

博士学位論文

市街地道路地図の自律生成に基づく
交通参加者の移動予測と自動運転制御

Traffic Participant Motion Prediction and Autonomous Driving Control
Based on Urban Road Map Construction

国立大学法人 東京農工大学大学院
工学府 機械システム工学専攻

前田 健太

Kenta Maeda

2020年9月

論文要旨

交通事故ゼロをめざす、高齢化社会において特に過疎地の足を確保する、などの社会課題の解決を目的として、ドライバ操作を代替する自動運転システムの実現を見据えた研究開発が盛んに行われている。国内外で高速道路における公道試験走行が進んでおり、ドライバがハンドルから手を離すことが認められるレベル3自動運転が日本国内で認められ、今後は市販の乗用車への搭載も進むと考えられる。一方、一般道では最近になって一部地域で公道試験走行が開始された段階である。限定エリアにおけるレベル4自動運転システムを搭載した無人運転バスの実証試験も全国で行われているが、実用化には至っていない。高速道路と比べて、自動運転に必要なHD地図の整備が一般道（特にラストワンマイル自動運転の領域）では遅れること、一般道は歩行者・自転車などの移動体に対する衝突回避が求められるため技術的な難易度が高いことが課題となっている。

本論文では、自動運転システムにおける判断・制御の観点から、これら課題を解決する。特に、【1】低コストな車載センサのみを用いて自動運転用の地図を自己生成すること、そして【2】歩行者・自転車の行動変化を予測すること、の2点を研究対象とする。

まず【1】の課題として、地図生成手法について具体的な手法を構築し、テストコースを手動で走行した際のデータを用いて検証する。その際、レンジと画角が異なる2種類のカメラを比較し、地図生成におけるセンサ要件を考察する。また、地図生成においては真値が得られないことから、生成した地図が自動運転に使用可能な十分精度を有しているかを判定する必要がある。そこで、構築した地図自体の精度を判定する地図精度判定手法を構築する。本論文では、自己位置推定における横方向誤差を0.5 m以内に収められるような地図情報を「自動運転に使用可能」と判定する。地図精度判定手法として、オフラインで自己位置推定精度を検証する手法、横方向のばらつきを統計的に判定する手法、の2つを提案する。

次に、【2】の課題に対して、【1】で得られた知見を応用する。すなわち、ローカルダイナミックマップ（LDM）内の静止物（地図）の情報と移動物体の情報を組み合わ

論文要旨

せることで歩行者・自転車の将来の行動変化を予測する歩行者行動予測を構築する。行動予測にはポテンシャル法を適用し，自車両と歩行者とが将来干渉することが予測される場合には終端状態制御を用いてなめらかに減速する速度計画法を構築する。ある特定の高密度道路環境を想定したユースケースにおけるシミュレーションと，テストコースにおける実車とダミー歩行者を用いた実験により，本手法の有効性を示す。本手法により，歩行者の将来の行動変化が予測されない場合には速度を維持しつつ，行動変化が予測される場合には所定内の減速度で減速可能である。すなわち，歩行者行動予測により，歩行者・自転車が混在する市街地道路環境において，速度（利便性）と減速度（乗り心地）のトレードオフを解消可能である。

Abstract

For solving social issues such as maintaining the transportation of the rural area in the aging society, and aiming at zero traffic accidents, research and development has been actively focused on realizing autonomous driving system that substitutes driver operation. In Japan and abroad, driving tests on expressways are progressing, and the level 3 autonomous driving, which allows drivers to release their hands from the steering wheel, has been authorized in Japan and will continue to be installed on commercially available passenger cars. On the other hand, it is a stage where driving tests have just been started in some regions recently in general roads. The demonstration tests of the unmanned driving bus equipped with a level 4 autonomous driving system in limited areas have been conducted nationwide, but has not yet been commercialized. Compared to the expressways, construction of the high-definition map required for autonomous driving is delayed in the general roads (especially the last one-mile autonomous areas). In addition, the general road has a high technical difficulty because the collision avoidance to the moving bodies such as pedestrians and the bicycles is demanded.

This paper solves these problems in terms of decision making and control in the autonomous driving system. In particular, the following two subjects of the research is studied; (1) to construct a map for autonomous driving using only low-cost on-board sensors, and (2) to predict movement changes of pedestrians and bicycles.

First, as a challenge of (1), a map construction method is developed, and it is verified using the data of manual driving on a proving ground. Two cameras with different range and field of view are compared for verification in order to consider the sensor requirements for map construction. Moreover, since the true value is not available while map construction, it is necessary to determine whether the constructed map has sufficient accuracy that can be used for autonomous driving. Therefore, this paper proposes a map evaluation method that determines the accuracy of the constructed map itself. In this paper, the constructed map with which the lateral error of localized position is less than 0.5 m, is determined as “usable” for

Abstract

autonomous driving. As the map evaluation methods, a method for estimating the accuracy of localized position, and a method of statistically determining the lateral variation, are proposed.

Next, as a challenge of (2), the knowledge obtained in the map construction method is applied. Namely, this paper proposes a pedestrian behavior prediction method that predicts the future movement change of pedestrians and bicycles by combining information of moving objects with static objects (map) in local dynamic map (LDM). The potential method is applied to the prediction method, and a velocity planning method which slows down the vehicle smoothly by using the Final State Control (FSC) when the vehicle and the pedestrian are expected to collide in the future, is developed. The effectiveness of the proposed method is verified by simulation in the use case which assumes a certain high-density road environment, and by experiment using the real vehicle and the dummy pedestrian in the proving ground. By this method, the vehicle's speed is maintained if the future movement change of the pedestrian is not predicted, while it can be decelerated within a predetermined deceleration when the movement change is predicted. In other words, the movement prediction method can eliminate the tradeoff between speed (convenience) and deceleration (ride comfort) in city area where pedestrians and bicycles exist in high density.

目次

第 1 章	序論	1
1.1	はじめに.....	1
1.2	研究背景.....	1
1.2.1	社会的背景	1
1.2.2	社会課題を解決するための予防安全技術の普及.....	4
1.2.3	自動運転システムの開発推進	6
1.2.4	自動車のサービス化とラストワンマイル自動運転	8
1.2.5	市街地道路環境での自動運転実現に向けた課題.....	9
1.3	本研究の目的.....	11
1.4	本論文の構成.....	13
第 2 章	自動運転システムの概要	16
2.1	はじめに.....	16
2.2	実験車両および車両に搭載するセンサ・カメラ.....	17
2.2.1	実験車両.....	17
2.2.2	搭載されている外界認識用カメラ	18
2.3	地図に基づく自己位置推定手法	19
2.3.1	自己位置推定技術の動向	19
2.3.2	ランドマーク地図に基づく自己位置推定手法	21
2.3.3	自車両周辺の静止物体に基づく自己位置推定	25
2.4	自動運転に必要な操舵制御設計	34
2.4.1	軌道追従制御設計	34
2.4.2	操舵角サーボ.....	37
2.5	本章のまとめ.....	39
第 3 章	市街地道路環境における自動運転の課題	40

目次

3.1	はじめに.....	40
3.2	地図生成における課題	41
3.2.1	量産車による地図生成手法と技術的課題	43
3.2.2	実験車における地図生成の課題	46
3.3	歩行者・自転車等の混在環境における課題.....	50
3.3.1	課題抽出のためのドライブレコーダデータベースの利用	51
3.3.2	先行研究におけるヒヤリハットデータ活用例	53
3.3.3	本研究におけるヒヤリハットデータ活用方法	54
3.4	ヒヤリハットデータに基づく歩行者・自転車等に対する課題分析 .	55
3.4.1	交差点右折時のヒヤリハット事例.....	55
3.4.2	単路走行時のヒヤリハット事例	59
3.4.3	両者に共通するヒヤリハット事例.....	66
3.4.4	ヒヤリハット事例の分類.....	69
3.4.5	歩行者・自転車等の存在に対する解決方針.....	73
3.5	本章のまとめ.....	75
第4章	地図生成手法及びカメラ特性による比較	77
4.1	はじめに.....	77
4.2	地図生成手法.....	79
4.2.1	地図生成ステップ	80
4.2.2	テストコースの白線を用いた地図生成結果.....	82
4.3	自己位置推定誤差を用いた地図精度判定手法	83
4.3.1	地図精度判定の考え方	84
4.3.2	テストコースの白線情報を用いた検証.....	85
4.4	Fisheye camera を用いた自動運転実験	87
4.4.1	自動運転実験における評価ポイント	88
4.4.2	自己位置推定手法をそのまま適用した自動運転結果.....	89
4.4.3	自己位置推定手法の変更による実験結果	91
4.4.4	実験結果まとめ	93
4.5	本章のまとめ.....	94

第 5 章	地図情報精度判定手法	96
5.1	はじめに	96
5.2	地図精度判定手法の検討	97
5.2.1	地図精度判定の基本的方針	97
5.2.2	線形回帰モデルに基づく閾値設定	98
5.2.3	白線点数の閾値に基づく地図精度判定方法	102
5.3	地図精度手法の検証	103
5.3.1	検証方法	103
5.3.2	パラメータ設定による傾向	105
5.3.3	直線部・曲線部における精度判定結果	107
5.3.4	考察及び残課題	110
5.4	本章のまとめ	112
第 6 章	地図情報応用技術としての歩行者行動予測	113
6.1	はじめに	113
6.2	想定する自動運転シーン	115
6.2.1	歩行者・自転車の行動傾向	115
6.2.2	想定する道路環境	117
6.3	安全性を確保する速度計画方法	118
6.3.1	安全速度の考え方	118
6.3.2	安全速度の算出方法および算出結果	119
6.3.3	技術的課題と達成目標	127
6.4	ポテンシャル法に基づく歩行者行動予測	128
6.4.1	仮想物理モデルの導入とパラメータ同定	129
6.4.2	ポテンシャル法に基づく歩行者行動予測	132
6.5	終端状態制御を用いた速度制御手法	134
6.5.1	問題設定	134
6.5.2	経路交差点の選択	135
6.5.3	終端状態制御	136
6.5.4	全体の制御系設計	138

目次

6.5.5	終端状態制御における初期状態の与え方	140
6.6	机上検証.....	141
6.6.1	机上検証シナリオ	142
6.6.2	机上検証結果.....	143
6.7	実車検証.....	145
6.7.1	歩行者予測実験に用いるダミー人形	145
6.7.2	実車検証における条件	146
6.7.3	単路を直進する歩行者（実験 I）	147
6.7.4	駐車車両を避けて横移動する歩行者（実験 II）	149
6.8	本章のまとめ.....	152
第 7 章	結言	154
7.1	本論文のまとめ	154
7.2	今後の課題	156
	参考文献	158
	謝辞	169
	発表文献	170

第1章 序論

1.1 はじめに

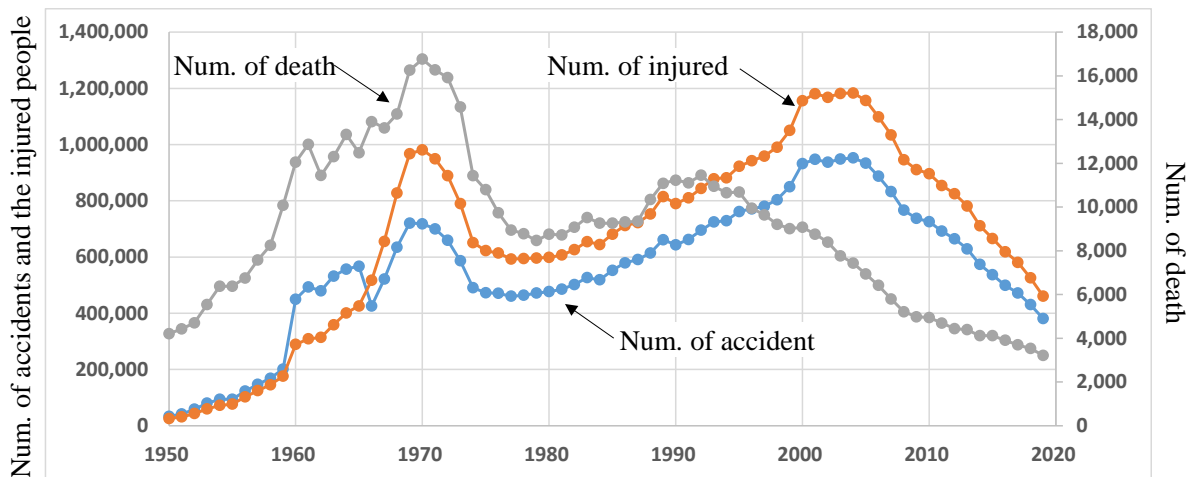
本章では、1.2 節において社会的および工学的視点から本研究の背景について述べる。次に 1.3 節において本研究背景を踏まえた現状の問題点に対する本研究の目的を述べる。さらに 1.4 節において本論文の構成を示す。

