

「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」

平成30年度研究成果報告書

平成30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

目次

1.	研究開発の内容及び目標	3
1.1.	研究開発全体の概要	3
1.2.	研究テーマごとの研究開発内容と目標	5
a.	「信号機認識技術の開発及び認識が困難な条件の検討」	5
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」	6
c.	「高精度自己位置技術の開発」	7
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」	8
e.	「複数自律型自動車が走行する状態での問題点の検討」	9
f.	「実証実験」	10
1.3.	成果の要約	11
2.	研究開発成果	14
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」	14
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	14
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	28
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」	33
①	遠距離向け車載カメラの選定・検知アルゴリズム開発	33
②	LiDAR およびミリ波レーダに基づく遠方物体認識	54
2.3.	c. 「高精度自己位置技術の開発」	62
①	GNSS/INS の開発	62
②	マップマッチング技術の開発	69
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」	78
①	人工知能(AI)に基づく歩行者の行動予測	78
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	84
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」	92
①	ロボティクス技術を活用したデッドロック回避	92
②	人工知能(AI)を活用したデッドロック回避	96
2.6.	f. 「実証実験」	97
3.	実施体制	99

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の要件や、またそのインフラ要件のもとで必要とされる認知判断技術の要件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要件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インフラ設備の最低限の要件を見極める。この必要最低限のインフラ要件のもとで認知判断技術の必要要件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。

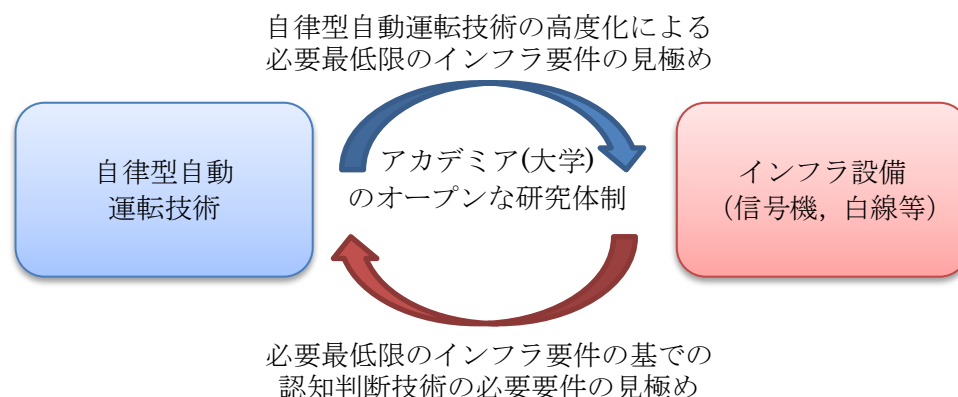


図 1.1-2 必要最低限のインフラ要件の見極めと認知判断技術の要件の見極め

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

- 「信号機認識技術の開発及び認識が困難な条件の検討」
- 「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」
- 「高精度自己位置技術の開発」
- 「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」
- 「複数自律型自動車が走行する状態での問題点の検討」
- 「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の必要要件を検討する。

以下に実施内容および2018年度の目標を示す。

① パターン認識による信号認識と交差点進入判断アルゴリズムの開発

パターン認識による信号認識では、車両位置からデジタル地図を参照して撮影画像内の信号機を検出して、点灯状態を認識する。車載カメラの画角・解像度に依存するが、120m程度の遠方から認識する場合は10×10ピクセル以下の信号灯や矢印灯を認識する必要があるため、特に矢印信号の状態を正確に認識することが課題である。また、非常に厳しい逆光時では認識アルゴリズムとしての課題だけではなくハードウェアの性能限界によって本質的に認識不適な画像が撮影される。こうした本質的課題を解決可能なセンサの選定および性能評価が重要である。従って、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する。

高度な信号認識により適切な交差点走行が期待できるものの、車載カメラによる認識のため前方に大型車両が停止している場合や樹木による隠れが発生する場合では信号機の認識は本質的に不可能である。そのような問題が頻繁に発生する交差点では、インフラ支援型信号機から取得する信号情報が望ましい。V2I通信では、現在の信号状態に加えて、自車が交差点に到達するときの状態を事前に知ることができるため、交差点進入時の急加減速を緩和して乗り心地や省エネに配慮した走行の実現が期待できる。しかしながら、インフラ支援信号情報を取得した自動運転自動車と先読み情報を持たない一般車両が混在する状況下において、どのような効果や課題が起こり得るのかを明らかにすることが重要な課題である。そこでインフラ支援型信号機の情報を活用した交差点進入アルゴリズムの開発を目的とし、2018年度にはインフラ支援型信号機を簡易的に模擬できる試験用信号機を作成する。

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、2018 年度は、複数のセマンティックセグメンテーション手法による信号機認識領域の抽出精度を評価し、現状を把握する。

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2018年度の目標を示す。

① 遠距離向け車載カメラの選定・検知アルゴリズム開発

一般的な車載カメラは視野角100度程度であり、画像サイズが1024x786の場合、50m遠距離に存在する歩行者の高さは37ピクセル、70m遠距離に存在する歩行者の高さは27ピクセル程度と小さい。また、車載カメラは特定の距離に焦点を当てるため、その距離よりも遠方はピントがずれて物体がぼやけてしまう課題がある。これらの課題に対して、2018年度は遠距離の物体検知に適した視野角および高画質化機能を有するカメラを評価し、目標達成に必要なカメラの仕様を検討する。

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である。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。本研究提案では、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て用いた場合の、高精度自己位置推定が可能なアルゴリズム開発を行い、地図と実環境との特徴物の差異などの観点から地図及びインフラのメンテナンスに関するインフラ要件を検討する。なお、GNSS/INSの精度が劣化する可能性が高く、また、地図にも特徴が無い場所では、上記の開発ができたとしても、“道路に設置されたインフラ”による位置推定に頼らざるを得ない場所も存在することが予想される。そのため、自動運転システムを安定して運用可能なインフラの要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マップマッチングに分け、実施内容および2018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う。その評価により、今後実施すべき改善点を明らかにする。

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の要件を明らかにすることを主目的とした、マップマッチング技術の開発をする。

具体的には、GNSS/INSとマップマッチング手法を連動して運用しつつ、マップマッチング時の地図の特徴とLiDARのスカ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の要件を検討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する。

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 2018 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。2018 年度は本アルゴリズムの開発に必要なデータ収集を行う。データ収集は、下記②の開発項目と共通の走行エリア、走行条件とし、複数の箇所でのデータ収集を行う。

② 時系列追跡による車両の行動予測とパスプランニング

市街地における自動運転では、移動物体の将来の予測軌道を求め、その軌道に衝突しない自車の走行軌道をリアルタイムに計画することが重要となる。ただし、特に多数の移動車両が存在する都市部においては、これを実現するためには様々な問題に対処する必要がある。例えば、都市部では自車周辺に多数の移動車両が存在しているため、これらの移動車両同士で一時的に隠れられて死角(オクルージョン)が頻繁に生じる。また自転車等の複雑な動きをするような移動物体の将来の予測軌道をどのように精度よく求めるのかも課題となる。さらに、都市部での走行では複数車線ある道路に多数の車両が存在している場合が多く、自動運転自動車はこれら多数の車両に囲

まれた状況が生じる。このため、このような相対的に狭いスペースの中で多数の移動物体の将来予測軌道を考慮して、どのようにしてスムーズかつ安全に走行するのも課題となる。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。

2018年度は、アルゴリズム開発に必要となる複数箇所の走行エリア、走行条件をピックアップし、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基礎設計を行う。

e. 「複数自律型自動車が走行する状態での問題点の検討」

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

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

以下に実施内容および2018年度の目標を示す。

① ロボティクス技術を活用したデッドロック回避

自動運転システムにおいて、自動車の振る舞いを決定するパスプランニング技術には、大きく分けて自動運転自動車が目的地に到達可能なルートを計画する技術(A.「経路計画技術」)、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(B.「意思決定技術」)、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(C.「軌道計画技術」)に大別可能であると考えられる。この中で、複雑なデッドロック状況において柔軟な回避行動を実現するためには、特にB.「意思決定技術」およびC.「軌道計画技術」に関する高度化が重要となる。本課題では、まずはシミュレーションソフト上で複数の自動運転車が走行する環境を再現させ、金沢大学において開発した既存の自動運転システムにおいてデッドロックが発生しやすい状況を明らかにする。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、上述の主にB.「意思決定技術」およびC.「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。なお、この過程で見つかったデッドロックシーンに関しては、後述の②「人工知能(AI)を活用したデッドロック回避」に用いる学習シーンのデータセットとしても用いることで効率化を図る。そして最終的には、②「人工知能(AI)を活用したデッドロック回避」において開発されたデッドロック回避策を融合し、回避行動の質をデッドロックの発生頻度、デッドロック回避にかかる時間等といった観点からシミュレーションを用いて評価を行う。また実車試験により本課題で提案したデッドロック回避策の有効性を検証する。

2018年度は、本研究課題の遂行に必要となる2台の試験車両の構築を進めるとともに、意思決定技術および軌道計画技術の方式調査・検討を行う。

② 人工知能(AI)を活用したデッドロック回避

2018 年度は実施なし

f. 「実証実験」

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

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

2018 年度は、2 台の試験車両の構築に向け、自動運転 ECU の制作、各種センサの搭載を進める。

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、来年度の公道走行試験に使用するカメラを選定するための事前評価実験を実施した。具体的には異なる解像度のカメラや HDR (High Dynamic Range) 機能及び LFM (LED Flicker Mitigation) 機能を有するカメラなど複数種類のカメラを用意し、視認性が低下すると考えられる悪条件下における信号機画像を撮影し、目標認識距離に対する対象物の画像を評価した。ここで想定する悪条件とは、夜間・逆光(昼間、西日)・霧・雨を対象としており、信号機の明るさが十分に確保できない状況や太陽光の影響によって画像が白飛びする場合が起こりうる状況を扱うこととした。

本評価実験は、日本自動車研究所の特異環境試験場で実施しており、昼・夜・逆光・霧・雨の各条件においてランプ式信号機、LED 式信号機及び矢印信号機の画像計測を行った。この評価結果より、通常の夜間の走行シーンにおける信号認識では HDR 機能は必須ではないものの、視程 80m 程度の霧の場合では HDR 機能を有するカメラを使用することで 90m 以上先の信号灯火を視認可能となることが確認できた。

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として、PSPNet をベースとした手法を用いて一般道走行データを評価した。評価データには、経産省主催の AI エッジコンテストのデータを利用した。その結果、IoU は 0.252 程度であった。なお、IoU は、正解領域と認識領域の重なり度合いを示す評価指標である。遠方の信号機の場合、正解領域からわずかにずれた場合でも精度が低くなるため、IoU の数値は低い値となっている。目視で認識結果を確認したところ、50m 程度遠方の走行レーン上にある信号機は概ね認識できている。また、昼夜問わず認識できていることを確認した。今後は認識精度の向上、信号の色の識別処理を統合する。

b. 「遠距離の物体を検知するために必要となる AI 技術の開発」

①. 遠距離向け車載カメラの選定・検知アルゴリズム開発

遠距離での物体検知アルゴリズム開発に向けて、複数のカメラでのデータ収集を行った。カメラとして、1) 解像度 4096×3000, 画角 H-47.6[deg], V-36.7[deg], 2) 解像度 4096×3000, 画角-31.5[deg], V-23.9[deg], 3) 解像度 1920×1080, H-51[deg], V-30[deg] の 3 種類を比較した。1) および 2) は 4K クラスの高解像度、3) は HDR の高画質カメラである。各画像に対して、歩行者、自転車、自動車、信号機のアノテーションを行った。物体検出手法として、高速な手法(FaceBoxes, DCFPN), 高精度な手法(Faster RCNN, YOLO V3)を比較した。精度としては YOLO V3 が最も高い精度であった。カメラとしては、1) または 2) の 4K クラスのカメラの場合、mAP が 0.78 程度であった。歩行者の AP はカメラ 2) の場合に 0.93 であり、100m 遠方の歩行者も検出できた。今後は、精度向上に向けてアルゴリズムの改良および詳細な評価を行う。

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、最新型の LiDAR として Velodyne 社の VLS-128 を対象として認識対象物(自動車、歩行者、二輪車)の観測距離の評価を実施した。本評価実験は、日本自動車研究所の特異環境試験場で実施しており、通常時・雨天時などの条件時において最大 200m 先に設置した認識対象のセンサデータを計測し、この計測データから目標とする認識距離に対する LiDAR の貢献度の見通しを評価した。

評価基準は、認識対象物の観測点数が 10 点以上となる物体距離を検出可能距離、点群から物体種別を目視で判断可能な距離を識別可能距離として設定した。評価結果としては、通常時や雨天時であれば自動車の識別可能距離は約 90m、歩行者・二輪車は約 70m であることを確認した。また、検出可能距離はさらに 20~30m ほど遠方となるが、これだけでは物体種別の確認が困難であることから、他のセンサで得られる情報とのフュージョンによって

認識距離の改善が必要となる。

c. 「高精度自己位置技術の開発」

①. GNSS/INS の開発

GNSS/INS の開発では、2018 年度には東京都の都市部におけるデータ収集を実施し、従来手法の精度把握を行った。なお、データ収集では安価な機器として、GNSS には ublox F9, INS として多摩川精機製の MEMS IMU, 及び車両 CAN から取得できる車輪速を利用した。その結果、2017 年度までに名城大学が開発した手法ではお台場にて 1.5m 精度が 93%, 新宿では 73% で達成していることを確認した。同時に、30cm 精度を達成するために開発している RealTime Kinematic 法の初期条件を最適化する手法の評価も実施し、お台場では 30cm@78%, 1.5m@90%, 新宿では 30cm@58%, 1.5m@91% の範囲で達成できることを確認した。以上の確認より、本プロジェクトで目標としている 1.5m, 30cm の精度を達成可能な見込みを得ることができた。今後は、30cm の信頼度を検証すると共に、開発しているアルゴリズムの高精度化、ロバスト化を実施する。併せて、リアルタイム化を実施することで、自動運転に適用可能な GNSS/INS とする予定である。

