




図 2.5.②-19 シーン 5 での学習ステップごとの累積報酬の推移




図 2.5.②-20 シーン 5 における各自動運転自動車の行動

・まとめ

デッドロックが生じる5シーンにおいて，深層強化学習を行うシミュレーション環境を構築し，各シーンでデッドロックを回避する行動を獲得可能か検証した．シーン3，5において，他の自動運転自動車を考慮する行動を獲得することで，デッドロック回避を行う行動の獲得を実現した．これらのシーンでは，デッドロック回避する行動が一意または限定されており，回避行動を獲得しやすいと考える．一方で，シーン1，2，4では，デッドロック回避を行う行動の獲得を実現できなかった．これらのシーンでは，複数のデッドロック回避行動があり，また複数台が連携して行動しなければ困難なシーンである．このようなシーンにおいては，デッドロックシーンを重点的に学習する，環境設計を見直す，報酬ルールを見直すなどが必要である．今後は，これらを行い，デッドロック回避を実現できなかったシーンに対応する手段を明確にすることが課題となる．

【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.
- [6] 五藤他, “インタラク션을考慮したマルチブランチネットワークによる深層強化学習”, 人工知能学会全国大会, 2020.

2.6.f. 「実証実験」

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2.6-1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

特に今年度は、昨年度構築した試験車両等に対して下記の改善を加えつつ公道走行実証実験推進を行った。

- ・ 2.6.a「信号機認識技術の開発及び認識が困難な条件の検討」節で述べたインフラ支援型信号機（ITS 無線路側器を備えた信号機）との連携によって、交差点進入直前に信号機が青色（緑色）から黄色，赤信号へと変化してしまう状況において発生する，いわゆるジレンマゾーンにおける急ブレーキの抑制を実現する技術の開発を目的として，図 2.6-3 に示すように ITS 無線受信機のアンテナを車両上部に設置するとともに，受信感度向上のためアンテナ設置位置の見直しを行い，ジレンマゾーンでの減速度抑制に関する公道走行実証実験を実施した。



図 2.6-3 車両上部に設置した ITS 無線受信機のアンテナ

- ・ 2.6.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」節で述べた，LiDAR および画像のフュージョンによる物体検知アルゴリズムの実現のため，図 2.6-4 に示すようにディープラーニングによる認識処理用コンピュータを更新し，認識技術の性能向上，リアルタイム性の向上を実施した。




図 2.6-4 更新したディープラーニングによる認識処理用コンピュータ

- ・ 2.6.c「高精度自己位置技術の開発」節で述べた，車載グレード GNSS/INS の自己位置推定技術の評価を目的とし，高精度 GNSS/INS に加え，車載グレードのローコスト GNSS/INS からの測位情報，車両運動情報を同時に取得可能とした．
- ・ 2.6.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」節で述べた，石川県金沢市内での公道走行実証実験推進のため，新たに石川県金沢市内における地図の整備を追加で実施した．また，東京臨海部においても，昨年度実施したお台場エリアでの走行実証実験に加え，羽田エリアでの地図整備も追加で実施し，東京臨海部における走行実証実験の範囲を拡大させた．
- ・ SIP 他事業で実施している「仮想空間での自動走行評価環境整備手法の開発（通称 DIVP 事業）」施策との連携のため，仮想空間における評価対象として検討中のセンサと同等のカメラを車両内に設置し，仮想空間と実証実験によって得られたデータの比較評価が可能な環境の構築を行った．

これらの取り組みを通し，2020 年度は東京臨海部での走行実証実験に関しては合計 54 日実施し，自動運転状態で約 1,287.2km を走破した．




図 2.6-5 仮想空間と実証実験データの比較評価用センサの設置

また、内閣府が主催して開催した東京臨海部実証実験メディア向けガイドツアー(2020年9月1日実施)、SIP-adus 中間成果報告会(2021年3月24、25日実施)などにおいて、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。



図 2.6-6 SIP-adus 中間成果報告会における車両展示の様子

3. 実施体制