1.2 研究背景

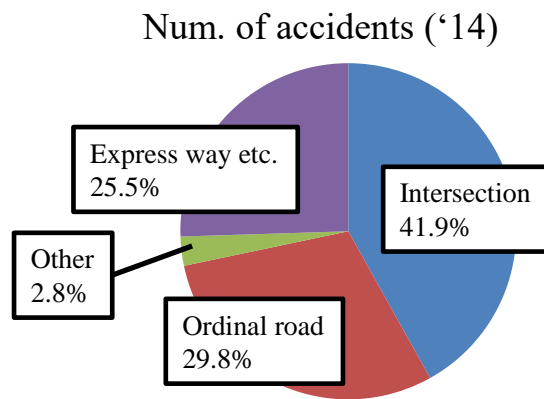
本節では、本研究の背景について、社会的な研究背景を述べた後、その社会課題を解決するためにこれまで開発・普及してきた技術と、残存する工学的課題について述べる。

1.2.1 社会的背景

交通事故および交通事故による死傷者を削減することは、自動車社会において最重要課題の一つである。そのため、衝突時の被害を最小限にするためのシートベルトやエアバックのような衝突安全技術 (Passive Safety), 制動時のスリップを抑制する ABS (Antilock Brake System), 横滑り防止装置 (ESC : Electronic Stability Control) のような予防安全技術 (Active Safety) が導入され普及してきた [1][2]。これらの技術により、交通事故件数や死者数は減少傾向にある。警察庁の交通事故発生状況に関する統計 [3]によれば、国内では Fig. 1-1(a)に示す通り死者数は 1991 年から、事故件数は 2005 年から減少傾向にある。国外においても同様の取り組みが行われており、先進国では国内同様に交通事故や事故による死者数は減少傾向にある。しかし、事故件数自体は依然として高い状態にあり、自動車業界の各社ともに交通事故ゼロを目指した取り組みを継続している。一方、事故がどこで発生したかを示す Fig. 1-1(b)の円グラフを参照すると、2014 年に発生した事故は 25.5%が高速道路や自動車専用道路であったが、それ以外の 74.5%は一般道 (交差点や単路) で発生したことが分かる。



(a) Transition (1950 ~ 2019).



(b) Breakdown (2014).

Fig. 1-1 Transition of the number of crash fatalities in Japan [3].

次に、2017年における日本と一部他国の状態別交通死者数割合の比較を Fig. 1-2 に示す。本データは公益財団交通事故総合分析センターによるものである [4]。Fig. 1-2 より、日本では歩行者の死亡者数割合が 35%を占めており、比較国の中では韓国に次いで 2 番目であり、他の欧米諸国に比べて高い割合となっている。また、自転車の死亡者数割合も 15%あり、オランダに次いで 2 位と高い水準にある。このように、日本における歩行者・自転車の死亡事故割合の高さは他国に比べて高い傾向にある。これは日本特有の交通事情が影響していると考えられ、道路の広さ、歩道の整備状況、歩行者との混在環境道路の多さなど、さまざまな要素が考えられる。交通事故ゼロを目指した取り組みにあたって、他国と比較して割合の高い歩行者・自転車の死亡事故を




Fig. 1-2 Ratio of fatality reason compared with several countries (2017) [4].

防止するための対策が必要であると考えられる。

社会動向のもう一つの側面が高齢化社会である。日本の高齢者の人口比率の推移を Fig. 1-3 に示す。本統計は内閣府が毎年発行する高齢社会白書に基づく [5]。他国に先駆けて、日本は超高齢化社会に突入ことが知られている。2018 年時点の高齢化率（全人口に占める 65 歳以上の人口比率）は 28.1% となっており、その中で 65 歳～74 歳人口 13.9%，75 歳以上人口が 14.2% と、いわゆる「後期高齢者」と呼ばれる年齢層の人口の割合が多くなったことが指摘されている。日本の高齢化率は今後も増加すると予想されており、2065 年には 38.4% に達する見込みである。人口に対する高齢者の割合が増えれば、身体能力の低下などの理由により、自身で運転することが困難な人の割合も増えることになる。

警察庁の運転免許統計 [6]によれば、2019 年末時点の免許保有人口の年齢比率では、65 歳以上が全体の 25.6% を占め、75 歳以上に限定しても全体の 9.1% となるなど、運転免許証保有者の高齢化率も高くなっている。一方、免許返納（運転経歴証明書交付）件数も年々増加しており、2019 年中に 60 万件を超え、その大部分にあたる 95.7% は 65 歳以上が占める。このような人々に対して社会がどのように移動手段を提供して




Fig. 1-3 Ratio of elderly people over 65 years old [5].

いくかが大きな社会課題となる。

1.2.2 社会課題を解決するための予防安全技術の普及

前述した交通事故統計や削減目標，社会的な取り組みと自動車の安全技術の普及状況などから，現在までに広く普及している衝突安全や車両運動安定化制御に加え，現在急速に世界に普及しつつある予防安全技術（Active safety）が交通事故件数および死者数の更なる減少に大きく貢献すると期待されており，近年研究開発が盛んに行われ実用化されている。国土交通省では，予防安全に関する先進技術を利用してドライバの安全運転を支援する先進運転支援システム（ADAS: Advanced Driver Assistance System）を搭載した自動車のことを先進安全自動車（ASV: Advanced Safety Vehicle）と名付け，1991年からASVに関する技術の開発・実用化・普及を促進するプロジェクトに取り組んできた [7]。

ASVの代表的なシステムの一つとして，前方の障害物（車両・自転車・歩行者等）に対して衝突前に停止する自動緊急ブレーキ（AEB: Autonomous Emergency Braking）の実用化が進んでいる。ボルボ・XC60（2008年）に搭載されたVolvo City Safety [8]

や富士重工業・レガシー（2010年）に搭載された EyeSight (ver.2) [9]では、国内では初めて衝突前の停止を自動で行う自動緊急ブレーキが市場に投入され、高い評価を得た。現在市場に出ている AEB は、車両の前方に取り付けられたカメラやレーダを利用して前方の障害物を検知し、ドライバーへ警告および自動ブレーキを行うシステムである。前方の障害物に対して衝突を回避または衝突被害を軽減する点で、死傷事故低減のために重要な役割を果たすといえる。日本で車両の安全性評価を行っている JNCAP（Japan New Car Assessment Program） [10]では、AEB の評価項目として直線路における横断歩行者へ拡張した評価が 2016 年から導入され、高いレーティングを得るためには歩行者衝突回避用の AEB が必須となっている。なお、2018 年度からは「夜間：街灯あり」、さらに 2019 年度には「夜間：街灯なし」が対象となるなど、年々より多くのユースケース（特にセンシングが難しいと考えられるケース）が採点対象に追加されている。

高度化する ADAS は衝突回避のみならず、運転負荷軽減の観点で走行制御システムも同様であり、前後方向制御としては、従来の車間距離制御システム（ACC：Adaptive Cruise Control System）を拡張し、停止制御まで拡張した全車速域車間距離制御システム（FSRA：Full Speed Range ACC）や渋滞における低速時の追従制御（LSF：Low Speed Following System）、横方向制御としては、車線維持支援システム（LKAS：Lane Keeping Assist System）や車線逸脱防止システム（LDP：Lane Departure Prevention System）が既に実用化されている。ACC、FSRA および LSF は、車両の前方に搭載したセンサ（レーダ、カメラ等）を用いて、前方を走行する車両との車間距離を一定に保ち、必要に応じてドライバーへの警告を行うシステムである。LKAS は、車両の前方に取り付けられたセンサ（主にカメラ）を利用して道路の白線などの走行環境を検知し、車両が走行車線を維持するよう、ハンドル操作を支援するシステムである。LDP は車両の前方に取り付けられたセンサ（主にカメラ）を利用して道路の白線などの走行環境を検知し、車両が走行車線を逸脱しそうな際にドライバーへの警告および操舵制御またはブレーキ制御の介入を行うシステムである。

この他にも、後部バンパー内に備えたレーダによって、自車後側方の死角に存在する他車両を検知し、車線変更時の衝突防止を支援する後側方衝突警報システムや、制限速度などの標識の見落としをカバーするため、カメラや地図から得られた標識情報をメータ装置内に表示する支援システム、カメラやソナーなどのセンサによって駐車

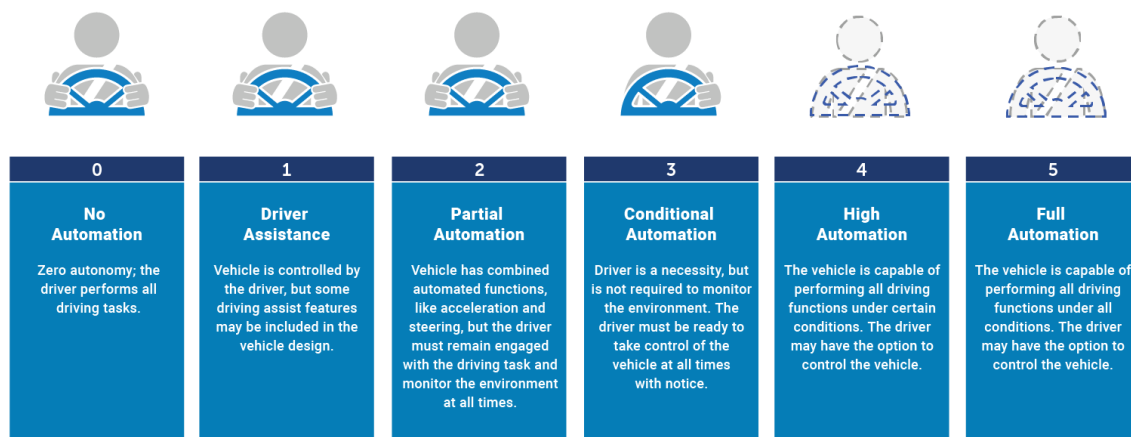


Fig. 1-4 Definition of automation level [16].

可能なスペースを検知して、車庫入れのステアリング操作を自動で行う駐車支援システムなどの予防安全技術が実用化されている。

1.2.3 自動運転システムの開発推進

予防安全技術が進歩する一方、1.2.1 項で述べたような、運転することが困難となった人々に対する貢献技術として、自動運転システムに対する期待も高まっている。先述の通り、前後、横方向の制御技術、衝突回避技術、およびそれらを支えるセンシング技術はますます高度化しており、これら ADAS に関する技術を統合することで、ドライバ操作を代替する自律・自動走行システムの実現を見据えた研究開発が産官学で盛んに行われている [11] [12] [13] [14]。内閣府の科学技術政策である SIP（戦略的イノベーション創造プログラム） [15]でも、課題の一つとして自動走行システムが取り上げられるなど、官民を挙げての研究推進がなされている。

自動運転は先述の通り ADAS の技術を発展させることで実現を目指してきたことから、現在世の中の自動運転システムの技術レベル（自動化レベル）を SAE が定義した 5 つのレベルに分けて論じることが一般的となっている [16]。Fig. 1-4 は各自動化レベルの定義を示す。自動化レベル 0 を手動運転とし、操舵または加減速を自動化している従来の ADAS 機能を持つ車両を自動化レベル 1 とする。そして、操舵と加減速を両方制御可能な車両について、ドライバが常に前方監視の責任を負うシステムを自動化レベル 2、自動運転中はシステムが責任を負うが緊急時には十分な引き継ぎ時間

を経てドライバ責任に移行するシステムを自動化レベル3としている。さらに自動化レベル4になると、特定の限定エリア内に限定してドライバ不在の自動走行が実現され、自動化レベル5はあらゆる地域・条件下でドライバ不在の自動走行が実現される。

従来、自動化レベル2は「自動運転」と名付けていたが、自動化レベル2のシステムはドライバが常に前方監視の責任を負うことから、世の中の人々が想像する自動運転のイメージと異なり紛らわしいということで、名前を変更する議論が日本国内で行われている [17]。この背景には、2016年頃から日本でもレベル2のシステムが市販されるようになったこと [18]、同時期に米国でレベル2のシステム搭載車が相次いで事故を起こしたことが話題となるなど [19]、世間の自動運転システムに対する関心の高まりがあったと考えられる。

レベル3の自動運転はこれまで法制の壁があったが、日本国内では2020年4月に改正道路交通法及び道路運送車両法が施行となり、レベル3自動運転が解禁となった。ただし、レベル3ではありながら、当面の間はこれまでのレベル2と同様、運転者に安全運行義務が課される。また、高速道路の同一車線低速走行に限定して詳細な基準を規定し、実質的に適用領域を限定している。世界的にも高速道路での同一車線内の低速走行に限定してのスタートとなる可能性が高く、まずは高速道路に限定した製品化が進むと考えられる [20]。そして日本で最初に販売された自動運転レベル3搭載自動車は、7個のカメラ、5個のレーダ、12個のソナーで周辺環境を検知するシステムであり、高精度地図データを用いて高速道路での手放し運転を実現した [21]。

世界各国を見ても、高速道路における自動運転システムが実証試験フェーズを超えて製品化フェーズに突入しつつある。これは高速道路の形状がシンプルでかつ、他の交通参加者が自動車（あるいは二輪車）のみであり、歩行者・自転車等の交通参加者がいないという道路環境であることが理由であると考えられる。一方、一般道では最近まで、一部地域で公道試験走行が開始されたという段階であった [12]。これは、高速道路と比べて、一般道は歩行者・自転車などの移動体に対する衝突回避が求められ、技術的な難易度が高いことが理由と考えられる。しかし今日、一般道や市街地道路環境における走行試験も進みつつある。その過程において、従来は自動車とはあまり縁のなかったIT業界が自動運転開発に参入するなど業界の勢力図やエコシステムが変わりつつあり、それがスマートフォン普及期に似ていることから「自動車のスマホ化」が指摘されている [22]。



Fig. 1-5 A lv.4 autonomous bus driving test.