②. マップマッチング技術の開発

平成 30 年度は複数方式のマップマッチングアルゴリズムの検討を目的として、論文ベースでの調査を行い、その結果として次の 3 つの手法を次年度に開発・検討を行う候補に選出した。①3 次元点群を用いた NDT スキャンマッチング ②2 次元の路面パターン画像を用いたテンプレートマッチング ③デジタル地図の区画線等の情報を用いた線分マッチング。候補の選出基準として、自動運転自動車における自己位置推定はリアルタイムに処理可能であることが非常に重要であり、計算コストの小さいマップマッチングアルゴリズムが適切である。また、それに加えて 2020 年度の最終的な目標である精度 0.1m の達成および道路整備・メンテナンスすべきインフラ項目の要件の提言を見据えた上で、マップマッチングに使用する道路の特徴や、現状で達成されている精度などを考慮しての選定を行った。また、次年度の手法の比較検討に向けての準備として、金沢市内での地図データ収集のための打ち合わせを地図会社と行っている最中である。

d. 「交通参加者の行動予測推定とそれに基づくパスプランニング技術の開発」

①. 人工知能(AI)に基づく歩行者の行動予測

歩行者の行動予測に向けて、データ収集を行う走行エリアと走行条件の抽出を行った。走行エリアを模した環境で撮影できる画角を確認し、関連する歩行者の行動予測アルゴリズムの調査を行った。歩行者間のインタラクションを考慮した経路予測手法(Social LSTM, Social GAN)や周辺環境を考慮した手法(DESIRe)などが提案されている。これまで提案した周辺環境と属性を考慮した経路予測手法とこれらの調査結果を組み合わせでより高精度な行動予測手法を検討する。

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

平成 30 年度は、アルゴリズム開発に必要となる複数個所の走行エリア、走行条件をピックアップし、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基礎設計を行った。その結果、石川県金沢市内における走行において、金沢大学において所有する既存の LiDAR, RADAR を用いて移動物体の位置・姿勢や速度・加速度等の運動状態に加え、物体の大きさを同時に推定可能なアルゴリズムを構築した。今後は、最新型の高分解能 LiDAR に対応可能とするため、処理速度の高速化等の検討を引き続き進めていく予定である。

e. 「複数自律型自動車が走行する状態での問題点の検討」

①. ロボティクス技術を活用したデッドロック回避

平成 30 年度は、本研究課題の遂行に必要となる 2 台の試験車両の構築準備を進めるとともに、意思決定技術および軌道計画技術の方式調査・検討を実施した。具体的には、2007

年に DARPA(国防高等研究計画局)による主催で開催された Urban Challenge(自律型無人自動運転自動車の走行協議会)に出場者らが開発したデッドロック回避技術を中心として、方式調査を行った。その結果、デッドロック時の回避行動に複数の目標候補を定め適応的にこれらを切り替えて回避行動をとる手法などが提案されていることが分かった。今後は、起こりうるデッドロック事象についての調査を進め、デッドロック回避手法の構築・高度化を進める予定である。

f. 「実証実験」

平成 30 年度は、平成 31 年度以降に実施予定の東京臨海部や石川県金沢市内での走行実証実験に向けて、試験車両の仕様検討および搭載するセンサの仕様検討を進めた。

その結果、改造の容易さや搭載人員の多さから LEXUS RX450hL をベースに試験車両の構築を進め、これに LiDAR, GNSS/INS, ミリ波レーダ, カメラ等のセンサを搭載することとした。現在これらのセンサの搭載やベース試験車両の改造に向けて、関連会社と調整中であり、次年度以降に実施する実証実験の実施に向け、引き続き調整を進める予定である。

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

・ デジタル地図を活用した信号認識アルゴリズムの基礎検討

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と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。前述の通り、信号機形状や信号灯色など既知の情報をを用いて信号機状態を認識する試みはこれまでも行われてきた。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る可能性がある。例えば図 2.1.①-1 (b) に示すように、夜間においては形状情報が欠如するという課題もある。




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

そこで、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開発されている。単眼カメラと車両姿勢情報、および地図情報を活用することで画像上における各信号機の位置を算出可能である。検出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

これに基づき、各信号機について画像上での ROI が定義される。しかし図 2.1.①-1(c) に示すように、ROI 内に複数の信号機が観測される場合がある。この場合、通常の画像処理アルゴリズムのみで認識する手法では、すべての信号機を認識可能であるものの、その ROI と対応付けられた信号機のみを正しく認識することが難しい。そこで我々はこれまでに、ROI 内の信号機位置を表す存在確率を定義し、他の点灯物の誤検出を低減する方法を提案してその性能を示した[5]。これにより ROI 内に写る複数の信号機のうち、ROI に対応した信号機を効果的に抽出し、信号機状態を認識できるようになっている。図 2.1.①-2 に信号認識アルゴリズムのフローチャートを示す。まず絶対座標系上において、地図情報から得られた信号機位置に対する、自車の車両座標系の位置 $x_v = [x_v, y_v, z_v]$ を取得する。自車から

$d_v(=\sqrt{x_v^2 + y_v^2})$ [m] 以内に存在する信号機について、自車の信号機に対する位置情報（距離および姿勢）、および車両座標系上のカメラの位置情報から、車両に搭載したカメラで撮影した前方画像上での信号機位置を推定し、ROI を設定する．この ROI は撮影画像上で信号機が存在する位置を示す．




図 2.1.①-2 信号認識アルゴリズム

一般的に信号灯火は、周囲より明るい色をもつこと、すなわち高い彩度と明度を持つ特徴があるため、HSV 画像がもつ彩度(S)画像と明度(V)画像の積をとって得られる特徴画像を用いて信号機領域の強調を強調する．加えて画像全体の明るさを考慮するため、SV 画像のコントラストを正規化した画像(点灯部強調画像)を作成する．しかし、これで得られる特徴画像では、空や建物などの周囲の背景と比較して点灯中の信号機が暗い場合、単純な SV 画像に基づくコントラスト正規化では信号機領域の強調が充分ではない場合がある．そこで、明度(V)画像や彩度(S)に統計学的補正を行うことで、信号灯火部をより強調した特徴画像を生成する（図 2.1.①-3）．まず、特徴画像生成時における平均明度を一定レベルに補正するため、ROI 内の各画素の V 値を、以下の式に基づいて更新する．

$$V_m(u, v) = k_v \bar{V} + (V(u, v) - \bar{V})\sigma_v/\sigma \quad (1.2.1)$$

ここで $V(u, v)$ と $V_m(u, v)$ はそれぞれ ROI 内の画素座標 (u, v) における補正前と補正後の明度値、 $\bar{V}$ は元の ROI 画像の平均明度、 σ と σ_v はそれぞれ補正前と補正後の画像の明度の標準偏差、 k_v は補正後の画像の平均明度調整用の任意定数である．また、信号の灯火部は通常、一定値以上の彩度をもつ．一方で上空の白雲などは、色相値に関わらず彩度が低くなる．このような背景と信号機の違いを明確にするため、以下の式を用いて低彩度画素をさらに低減させる．

$$S_m(u, v) = S(u, v) \cdot 1/\exp(-a_s(S(u, v) - b_s)) \quad (1.2.2)$$

ここで $S(u, v)$ と $S_m(u, v)$ はそれぞれ ROI 内の画素座標 (u, v) における補正前と補正後の彩度値、 a_s はシグモイド関数のゲイン、 b_s は彩度補正の中心値を指定する定数である。以上より補正後の S 画像と V 画像である S_m 画像と V_m 画像が得られる。これらの操作によって得られる特徴画像の例を図 2.1.①-3 (左下) に示す。また、標識など他の類似する円形物の誤検出を防ぐため、色相値に応じて S_mV_m 画像の画素値を重み付けする。色相に応じた重み値の分布の例を図 2.1.①-4 に示す。元の ROI 画像において信号燈の点灯時の色相に近い色相領域に高い重みづけを行うことで、図 2.1.①-3 (右上) に示す重み画像が得られる。この重み画像と S_mV_m 画像の積により、図 2.1.①-3 (右下) に示す強調画像が得られる。効果的に信号燈部のみを強調できていることがわかる。信号燈は発光しているため、その色相値は他の光源の影響を比較的受けにくい。したがってホワイトバランスの調整等により、異なるカメラでも類似した色相の重み分布を定義可能である。




図2.1.①-3 パターン認識による信号燈火の認識例




図2.1.①-4 色相による重み付け分布の例

強調画像から、信号灯領域を検出する。信号灯領域は円形であることに着目し、SURFアルゴリズムを用いて画像上の円形領域を候補として抽出する。この円形領域の半径 r_l を指標とし、想定される信号灯の画像上のサイズと大きく異なる候補候補はノイズとして除去する。具体的には以下の式に示す条件を満たすサイズの候補領域を抽出する。

$$k_{min}f_x s_l / (2z_s) \leq r_l \leq k_{Max}f_x s_l / (2z_s) \quad (1.2.3)$$

ここで s_l は信号灯の直径[m]、 f_x はカメラの焦点距離、 z_s は信号灯の高さ[m]である。また、 k_{min} および k_{Max} はそれぞれ、候補領域の許容半径の最小値と最大値を定義するための係数である。以上の手順で抽出された各候補領域において、平均色相値を表 2.1.①-1 に示す色相範囲と照合し、その色を判断する。

表 2.1.①-1 信号灯火色の Hue 値範囲例

Signal state	Hue range
Green	153-206
Yellow	35-60
Red	0-34, 350-360

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、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。矢印信号の認識処理は、信号機の認識結果が赤または黄であると判断された場合、図 2.1.①-5 に示すように矢印信号認識用の ROI を検出した信号灯領域の下部に設定する。ROI は信号機の設置方向に従って設定する。矢印信号は事前に機械学習アルゴリズムによって訓練された右矢印検出器によって認識される。直進方向および左方向の矢印に対しては矢印信号認識 ROI を 90° ずつ回転していき、各回転状態で右矢印検出器を適用する。これにより、単一の検出器のみで矢印信号の方向を検出する。なお、矢印信号認識用 ROI についても前述した強調画像を作成して使用する。これにより背景ノイズの誤検出を抑制する。




図 2.1.①-5 横型信号機に対する矢印 ROI の設定例


・ 信号認識アルゴリズムの事前評価

事前検討している認識アルゴリズムに対して、一般道で得られるデータを持ちた性能評価を実施する。走行データは石川県金沢市及び珠洲市内にて計測したデータを使用しており、データの総数は信号灯が 19,988 件、矢印灯が 943 件である。各データの内訳は以下の通りである。また、実験に使用するカメラは FILR 社の Flea2 FL2-14S3C-C としており、画角


は 40x30[deg], 解像度が 1280x960[px]の画像を計測している. 走行環境の主な画像を図 2.1. ①-6 に示す.

表 2.1.①-2 事前評価に用いたデータ数

Label	Number of Data
Green	14,415
Yellow	849
Red	4,724
Left	105
Straight	160
Right	678



(a) 石川県珠洲市における走行画像例



(b) 石川県金沢市における走行画像例

図 2.1.①-6 事前評価データの代表的な様子（白枠が認識対象信号機）

こちらのデータに対して事前検討アルゴリズムを適用して信号機からの距離に対する認識率を評価した。図 2.1.①-7 に評価結果として信号機との距離ごとの認識率(F 値)を示す。信号機認識に関しては、全体的に 80[%]以上の認識率が得られていることが確認できる。また、自車から 80[m]の範囲では 95~97[%]の認識率が得られており、130[m]を超えると 90[%]を下回る傾向が確認できた。信号機全データの認識率は 94.6[%]である。一方、矢印灯の認識では 70[m]を超えるあたりから極端に認識率が低下している結果が得られた。これは、遠方の矢印灯の画像サイズが 10x10[px]を下回る事によって、矢印の向きを適切に認識できていないことが原因である。矢印灯に対する全データの認識率は 57.3[%]である。図 2.1.①-8 のように比較的近距离の矢印灯は目視で向きを認識しやすいものの、遠方の場合で矢印灯の向きが不鮮明または青信号と間違えやすいなどの原因で認識率の低下が確認されている。こ

うした小さな対象物に対しては、解像度の更新だけでなく、小さな点灯物に対する認識アルゴリズムの改善、同時に点灯する信号灯との位置関係などから点灯方向を判断、などの認識方法の導入が必要となる。




図 2.1.①-7 事前評価の認識結果



図 2.1.①-8 遠方の矢印灯の画像例（左信号機：109[m]先，右信号機：76[m]先）

- ・ 視認性が低下する状況下における信号機画像の評価

事前検討している認識アルゴリズムに対して、視認性が低下する状況下での認識性能を評価する。評価用データは日本自動車研究所の特異環境試験場を使用しており、ランプ式、LED 式信号機を対象として各天候条件における信号機画像を撮影した。試験場に設置した信号機の様子を図 2.1.①-9 に示す。LED 式信号機には矢印灯が設置されており、本実験では青、黄、赤、赤+右、赤+左、赤+右・直進の 6 パターンの点灯状態における各距離からの画像を計測した。試験環境の都合上、天候条件に応じて車両の走行可能エリアが制限されるため、信号機との最大距離が異なる。各天候条件における信号機との最大距離を表 2.1.①-3 に、データ数を表 2.1.①-4 及び表 2.1.①-5 に示す。各条件では計測車両が低速で前後に走行しながら画像計測を行っているため、走行時の速度の都合によりデータ数にばらつきがある。なお、LED 式信号機が矢印灯を点灯中におけるランプ式信号機は赤信号を点灯させていたため、赤信号のデータ数が他の点灯色の約 2 倍となっている。

実験に使用するカメラは事前評価に使用した FILR 社の Flea2 に加えて、HDR 機能及び LED フリッカ抑制機能を有する車載カメラを使用して認識性能を評価する。HDR カメラの画角は 50x30[deg]、解像度が 1920x1080[px]となっており、縦方向の画角・解像度は事前評価のカメラと同程度である。遠方の矢印信号機の認識性能に関しては事前評価と同程度の認識率が予想されるが、天候条件の変化に対する影響を評価する。



図 2.1.①-9 特異環境試験場における信号機画像

表 2.1.①-3 評価条件

天候条件	信号機との最大距離
通常 (1,600[lx])	ランプ式 : 80[m], LED 式 : 120[m]
逆光 (昼白 (最大 65,000[lx]), 夕日 (最大 25,000[lx]))	ランプ式 : 80[m], LED 式 : 120[m]
雨 (降雨量 30[mm/h], 激しい雨)	ランプ式 : 80[m], LED 式 : 120[m]
霧 (視程 80[m])	ランプ式 : 60[m], LED 式 : 100[m]

評価実験では、2 種類のカメラに対して以下の項目に関して認識性能を比較する。

- ・ 全データでの認識性能 (1 パターン)
- ・ 矢印灯の点灯状態による評価 (青・黄・赤信号, 赤信号+単一矢印, 赤信号+複数矢印の 3 パターン)
- ・ 天候条件の違いによる評価 (通常, 逆光, 雨, 霧の 4 パターン)

表 2.1.①-4 評価データ数 (非 HDR)

	青信号	黄信号	赤信号	赤+右	赤+左	赤+右・直進
通常	733	656	1,692	510	558	492
逆光	481	507	1,052	312	342	308
雨	920	1,016	2,159	602	560	591
霧	817	591	1,134	390	390	427


表 2.1.①-5 評価データ数 (HDR)

	青信号	黄信号	赤信号	赤+右	赤+左	赤+右・直進
通常	897	713	1,865	530	604	526
逆光	702	523	1,162	345	366	450
雨	1,253	1,341	2,985	851	699	817
霧	882	771	1,629	511	618	622


評価結果として上記の8パターンの評価条件における認識率(F値)を表 2.1.①-6 に示す。全体のデータに対する認識率を比較すると HDR カメラの利用により信号灯の認識率が約 4[%]改善していることが確認できる。認識率が改善した理由としては逆光時の条件下での信号灯の認識率が約 14[%], 矢印灯の認識率が約 28[%]改善したことが理由として挙げられる。逆光時の条件下では図 2.1.①-10 のように視認性が向上し、誤検出・未検出の改善に効果があると言える。また、その他の条件で視認性の改善が確認できたものは霧の条件である。図 2.1.①-11 のように非 HDR カメラでは 100[m]先の信号機(図中右側の信号機)を画像中で確認できないが、HDR カメラを使用することで信号機の確認ができる。一方でこのときの認識率を比較すると矢印灯の認識率低下が確認された。これは矢印灯の向きの誤認識による認識率低下である。したがって、視認の改善に加えて、前述の通り事前情報の活用や遠方矢印灯に特化したアルゴリズムを導入による認識率改善が必要である。

表 2.1.①-6 評価結果

	非 HDR カメラ		HDR カメラ	
	信号灯認識率	矢印灯認識率	信号灯認識率	矢印灯認識率
全データ	0.882	0.687	0.928	0.649
青・黄・赤信号	0.871	---	0.951	---
赤信号+単一矢印	0.896	0.691	0.868	0.668
赤信号+複数矢印	0.920	0.680	0.892	0.614
通常天候	0.982	0.726	0.999	0.675
逆光	0.796	0.405	0.936	0.689
雨	0.927	0.875	0.950	0.668
霧	0.789	0.675	0.790	0.535




非 HDR カメラ



HDR カメラ

図 2.1.①-10 逆光条件下での視認性の改善例



非 HDR カメラ



HDR カメラ

図 2.1.①-11 霧の条件下での視認性の改善例

次に、信号機との距離に基づいた認識率を図 2.1.①-12～図 2.1.①-14 に示す。全体の認識率は事前評価と同様の傾向を示している。ただし、HDR 化によって信号灯の認識率が全体的に向上している傾向が確認できる。例えば、図 2.1.①-12 を比べると、非 HDR カメラでは 60[m]より遠方では信号等の認識率が 90[%]を下回っているのに対して、HDR カメラのデータでは 80[m]の距離までは 93～98[%]の認識率が得られ、さらに遠方では 80[%]台の認識率を示している。今回の条件では降雨量 30[mm/h]の激しい雨や視程 80[m]の霧など実際の道路環境ではレアケースとなるような天候条件での評価となったため、前述の事前評価で示した認識結果と比べて全体的な認識率が低い傾向が確認されている。こうした状況における認識限界を見極めていくことが今後の課題としてあげられる。

その他、特筆すべき点として、通常天候時における信号認識率では、非 HDR カメラでは 96[%]以上、HDR カメラでは 99[%]以上の認識率が達成されている。したがって、基礎検討しているアルゴリズムは、信号灯の認識に関しては目標精度の達成が期待可能な手法であると言える。逆光、雨の条件下における認識精度及び矢印灯の認識精度の改善が次年度の技術的課題である。







図 2.1.①-12 全評価データに対する認識性能




(a) 非 HDR カメラ (矢印なし)




(b) HDR カメラ (矢印なし)




(c) 非 HDR カメラ (単一矢印)



(d) HDR カメラ (単一矢印)




(e) 非 HDR カメラ (複数矢印)




(f) HDR カメラ (複数矢印)


図 2.1.①-13 矢印の点灯状態の違いによる認識性能




(a) 非 HDR カメラ (通常)




(b) HDR カメラ (通常)




(c) 非 HDR カメラ (逆光)




(d) HDR カメラ (逆光)




(e) 非 HDR カメラ (雨)



(f) HDR カメラ (雨)



(g) 非 HDR カメラ (霧)



(h) HDR カメラ (霧)

図 2.1.①-14 天候条件の違いによる認識性能

・ まとめ

HDR カメラの利用によって、逆光や霧の条件下での視認性改善に加えて信号灯の認識率改善が確認された。信号灯認識率は、一般道の走行データに対して 94.8[%], 特異環境試験場のデータで 92.8[%]を示した。一方、矢印灯に関してはピクセル数が小さくなる遠方の認識率改善が大きな課題として挙げられる。次年度において遠方に特化した矢印灯の認識アルゴリズムの開発の必要性が確認された。

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] Z. Chen and X. Huang, “Accurate and Reliable Detection of Traffic Lights Using Multiclass Learning and Multiobject Tracking”, IEEE Intelligent Transportation Systems Magazine, Vol.8, No.4, pp.28-42, 2016.
- [4] 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.
- [5] 米陀佳祐, 菅沼直樹, M. Aldibaja, “複数の点灯物による誤検出を考慮した信号機認識”, 自動車技術会論文集, Vol.48, No.2, pp.575-580, 2017.
- [6] K. Yoneda, A. Kuramoto, J. Kameyama and N. Suganuma, “Traffic Light and Arrow Detection using Digital Map and Luminance Enhancing”, Proceedings of The 1st International Conference on Digital Practice for Science, Technology, Education, and Management (ICDP), March, 2018.
- [7] A. Kuramoto, J Kameyama, R. Yanase, M. Aldibaja, K. Yoneda and N. Suganuma, “Digital Map based Signal State Recognition of Far Traffic Lights with Low Brightness”, Proceedings of The 44rd Annual Conference of the IEEE Industrial Electronics Society (IECON2018), October, 2018.

② セマンティックセグメンテーションによる信号認識アルゴリズムの開発

信号機や信号灯の一部が隠れていたり風景に溶け込んでいたりする場合や、古いランプ式信号機のような点灯部の輝度が十分ではない場合、従来の矩形や円形特徴を認識する手法だけで正確に信号機の位置と色を認識することが困難である。このような課題に対応するため、ディープラーニングを活用したセマンティックセグメンテーションにより信号機の位置を画素単位で抽出する。これにより、局所的な形状の情報だけでなく、画像全体の構図を考慮することができ、また信号機が小さくかつ部分的にしか見えていない場合でも信号機であることを検知可能となる。2018 年度は、従来のセマンティックセグメンテーションによる信号機領域の評価を行う。

・ 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。信号機の認識に適したセマンティックセグメンテーション手法を検討するために、ここでは、以下の手法を比較した。

PSPNet [1]

DeepLabV3+ [2]

Mnet [3]

PSPNet[1]は、図 2.1.②-1に示すようなネットワーク構造をしており、エンコーダとデコーダおよびその間に配置される Pyramid Pooling Module から構成される。Pyramid Pooling Module は、エンコーダで得た特徴マップをサイズの異なるプーリング処理により複数の特徴マップを求める。各特徴マップは、プーリングサイズが異なるため、異なる解像度の特徴マップとなる。これらに対してそれぞれ個別に畳み込み処理を行い、新たな特徴マップを得る。そして、それらを一定のサイズになるようにアップサンプリングし、エンコーダで得た特徴マップと連結し、デコーダに与える。様々な解像度の特徴マップを求めることで、画像全体の特徴や人などの小さな物体の特徴などを捉えることができる。




図 2.1.②-1 PSPNet の構造




図 2.1.②-2 DeepLabV3+の構造

DeepLabV3+ [2] は、図 2.1.②-2 のようにエンコーダ・デコーダのネットワーク構造をしており、エンコーダ側には、Atrous Convolution を採用している。Atrous Convolution は、畳み込み処理を行うカーネルが疎な構造をしており、畳み込む要素を一定間隔であけて畳み込み処理を行う。これにより、計算量を増やさずに receptive field を広げることができ、より広い範囲の特徴を捉えて判断することができる。




図 2.1.②-3 MNet の構造

MNet [3] は、図 2.1.②-3 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、エンコーダ側の特徴マップが直接デコーダ側に連結している。これにより物体の詳細なエッジ情報などの特徴が伝播される。また、エンコーダ側は ResNet のようなショートカット接続を採用しており、深いネットワーク構造でも学習できるような工夫を施している。

・ 評価データセット

アルゴリズムの比較には、AI エッジコンテスト[4]のセグメンテーション部門のデータセットを用いた¹。このデータセットには、朝昼夜の時間帯で撮影された学習用画像約 2,300 枚とそれらの画像をピクセル単位で 20 のクラスに分類した真値カラー画像及び撮影された時間帯を示す json ファイルが含まれる。また、学習用画像とは異なる約 700 枚の車両前方カメラ画像(コンテスト提出用のテスト画像)が含まれる。テスト画像に対する真値カラー画像は公開されていないため、学習用画像のうち、約400枚を検証用画像とした。

AI エッジコンテストでは、自動車、車道、歩行者、信号機を主な検出対象としており、本アルゴリズムの検討においても、この4クラスを対象として評価を行った。

・ アルゴリズムの比較

各アルゴリズムのセマンティックセグメンテーションの精度を比較する。比較には、AI エッジコンテストの画像を用いる。表 2.1.②-1に各アルゴリズムの IoU を示す。これより、平均精度では、PSPNet が最も高い精度となっている。また、信号機(Signal)も同様に PSPNet が最も高い精度である。

表 2.1.②-1 各アルゴリズムの評価結果(IoU)


	PSPNet (Dilated ResNet50)		DeepLabV3+ (ResNet101)		MNet	
	検証 データ	学習 データ	検証 データ	学習 データ	検証 データ	学習 データ
平均精度	0.638	0.744	0.573	0.587	0.394	0.459
Car	0.675	0.807	0.611	0.638	0.452	0.553
Lane	0.918	0.967	0.842	0.85	0.552	0.565
Pedestrian	0.328	0.445	0.3	0.301	0.27	0.347
Signal	0.212	0.257	0.166	0.164	0.176	0.23

図 2.1.②-4に PSPNet による評価結果例を示す。図 2.1.②-4(a)の入力画像に対して、図 2.1.②-4(b)のような結果を得た。図 2.1.②-4(c)の正解画像と比較すると、大まかには正しくセマンティックセグメンテーションできているものの、中距離にある2つの信号機のうち、1つは正しく抽出できていない。また、遠方の信号機は小さいため、抽出できていない。これより、入力画像を大きくする、小さな信号機に対応するためのアルゴリズムの検討などが必要であることがわかる。

¹ AI エッジコンテストのデータセットはコンペティション利用に限定されているため、本検討はコンペティションへ参加する前提で行った。



(a) 入力画像



(b) セマンティックセグメンテーション結果



(c) 正解画像

図 2.1.②-4 PSPNet による結果例

次に, PSPNet について, 時刻によるセマンティックセグメンテーション結果に差が生じるかを検証した. 検証結果を表 2.1.②-2 に示す. これより, 夜間(Night)は若干 IoU が低下している.

表 2.1.②-2 時刻による評価結果(IoU)

	PSPNet (Dilated ResNet 50)	
	検証 データ	学習 データ
Morning	0.679	0.800
Day	0.656	0.764
Night	0.606	0.776

・ まとめ

2018年度は, 従来のセマンティックセグメンテーション手法を用いた場合の信号機認識精度を評価した. PSPNet を用いた場合, 比較的近距離または中距離の信号機はある程度抽出できるものの, 遠方の信号機は抽出できていない. これは, 入力画像サイズを大きくすると抽出できるようになると考える. 一方で, 精度向上にはアルゴリズムの検討も必要である.