1.2.4 自動車のサービス化とラストワンマイル自動運転

先述の通り、従来の自動車業界の常識にとらわれないプレイヤーが参加してきたことで、近年自動車業界では技術とビジネスモデルの両面で転換が起きつつあり、CASEがトレンドとなっている。CASEとは Connected, Autonomous, Sharing & Service, Electric の頭文字をとったもので、2016年にドイツのダイムラー社が提唱した [23]。そして、このCASEのトレンドの中で、限定領域でのレベル4自動運転が注目されるようになってきた。

1.2.1項で述べたような、運転することが困難となった人々の中には、地方の過疎地など公共交通機関が乏しい地域に住んでいる人も多い。その解決策の一つとして、公共交通機関の最寄り駅と最終目的地の間などの「ラストワンマイル」を、自動走行（レベル4）技術を活用して結ぶ新しい移動サービスが注目されており、ラストワンマイル自動走行と呼ばれている。国土交通省が取りまとめている自動走行ビジネス検討会でも、ラストワンマイル自動走行が課題として認識されており [24]、日本国内でも2017年ごろから、レベル4以上の無人自動運転実証 [25]、自動運転バス実証 [26](Fig. 1-5) など、自動運転車を用いたサービス分野でも開発競争が激化し、実証実験のフェーズに達している。

レベル4自動運転を中心とする新しい移動サービスは、過疎地に限らず都市部でも、渋滞や物流業界の人手不足などの社会課題の解決に向けて期待されている。それは自動車に限らず、ICTを活用して交通をクラウド化し、公共交通か否か、またその運営主体にかかわらず、マイカー以外のすべての交通手段によるモビリティ（移動）を1

つのサービスとしてとらえ、シームレスにつなぐ新たな「移動」の概念を生み出している。そのような移動サービスは MaaS (Mobility as a Service) と呼ばれ [27]、近年では、上述した CASE とともに自動車業界のトレンドにもなっている。例えば、トヨタ自動車は 2018 年に MaaS 向けレベル 4 自動運転車「e-Palette concept」 [28]、2020 年には MaaS 実証都市「Woven City」 [29]を公表した。

1.2.5 市街地道路環境での自動運転実現に向けた課題

以上述べてきたように、自動運転技術により解決することが期待されている社会課題は大きく分けて、事故ゼロをめざすこと、過疎地の新たな足になること（ラストワンマイル自動運転の実現）、の二つに大別される。本項では、これらを実現するための自動運転システムの課題について整理する。

まず、交通事故ゼロをめざす観点では、手動運転において現存する主な事故原因を調査・整理した研究が報告されている。それによれば、未だ残る事故原因は主に以下の4つに分類される [30]: ①対象物が見えない（急カーブ上での追突、路外転覆、遮蔽物の裏にいる歩行者、センサ死角、検知角不足や遮蔽による出会い頭事故）、②対象物の急な動き（車両の急な割込み、歩行者等の飛び出し、車両の一時不停止による出会い頭事故）、③高速度・高相対速度、④高齢者の運転能力（駐車場での誤踏み発進、ハンドル誤動作、単路での誤踏み）。これら①～④を解決することが交通事故ゼロへの道筋であり、自動運転技術が期待されている部分である。このうち①はセンシング技術もしくは V2X によるセンシング情報共有技術により、②はリスク推定技術により、③はセンサ検知距離の拡大や高応答化技術により、④は誤操作の検知精度向上技術もしくは平常時の運転診断技術により解決を図ることになる。市街地道路環境における自動運転を考えると、③に関しては相対速度は比較的小さく、④は driver の操作ミスであるから自動運転システムの導入自体により解決される。従って、市街地道路環境においては①のセンシングの課題と、②のリスク予測（歩行者・自転車行動予測）に関する技術課題を解決することが必要である。

次に、ラストワンマイル自動運転の実現という観点では、先述の通り限定地域におけるレベル 4 自動運転による無人移動サービスの実証試験が国内外の各地で行われている。その中で、自動運転が継続困難となった状況、すなわち市街地道路環境でのラストワンマイル自動運転を実現するための技術的課題が見えてきており、主に以下

の点が挙げられている [31]。

- (a) 住居等が立ち並び歩行者等の行き交う人家連坦部等における道路上の路上駐車回避場面
- (b) 狭隘路におけるすれ違い場面
- (c) 歩行者・自転車の回避場面
- (d) 積雪や雑草等を障害物と誤認識し回避した場面
- (e) GPS による自己位置特定ができず、高精度の自己位置推定技術が不可欠となる場面
- (f) LiDAR 等の車載センサを用いた自己位置推定手法で、降雪や霧等の気象条件により機能低下が発生する場面

これら列挙されている課題のうち、(d)と(f)はセンシングの課題を表しており、センサおよび認識技術の向上が必要である。一方、(a)(b)(c)はいずれも、他の交通参加者との衝突回避の関係で自動運転継続困難となったのであり、特に(a)(c)は歩行者・自転車の存在が課題であることが示唆されている。そして(e)は、GPS に頼らずに自己位置を推定するための自己位置推定手法の性能向上が重要であることを表している。

(e)の課題に対して、現在世界中で地図ベースの自動運転が主流となっている。そのきっかけは、アメリカの国防高等研究計画局（DARPA: Defense Advanced Research Projects Agency）が2004年より始めたロボットカーレース「DARPA Grand Challenge」であり、2007年には模擬市街路環境において自動運転車の走破を競う「Urban Challenge」に変化した [32]。この Urban Challenge において、HD 地図を用いた自動運転システムは走破のためのキーテクノロジーとして注目されるようになった [33] [34] [35]。そして現在、自動運転を各地で普及させるために、HD 地図の整備の重要性が認識されている。

地図の整備に関しては現状、政府が主導する戦略的イノベーション創造プログラム (SIP) で協調領域として整備の検討が進められているものの [36]、地図の整備には時間とコストがかかり、まずは高速道路や国道などの主要道路から整備されると見込まれる [37]。ところが、国土交通省の道路統計年報 2019 [38]によれば、日本国内における道路の総延長に対し、高速道路、国道、県道などの主要道路が占める割合は Table 1 に示すように 15.9%しかなく、残りの 84.1%を占める市道や無名の道路は自動運転用

HD 地図の整備が遅れることが予想される。1.2.4 項で述べたラストワンマイル自動運転は、過疎地域における移動弱者（公共交通機関の欠如による移動困難者）の足となることが期待されていることから、まさに「残りの 84.1 %」の道路が対象となる。このような地域における地図拡張を安価に行うリーン地図の研究開発が国家プロジェクト（JST-S イノベーション）で進められている [14] [39]。

1.3 本研究の目的

本研究の目的は、自動運転用 HD 地図が整備されていない市街地道路環境において、低コストでレベル 3 以上の自動運転（ラストワンマイル自動運転）を実現することである。市街地道路環境でのラストワンマイル自動運転にあたっての課題は 1.2.5 項において①②および(a)~(f)の通り整理した。本研究では、①(d)(f)のセンシング・認識の課題は将来的に解決されるという前提で、主に判断の部分の課題となる②(a)(b)(c)(e)について取り組む。具体的には、まず課題(e)については【1】低コストな車載センサーのみを用いて自動運転用の地図を自己生成すること、そして課題②(a)(b)(c)については【2】歩行者・自転車の詳細の行動変化を予測すること、を目的とする。

【1】について、ラストワンマイル自動運転を実現するためには、利用者の自宅前まで、例えマイナーな道路であっても自動運転を実現するための地図が必要である。現在の、自動運転用 HD 地図が生成されている道路のみで自動運転が可能な自動車は、地図の整備が後回しにされると予想される郊外や私道等での自動運転ができずにユ

Table 1 Length of road in Japan, classified by type of road.

Type of roads	Total length (1000km)	Ratio of length
Expressways	8.9	0.7 %
National highways	55.7	4.5 %
Prefectural roads	129.7	10.6 %
Municipal roads	1030.4	84.1 %
Total	1224.8	100%

第 1 章 序論

一ザメリットを損なう恐れがある。ユーザの求める場所での自動運転を実現するためには、市場投入された量産車が自律的に自動運転用地図を拡張することが求められる。そこで本研究では、車載センサのみを用いて自動運転用地図を構築する。そのために、何が技術的課題となるのかを明らかにする。

次に【2】について、本研究の目標は、一般道を含めたさまざまな道路環境における自動運転システム実現である。この時、歩行者が多数存在する市街地道路環境では、歩行者の急な行動変化に対して急ブレーキでの衝突回避が頻発し、乗員にとっての乗り心地低下や不安感につながる可能性がある。一方、急ブレーキ防止を優先して歩行者の近くで過度に速度を落とすと、目的地への速達性を求める乗員に対しては利便性を損なうことになる。このように、歩行者に対する安全性を前提とすると速度（利便性）と加速度（乗り心地）の間にはトレードオフがある。これは、現在の自車両と歩行者の位置関係に基づき速度を決定することが一因であり、上記トレードオフの解消のためには、歩行者の将来の行動変化を予測し、あらかじめ自車両の速度を変更することが必要である。そこで本研究では、移動体や駐車車両などの障害物が多数存在する高密度道路環境下で、歩行者の横移動を予測する行動予測モデル、及び行動予測に基づき良好な乗り心地を実現する速度制御手法を構築する。歩行者の行動変化を予測し、予め走行計画を変更することで、良好な乗り心地の確保と平均速度の向上が両立可能となる。

上記【1】と【2】を実現するために、近年自動運転システムにおいてスタンダードになりつつある Local Dynamic Map (LDM) を適用する。LDM は、いわゆる「地図」だけでなく、静止物や移動物体を一つの統一したプラットフォームで管理するという考え方であり、2011 年に欧州電気通信標準化機構 (ETSI) で標準化され [40]、名古屋大学と同志社大学が共同で開発と評価を推進している [41]。Fig. 1-6 に LDM の各 Type が該当する情報の概念図をレイヤーとして示す。LDM の特徴として、地図情報を 4 つの Type に分類しており、Type 1 はいわゆる「地図情報」すなわち最も静的な情報、Type 2 は準静的情報で、信号機やランドマークなどの情報である。Type 3 は準動的情報で、渋滞や工事中などの情報が該当する。そして Type 4 は最も動的な情報