【参考文献】

- [1] H. Zhao, et al., “Pyramid Scene Parsing Network.”, CVPR, 2017.
- [2] L.C. Chen, et al., “Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation.”, ArXiv, 2018.
- [3] T. Yamashita, et al., “Multiple Skip Connections of Dilated Convolutions Network for Semantic Segmentation.”, ICIP, 2018.
- [4] <https://lp.signate.jp/ai-edge-contest/ja/>

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

一般的な車載カメラは視野角 100 度程度であり、画像サイズが 1024x786 の場合、50m 遠距離に存在する歩行者の高さは 37 ピクセル、70m 遠距離に存在する歩行者の高さは 27 ピクセル程度と小さい。そこで、2018 年度は遠距離の物体検知に適した視野角および高画質化機能を有するカメラを評価し、目標達成に必要なカメラの仕様を検討する。

カメラの仕様は以下の通りである。

- 1) FLIR GS3-U3-123S6C-C + 興和光学 LM16FC
 - 解像度: 4096x3000
 - 画角: H=47.6[deg], V=36.7[deg] (レンズ仕様表より)
 - シャッタースピード: 制限なし
 - その他: バイヤーパターン画像として保存 (バイヤーパターン: GBRG)
- 2) FLIR GS3-U3-123S6C-C + 興和光学 LM25FC
 - 解像度: 4096x3000
 - 画角: H=31.5[deg], V=23.9[deg] (レンズ仕様表より)
 - シャッタースピード: 制限なし
 - その他: バイヤーパターン画像として保存 (バイヤーパターン: GBRG)
- 3) HDR+LFM カメラ (試作品)
 - 解像度: 1920x1080
 - 画角: H=51[deg], V=30[deg] (キャリブレーション値より算出)

1) および 2) は 4K クラスの解像度で撮影できるカメラである。3) は HD クラスの解像度であるが HDR 機能を有する高画質な映像を撮影できるカメラである。

・ 物体検知アルゴリズム

これらのカメラで撮影した映像に対する物体検知の精度を比較するために、計算コストの低い FaceBoxes[14] と DCFPN[15]、物体検出の高精度な手法である Faster R-CNN[9]、YOLOv3[8] を物体検知アルゴリズムとして用いる。これらのアルゴリズムについて以下で説明する。

FaceBoxes[14]

CPU で高精度かつリアルタイムで物体を検知する手法である。Faster R-CNN[9] で提案されている Region Proposal Network (RPN) をもとにしている。ネットワーク構造を図 2.2. ①-1 に示す。FaceBoxes は、Rapidly Digested Convolutional Layers (RDCL) でストライドの大きな畳み込み処理を行い、特徴マップのサイズを一気に小さくする。活性化関数には図 2.2. ①-2(a) に示す C. ReLU[10] を使用する。




図2.2. ①-1: FaceBoxesのネットワーク構造




図2.2.①- 2: (a): C.ReLUの構造, (b): Inception module

図2.2.①- 1のMultiple Scale Convolutional Layers (MSCL)では、複数の層で物体を検出する。Single-Shot Multi box Detector(SSD) [5] のように、各層のサイズを変えることでマルチスケールな検出が可能となる。各 Inception では、図2.2.①-2(b)に示すような Inception modules[11] を用いて特徴量マップを抽出する Inception modules によって様々な大きさの特徴を捉えることができる。




図2.2.①- 3: Examples of anchor densification. 黒い点は receptive field の中心であり、対角のアンカーのみを色付きの四角形で描いている。

FaceBoxes では, Anchor densification strategy と呼ぶ方法により, 小さいスケールのアンカーを増やしている. 従来の RPN では図 2.2. ①-3 の左上のように アンカーは receptive field と同じ位置のみに置かれる. Anchor densification strategy では 図 2.2. ①-3 のように, receptive field の中心の周りに g^2 個のアンカーを置くことでアンカーの密度を増やしている.

また, 学習の工夫として, Hard negative mining. [5, 12]によってポジティブ・ネガティブサンプルの不均衡に対処している. アンカーを loss の値が高い順にソートし, ネガティブとポジティブの数が 3 : 1 の比となるように学習サンプルを選別する. 顔検出のデータセット Fddb において, 検出精度 $mAP = 96.0$, 処理速度は 20FPS@Xeon E5-2660v3@2.6GHz となっている.

DCFPN[15]

2.60GHz の CPU で 30FPS, GPU で 250FPS と高速な物体検知手法である. 顔検出のデータセット WIDER FACE Test:Easy, Test:Medium, Test:Hard で, 検出精度 mAP はそれぞれ, 0.879, 0.853, 0.771 となっている.




図2.2. ①- 4: DCFPNのネットワーク構造

DCFPN は 図 2.2. ①- 4 に示す通り, 大きく2つの部分から構成される. それぞれ Rapidly Digested Convolutional Layers(RDCL) 、 Densely Connected Convolutional Layers(DCCL) と呼ぶ. RDCLはFaceBoxes[14] のように特徴マップのサイズを一気に小さくする. DCCLは, 2 つの micro inception layers で 特徴マップを抽出する. DCCL[3] によって様々な大きさの特徴を捉える. 最後の畳み込み層は 75 ピクセルから 235 ピクセルの広い範囲の receptive field を持つ. DCFPN は, SSD 等とは違って 1 つの特徴マップだけで出力するが, その層は DCCL や micro inception の構造によって様々な大きさの receptive field を含むので, 異なる大きさの物体を学習できる.

また, FaceBoxes[14] の Anchor densification strategy と同じ考え方の Dense anchor strategy を利用する. これは, receptive field の中心から上下左右に少しずつ離れた位置にもアンカーを置くことによって小さいスケールのアンカーを増やしている. 一般的に, 特に小さい物体は対応するアンカーが少ないことで recall が低くなる問題がある. 小さい物体については大きい物体と異なる処理を行う Scale-aware anchor matching scheme を用いる. 矩形の面積が 400 ピクセルを超える物体は通常通り $IOU \geq 0.5$ のアンカーと対応づけする. 矩形の面積が 400 ピクセル以下の物体は, その矩形の 0.75 倍の範囲に中心が入っている最小(16x16)

のアンカーと対応づけさせる。

学習において、小さい物体の中心と大きさを精度良く推定するために Fair L1 loss を導入している。RPN[9] 等では smooth L1 loss が回帰の学習に使用されていたが、ここでは単純な絶対値を loss に使用する。RPN では矩形の幅と高さをアンカーのサイズで正規化して対数を取った値を回帰で求めているが、ここでは対数を取らない。

Faster R-CNN

物体候補領域を抽出する処理 (Region Proposal Network :RPN) と、その領域が何の物体であるかを認識する処理から構成される高精度な物体検出手法である。物体候補領域を抽出する RPN と、その領域が何かを識別する Fast R-CNN の部分から構成されており、特徴量マップを共有することによって従来法よりも大幅に高速化している。発表当時は PASCAL VOC、MS COCO データセットで 最高精度を達成していた。




図2.2.①- 5: Faster R-CNN

YOLO

物体の領域を入力画像から直接出力する高速かつ高精度な物体検出手法である。入力画像や処理の簡略化などを施し、いくつかのバージョンがある。現時点で最も精度が高いのは YOLOv3 である。YOLOv3 は YOLOv2 に細かい改良をいくつも加えて作られている。YOLOv3 は SSD[5]、SPP[2]、FPN[4] のような構造を取り入れている。

・ 検知対象物体について

市街地での安全な自動運転には、遠距離での人・自動車、信号機などの物体検出が不可欠である。そこで、本検討においては、以下の4種類の物体を検知対象とし、各アルゴリズムの学習および評価を行う

- ・ バイク (bike)
- ・ 自動車 (car)
- ・ 歩行者 (person)
- ・ 信号機 (traffic sign)

- ・ 評価データセットについて

各アルゴリズムは、顔を対象とする手法，一般物体を対象とする手法と対象物体が統一されていない．そこで，各アルゴリズムを上記4つの物体を対象とした場合の検出精度を比較する．比較には，一般に公開されている Cityscapes データセットを用いる．

CityScapes dataset[1]

Cityscapes dataset は，市街地のシーン理解に焦点をあてたデータセットであり，ドイツやその周辺の国 50 都市を撮影した画像とアノテーションである．アノテーションは，図 2.2.①-6 のように，ピクセルごとにラベル付けされている．図 2.2.①-6 のように綺麗にラベルづけされた画像が 5000 枚，そのほかにポリゴンで簡易的にラベルづけされた画像が 20000 枚公開されている．本検討では，Cityscapes dataset のピクセル単位のラベルをもとに，歩行者・車などの対象を包含する矩形を求める．Cityscapes では，重なって見えていても，歩行者は一人一人分離できるようにラベルづけされているため，各歩行者のラベルから矩形を抽出することができる．



図2.2.①- 6: Cityscapesデータセットの画像例

Cityscapes dataset のアノテーションでは，多くの種類のクラスがある．学習や評価に十分なデータ数が無いクラスも多い．ここでは，表 2.2.①-1のように，Cityscape のクラスのなかで上述した4クラスに対応させて用いる．Cityscapes の画像とそのアノテーション例を図 2.2.①-7 に示す．



図 2.2.①- 7: Cityscapes の 例

ここでは、約3000枚の学習用画像を学習に用い、約500 枚の検証用画像を評価に用いる。Cityscapes には粗いアノテーションが付けられた約2万枚の画像もあるが、これを学習に用いると検出性能が落ちたため利用しない。

表 2.2.①-1: Cityscapes のラベルと本検討のラベルの関係

Cityscapes のラベル	使用するラベル
bicycle	bike
motorcycle	
bus	car
car	
caravan	
trailer	
train	
truck	
person	person
rider	
traffic light	traffic light

Chubu dataset

カメラ仕様を検討するために、様々なシーンを想定して撮影したデータを利用してデータセットを構築した。データの撮影は、日本自動車研究所の特異環境試験場にて行った。撮影シーンは昼間、夜間、夕方を想定し、昼間と夜間については晴れ、雨、霧の異なる天候を想定して撮影した。各撮影シーンにおいて、歩行者、自転車、自動車を200m 先に配置し、自車が時速20 km 程度で近づいていくようにした。その際、上述した3種類のカメラにて前方を撮影している。なお、霧の天候は前方の視界が悪いため、各対象物体の配置130m、夕方は160m 先としている。撮影したデータから学習用に800枚、評価用に400枚ランダムに選択し、各物体の位置をアノテーションした。本データセットの画像例を図 2.2.①-9に示す。



(a)



(b)



(c)



(d)

図 2.2.①- 8: Chubu dataset の例

Cityscape データセットにおける各アルゴリズムの評価について

FaceBoxes, DCFPN, Faster R-CNN, YOLOv3 の4つの検出アルゴリズムについて, 上記 Cityscapes データセットを用いて学習・評価を行った. Faster R-CNN は, ChainerCV[6] に実装されているクラスを使用した. YOLOv3 は Darknet[7] に実装されているオリジナルのソースコードを使用した. FaceBoxes, DCFPN はソースコードが公開されていないため, ChainerCV を一部使用して論文をもとに実装した. DCFPN と FaceBoxes, YOLOv3 は, 検出の際に入力する画像サイズを変えることで, 精度と速度のバランスを調整することができる. YOLOv3 に関しては入力画像サイズを 416, 640, 800 の3パターンで評価した. DCFPN に関しては, 入力画像サイズ 512, 768 の2パターンで評価した. YOLOv3, DCFPN の論文では, 標準の入力画像サイズはそれぞれ 416, 512 となっている.

FaceBoxes, DCFPN, Faster R-CNN, YOLOv3 を用いた際の1枚あたりの処理時間を表 2.2.①-3, 各アルゴリズムの検出精度を表 2.2.①-4 および表 2.2.①-5 に示す. 処理時間の計測には Intel(R) Core(TM) i9-7940X CPU @ 3.10GHz の1コアを使用した.

表 2.2.①-2 処理時間

	入力サイズ	処理時間[s]
Faceboxes	1536	0.630
DCFPN	512	0.230
	768	0.532
Faster R-CNN	1000	10.4
YOLOv3	416	6.03
	640	17.6
	800	30.7

表2.2.①-3 Cityscapesデータセットにおける評価結果AP

	入力サイズ	bike	car	person	traffic light
Faceboxes	1536	0.300	0.622	0.143	0.049
DCFPN	768	0.310	0.617	0.311	0.107
Faster R-CNN	1000	0.306	0.495	0.325	0.118
YOLOv3	640	0.303	0.644	0.466	0.277

表 2.2.①-4 より，検出精度に関して，YOLOv3 が他の手法と比べて高い性能となった．DCFPN は YOLOv3 と比べると処理時間は最も高速であるが，person, traffic light の検出精度が YOLOv3 と比べて低い結果となった．

・ Chubu データセットにおける各アルゴリズムの評価について
Cityscapes dataset と Chubu データセットを合わせて学習し，Chubu データセットの評価データを評価した．各アルゴリズムの入力サイズは上記の Cityscapes の評価時と同じである．そのため，各アルゴリズムの処理時間は変わらず，表 2.2.①-3 の通りである．各アルゴリズムの評価用結果を表 2.2.①-5 に示す．Cityscapes での評価と同様に，YOLOv3 が他の手法と比べて高い性能となった．

表2.2.①-4 Chubuデータセットにおける評価結果AP

	入力サイズ	bike	car	person	traffic light
Faceboxes	1536	0.112	0.763	0.161	0.486
DCFPN	768	0.147	0.856	0.442	0.588
Faster R-CNN	1000	0.264	0.737	0.494	0.477
YOLOv3	640	0.495	0.869	0.833	0.752

Faceboxes による Cityscapes および Chubu データセットにおける検出結果の例をそれぞれ図 2.2.①-9, 図 2.2.①-10 に示す．また，DCFPN による Cityscapes および Chubu データセットにおける検出結果の例をそれぞれ図 2.2.①-11, 図 2.2.①-12 に示す．Faster R-CNN による Cityscapes および Chubu データセットにおける検出結果の例をそれぞれ図 2.2.①-13, 図 2.2.①-14 に示す．YOLOv3 による Cityscapes および Chubu データセットにおける検出結果の例をそれぞれ図 2.2.①-15, 図 2.2.①-16 に示す．



図 2.2.①- 9: Faceboxes の Cityscapes での検出結果



図 2.2.①- 10: Faceboxes の Chubu データでの検出結果




図 2.2.①- 11: DCFPN の Cityscapes での検出結果





図 2.2.①- 12: DCFPN の独自データでの検出結果




図 2.2.①- 13: Faster R-CNN の Cityscapes での検出結果




図 2.2.①- 14: Faster R-CNN の独自データでの検出結果






図 2.2.①-15: YOLOv3 の Cityscapes での検出結果




図 2.2.①-16: YOLOv3 の独自データでの検出結果

- ・ カメラ毎の物体検出性能について

Chubu データセットは、3つのカメラで撮影された画像が含まれている。4K クラスの高解像度カメラ1 (0x09_0), 高解像度カメラ2 (0x09_1), HDR 機能付きの HD クラスのカメラ(0x35)に対して、評価画像はそれぞれ83枚, 77枚, 237枚となっている。カメラ毎の精度を表 2.2.①-6に示す。各アルゴリズムに入力する画像サイズは、Faceboxes:1536ピクセル, DCFPN:768ピクセル, YOLOv3:640 ピクセルである。

表 2.2.①-6より, YOLOv3 の場合, 4K クラスの高解像度カメラ1 (0x09_0)または4K クラスの高解像度カメラ2 (0x09_1)を用いることで, bike, car, person のように遠方に存在し, 大きさの小さい物体を検知できている。一方, traffic light は 50m 程度の近距離に存在するため, Faster R-CNN でも高い精度を達成している。DCFPN の場合は, HDR 機能付きの HD クラスのカメラ(0x35)の場合でも 4K クラスと同等の精度を達成している。しかしながら YOLOv3 と比較すると検出精度が低いため, HD クラスでも遠方の物体を検知できるとは言えない。

表2.2.①-5 カメラ毎の評価結果AP

	カメラ	bike	car	person	traffic light
Faceboxes	0x09_0	0.15	0.77	0.23	0.48
	0x09_1	0.14	0.87	0.20	0.49
	0x35	0.09	0.73	0.15	0.50
DCFPN	0x09_0	0.16	0.83	0.35	0.56
	0x09_1	0.13	0.86	0.43	0.58
	0x35	0.16	0.87	0.48	0.61
Faster R-CNN	0x09_0	0.22	0.71	0.37	0.49
	0x09_1	0.19	0.85	0.50	0.50
	0x35	0.30	0.70	0.53	0.47
YOLOv3	0x09_0	0.67	0.89	0.84	0.73
	0x09_1	0.61	0.88	0.93	0.64
	0x35	0.38	0.86	0.80	0.79

- ・ まとめ

2018年度は、遠方の物体を検知するためのカメラ仕様を検討した。高精度な物体検知を行うためには、4K クラスの高解像度カメラが必要である。

【参考文献】

- [1]M.Cordts, et al., “The cityscapes dataset for semantic urban scene understanding.”, CVPR, 2016.
- [2] K. He, et al., “Spatial pyramid pooling in deep convolutional networks for visual recognition.”, IEEE TPAMI, 2015.
- [3] G. Huang, et al., “Densely connected convolutional networks.”, CVPR, 2017.
- [4] T. Lin, et al., “Feature pyramid networks for object detection.”, CVPR, 2017.

- [5] W. Liu, et al., “SSD: Single shot multibox detector.”, ECCV, 2016.
- [6] Y. Niitani, et al., “Chainercv: a library for deep learning in computer vision.”, ACM Multimedia, 2017.
- [7] J. Redmon. “Darknet: Open source neural networks in c.”,
<http://pjreddie.com/darknet/>, 2013-2016.
- [8] J. Redmon et al., “Yolov3: An incremental improvement.”, arXiv, 2018.
- [9] S. Ren, et al., “Faster R-CNN: Towards real-time object detection with region proposal networks.”, NIPS, 2015.
- [10] W. Shang, et al., “Understanding and improving convolutional neural networks via concatenated rectified linear units.”, ICML, 2016
- [11] C. Szegedy, et al., “Going deeper with convolutions.”, CVPR, 2015.
- [12] S. Wan, et al., “Bootstrapping Face Detection with Hard Negative Examples.”, ArXiv, 2016.
- [13] S. Yang, et al., “Wider face: A face detection benchmark.”, CVPR, 2016.
- [14] S. Zhang, et al., “Faceboxes: A cpu real-time face detector with high accuracy.”, IJCB, 2017.
- [15] S. Zhang, et al., “Detecting face with densely connected face proposal network.”, Neurocomputing, 2018.

② LiDAR およびミリ波レーダに基づく遠方物体認識

(1) 評価対象のセンサ仕様

さまざまな道路環境において遠距離物体を検知するためにはカメラ・LiDAR・ミリ波レーダなどの各センサを複合的に利用することによって、頑健な検知性能の達成が期待される。2018年度では最新型のLiDARを対象とした性能評価を行い、遠距離物体認識におけるLiDARの貢献度を見積もる。評価対象とするセンサの仕様を以下に示す。

表 2.2.②-1 評価対象の LiDAR 仕様

センサ型番	Velodyne VLS-128
レーザ数	128 個
レーザクラス	Class 1 Eye Safe
レーザ波長	903[nm]
FOV（水平）	360[deg]
FOV（垂直）	40[deg]（+15[deg]～-25[deg]）
水平角度分解能	約 0.192[deg]（フレームレート 10[Hz]のとき）
測定距離	約 250[m]
フレームレート	5～20[Hz]
重量	約 3.5[kg]
寸法	高さ 138.3[mm]×直径 165.8[mm]



図 2.2.②-1 評価対象の LiDAR（出典：<https://velodynelidar.com/vls-128.html>）

(2) 評価データの計測条件

図 2.2.②-1 および表 2.2.②-1 に示すセンサを使用して遠方の自動車，歩行者，二輪車のデータを計測し，検知可能距離を評価する．データ計測は，日本自動車研究所の特異環境試験場にて実施した．撮影シーンは，通常時，雨，霧の異なる天候を想定する．各条件における対象物の最大距離は以下のとおりである．このときの各条件におけるカメラ画像の様子を図 2.2.②-2 に示す．撮影対象の自動車はシルバ一の車両を計測車両と向かい合うように配置した．また，歩行者及び二輪車はマネキンなどを使用せず，停車する自動車付近に被験者を配置して，自動車付近を移動しながら計測を行った．

表 2.2.②-2 評価条件


天候条件	自動車・歩行者・二輪車との最大距離
通常	200[m]
雨（降雨量 30mm/h）	140[m]
霧（視程 80m）	170[m]



(a) 通常（対象物距離：約 80m）



(b) 雨（対象物距離：約 50m）



(c) 霧（対象物距離：約 30m）

図 2.2.②-2 カメラ画像の様子

計測データの評価には、現時点では特定の認識アルゴリズムは使用していない。今回の評価では目視による確認で検知距離を評価しており、評価基準を以下に示す。

- 検出可能距離：観測点数が 10 点以上となる距離
- 識別可能距離：観測点数が 20 点以上となる距離

検出可能距離は、物体の種類を認識することは難しいが、障害物が存在していることを検知可能な距離として定義する。また、識別可能距離は、物体種別を目視で確認可能な条件として設定した。

(3) 計測データの評価結果

事前に LiDAR の仕様から検出可能距離の見積もりを行う。LiDAR のセンサは各水平方向にレーザを照射して距離を計測している。そのため、遠方になることで水平方向の分解能が疎になるため観測が困難となる場合がある。例えば、表 2.2.②-1 の LiDAR の場合では水平方向の角度分解能が約 $0.192[\text{deg}]$ となるため、 $200[\text{m}]$ 先の水平分解能（レーザ間の水平距離）は $200[\text{m}]\tan(0.192[\text{deg}]) = 0.67[\text{m}]$ として試算可能である。日本人の平均的な肩幅が約 $42.7[\text{cm}][5]$ であることから、計測時の位置関係によっては観測が困難であることが予想される。本実験で使用する LiDAR の角度分解能は約 $0.096[\text{deg}]$ ～約 $0.384[\text{deg}]$ （フレームレート $5[\text{Hz}]$ ～ $20[\text{Hz}]$ と対応）まで調整可能であるが、 $0.096[\text{deg}]$ 、 $0.192[\text{deg}]$ 、及び $0.384[\text{deg}]$ の条件での、対象物との距離に対応する水平分解能を図 2.2.②-3 に示す。




図 2.2.②-3 対象物との距離に対する水平分解能


例えば $10[\text{Hz}]$ で計測した場合では、図 2.2.②-3 のグラフより歩行者及び二輪車の検出可能な距離が約 $100[\text{m}]$ と見積もることができる（1 本のレーザで 2 点程度の観測点が得られる距離とした場合）。また、自動車の車幅が約 $1.7[\text{m}]$ であると仮定した場合、自車両から $150[\text{m}]$ 程度離れた位置でも 1 本のレーザで約 3 点の観測点が得られることが予想できる。以上を踏まえて天候条件の異なる環境でのデータ計測を実施した。

評価結果を表 2.2.②-3 に示す。それぞれの条件におけるセンサと対象物との位置関係が一致しているわけではないため識別距離にばらつきが見られる。また、それぞれの条件の観測点の画像を図 2.2.②-4～図 2.2.②-6 に示す。全体的には雨による直接的な影響は少ないが霧の場合には検出可能距離が 6 割程度に減少している傾向が確認された。事前の見積もりと比較すると、歩行者及び二輪車に関しては同程度の識別距離が得られている。一方で自動車の検出距離は事前の予測よりも短くなっており、歩行者・二輪車より $5[\text{m}]$ 程度遠方となる結果が得られた。この理由としては、自動車は歩行者と比べて横幅が広いが、遠方となることで車両下部のボンネット付近しか観測点が得られず、その結果十分なレーザ数の観測が得られなかったことが原因である。これからの評価結果より、一般的な走行環境においては $100[\text{m}]$


程度先の物体を検知可能であるといえる。また、150[m]など更に遠方の場合においても観測点が得られる場合も確認できているため、100[m]付近までに移動物体として追跡できている自動車の場合は追跡処理を継続することによって150[m]相当の遠距離まで継続的に認識することも期待される。

表 2.2.②-3 LiDAR による遠距離物体の観測距離評価結果

	通常		雨		霧	
	検出可能	識別可能	検出可能	識別可能	検出可能	識別可能
自動車	約 107[m]	約 90[m]	約 110[m]	約 92[m]	約 55[m]	約 45[m]
歩行者	約 100[m]	約 65[m]	約 105[m]	約 75[m]	約 65[m]	約 55[m]
二輪車	約 100[m]	約 65[m]	約 105[m]	約 75[m]	約 65[m]	約 55[m]




(a) センサから 110[m]付近




(b) センサから 60[m]付近

図 2.2.②-4 通常時の対象物の様子




(a) センサから 110[m]付近





(b) センサから 75[m]付近

図 2.2.②-5 雨の時の対象物の様子



(a) センサから 110[m]付近



(b) センサから 60[m]付近

図 2.2.②-6 霧の時の対象物の様子

(4) まとめ

今年度の評価では最新型の LiDAR を用いた遠距離物体の検知可能距離を評価した. この評価結果より LiDAR 単独では約 65[m]先の歩行者・二輪車を, 約 90[m]先の自動車の認識が期待できる観測結果が得られた. 次年度では, 物体識別アルゴリズムを適用して実際に認識可能であるかを評価することが課題となる. また, 時系列追跡処理の導入や他のセンサとのフュージョンを検討し, 遠距離物体の認識に特化下認識アルゴリズムを開発することで認識可能距離の改善を試みる.

参考文献

- [1] A. Teichman, J. Levinson, S. Thrun, “Towards 3D object recognition via classification of arbitrary object tracks,” Proceedings of IEEE International Conference on Robotics and Automation, pp. 4034-4041, 2011.
- [2] L. Spinello, K. O. Arras, R. Triebel, R. Siegwart, “A Layered Approach to People Detection in 3D Range Data”, Proceedings of the Twenty-Fourth AAAI Conference on Artificial Intelligence, pp.1625-1630, 2010.
- [3] N. Suganuma, M. Yoshioka, K. Yoneda and M. Aldibaja, “LIDAR-based Object Classification for Autonomous Driving on Urban Roads”, Journal of Advanced Control, Automation and Robotics, Vol.3, No.2, pp.92-95, 2017.
- [4] C. R. Qi, H. Su, K. Mo, L. J. Guibas, “PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation”, Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017.
- [5] 社団法人人間生活工学研究センター, “平成 17 年度経済産業省委託事業 人間特性基盤整備事業 成果報告書”, 2006.

2.3. c. 「高精度自己位置技術の開発」

① GNSS/INS の開発

(1) データ収集と評価の概要

2018年度は東京でのデータ収集と、従来技術、及び提案手法での精度評価を実施した。まず、図2.3.①-1にデータ収集を行った車両を、表2.3.①-1にセンサ構成を示す。使用するGNSS 受信機はU-blox F9Pであり、価格は約1万円程度の受信機を採用している。また、GNSSアンテナはマルチGNSS、多周波に対応したアンテナを使用する。慣性センサには、多摩川精機製のTAG264に使用されているMEMS-IMUの生値を利用した。なお、リファレンスにはPOSLV 620を使用する。POSLV 620は測量用GNSS受信機、光ファイバージャイロ、高精細エンコーダを用いており、非常に高精度に位置推定が可能である。今回の評価では、高精度に推定されたPOSLV の位置結果を評価に用いる。また、データ収集は都市部のマルチパスが発生しやすい環境を想定し、図2.3.①-2、図2.3.①-3に示すお台場、新宿のコースで実施した。

表 2.3.①-1 センサ構成

Equipment	Manufacturer	Model(cycle)
GNSS antenna	Trimble	Zephyr model 3
GNSS receiver	Ublox	F9P (5Hz)
IMU	Tamagawa Seiki	TAG264 (50Hz)
Reference	Applanix	POSLV 620



図 2.3.①-1 データ収集を行った車両の外観，Ublox 社 F9P と多摩川精機社 TAG264




図2.3.①-2 東京都お台場での評価コース概要




図2.3.①-3 東京都新宿での評価コース概要

ここで、走行時における衛星配置を図2.3.①-4、図2.3.①-5に示す。実際に衛星測位を行う場合、低仰角にある衛星は高仰角にある衛星に比べ、構造物の影響を受けやすい。従って、仰角が15度以下の衛星は

測位には測位計算には使用していない。また、走行時における観測衛星の数の変動を、図2.3.①-6、図2.3.①-7に示す。なお、今回は衛星の信号強度であるSN比が、35[dBHz]以下の信号を使用せずに評価を行った。




図 2.3.①-4 お台場での衛星配置




図 2.3.①-5 新宿での衛星配置




図2.3.①-6 お台場での衛星数




図2.3.①-7 新宿での衛星数

(2) 従来研究と提案手法の評価

なお、収集したデータを利用した評価では、以下の4つの方法を用いて評価を行った。

1. オープンソースのソフトウェア(RTKLIB[1])を利用したRTK(Real Time Kinematic)

: RTK

2. Meguroらが提案した車両軌跡を利用した測位手法[2]

: Conventional 1

3. Shimizuらが提案したRTKを改善した手法[3]

: Conventional 2

4. 本プロジェクトで提案しているRTKを改善した手法[4]