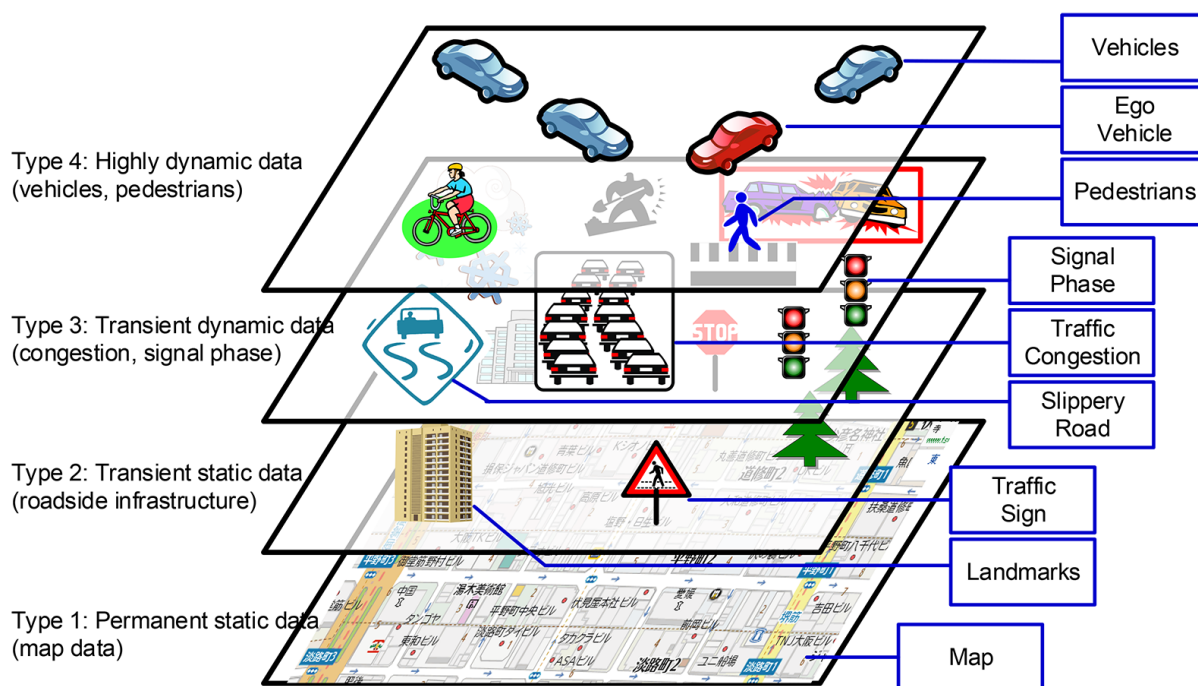


Fig. 1-6 Concept of Local Dynamic Map (LDM) [41].

で、自車両周辺に存在する（自車が検知、または他の車両やセンサからの検知情報を共有する）車両、自転車、歩行者などの移動体情報を持つ。LDMは追突防止支援、緊急車両接近警告、信号情報提供、移動体の存在情報提供など、主に安全性向上に寄与する様々な応用が期待されている [42]。本稿で提案する【2】の歩行者行動予測手法は、地図生成手法の一応用例として、このLDMにおける静的な地図情報（Type1~2）と動的情報（Type3~4）の組み合わせにより実現する。

1.4 本論文の構成

第1章では、自動車社会における社会問題である交通事故の現状と日本における交通事故削減目標について示し、事故防止のための予防安全技術や自動運転技術の既存研究の概要について述べた。また、それらを踏まえ本研究の目標について述べた。

第2章では、自動運転システムの一般的な構成について述べる。具体的には、本研究のために構築した実験車両および車両に取り付けられた車載センサ、本稿が適用した一般的な自己位置推定手法を示す。そして自動運転に必要な操舵制御設計として、

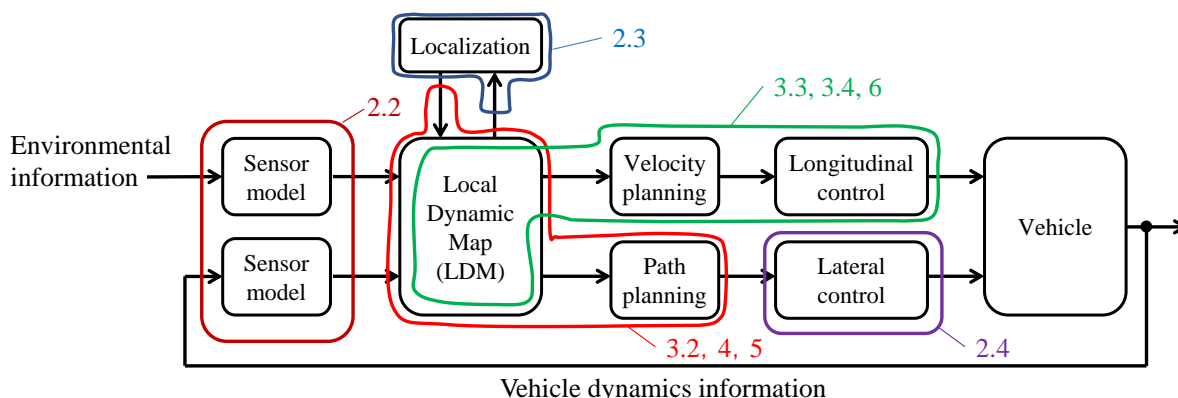


Fig. 1-7 Chapters of this paper corresponding to system architecture of AD.

前方注視モデルに基づく軌道追従制御と操舵角サーボについて述べる。

第 3 章では、本稿で目的とする市街地道路環境での自動運転実現に向けた技術課題を深掘りする。前節で示した①地図生成，②歩行者行動予測のそれぞれについて，現状と課題を示す。

第 4 章では，①地図生成について具体的な手法を構築し，テストコースを手動で走行した際のデータを用いて検証する。その際，レンジと画角が異なる 2 種類のカメラを比較し，地図生成におけるセンサ要件を考察する。また，生成した地図の精度判定手法について，その一つの考え方を提案する。

第 5 章では，地図精度判定手法のもう一つの考え方を提案し，第 4 章と同じくテストコースを手動で走行した際のデータを用いて検証する。

第 6 章では，②歩行者行動予測について具体的な手法を構築し，ある特定の高密度道路環境を想定したユースケースにおけるシミュレーションと，テストコースにおける実車とダミー歩行者を用いた実験により検証する。

第 7 章では，本研究の結論と今後の課題について述べる。

Fig. 1-7 に，本論文の各章・各節で触れる技術がそれぞれ自動運転システムにおけるどの部分に該当するかを示す。自動運転システムは 2.1 節で後述する通り，外界情報や車両情報をセンサにより取得し，取得した外界情報を LDM で管理する。そして，LDM のランドマーク情報を用いて自己位置推定を行い，地図情報を用いて軌道計画および横方向制御を実行し，LDM 内の地図情報，静止物体情報及び移動物体を用いて，移動体行動予測に基づく速度計画と前後方向制御を実行する。本論文で取り上げ

る手法・技術をすべて統合し，センシング技術を組み合わせることで，市街地道路環境を走行可能な一つの自動運転システムとなる。

第2章 自動運転システムの概要

2.1 はじめに

本章では、本研究が対象とする自動運転システムの概要について述べる。自動運転システムは、人間が一般に行っている運転行動を模擬する考え方にに基づき構成されており、およそどのような自動運転システムであってもその役割を大きく分けると、認知、判断、操作に分けられる [43]。全体のブロック図を Fig. 2-1 に示す。

まず、認知ブロックでは、車両に取り付けられた各種センサ情報を取得する。これらセンサ情報による自車両周辺物体の情報と、自車両周辺のランドマーク（路面ペイント、標識など）の位置や形状を記憶した地図とを統合した Local Dynamic Map (1.3 節参照) の情報と照合し、自車両の位置（自己位置）を推定する（Localization）。自己位置推定手法の詳細は本章で後述する。次に、推定した自己位置に基づき、自車両の走行計画に必要な情報を計画のブロックに渡す。計画ブロックは推奨ルートに沿って自車両の目標走行軌道を計画し、障害物等が存在する場合は軌道を修正する。また、道路の速度制限や信号情報に基づき速度目標値を決定する。末端の制御のブロックでは、計画ブロックで算出した目標走行軌道に追従するような横制御と、目標速度を満たすような前後加速度制御を行うための加減速度指令値および操舵角指令値を算出し、パワートレイン（エンジン、主機モータ等）、ブレーキおよび操舵の制御を行う。

本章では自動運転システムの概要として、2.2 節において実験車両を紹介し、車両に取り付けられたセンサからどのような情報が取得できるかについて説明する。次に

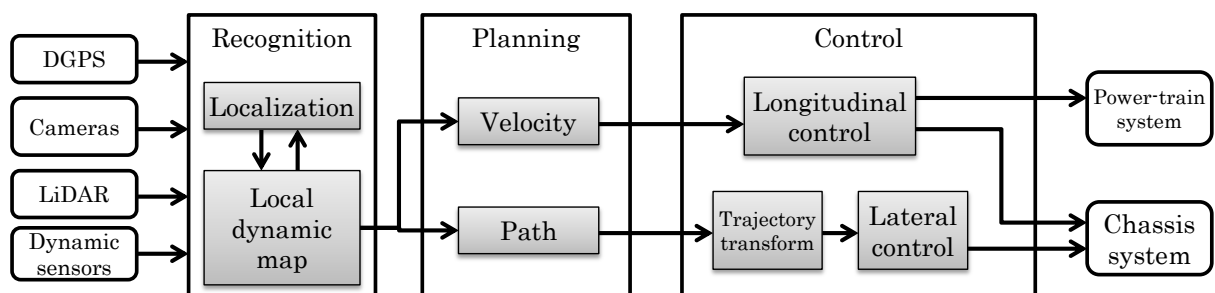


Fig. 2-1 Schematic flow of developed autonomous driving system.

2.3 節において、本研究で適用した自己位置推定手法について述べる。そして 2.4 節では、目標軌道に追従するための操舵角指令値の生成方法と、操舵角指令値に追従するためのステアリングモータのサーボ制御について述べる。本研究が対象とする地図生成手法、周辺の道路環境に基づく速度計画方法については第 4 章以降で述べる。

2.2 実験車両および車両に搭載するセンサ・カメラ

まず本節では、自動運転システムの検証に用いた実験車両と、構築した自動運転システムの概要について述べる。

2.2.1 実験車両

本研究では自動運転システムの検証用に試作した実験車両を用いた。その外観を Fig. 2-2 に示す。ベース車には、前方に向けて測距可能なカメラ (Long-range camera) を搭載している。実験車両に加速度指令値を送信することで、外部コントローラから車両の速度制御を行うことが可能である。また、本車両には検知角度 (FOV: field of view) がほぼ 180° で検知距離が短い魚眼カメラ (Fisheye camera) を車両の 4 辺全てに搭載している。

自車位置測位のための GPS/GNSS 受信機を実験車の屋根に前後 2 台搭載している。2 台搭載することにより、前後の受信機の位置関係から自車両の向いている方向（進行角）が検出可能である。また、車両の周囲の静止物および移動体を検知するためのレーザスキャナ (LiDAR: Light Imaging Detection And Ranging) が車両の各コーナーに計 6 台設置されている。このレーザスキャナは 110° の視角と最大 200m の検知距離を備え、検知した対象物の動きや大きさなどから人、バイク、車などに分類する機能を持つ。さらに、最大 6 台までのセンサデータを統合する ECU を備え、車両周囲 360° の障害物検知が可能である。

自動操舵機構として、モータをステアリングコラム部分に外付けした。このモータに対応するアンプ（モータコントローラ）は外部コントローラからアナログ通信でトルク指令を受信可能であり、本車両においては外部コントローラに操舵角制御を実装することで自動操舵を実現する。操舵角制御の詳細は 2.4.2 項で述べる。また、未使用時および緊急時には電磁クラッチによりステアリングコラムとモータを機械的に



Fig. 2-2 Experimental vehicle.