: Proposal

1. RTKは、オープンソースのソフトウェアを利用した手法である。なお、RTKLIBは広く実用、研究用途で利用されている測位ソフトウェアである。次に、2. Meguroらの手法は、GNSSドップラを活用して高精度に推定された車両の運動を活用した測位手法であり、都市部においてマルチパスの影響を低減できる特徴を持っている。ただし、疑似距離を活用した手法であるため、1m以下の精度は期待することはできない。3. Shimizuらの手法では、従来のRTKの技術にGNSSドップラを活用することで高精度化を狙った手法である。ただし、GNSSドップラがマルチパスの影響を受ける場所では、その効果は限定的となる決定がある。一方、4. 本プロジェクトで提案する手法では、3. Shimizuらの手法と2. Meguroらの手法の利点を融合した手法である。2018年度では、以上の4つの手法の精度を都市部で把握した。

(3) お台場での評価結果

次に、お台場における各手法の評価結果を表 2.3.①-2 に示す。また、各手法の精度と、それを達成している割合の関係を示したグラフを、図 2.3.①-8 に示す。

表 2.3.①-2 お台場での評価結果概要

	Position Err			Fix Rate
	2DRMS meter	2DErr <0.3 meter Rate	2DErr <1.5 meter Rate	
RTK	3.04	55.2	76.2	47.3
Conventional 1	0.81	21.6	94.0	51.0
Conventional 2	5.26	58.4	78.6	
Proposal	0.74	76.6	90.4	




図 2.3.①-8 お台場での精度比較結果（精度と達成割合の関係）

図 2.3.①-8 より，“Conventional 1”では，マルチパス等による大きな誤差を抑制しているため，1.5m を達成している割合は 94%となっていることが確認できる．一方，誤差 0.3m 以下の割合は，疑似距離を利用した測位手法であるため，搬送波を利用した“RTK”より低くなってしまっていることが確認できる．また，“Conventional 2”では Fix 率を向上させているため，“RTK”と比較して高精度な割合が向上している．しかし，GNSS ドップラもマルチパス等の影響を受けるため，その効果は限定的であることが確認できる．一方，“Proposal”は，“Conventional 1”，“Conventional 2”のそれぞれの課題を考慮しつつ，利点を活かすことで，30cm の割合が 77%を実現できていることがわかる．加えて，“Proposal”は 1.5m の精度の割合も 90%を達成している．

また，初期値に POSLV620 で計測したリファレンス値を用いることで，提案手法の性能限界値が計算できる．そこで，現状の精度との比較を行うため，提案手法の現状の精度，性能限界精度，参考として一般的な RTK 測位の精度を図 2.3.①-9 に示す．図 2.3.①-9 より，性能限界値が現状より 5%程度向上しているのが確認できる．これは，提案手法において初期値を改良することで改良できる伸びしろと考えることができる．ただし，性能限界値においても 1.5m 以上の誤差割合が 5%程残存していることも確認できる．




図 2.3.①-9 お台場における提案手法の改善見込み

(4) 新宿での評価結果

新宿における各手法の評価結果を、表 2.3.①-3 に示す。また、各手法の精度と、それを達成している割合の関係を示したグラフを、図 2.3.①-10 に示す。図 2.3.①-10 より、“Proposal”は、30cm@57%、1.5m@92%の範囲で位置精度を達成できることが確認できる。また、“Proposal”、“Proposal”の性能限界精度、“RTK”の精度を図 2.3.①-10 に示す。図 2.3.①-10 より、性能限界値の高精度割合が、“Proposal”より 30%程度向上しているのが確認できる。お台場と比較すると、その差が大きいことから、新宿では初期値の精度をさらに向上させることで、精度改善の余地が大きいことが確認できる。一方、お台場同様に性能限界値においても 1.5m 以上の誤差割合が 5%程残存していることがわかる。

表 2.3.①-3 新宿での評価結果概要

	Position Err			Fix Rate
	2DRMS meter	2DErr <0.3 meter Rate	2DErr <1.5 meter Rate	
RTK	15.00	29.5	57.5	26.5
Conventional 1	1.32	5.6	77.0	23.9
Conventional 2	4.37	34.8	61.5	
Proposal	1.50	57.0	92.3	45.1




図 2.3.①-10 新宿での精度比較結果（精度と達成割合の関係）




図 2.3.①-11 新宿における提案手法の改善見込み

(5) まとめ

2018 年度には東京都の都市部におけるデータ収集を実施し、従来手法の精度把握を行った。なお、データ収集では安価な機器として、GNSS には ublox F9、INS として多摩川精機製の MEMS IMU、及び車両 CAN から取得できる車輪速を利用した。その結果、2017 年度までに開発した手法ではお台場にて 1.5m 精度が 94%、新宿では 77% で達成していることを確認した。同時に、30cm 精度を達成するために開発している RealTime Kinematic 法の初期条件を最適化する手法の評価も実施し、お台場では 30cm@77%、1.5m@90%、新宿では 30cm@57%、1.5m@92% の範囲で達成できることを確認した。以上の確認より、本プロジェクトで目標としている 1.5m、30cm の精度を達成可能な見込みを得ることができた。今後は、30cm

の信頼度を検証すると共に、開発しているアルゴリズムの高精度化，ロバスト化を実施する．併せて，リアルタイム化を実施することで，自動運転に適用可能な GNSS/INS とする予定である．

【参考文献】

- [1]Tomoji Takasu and Akio Yasuda, “Development of the low cost RTK-GPS receiver with an open source program package RTKLIB. In Proceeding of the International Symposium on GPS/GNSS”, Jeju, Korea, 4-6 November 2009.
- [2]Junichi Meguro, Takuya Arakawa, Syunsuke Mizutani and Aoki Takanose, “Low-cost Lane-level positioning in Urban Area Using Optimized Long Time Series GNSS and IMU Data”, IEEE ITSC,2018
- [3]Natsuka Shimizu, Kazuki Kusama, Taro Suzuki and Yoshiharu Amano, “Improving Accuracy of Single-Frequency RTK-GNSS using Satellite Selection and Doppler Frequency”, IAIN, 2018
- [4]高野瀬，荒川，滝川，目黒，都市部における車両軌跡を活用した高精度測位 ―初期条件の最適化による精密測位の改善―，ロボティクスメカトロニクス講演会 2019，2019.6(発表予定)

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。

2018 年度はマップマッチングアルゴリズムの調査および実験のための走行エリアの選定を行った。

マップマッチングアルゴリズムの調査

自動運転において、マップマッチングには主に建物や電柱などの立体構造物の特徴を用いる手法と、白線や横断歩道などの路面パターンを用いる手法の 2 つが挙げられる。図 2.3.②-1～2 に 3 次元点群地図と路面パターン地図の例を示す。

立体構造物に注目し、3 次元点群のマッチングを行う手法は縁石やポールなど周辺環境の様々な物体をランドマークとして利用可能であるが、植え込みや街路樹などの季節によって形が変化するものが地図に含まれている場合、リアルタイムにセンサから取得したデータとの照合が正しく行えない場合がある。

路面パターンに注目する手法では、地図データを図 2.3.②-2 のような画像の形式や線分情報(ベクトル形式)で保持することが可能であるため、3 次元点群と比較してデータ容量が軽量となる。また、季節の変化などの環境要因によって変化することが少ないため、耐環境性に優れているといった利点をもつ。しかし、特徴となるような白線などのない道路や交差点内部では正しいマッチング結果が得られないといった欠点が存在する。




図 2.3.②-1. 3 次元点群地図の例



図 2.3.②-2. 路面パターン地図の例

・ ICP アルゴリズム[1]

ICP (Iterative Closest Point) アルゴリズムは、2つの点群の位置・角度のずれ量を計算するためのアルゴリズムである。ICP は図 2.3.②-3 のように、一方の点群に含まれる各点について他方の点群の最近傍点を探索し対応点のペアを作り、これらのペアについて、2点間の距離の和を最小化するような変換(並進・回転)を推定する。これらの手順を繰り返すことで、2つの点群の位置合わせを行い、最終的な位置と角度のずれが求められる。ICP では、2つの点群の対応点を探索する処理を繰り返し行うこととなるが、マッチングに使用する範囲を広げてより多くの点群を用いる場合、全体的な処理時間が増大してしまうといった欠点がある。この問題を解決する手法として、点群を複数のレイヤーに分割し、レイヤーごとにマッチングを行うものが提案されている^[2]。




図 2.3.②-3. ICP アルゴリズムの外観図

・ NDT スキャンマッチング[3]

NDT (Normal Distributions Transform) スキャンマッチングでは、図 2.3.②-4 に示すように点群地図をグリッド状に区切り、各グリッド内の点群を正規分布で近似する。この正規分布によって表された地図とセンサデータについて、ICP と同様に対応要素の探索および変換の推定を繰り返すことで2つの点群間の位置・角度のずれを計算する。この手法は地図の点数に依存しないため、ICP と比較して高速に計算可能であり、リアルタイム処理が必要である自動運転で用いられている実績がある[4]。




図 2.3.②-4. NDT スキャンマッチングの外観図

画像マッチング

画像ベースのマッチングでは、路面パターンの地図を 2 次元の画像として保持しておき、センサデータとの照合を行う手法である。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。マッチングではテンプレートマッチング等が挙げられる。テンプレートマッチングは高速フーリエ変換を利用して処理の高速化が可能であり、自動運転の行動実証実験において用いられている実績がある[5]。




図 2.3.②-5. 画像マッチングの外観図

線分マッチング

線分ベースでのマッチングにおいては、道路の区画線や横断歩道などの情報を図のような線分情報からなる地図(ベクトル地図)として保持する．図 2.3.②-6 のように、センサにより得られたデータから LSD(Line Segments Detector) [6]やハフ変換[7]により線分を検出し、ベクトル地図との線分マッチングを行うことで位置や角度のずれを推定する．マルチカメラのデータを鳥瞰画像に変換し線分検出・ベクトル地図とのマッチングを行う手法が提案されており、リアルタイムに処理可能であることが実験で示されている[8]．




図 2.3.②-6. 線分マッチングの外観図

実験のための走行エリアの選定

次年度において、複数のマップマッチング方式を開発し比較検討する際の走行エリアの選定を行った。上記のアルゴリズム調査で述べた通り、手法の開発・検討を行うにあたって3次元点群および路面パターンの情報が必要となる。また、走行ルートの選定には、それぞれの地図の利点・欠点を考慮し、各地図が得意・不得意とするシーンを含んでいる必要がある。そこで、以下に述べるようなシーンを含む走行ルートとして、図2.3.②-7に示すように金沢市内における片道約20kmの経路を選出した。

・立体構造物が多い/少ない場所




図 2.3.②-7. 選定した走行ルート

3次元点群を用いたマッチングの特徴から、図2.3.②-8のような建物などの立体構造物の多い場所では高精度に位置を推定でき、図2.3.②-9のような立体構造物の少ない場所ではマッチングが正しく計算されないと想定される。これを検証するために立体物構造の多い道路と少ない道路を含むルートを選定した。




図 2.3.②-8. 立体構造物の多い場所の



図 2.3.②-9. 立体構造物の少ない場所の例

・街路樹や植え込みのある道路

図 2.3.②-10 のような街路樹のある道路では季節によって樹木の形が変化するため, 3 次元点群を用いたマッチングによる位置推定が正しく行われなことが想定される. 樹木の形の変化の影響を確認・検証するため, 選定したルートには街路樹や植え込みのある道路を含めている.



図 2.3.②-10. 街路樹のある道路の例

・白線などの路面パターンが多い/少ない道路

路面パターンを使ったマッチング手法の特徴より, 図 2.3.②-11 のようにランドマークとなり得る白線や横断歩道などの路面パターンが多い道路では高精度に位置も推定でき, 図 2.3.②-12 のようなパターンの少ない道路ではマッチングが正しく計算されない可能性がある. これを検証するため路面パターンの多い道路と少ない道路を含む走行ルートを選定した.



図 2.3.②-11. 白線などの路面パターンが多い道



図 2.3.②-12. 白線などの路面パターンが少ない道

・長い区間のトンネル

GPS の信号を捉えにくいような場所において、マップマッチングにより位置推定精度を保証可能であるかを検証するためには長距離区間のトンネルなどを含む走行ルートであることが望ましい。今回選定した経路には図 2.3.②-13 のような全長約 1km のトンネルが含まれている。



図 2.3.②-13. 長距離区間トンネルの例

・車線数・交通量の多い道路

東京臨海部での実証実験を見据えた上で、東京臨海部と類似した環境での走行試験を行い、方式を検証する必要がある。今回選定した走行ルートは、図 2.3.②-14 のような金沢駅周辺の比較的交通量の多い片側3車線の道路を含んでいる。



図 2.3.②-14. 車線数・交通量の多い道路の例

【参考文献】

- [1] P. J. Besl et al., “A Method for Registration of 3-D Shapes,” IEEE Trans. on Pattern Analysis and Machine Intelligence, 1992.
- [2] K. Yoneda et al., “Urban Road Localization by using Multiple Layer Map Matching and Line Segment Matching,” Proceedings of 2015 IEEE Intelligent Vehicles Symposium, 2015.
- [3] P. Biber et al., “The Normal Distributions Transform: A New Approach to Laser Scan Matching,” Proceedings of the 2003 IEEE International Conference on Intelligent robots and Systems, 2003.
- [4] S. Kato, et al., “An Open Approach to Autonomous Vehicles,” IEEE Micro, 2015.
- [5] N. Suganuma et al., “Localization for Autonomous Vehicle on Urban Roads,” Journal of Advanced Control, Automation and Robotics (JACAR), 2016.
- [6] R. Gioi et al., “LSD: A fast line segment detector with a false detection control,” IEEE Trans. on Pattern Analysis & Machine Intelligence, 2008.
- [7] R. O. Duda et al., “Use of the Hough transformation to detect lines and curves in pictures”, Communications of the ACM, 1972.
- [8] K. Hara et al., “Vehicle Localization Based on the Detection of Line Segments from Multi-Camera Images,” Journal of Robotics and Mechatronics, 2015.

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。

2018 年度は本アルゴリズムの開発に必要なデータ収集を行う走行エリアと走行条件の抽出と関連する歩行者の行動予測アルゴリズムの調査を行った。

走行エリアと走行条件の抽出

走行エリアは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と共通データセットを構築するために、金沢市内の街中とした。2018 年度は、図 2.4.①-1 のようなアルゴリズムの検証ためのデータセットを収集した。



(a)金沢市内想定シーン



(b)アルゴリズム検討用のデータ例(中部大学内で撮影)

図 2.4.①-1:データ収集例

行動予測アルゴリズムの調査

歩行者や自動車の行動予測手法が注目され、物体間のインタラクションを考慮した経路予測手法や周辺環境を考慮した手法などが提案されている。2018 年度は、従来の行動予測手法について調査した。

•Social LSTM [1]

シーン内の複数の歩行者の移動経路を同時に予測する LSTM による経路予測手法であり、予測対象毎に個別の LSTM を用意している。この手法では、予測対象周囲に存在する他の歩行者間のインタラクションを考慮するために Social Pooling Layer(S-Pooling)を提案している。S-Pooling では、予図 2.4.①-2 のように、測対象を中心とした特定の範囲内の全対象の位置座標、すなわち動的対象に関する空間情報を Pooling し、次時刻の LSTM への入力として使用する。




図 2.4.①-2:Social LSTM の外観図

•Convolutional Social Pooling [2]

図 2.4.①-3 のように、高速道路における車両の行動を予測する手法である。Social LSTM で使用されている S-Pooling は空間情報を全結合層へ入力した後、次時刻の予測対象の経路を予測している。しかし、全結合層へ入力した場合、対象間のインタラクションに関する空間情報が壊れてしまう。そのため、この手法では、図 2.4.①-4 のように、S-Pooling を改良した Convolutional Social Pooling を提案している。




図 2.4.①-3:予測対象(赤), 他対象(黒, 青)




図 2.4.①-4:Convolutional Social Pooling の外観図

•Social Attention [3]

ロボット分野における人のナビゲートを目的とした手法である。従来は近隣に存在する対象間のインタラクションのみを考慮しているが、この手法では遠方の対象の相互作用も考慮している。さらに、図 2.4.①-5 のように、近隣の対象に対して、より重視している。この手法は、図 2.4.①-6 のように、グラフィカルモデルで使われるエッジ・ノードで対象間の位置関係、次時刻の対象の予測値を取得しているただし、グラフィカルモデルとは異なる方法で問

題を定義した手法で解いており、論文中では時空間グラフとして表現している(spatio-temporal graph(st-graph)).




図 2.4.①-5:近隣の対象(赤線)




図 2.4.①-6:st-graph の外観図

•Social GAN [4]

GAN を使用した経路予測手法. 従来の手法の予測値は確率, または直接予測値を出力していたが, この手法では, 図 2.4.①-7 のように, GANを用いることで幾つかの予測経路を生成し, 最適な予測経路を抽出する. また, 図 2.4.①-8 のように, 対象間のインタラクションを考慮するために, Pooling Module(PM)の提案をしている. PM は, 予測対象と周囲に存在する移動対象の位置情報の差分を算出した後, 予測対象の位置情報, ノイズベクトル z と共に LSTM への入力として用いる.




図 2.4.①-7: Social GAN の外観図




図 2.4.①-8: Pooling Module の外観図

•SoPhie [5]

Social GAN に歩道や道路などの静的環境を加えた経路予測手法である。この手法では、静的環境を考慮した Physical Attention, 対象間の相互作用, すなわち経路に関する動的環境を考慮した Social Attention の 2 つの Attention Module を導入している。その後 2 つの Attention Module を連結し LSTM への入力として用いる。図 2.4.①-9 のように、LSTM の出力に対してノイズベクトル z を連結し Social GAN と同様に最適な経路を生成する。




図 2.4.①-9: SoPhie の外観図

•SR-LSTM [6]

従来の経路予測手法は、対象間の振る舞いに対して過去の情報を見ている。しかし、過去の情報を考慮した対象間のインタラクションでは、現時刻の対象同士がそれぞれどこに向かって行動するか判断ができない。例えば図 2.4.①-10 のように、現時刻 $t-1$ で男性の方が避けるか進んでくるかで女性の行動に変化が起こる。そういった、現時刻の行動に基づいて、図 2.4.①-11 のように、各対象が判断、アクションする Data-Driven を考慮した SR-LSTM を提案している。




図 2.4.①-10:予測経路の判断例





図 2.4.①-11:SR-LSTM の外観図

【参考文献】

- [1] A.Alahi et al., "Social LSTM:Human Trajectory Prediction in Crowded Spaces," CVPR, 2016
- [2] N.Deo et al., "Convolutional Social Pooling for vehicle Trajectory Prediction ," CVPRW, 2018
- [3] A.Vemula et al., "Social Attention:Modeling Attention in Human Crowds ," ICRA, 2018
- [4] A.Gupta et al., "Social GAN:Socially Acceptable Trajectories with Generative Adversarial Networks ," CVPR, 2018
- [5] A.Sadeghian et al., "SoPhie:An Attentive GAN for Predicting Paths Compliant to Social and Physical Constraints ," CVPR, 2019
- [6] P.Zhang et al., "SR-LSTM:State Refinement for LSTM towards Pedestrian Trajectory Prediction ," CVPR, 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

都市部市街地でのスムーズかつ安全な自動運転において技術的に課題となる状況として、図2.4.②-1 (a)のように多数のバスや自動車等によって囲まれて相対的に狭いエリアの中を走行する状況が挙げられる。このような場合、例えば単純に周辺に存在する移動物体との接近可能な距離(避け幅)を小さくするという対処も可能であるが、停止車両などの静止障害物に対して同一の避け幅で回避行動をとると、過度に接近しすぎてしまうなどの問題も生じる(図2.4.②-1(b))。このような状況では、周辺に存在する物体との適切な避け幅を考慮した軌道計画が重要である。



(a) 都市部において相対的に道幅狭くなる状況


(b) 停止車両に対する回避

図2.4.②-1 都市部市街地における走行が困難となる状況


そこで、都市部市街地での軌道計画技術を開発するため、上記の相対的に道幅が狭くなる状況を対象とした走行エリアを選定する。具体的には以下の道路環境を考慮する。

- バスの交通量が多い道路
- 路肩の停止車両の多い幹線道路

これらの条件を満たす走行エリアを2箇所選定した。1つ目は石川県金沢市中心部のルート（約2.5km）を検討している。また、2つ目は、東京都臨海地区(お台場周辺約5km程度の広さのエリア)を検討している。両走行エリアの地図を図2.4.②-2に示す。石川県金沢市の走行エリアでは市内の観光エリアや繁華街を通るルートとして金沢駅から武蔵ヶ辻・香林坊を經由して片町へ向かうルートを選定した。このルートは、市内において最も多くのバス路線となっているエリアであり、大型のバスが頻繁に走行する状況のため相対的に道幅が狭くなる道路となっている。このような環境でパスプランニング技術の中心的な技術開発を実施する予定である。これによって難易度の高い先端的な技術開発を期待することができる。次に選定した東京臨海地区周辺部は、タクシーやトラックなどの車両が路肩に停車している頻度の高いエリアとして選定した。このように多くのバスや停車車両が混在する走行環境を対象として次年度以降の実証実験を実施予定とする。



(a) 金沢市内中心部で選定した走行ルート（全長約2.5[km]）




(b) 東京臨海部で予定する走行エリア

図2.4.②-2 アルゴリズム開発のために選定した走行エリア


1. 物体形状を考慮した運動状態の追跡アルゴリズムの基礎設計

都市部市街地における相対的に狭い環境下での走行では、周囲の移動物の形状を考慮した状態推定アルゴリズムが重要となる。運動状態に加えて物体形状を精密に推定することで避け幅の小さい環境での安全な走行が可能となる。移動物体の運動状態と形状の同時推定に関する研究では、申請者らは古くから計測精度の低いセンサ情報であったとして頑健に移動物体を抽出し、その航跡を求めることで運動状態や物体形状を推定する手法[1]を提案している。また複数の運動モデルを同時に考慮し、IMM(Interacting Multiple Model) 法に基づき精度の高い移動物体の運動状態を推定可能とする手法[2]等も提案してきた実績がある。また、近年では、移動物体の位置・姿勢・運動状態などの情報と、移動物体の横幅、長さ等の形状情報を同時に推定する拡張物体追跡(Extended Object Tracking)技術[3]も検討されている。2018年度はLiDARを用いた移動物体の追跡問題を対象として、従来用いられている質点ベースの運動状態の推定アルゴリズムに対して形状を考慮した追跡アルゴリズムを考案し、その効果を検証する。

LiDARをベースとする物体認識では、センサから得られる点群(図2.4.②-3(a))の位置情報を基に障害物を検知し、障害物であると判断された観測点(障害物点, 図2.4.②-3(b))を物体毎に区別するクラスタリングを行う。クラスタリングして得られる各物体に対して前述の状態推定アルゴリズムを適用することで物体の運動状態の推定が行われる。



(a) LiDARの観測点群



(b) 路面点群の除去による障害物認識

図2.4.②-3 LiDARの観測点群の様子

クラスタリングをベースとした追跡処理では、瞬間的にクラスタリングが失敗した場合や死角の影響で対象物の全体形状を観測できない場合などにおいて誤認識が発生する状況がある。典型的な誤認識の例を図2.4.②-4に示す。図2.4.②-4(a)は交差点付近において車両と道路中央のポールが誤クラスタリングされてしまい、これによって停止車両の速度が誤って推定され、物体が自車両方向に進行してくると判断された例である。対象物とそれに接近した他の物体を同一物体としてクラスタリングしてしまう状況を完全に防ぐことは本質的に困難であるため、物体形状を考慮して誤クラスタリングの状況にも適切に対処可能な追跡アルゴリズムが重要である。

また、図2.4.②-4(b)はオクルージョン時の観測において、低速物体の姿勢角推定の精度が低下した状況である。移動速度の高い物体であれば運動モデルを考慮することで精度良く姿勢角を推定可能であるが、

低速時は進行方向の速度ベクトルの情報が十分に得られないため、物体形状を適切に考慮しなくては安定した状態推定が実現できない。そこで、このような瞬間的な誤検知による影響を抑えた、ロバストな追跡手法の基礎設計を行った。



(a) クラスタリングの失敗による速度ベクトルの誤認識

(b) オクルージョン時の観測による物体姿勢角の誤認識

図2.4.②-4 移動物体の追跡処理における誤認識の例




図2.4.②-5 基礎検討している物体追跡アルゴリズム

検討している物体追跡アルゴリズムの概要を図2.4.②-5に示す。周辺移動物体の追跡には、時系列的な状態推定手法の一つであるカルマンフィルタを応用したInteracting Multiple Model(IMM)法[2]を用いる。IMM法を用いることでカルマンフィルタでは推定困難な複雑な運動をする対象の状態推定が可能となる。移動物体の追跡では、前時刻の状態から運動モデルを用いて現時刻の状態を予測し、予測状態と観測情報に基づいて現時刻の状態を推定する。また、赤字で記載した処理に関して、誤クラスタリング時や低速物体の追跡安定化に効果が期待される処理を導入した。

速度推定に用いる観測情報について説明する。速度推定には、図 2.4.②-6 のような点群の凸包体を内包する Bounding box の 8 点のうち最近傍点を用いる。この時、2 次元平面上における自車位置から最近傍点まで距離を速度推定に必要な観測情報とする。LiDAR の観測情報はセンサから見た物体の位置や向きによって変化するため、物体の幅や長さなどの情報を正確に把握することは困難である。そこで、最近傍点を用いることで、観測状態からの影響が少ない点の運動として状態の推定が可能となる。しかし、速度推定手法では誤クラスタリングの影響を受けてしまう問題がある。観測した点群のクラスタリングに失敗すると図 2.4.②-4(a)のように、本来の物体とは異なる形状となってしまう。そしてその最近傍点により状態推定を行うことで誤った運動を認識してしまう。したがって誤クラスタリングの影響が少ない速度推定手法が必要となる。

次に物体向きの推定手法について述べる。まず 2 次元点群に対して凸包体を作成する。その凸包体に対して Rotating calipers 法[6]を適用することで、凸包体を内包する Bounding box の候補が生成される。凸包体は物体が存在する領域を示している。そのため、Bounding box の面積が小さいことは、余分な領域が含まれない適切な物体領域を表すと考えられる。そこでこれらの向きと面積を図 2.4.②-7 のようなヒストグラムで表し、時系列的に積算する。その中で最も面積が小さくなる角度を物体の向きであると推定する。しかし、図 2.4.②-4(b)のように面積最小の Bounding box が適切な方向を向いていない場合が存在する。この状態が連続して観測されており、実際とは異なる向きが推定されてしまっていた。そこで、Bounding box の面積だけでない新たな向きの決定方法が必要となる。




図2.4.②-6 凸包体の形成と観測点の抽出




図2.4.②-7 姿勢角尤度の算出

そこで図2.4.②-5で示した追跡アルゴリズムでは、誤クラスタリングの影響が少ない速度推定手法として「可視輪郭を用いた速度推定手法」、より適切な向き推定手法として「可視領域を考慮した向き推定手法」を導入し改善を試みる。

まず、速度推定方法では、点群から得られる凸包体の内、自車両から見える輪郭線分（可視輪郭）に注目し、前時刻で観測した輪郭（予測輪郭）と現時刻に観測した輪郭（観測輪郭）の位置合わせをすることにより、予測位置と観測位置のずれ量を検知した状態推定を行う。2つの輪郭の位置合わせの例を図2.4.②-8に示す。位置合わせでは予測輪郭を観測輪郭のマッチング処理を行う。輪郭の頂点同士を対応付ける処理によって輪郭同士のずれ量を考慮することで追跡時の観測点を適切に設定する。