切り離す安全機構を備える。

2.2.2 搭載されている外界認識用カメラ

この実験車両において、白線情報は Long-range camera を用いて Fig. 2-3 に示す通り取得できる。自車両のカメラ設置位置を起点として、前方10 m, 20 m, 30 mの位置における左右の白線の横方向位置 $y_{L1} \sim y_{L3}$, $y_{R1} \sim y_{R3}$ が得られる。同様に、Fisheye camera からは Fig. 2-4 のように自車両のカメラ設置位置を起点として、前方1 m, 2 m, 3 mの位置における左右の白線の横方向位置 $y_{L1} \sim y_{L3}$, $y_{R1} \sim y_{R3}$ が得られる。このように、両者のカメラから取り出せる白線の仕様は同様であるが、画角の違いから、Long-range camera はより遠くの白線を検出可能であり、一方 Fisheye camera からはより近傍の白線を検出可能である。また、本車両に搭載されている Fisheye camera はさらに、自車両周辺の物体位置を検出可能である。詳細は割愛するが、車両前方に存在する駐車車

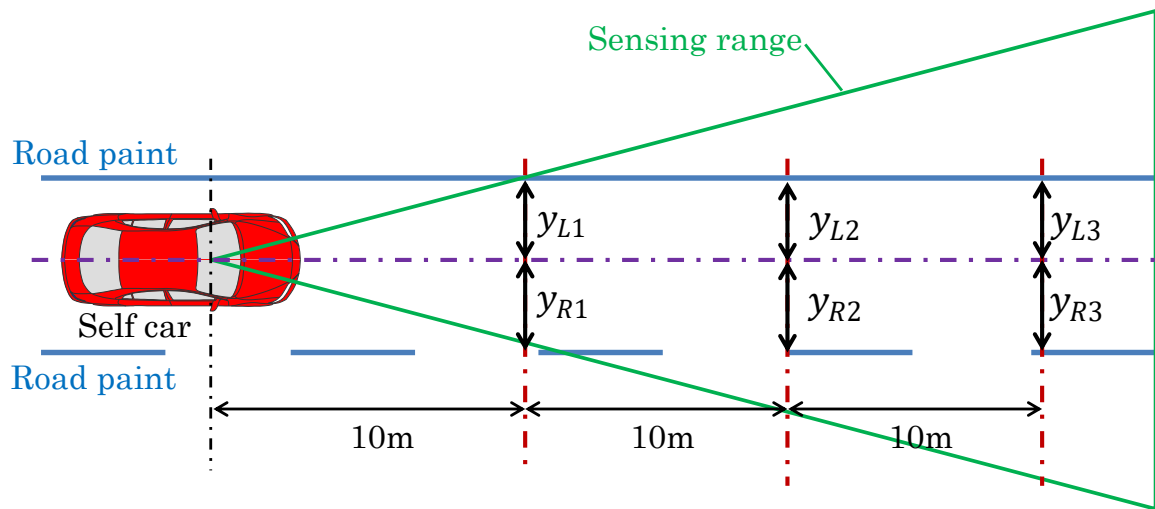


Fig. 2-3 Lane detection image of the Long-range camera.

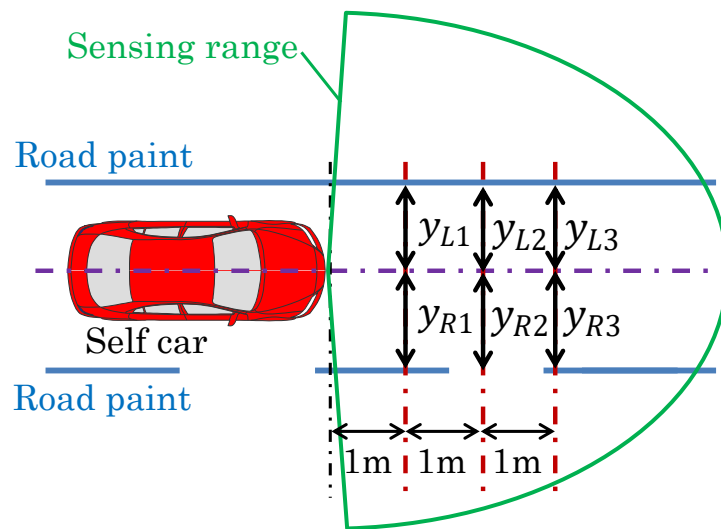


Fig. 2-4 Lane detection image of the Fisheye camera.

両を認識し，物体位置が自車両を基準とする相対座標で出力される。

2.3 地図に基づく自己位置推定手法

2.3.1 自己位置推定技術の動向

本節では，本研究で適用した自己位置推定手法について述べる。2.1 節でも述べた通り，自動運転システムは一般に，自車両の推定自己位置をマップマッチング手法で修正し，将来の走行（目標軌道，速度など）を計画するにあたってデジタル HD (High-

第2章 自動運転システムの概要

definition) 地図を必要とする [44]。1.2.5 項でも述べたように、HD 地図を用いた自動運転システムは走破のためのキーテクノロジーとして注目されるようになっており、さまざまな研究機関や産業界により地図に関する技術開発が行われ、現在ではテストコースだけでなく公道における自動運転車の実車走行試験が広く行われている [45] [46]。自動運転において、地図技術がここまで注目を浴びている理由の一つとして、今日広く普及している人工衛星を用いた全世界測位システム (GPS/GNSS: global positioning system / global navigating satellite system) の測位精度が挙げられる。例えばカーナビゲーションシステムは GPS/GNSS を用いて自車の位置を取得し、地図を用いてドライバに経路を案内するシステムであるが、その測位精度は衛星との通信状況により数 m ほどの誤差は頻繁に生じ、トンネル内や高層建築物の付近などではさらに精度が悪化する [47]。自動運転システムへの適用を考えるにあたり、自車両は複数レーンのうちどの車線を走行しているかを正確に把握する必要がある。すなわち数 m の精度では不十分であり、GPS/GNSS より高精度な自己位置推定技術が求められる。それゆえ、HD 地図が自車両の位置推定 (修正) に広く使われるようになってきている。

自車両の自己位置推定や経路計画に必要な地図を自動生成する研究では、自律移動ロボットの分野が先行している。自己位置推定や地図構築はセンサデータに基づいて行われ、センサデータは不確実性が伴うため、ベイズフィルタ (カルマンフィルタ, パーティクルフィルタ等) を用いた確率的推定手法が主流である [48]。

地図生成の原理は、車両に搭載されたセンサ情報を取得し、それらセンサ情報を車両の位置で座標変化することで、地図座標系におけるランドマーク地図を生成するというものである。その際、自己位置をオドメトリ (動作モデル) だけで推定すると累積誤差が生じるため、ランドマークの計測による自己位置修正が必要である。ところが、ランドマークを乗せた地図はこれから作るものであり、今は存在しないというパラドックスを抱えている。したがって、自己位置推定と地図生成を同時に行う、SLAM (Simultaneous Localization and Mapping) という枠組みを用いた地図生成手法が主流である [48]。

現在、自動運転システムにおいて主流となっているのは、自車両周辺の道路環境や物体形状を高精度に取得可能なレーザスキャナ (LiDAR: Light Imaging Detection And Ranging) を用いた地図生成および自己位置推定である。LiDAR はセンサから赤外光などの電磁波をレーザとして照射し、反射して戻ってくるまでの時間を用いて物体位

置 (3D 形状) を計測するセンサであり, 一般に周辺の物体形状を点群として取得可能である。LiDAR による点群情報をあらかじめ作成していた点群地図と照らし合わせ, 自身の位置や向きを修正する ICP (Iterative Closest Point) [49], パーティクルフィルタ [50] [51], Normal Distribution Transform (NDT) [52]などの各種アルゴリズムが提案されており, ICP による自己位置推定をベースとした自動運転システムは広く報告されている [53] [54]。パーティクルフィルタに関しては, 自車位置だけでなくセンシング対象である白線位置自体にも適用する例も報告されている [55]。その他, Monte-Carlo localization [56], Fourier-Mellin transformation [57]などを用いて自己位置推定の精度やロバスト性を向上する研究も報告されている。また, LiDAR をセンシングに用いることで, 周辺の物体だけでなく路面上の白線などのレーンマーカも取得可能である [58] [59]。これは, 照射対象のレーザ光線の反射率が路面と白線で異なることを利用しており, LiDAR を用いて 3D 点群情報だけでなく白線をランドマーク地図に利用する研究も報告されている [60]。原らは, 点群で生成された地図情報から路面上の白線や路端などの直線情報 (エッジ) を抽出する手法を提案している [61]。

このように, 自動運転システムにおいて地図情報を用いた自己位置推定は本研究においても必要不可欠であり, 次項からは本研究で適用した自己位置推定手法について詳しく述べる。

2.3.2 ランドマーク地図に基づく自己位置推定手法

本研究において, カルマンフィルタによる自己位置推定手法 [62] を適用した。カルマンフィルタを用いた自己位置推定は菅沼らの研究グループにより自動運転制御に適用されるなど [63], 自動運転システムでの適用例が多数報告されている。本手法は車両のオドメトリを用いた自己位置予測, GPS による自己位置修正, ランドマーク (マップマッチング) に基づく自己位置修正という 3つのステップに分けられる。以下, それぞれについて述べる。




Fig. 2-5 Absolute coordinates of self-car for Kalman filter.

なお、本章において、自車両の状態（座標および進行角）は Fig. 2-5 の通り定義する。グローバル座標系を、ある地点を基準とする直交座標系に変換し、東西方向を x 軸、南北方向を y 軸、 x 軸に対して自車両の進行角（向いている方向）を θ とする。また、添え字の k 、は離散時間システムにおいて制御開始から k 番目のサンプルであることを表す。そして、自車両の状態ベクトル μ_k を式(1)の通り定義する。

$$\mu_k = [x_k, y_k, \theta_k, O_{x,k}, O_{y,k}]^T \quad \dots \quad (1)$$

ここで、 $O_{x,k}$ 、 $O_{y,k}$ はそれぞれ x 方向、 y 方向について、GPS と地図座標のオフセット量を表す。

まず、オドメトリ（速度の積分）に基づく自己位置の予測を行う。次サンプル $k+1$ における自車の状態ベクトル予測値 μ_{k+1} および状態ベクトルの誤差共分散行列 Σ_{k+1} は、それぞれ式(2)および式(3)により推定する。

$$\mu_{k+1} = \begin{bmatrix} x_{k+1} \\ y_{k+1} \\ \theta_{k+1} \\ O_{x,k+1} \\ O_{y,k+1} \end{bmatrix} = \begin{bmatrix} x_k + v_k \cos \theta_k \Delta t \\ y_k + v_k \sin \theta_k \Delta t \\ \theta_k + \omega_k \Delta t \\ O_{xk} \\ O_{yk} \end{bmatrix} \quad \dots \quad (2)$$

$$\Sigma_{k+1} = G \Sigma_k G^T + V M V^T + P \quad \dots \quad (3)$$

ここで Δt はサンプル時間、 v_k は自車両の現在の車速、 ω_k は自車両の現在の角速度（ヨーレート：重心点まわりの回転速度）を表す。また、位置情報および車速・角速度の入力情報に分けたヤコビ行列 G 、 V 、位置情報および車速・角速度の入力情報に関する

誤差共分散行列 M , P はそれぞれ式(4), 式(5)の通りである。ただし, 行列 M , P における σ はそれぞれの要素に対する共分散を表す定数である。

$$G = \begin{bmatrix} 1 & 0 & -v_k \sin \theta_k \Delta t & 0 & 0 \\ 0 & 1 & v_k \cos \theta_k \Delta t & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}, \quad V = \begin{bmatrix} \cos \theta_k \Delta t & 0 \\ \sin \theta_k \Delta t & 0 \\ 0 & \Delta t \\ 0 & 0 \\ 0 & 0 \end{bmatrix}, \quad \dots \quad (4)$$

$$M = \begin{bmatrix} \sigma_v^2 & 0 \\ 0 & \sigma_\omega^2 \end{bmatrix}, \quad P = \text{diag}(\sigma_x^2, \sigma_y^2, \sigma_\theta^2, \sigma_{\dot{x}}^2, \sigma_{\dot{y}}^2) \quad \dots \quad (5)$$

ここで述べたオドメトリによる自己位置予測では, 誤差共分散が単調増加する。したがって, GPS 情報が取れる場合に, GPS による自己位置の修正を行う。サンプル k における自車の状態ベクトル μ_k の更新値 μ_c , および状態ベクトルの誤差共分散行列 Σ_k の更新値 Σ_c は, それぞれ式(6)および式(7)の通り算出する。

$$\mu_c = \mu_k + K(Z_k - Z_e) \quad \dots \quad (6)$$

$$\Sigma_c = (1 - KH)\Sigma_k \quad \dots \quad (7)$$

ここで, Z_k はサンプル k における観測値のベクトルであり, 式(8)の通り定義される。ただし, $x_{GPS}, y_{GPS}, \theta_{GPS}$ はそれぞれ GPS により観測した自車両の x 座標, y 座標および進行角 θ である。

$$Z_k = [x_{GPS}, y_{GPS}, \theta_{GPS}]^T \quad \dots \quad (8)$$

また, K はカルマンゲイン, H は観測値のヤコビ行列を表しており, それぞれ式(9), 式(10)式の通り算出する。ただし Q_k はサンプル k における観測値の誤差共分散行列を表しており, Q_k における σ はそれぞれの要素に対する共分散を表す定数である。

$$K = \Sigma_k H^T S^{-1}, \quad S = H \Sigma_k H^T + Q_k \quad \dots \quad (9)$$




Fig. 2-6 Coordinates for line landmark matching.

$$Q_k = \begin{bmatrix} \sigma_x^2 & 0 & 0 \\ 0 & \sigma_y^2 & 0 \\ 0 & 0 & \sigma_\theta^2 \end{bmatrix}, \quad H = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix} \quad \dots \quad (10)$$

次に、白線を線ランドマークとして、自己位置修正を行う。自車両の状態ベクトル μ_k を式(1)と同様に定義する。いま、自車両が状態ベクトル μ_k の状態にあり、自車両に取り付けられたセンサにより、白線が Fig. 2-6 に示す通り得られたとする。すなわち、自車両から白線までの距離 r と、自車両と白線とのなす角 ϕ が観測できたと想定する。また、白線の情報があらかじめ地図に登録されており、その関係式は既知の定数 c を用いて式(11)で表せるとする。

$$-x \sin \alpha + y \cos \alpha + c = 0 \quad \dots \quad (11)$$

点と直線の距離の公式および角度の関係から、式(12)に示す関係式が成立する。

$$\begin{aligned} |-x \sin \alpha + y \cos \alpha + c| - r &= 0 \\ (\alpha - \theta) - \phi &= 0 \end{aligned} \quad \dots \quad (12)$$

このとき、サンプル k における自車の状態ベクトル μ_k の更新値 μ_c 、および状態ベクトルの誤差共分散行列 Σ_k の更新値 Σ_c は、それぞれ式(13)および式(14)の通り算出する。

$$\mu_c = \mu_k + K(Z_k - Z_e) \quad \dots \quad (13)$$

$$\Sigma_c = (1 - KH_{\text{line}})\Sigma_k \quad \dots \quad (14)$$

ここで、 Z_k はサンプル k における観測値のベクトルであり、式(15)の通り定義される。

$$Z_k = \begin{bmatrix} r \\ \phi \end{bmatrix} \quad \dots \quad (15)$$

また、 K はカルマンゲイン、 Z_e はサンプル k における状態を元に予測した観測値のベクトル、 H_{line} は観測予測値 Z_e のヤコビ行列を表しており、それぞれ式(16)、式(17)の通り算出する。ただし Q_{line} は観測値の誤差共分散行列を表しており、 Q_{line} における σ はそれぞれの要素に対する共分散を表す定数である。

$$K = \Sigma_k H_{\text{line}}^T S^{-1} \quad \dots \quad (16)$$

$$S = \text{line} \Sigma_k H_{\text{line}}^T + Q_{\text{line}}$$

$$Q_{\text{line}} = \begin{bmatrix} \sigma_r^2 & 0 \\ 0 & \sigma_\phi^2 \end{bmatrix}, \quad Z_e =$$

$$\begin{bmatrix} -(x_k + O_{x,k}) \sin \alpha + (y_k + O_{y,k}) \cos \alpha + c \\ \alpha - \theta \end{bmatrix} \quad \dots \quad (17)$$

$$H_{\text{line}} = \begin{bmatrix} -\sin \alpha & \cos \alpha & 0 & -\sin \alpha & \cos \alpha \\ 0 & 0 & -1 & 0 & 0 \end{bmatrix}$$

2.3.3 自車両周辺の静止物体に基づく自己位置推定

次に、LiDAR や Fisheye camera で検出する自車両周辺の静止物位置（形状）の点群を地図に登録し、センシングした点群と地図とのマッチングに基づき自己位置推定を行う一般的な手法について述べる。前項では、左右の白線位置を地図情報として利用しており、ある程度ランドマークとして固定されているものであるため線ランドマー

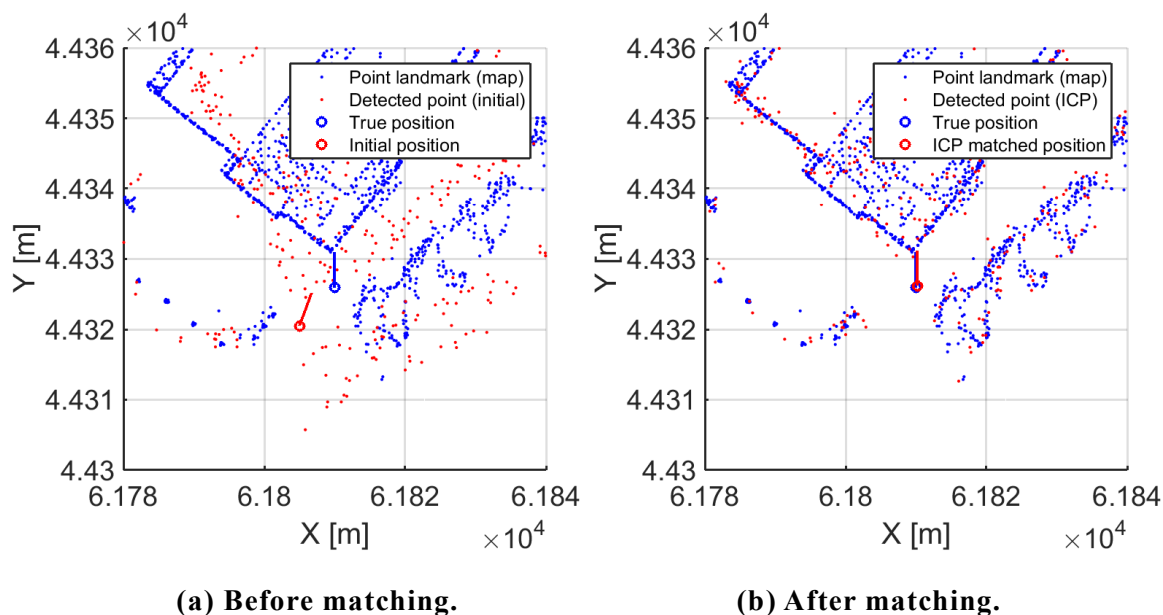


Fig. 2-7 A matching example of ICP.

クマッチングを利用して位置を補正していた。しかし、地図に登録される情報とセンシングされた物体が同一であると常に識別可能であるとは限らず、「大まかにこの場所付近に何かある」程度の情報であることも多い。このような課題に対し、繰り返し計算に基づき大域的に最も確からしい自己位置を見つける ICP (Iterative Closest Point) マッチングアルゴリズムを適用した。

ICP マッチングは、2つの点群情報を用意し、片方の点群をもう片方の点群に最もフィットするために、片方の点群をどれだけ移動すればよいかを計算するアルゴリズムである。今回の場合、2つの点群情報として、①センサ情報（現在位置からの相対座標系）、②地図情報（自己位置推定結果を基に相対座標へ変換したもの）を用いる。この場合、地図を変換した際に用いた自己位置推定結果に誤差が含まれると仮定しているため、地図情報がセンサ情報に合うように移動量を算出して自己位置推定結果を修正している。

Fig. 2-7 は ICP に基づく自己位置修正の一例を示す概要図である。ここではダミーの点群データを用いており、青点は地図に登録された点群情報、赤点はセンサで検出した点群情報を模擬している。赤点は青点からデータ数を間引いたうえ、ランダムノイズを付加している。図の中央付近に描画されている、丸に実線が接続された図形は、

自車両の位置および進行角を示しており、それぞれ青色は真値を、赤色はマッチング前後の自車両位置を示している。

Fig. 2-7(a)はマッチング前の状態を示す。ここでは青点と赤点をあえてずらしており、これは前節までに述べたオドメトリおよびGPSによる自車位置修正に誤差が生じている場合を模擬している。ICPマッチングでは、地図上の点群（ここでは青の点群）とセンサで検出した点群（赤の点群）を比較し、大局的に（統計的に）一致度を最大化するような並進及び回転の偏差を算出する。算出された並進および回転偏差に基づき、赤色で表示した自車両位置を修正することで、Fig. 2-7(b)に示すように青の点群と赤の点群がおよそ一致し、自車両位置が修正される。

ICPマッチングの計算式を以下に示す。まず、式(18)～式(22)により地図情報の各点を現在の自己位置推定結果を基に相対座標へ変換する。

$$dx = map_x - loc_x \quad \dots \quad (18)$$

$$dy = map_y - loc_y \quad \dots \quad (19)$$

$$angle = -loc_{yaw} \quad \dots \quad (20)$$

$$map_{rel_x} = dx * \cos(angle) - dy * \sin(angle) \quad \dots \quad (21)$$

$$map_{rel_y} = dx * \sin(angle) + dy * \cos(angle) \quad \dots \quad (22)$$

ここで、 loc_x, loc_y, loc_{yaw} は自己位置推定結果 (x, y, θ) 、 map_x, map_y は絶対座標における地図情報 (x, y) 、 map_{rel_x}, map_{rel_y} は現在の推定位置を用いて相対座標に変換した地図情報 (x, y) を示す。

次に、センサの点群と地図情報を相対位置化した地図点群の最近傍探索を行う。すなわち、センサ点群と地図点群の確定について、互いに距離が最も小さい点の組を抽出する。この最近傍探索の結果、対応しているとみなして抽出された組の距離の総和を収束判定（合計値が変化しなくなった場合収束したとして判定）に用いている。収束していない場合、最近傍探索によって求めた対応関係を基に、以下に述べる特異値分解により移動量（回転および並進移動）を算出する。

まず、式(23)～式(25)より、センサと地図それぞれの点群における重心位置を算出する。

$$\mathbf{SENSOR} = \begin{bmatrix} sensor_x \\ sensor_y \end{bmatrix}, \mathbf{MAP} = \begin{bmatrix} map_{rel_x} \\ map_{rel_y} \end{bmatrix} \quad \dots \quad (23)$$

$$\mu_{sensor} = \frac{1}{N_{sensor}} \sum_{i=1}^{N_{sensor}} \mathbf{SENSOR} \quad \dots \quad (24)$$

$$\mu_{map} = \frac{1}{N_{map}} \sum_{i=1}^{N_{map}} \mathbf{MAP} \quad \dots \quad (25)$$

ここで、 $sensor_x, sensor_y$ はセンサ情報 (x, y) (相対座標値)を示す。次に、式(26)および式(27)に基づき、それぞれの重心位置の座標系へ平行移動させる。

$$\mathbf{SENSOR}_{shifted} = \{\mathbf{SENSOR}_i - \mu_{sensor}\}_{i=1, \dots, N_{sensor}} \quad \dots \quad (26)$$

$$\mathbf{MAP}_{shifted} = \{\mathbf{MAP}_i - \mu_{map}\}_{i=1, \dots, N_{map}} \quad \dots \quad (27)$$

そして、式(28)～式(30)をもとに特異値分解を実施し、並進移動量と回転量を算出する。

$$[U \ S \ V] = \text{SVD}(\mathbf{SENSOR}_{shifted} \cdot \mathbf{MAP}_{shifted}^T) \quad \dots \quad (28)$$

$$\mathbf{R} = \mathbf{U} \cdot \mathbf{V}^T \quad \dots \quad (29)$$

$$\mathbf{t} = \mu_{sensor} - \mathbf{R}\mu_{map} \quad \dots \quad (30)$$

ここで SVD は特異値分解の関数を表している。また、 \mathbf{R} は回転量、 \mathbf{t} は並進移動量を表す。得られた回転量および並進移動量に基づき、式(31)～式(33)に従って、算出した移動量を地図データに適用し、地図データの位置関係の更新及びこれまでの移動量の更新を行う。

$$\mathbf{MAP}' = \mathbf{R} \cdot \mathbf{MAP} + \mathbf{t} \quad \dots \quad (31)$$

$$\mathbf{R}'_{all} = \mathbf{R} \cdot \mathbf{R}_{all} \quad \dots \quad (32)$$

$$\mathbf{t}_{all} = \mathbf{R} \cdot \mathbf{t}_{all} + \mathbf{t} \quad \dots \quad (33)$$

ここで \mathbf{MAP} は移動後の地図点群(相対座標値), \mathbf{R}_{all} は回転量の総和 (\mathbf{R}'_{all} は移動後の回転量), \mathbf{t}_{all} は並進移動量の総和を示している。