図2.4.②-8 可視輪郭を用いた速度推定における輪郭マッチング

次に物体向きの推定手法について述べる。図2.4.②-7に示したように Bounding box の面積のみから物体の向きを推定する方法では物体の形状によって適切な向きの推定ができない場合が確認されている。このような状況は、図2.4.②-9のように、凸包体の可視輪郭よりも自車両側の領域（斜線部分）が大きくなっていることが原因と考えられる。可視輪郭は凸包体の自車両から見える輪郭線分であるため、可視輪郭よりも自車両側には物体はないと考えられる。そこで、図2.4.②-7の斜線部分（可視領域）を考慮して物体の向きを推定する。具体的には可視領域の面積を算出する。そして、この面積を従来手法と同様にヒストグラム化し、時系列的に積算する方法を採用する。その中で最も面積が小さくなる角度を物体の向きであると推定する。本手法により可視領域の小さい、凸包体の可視輪郭に沿った Bounding box を物体の向きとすることができる。




図 2.4.②-9 不適切な凸包体形成時を例とする可視領域の算出

以上の基礎設計した追跡アルゴリズムに対する性能評価を実施する。評価内容は以下の2点とする。

- 可視輪郭を用いた速度推定の導入による誤クラスタリング物体の追跡精度の評価
- 可視領域を考慮した追跡方法の導入による低速移動物体の方位角推定誤差の評価

実環境において、周辺移動車両の速度や向きの真値を得ることは困難である。そこで提案手法の性能評価については、速度推定手法は停止車両の速度推定結果より評価し、向き推定手法は自車両の隣車線の移動物体の向き推定結果より評価する。評価データは図2.4.②-4にて示した誤認識のデータを対象とする。

まず速度推定結果について考察する。速度推定結果を図2.4.②-10に示す。ただし、図2.4.②-10において5フレーム目までは観測初期段階のため推定結果が安定していない。そのため、5フレーム以降に対して評価する。本図において、6～41フレームはクラスタリング成功時、42～79フレームはクラスタリング失敗時における速度推定結果を表している。クラスタリング成功時は平均0.23[km/h]、クラスタリング失敗時は平均1.01[km/h]だけ速度推定誤差を抑制することができた。また、図2.4.②-7からクラスタリングの結果に依らず、安定した速度推定ができていることがわかる。

また、向き推定結果について考察する。向き推定結果を図2.4.②-11に示す。図2.4.②-11より、向き推定結果の分散が小さくなり、従来よりも安定して向きの推定ができていることが分かる。また、角度推定値の二乗平均誤差(Root Mean Square Error : RMSE)を5.71[deg]だけ小さくすることができ、従来よりも自車両の向きと近い角度を推定できていることも分かる。本実験では自車両の隣車線を走行している車両の向きを推定しているため、自車両と同程度の向きを推定できていれば、向きの推定は正しい結果であると考えられる。従って、提案手法の導入によって正確で安定した向きの推定が可能となったといえる。

次年度では、基礎検討した追跡アルゴリズムを自動運転自動車に実装し、リアルタイム性の検証を行う。また、選定した実証実験の走行エリアでの実験をすすめ、高度な軌道計画アルゴリズムの開発を行う。




図2.4.②-10 停車車両の誤クラスタリング時における速度ベクトルの追跡結果





図2.4.②-11 大型低速移動物体に対する方位角推定結果

- [1] N.Suganuma, Clustering and Tracking of Obstacles Using Stereo Vision System, ICROS-SICE International Joint Conference, (2009), pp. 4623-4628.
- [2] 永野聖巳, 菅沼直樹, 米陀佳祐, Mohammad Amro Aldibaja, 岸田正幸, 松元利裕, 全方位ミリ波レーダを用いた自動運転自動車のための周辺移動車両追跡に関する研究, 自動車技術会論文集, Vol.48, No.2, pp.411-418, 2016
- [3] K.Granstrom, et al., Extended Object Tracking: Introduction, Overview and Applications, Journal of Advances in Information Fusion, Vol.12, No.2, pp.139-174, 2016
- [4] 菅沼直樹, 米陀佳祐, 自動車の自動運転におけるデジタル地図の活用, ロボット学会誌, Vol.33, No.10, pp.760-765, 2015
- [5] 菅沼直樹, 米陀佳祐, 自動運転自動車のパスプランニング, 情報処理学会誌, Vol.57, No.5, pp.446-450, 2016
- [6] G. Toussaint, "Solving geometric problems with the rotating calipers," IEEE MELECON, p. 1-8, 1983.

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

現在の自動運転自動車のパスプランニング技術にはロボット工学における移動ロボットの研究成果が応用されている．例えば，Thomas ら[1]は整備されていない火星の表面を自律で走行し探索するための軌道計画方法を提案した．この研究では，図 2.5.①-1(a)で示すような前進移動速度のプロファイルと図 2.5.①-1(b)で示すような角速度のプロファイルを用いて位置，姿勢と曲率を考慮して軌道生成を行っている．この手法を用いることで図 2.5.①-2 に示すような様々な軌道が計画され，より最適な軌道を考慮することが出来るようになる．



(a) 前進移動速度のプロファイル

(b) 角速度のプロファイル

図 2.5.①-1 速度のプロファイル[1]



図 2.5.①-2 位置，姿勢と曲率を考慮して生成される軌道 [1]

自動運転自動車の研究分野において，前方の移動方向のプロファイルと車線の幅を考慮した横方向移動のプロファイルを用いて軌道計画する方法を Moritz らが提案した[2]．この手法では図 2.5.①-3 で示す frenet frame の座標の解析方法を用いて，その 2 つのプロファイルを変換し一つの軌道を生成する．





図 2.5.①-3 Frenet-frame の座標の解析方法を用いた軌道 [2]

そこで、我々は Thomas らと Moritz らの研究内容を応用し、自動運転自動車に適応できる研究成果を出した[3],[4].

自動運転自動車の研究が進んでいる中でもまだ解決されていない問題が、軌道計画におけるデッドロック状態である。ここで定義するデッドロックとは、目標位置（即ちゴール）には通る道にも関わらず、未知の障害物（停止中の車など）や動的障害物（他に移動する車など）により進めない状態を意味する。特に、自動運転自動車が市街地を走行する際デッドロックになると考える場面は、図 2.5.①-4 に示すような商業施設の出入り口における進入・退出、幹線道路への合流や、狭い道路でのすれ違い、変則的な交差点などが挙げられる。

そこで、2018 年度はデッドロックを考慮した意思決定技術・軌道計画技術の方式調査を行った。



(a) 商業施設の出入り口における進入・退出

(b) 幹線道路への合流時の例

図 2.5.①-4 デッドロック発生時の例

この問題に関しては、Urban Challenge で参加チームだった Sören らと Chris らがこの問題の対象方法を研究成果として発表した[5][6].

Sören らは、図 2.5.①- 5 で示す状況においては移動時間を調整することで事前にデッドロックにならないようにした。まず、図 2.5.①-5 で示す自車(A)と他の車(B)が辿る経路を直線と考慮すべき点を用いて

単純化する．両車両が交わる点（図 2.5.①- 6 での MP）に同時に近づくとお互いデッドロックに落ちる可能性が高い．そのため，点 MP に他の車(B)が到達する時刻を算出し，その時刻に自車(A)が点 MP 上にいないように軌道を計画する．




図 2.5.①-5 交通シナリオを単純なシナリオに変換方法[5]




図 2.5.①-6 幾何学な方法を用いた移動時間計算法[5]

Chris らは，優先順位をきめるアルゴリズムを用いて，基本的な交通ルールを基に軌道を計画し走行する手法を提案した．ここで注目すべき点は，Chris らは実際に市街地を自動運転自動車が走行する際には様々な状況に応じて軌道計画において問題が生じることを想定し，図 2.5.①-7 で示す状況において発生するエラーからの回復方法も提案した．Chris らが想定したエラーが起きうる状況は我々が想定しているデッドロックの状況に近い．




図 2.5.①-7 交差点 [6]

Chris らが提案したデッドロック回避方法は、目標位置まで移動する際にエラーが生じた場合、目標位置を変更することでデッドロック状態からの回避を試みる。例えば図 2.5.①-7 で示すような交差点進入直前でデッドロックが発生し、当初の目的位置（図 2.5.①-7 の Original Goal）に到達できない状況を想定する。このような場合、1～6 番までの自車の目標位置の候補を設定し、各候補について軌道の再計算を行い、デッドロックを回避できる軌道を探索する。

また、交差点で想定されるデッドロックの問題にオントロジー理論を取り組んだ研究もある[7]。まず、オントロジーとは図 2.5.①-8 で示すように、その意思決定に関わる様々な要因を分類し木構造を作るものである。オントロジーを用いてデッドロックの状態を回避する意思決定を行う方法である。Lihua らが設定したデッドロックのシナリオは T 字路において両者が譲りあう状況である。

上記以外の状況においてもデッドロックは発生しうるため、次年度はシミュレーションを用いてデッドロック発生条件の分析や意思決定技術・軌道計画技術の詳細設計を行う。




図 2.5.①-8 マップにおけるオントロジー[7]

- [1] Thomas M. Howard and Alonzo Kelly, "Optimal rough terrain trajectory generation for wheeled mobile robots", The International Journal of Robotics Research vol. 26 no. 2, pp: 141-166, 2007.
- [2] Moritz Werling, et al., "Optimal trajectory generation for dynamic street scenarios in a frenet frame." IEEE International Conference on Robotics and Automation, pp. 987-993, 2010.
- [3] 菅沼直樹, 松井俊樹, “自動運転自動車の走行経路高速生成法”, 自動車技術会論文集 vol. 42 no.6 pp. 1281-1286, 2011.
- [4] Keisuke Yoneda, et al., “Trajectory optimization and state selection for urban automated driving”, Artificial Life and Robotics vol. 23, no. 4, pp. 474-480, 2018.
- [5] Sören Kammel, et al., “Team annieway’s autonomous system for the DARPA urban challenge 2007”, The DARPA Urban Challenge. Springer, Berlin, Heidelberg, pp. 359-391, 2009.
- [6] Chris Urmson, et al., “Autonomous driving in traffic: Boss and the urban challenge”, AI magazine vol. 30, no. 2, pp. 17-28, 2009.
- [7] Lihua Zhao, et al., “Ontology-based decision making on uncontrolled intersections and narrow roads”, IEEE intelligent vehicles symposium, pp. 83-88, 2015.

② 人工知能(AI)を活用したデッドロック回避

2018年度は実施なし

2.6. f. 「実証実験」

本事業では、次年度以降上記テーマ a.～e.までの研究開発項目の公道走行実証実験に向けて、自動運転自動車を用いた公道走行実証実験を実施する予定となっている。このため、本年度は公道走行実証実験に必要となる試験車両の構築に向けた準備を進めた。

(1) 試験車両

本事業では試験車両を公道で走行させるため、道路運送車両の保安基準に抵触しないことが必須となる。このため、改造の元となるベース車両はすでに市販車両として販売されている物の中から選定することとした。また、市販車両を自動運転が可能な状態に改造した状況で公道走行させるためには、特に安全性の配慮が必要となる。このため本事業では、改造元となる市販車両の内部システムを熟知している自動車会社もしくは自動車部品製造会社による改造が可能な車種を選定することとした。またこれらの条件に加え、本事業を効率的に実施するためには市販車両を短期間で改造させる必要もある。このため、既に市販車両の自動運転状態への改造実績を有する車種として、LEXUS RX450hL を選定した。下記に、主な仕様を示す。

表 2.6.①-1 試験車両(LEXUS RX450hL)の仕様

車両型式	DAA-GYL26W-ARXGB
トレッド	1,640[mm](前)/1,630[mm](後)
ホイールベース	2,690[m]
最小旋回半径	5.9[m]
乗車定員	7[人]
車両総重量	2,625[kg]
寸法	全長 5,000[mm]×全幅 1,895[mm]×全高 1,725[m]



図 2.6.-1 試験車両の内観（出典：<https://lexus.jp/models/rx/gallery/>）

(2) センサ

本事業では、次年度以降市街地の公道において Level4 相当の自動運転を行う予定となっている。このため、短期間での試験車両構築が必要となる。本事業の実施者のうち金沢大学は、既に 4 年以上の期間市街地における Level4 相当の自動運転実証実験を実施しており、既に約 14,000km の走行実績を有している。このため本事業では既に多くの公道実証実験を実施している金沢大学の自動運転自動車で得られた知見を活かして、必要となるセンサ構成を設計することで研究開発の効率化を図ることとした。具体的には、以下のセンサを搭載予定である。

- ・ **LiDAR(Light Detection and Ranging)**: 3 次元距離分布(ポイントクラウド)を取得可能なセンサであり、複数種類の LiDAR を組み合わせることで車両全周囲をカバーさせる。本センサは、高精度自己位置推定に用いるとともに、車両周囲の静的・動的物体の検出、物体種別の識別、移動物体の行動予測等に用いる。
- ・ **ミリ波レーダ**: 車両周辺の物体までの距離、方位、相対速度を計測可能なセンサであり、複数台のミリ波レーダを組み合わせることで車両全方位をカバーさせる。本センサは、主に交差点右左折や車線変更時の安全確認のための遠距離移動物検知に用いるとともに、車両周辺の移動物体の行動予測等に用いる。
- ・ **カメラ**: 車両周辺の物体検知等に用いるセンサであり、複数台のカメラを組み合わせることで車両全周囲をカバーさせる。本センサは、主に信号機認識や、車両周辺の物体検知および物体種別の識別等に用いる。
- ・ **GNSS(Global Navigation Satellite System) / INS(Inertial Navigation System)**: 高精度な車両位置と姿勢が計測可能なシステムであり、初期段階の実証実験に用いるとともに、各種性能評価に用いる。なお GNSS に関しては、準天頂衛星(QZSS: **Q**uasi-**Z**enith **S**atellite **S**ystem)も受信可能な仕様の装置を選定する。

このうち、カメラに関してはテーマ a.において **LFM(LED Flicker Mitigation)**機能や **HDR(High Dynamic Range)**機能等の特殊機能を有するカメラが必要となる。このため、カメラデバイス製造メーカーによるカスタム品を使用することとした。またミリ波レーダに関しても、入手性・これまでの金沢大学での使用実績等の観点から **DENSO TEN** 製のカスタム品を使用することとした。その他、LiDAR、GNSS/INS に関しては購入に向けて準備を行っており、次年度に購入を行う予定となっている。

3. 実施体制