更新した地図データを基に再度最近傍探索を実施し, 誤差の変化が閾値以内, または繰り返し回数の上限に達するまで同じ処理を行う。収束した場合, 蓄積しておいた移動量を基に位置の修正を行い, ICP マッチングによる位置推定結果として位置を出力する。移動量を基の位置推定結果に適用させる式を式(34)~式(37)に示す。

$$\mathbf{yawVec} = \mathbf{R}_{all} \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad \dots \quad (34)$$

$$ICP_{yaw} = loc_{yaw} - atan2(\mathbf{yawVec}_y, \mathbf{yawVec}_x) \quad \dots \quad (35)$$

$$ICP_x = loc_x - (t_{all_x} \cos(ICP_{yaw}) - t_{all_y} \sin(ICP_{yaw})) \quad \dots \quad (36)$$

$$ICP_y = loc_y - (t_{all_x} \sin(ICP_{yaw}) + t_{all_y} \cos(ICP_{yaw})) \quad \dots \quad (37)$$

次に, 静止物体 (点群) に対して一般的に行われている地図生成手法について述べる。本稿では, Fisheye camera や LiDAR で検出した静止物位置を点群として地図に登録する白線地図生成手法を適用する。前述の通り, ロボティクスの分野では LiDAR 等のセンサを用いた SLAM (Simultaneous Localization and Mapping) に基づく地図生成および自己位置推定の手法が研究されており [48], 本稿でも同様の考え方に基づく地図生成手法を構築した。

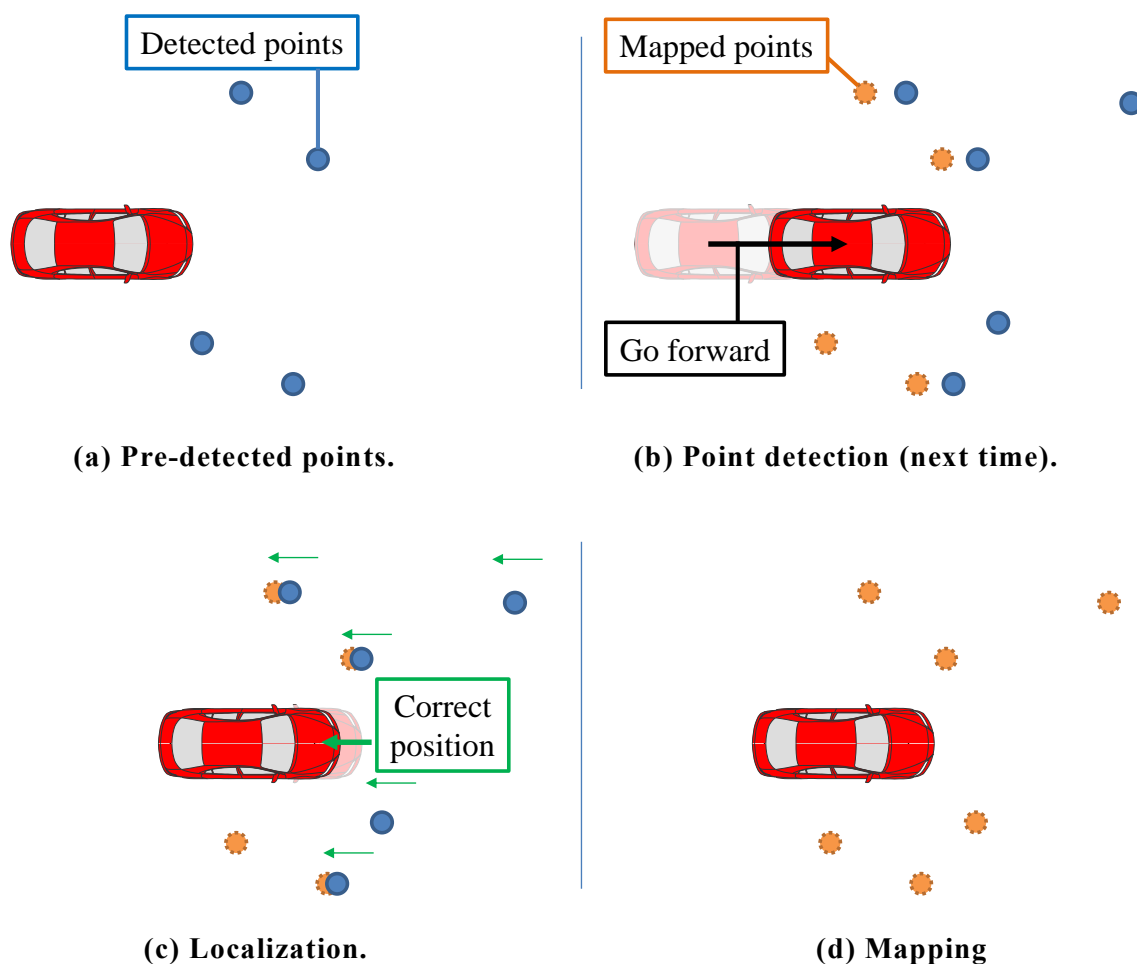


Fig. 2-8 Steps of SLAM (simultaneous localization and mapping).

以下，Fig. 2-8 を用いて SLAM の概要を示す。Fig. 2-8(a)は，初めて地図を作る際のステップであり，自車両前方に存在する静止物を検出し，自車両を基準とする相対座標系からグローバル座標系に変換し，地図として記憶する。次に，Fig. 2-8(b)から，SLAM は 3 つのステップに分かれる。Fig. 2-8(b)は 1 つめのステップであり，自車両前方に存在する静止物を検出し，自車両を基準とする相対座標系からグローバル座標系に変換する。そして，Fig. 2-8(c)は 2 つめのステップであり，地図として蓄積した白線位置を線ランドマークとして，前節で延べた ICP を用いて自車両の位置を修正し，修正した自己位置に基づき，グローバル座標における静止物の位置を修正する。最後に，Fig. 2-8(d)は 3 つめのステップであり，静止物の位置を点群地図として追加（統合）する。このように，SLAM は 3 つのステップにより自動運転用地図を生成する。

Fig. 2-8 で示した SLAM を制御周期ごとに繰り返すことにより，点群による自動運

転用地図を生成可能である。以下、LiDAR および Fisheye camera を用いた SLAM の動作結果例を示す。まず、Fig. 2-9 は敷地内において手動走行で LiDAR による点群地図生成を行った過程および結果を示す。Fig. 2-9(a)は地図生成の初期段階、Fig. 2-9(b)は経路のほぼ中間地点、Fig. 2-9(c)は経路を一周した後の地図である。長方形および実線は自車両位置および走行軌跡を表しており、点の集合は拡張した地図を表している。走行するごとに、地図の存在する領域が拡張している様子が見て取れる。

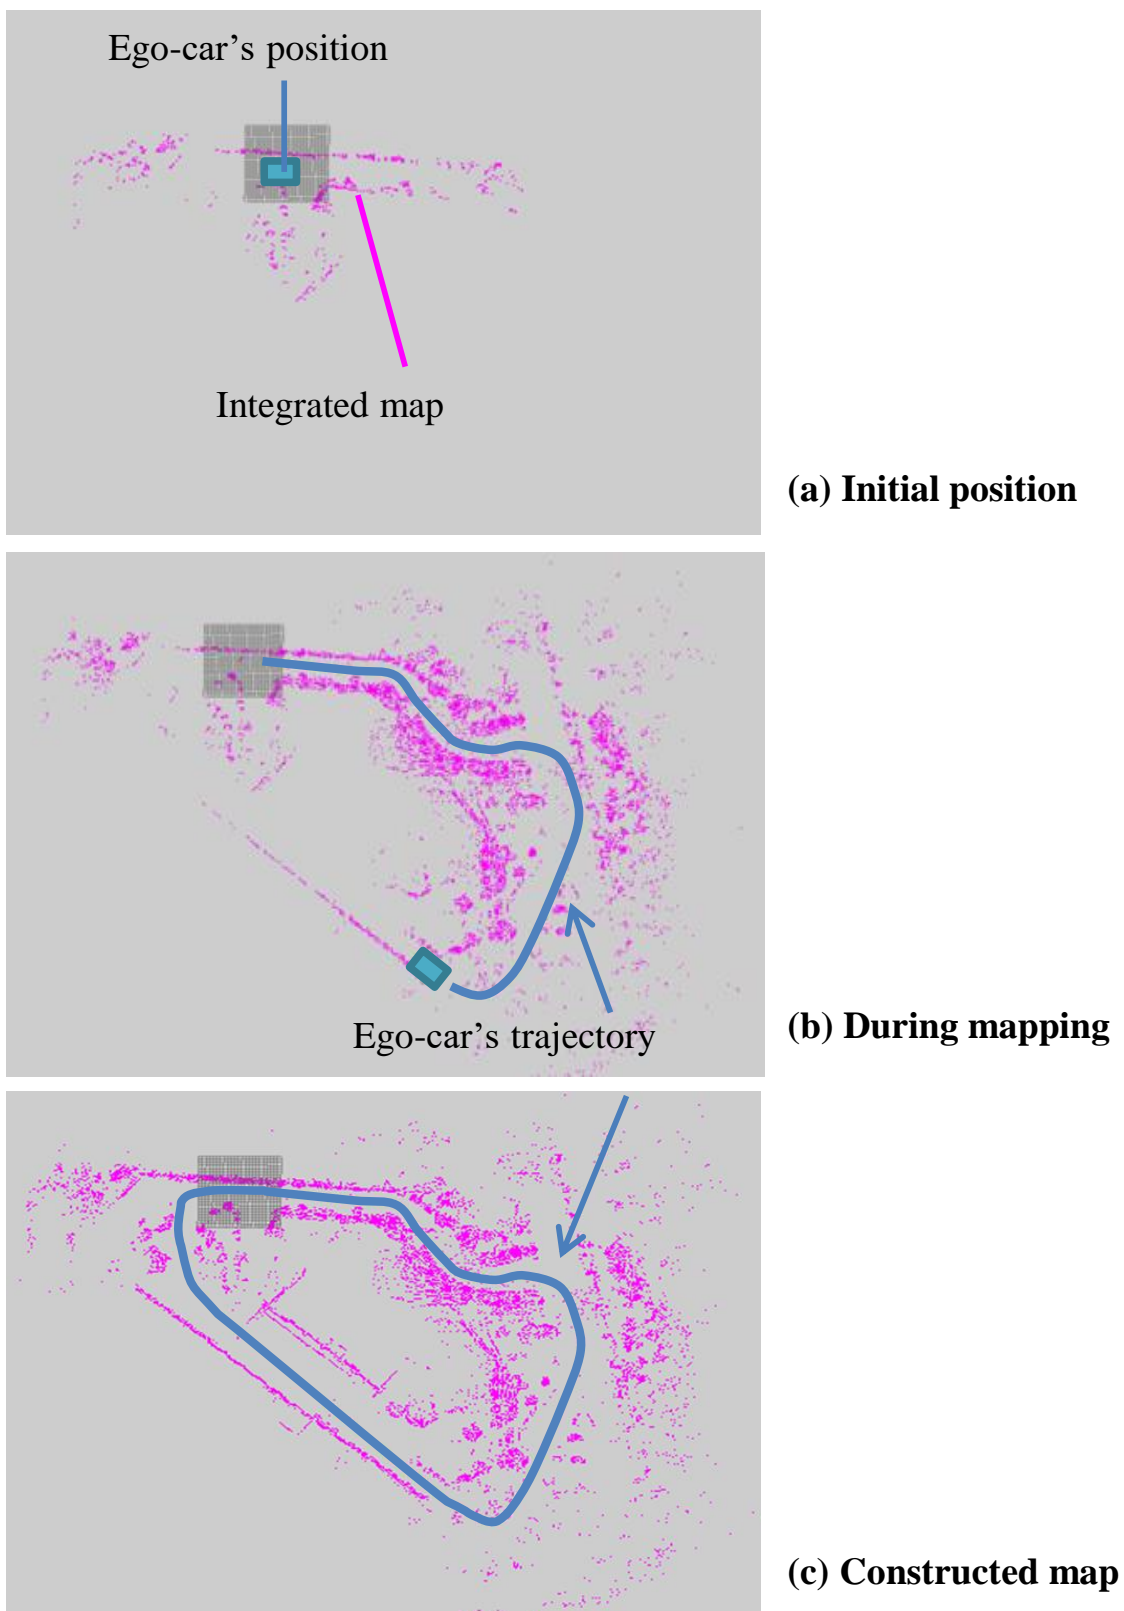
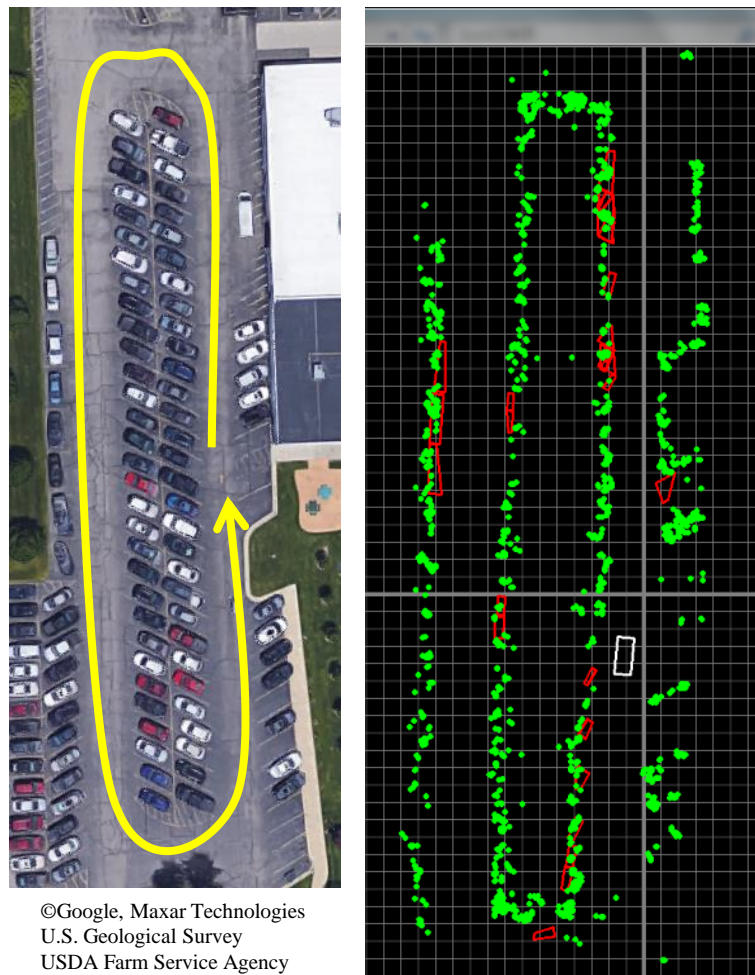


Fig. 2-9 An example of SLAM with a LiDAR.




(a) Bird-view of the parking lot. (b) Static object detection result.

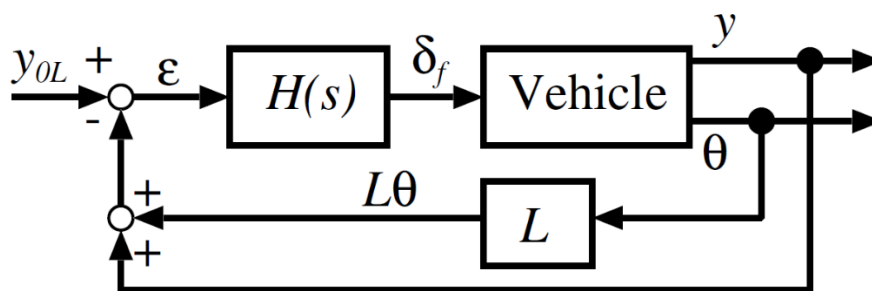
Fig. 2-10 Static-object detection result of the parking area with Fisheye camera.

次に、Fig. 2-10 は、敷地内の駐車場を手動走行した際の、Fisheye camera から得られた検出情報を統合してプロットしたものである。Fig. 2-10(a)は駐車場の航空写真を示しており、走行ルートは黄色の実線で表示している。Fig. 2-10(b)は検出情報の統合プロットであり、緑点は検出した物体位置、赤線は検出した駐車枠を示している。緑点はほぼ全域にわたって存在する一方、赤線は局所的に存在する程度である。ただし、本データは駐車車両が多い昼間に取得したものであり、駐車車両が居なくなる早朝、夕方以降および休日は静止物体位置（緑点）の量が急減する。

このように、LiDAR やカメラなど自車両周辺の静止物体を検出可能なセンサを用いることで、自動運転に必要な地図を生成可能である。



(a) Concept



(b) Block diagram

Fig. 2-11 “Look-forward” model for steering operation [64]

2.4 自動運転に必要な操舵制御設計

本節では、自動運転にあたって必要となる操舵制御設計について述べる。まず 2.4.1 項では、目標軌道に追従するための制御モデルを前方注視モデルに基づき構築する。次に 2.4.2 項では、操舵角指令値に対して外付けモータの角度サーボを行う手法について述べる。

2.4.1 軌道追従制御設計

目標コースに沿った操舵を行うシンプルな制御モデルとして、前方注視モデルが一般に知られている [64]。このモデルは人が自動車を運転する際の制御モデルとして検討されてきたものである。Fig. 2-11 を用いて前方注視モデルの概要を説明する。

Fig. 2-11(a)に示すように、ドライバは進路方向に前方注視距離 L だけ離れた前方注視点を見ている。この点における目標コースとの誤差を小さくする方向に操舵を行う。前方注視点の座標を y_{0L} とおけば、ヨー角 θ を微小として、車両の進路と目標コースとの誤差 ϵ は式(38)のようになる。

$$\epsilon = y_{0L} - (y + L\theta) \quad \dots \quad (38)$$

ドライバが行うフィードバック制御のコントローラにあたる部分を $H(s)$ とすると、ドライバモデルのブロック図は Fig. 2-11(b)のようになる。前方注視距離 L は速度の単調増加関数と考えられる。そこで、ドライバは T_d [sec] 後に通過する地点を見ていると考え、 $L = T_d V$ とする。 T_d を予見時間と呼ぶ。一般に、前方注視モデルでドライバの動きを模擬する際は $H(s)$ に時間遅れ等の項を入れることが多いが、本稿では操舵制御に用いることから、制御安定性も考慮して $H(s)$ は単純に比例制御器とする。

ここで述べた手法では、操舵角 δ_f が目標軌道と自車両位置の偏差によって算出されるため、カーブを走行中は常に目標軌道との偏差が生じるという問題がある。そこで本稿では、偏差のフィードバックに加え、目標軌道から曲率を算出し、操舵角に変換してフィードフォワード補償を行う。なお、この考え方はプログラム操舵モデルとしてすでに提案されている [64]。

自車両の速度および操舵角があまり大きくない領域において、ニュートラルステアを仮定すると、自車両の速度 V および曲率 ρ から操舵角 $\delta_{f,FF}$ は式(39)の通り求まる。

$$\delta_{f,FF} = V\rho \quad \dots \quad (39)$$

したがって、目標軌道から曲率の指令値 ρ_{ref} を算出し、自車両速度を乗ずることでフィードフォワード量を算出する。

Fig. 2-12 を用いて曲率の算出方法について述べる。図中で黒丸は自車両の目標軌道の点列を表している。自車両の現在位置を原点にとり、現在位置に最も近い目標軌道方向を x 軸としている。曲率算出にあたっては、道路が直線部から曲線部に遷移する場合を想定する必要がある。すなわち、長い距離範囲での目標軌道に基づく曲率を算出すると、自車両はまだ直線部にいるにもかかわらず、曲線部に影響されて過剰に




Fig. 2-12 Calculation of reference curvature

大きい曲率が算出される可能性がある。一方、過剰に短い距離範囲で曲率を算出すると、目標軌道に凹凸があった場合に曲率の算出値が急激に変化し、操舵角が不安定となる可能性がある。したがって、ここでは曲率算出に用いる軌道長の上限 x_{max} を速度に応じて決定するものとする。

図中の θ_N は、上限 x_{max} の範囲内で最も遠い距離にある軌道点列において、一つ前の点列と当該点列を結ぶ直線の向きを表す。また、最も遠い距離にある軌道点列の x 座標を x_N としている。自車両の直近の進行方向は x 軸方向であるから、自車両が距離 x_N 進んだ際の進行角の変化が θ_N となる。曲率は一般に、接線方向角度を軌道長で微分したものである。したがって、曲率が微小な領域では、近似的に接線方向角度を軌道長で除することにより曲率が得られる。このことから、曲率 ρ を下式により算出する。

$$\rho = \theta_N / x_N \quad \dots \quad (40)$$

以上、式(39)及び式(40)によりフィードフォワード補償量が算出される。このとき、フィードフォワード補償がすでに前方の目標軌道の曲率を考慮しているため、フィードバックでは現在の自車両の目標軌道からの偏差のみを考慮することで、制御をシンプルかつロバストにする。具体的には、式(38)の代わりに式(41)をフィードバックに用いる。

$$\epsilon = \Delta y + L\Delta\theta \quad \dots \quad (41)$$

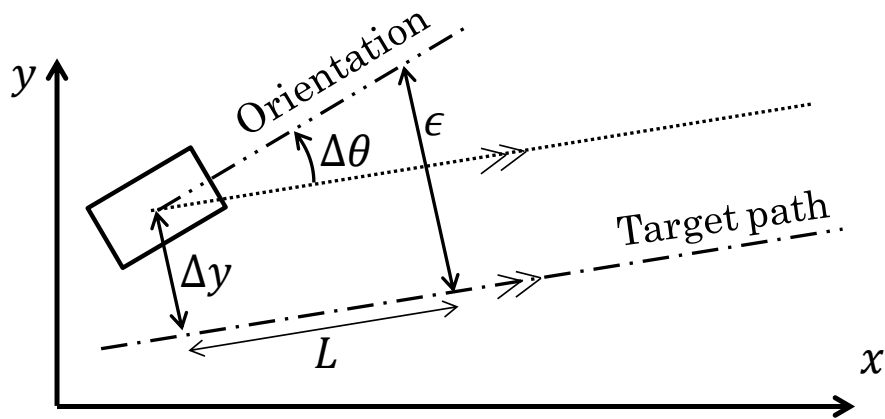


Fig. 2-13 Calculation of feed-back amount ϵ

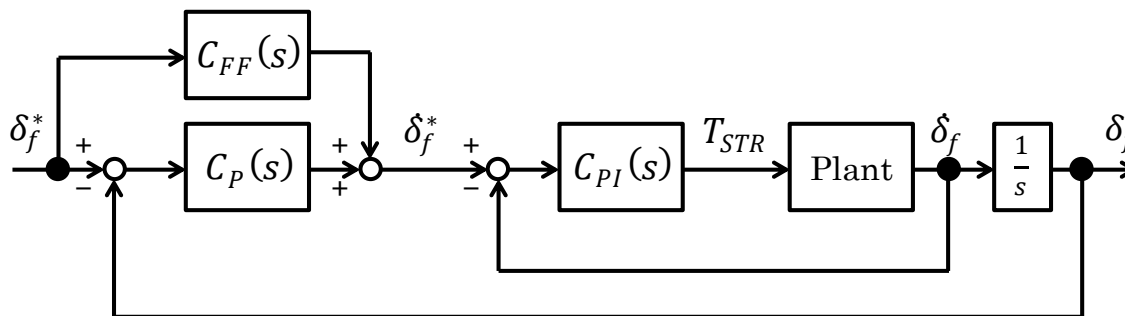


Fig. 2-14 Block diagram of steering angle control.

これは、Fig. 2-13 に示すように、目標軌道が直線であることを仮定した場合の前方注視点における自車両の位置と目標軌道との偏差をあらわす。

2.4.2 操舵角サーボ

本研究で開発した実験車両は、外付けのステアリングモータがトルク指令を受信するようになっている。したがって、角度制御を自前で構築する必要があったため、本章では構築した角度制御について述べる。

一般にモータの角度制御（位置サーボ制御）はフィードバック制御により実現する。本稿では、安定性解析の容易性と制御設計における見通しのよさを考慮し、Fig. 2-14 に示すように、インナーに速度ループ、アウターに角度ループを持つカスケード制御を構築した。この手法の利点としては以下の点が挙げられる。

- インナーループの安定性が確保されている場合、アウターの応答をインナーよ

第2章 自動運転システムの概要

り遅く設定することで安定性が担保される

- アウターの極配置設計は、インナーが理想的に動作していると仮定し、プラントと一体化した一次遅れ系として設計可能

プラントを(s)とおけば、操舵系のプラントは外乱等を見ればイナーシャJの一次系とみなせる。

$$P(s) = 1/Js \quad \dots \quad (42)$$

式(42)で示されるプラントに対し、インナーの速度制御フィードバック比例積分コントローラ $C_{pi}(s)$ は、例えばシンプルに極を重根配置することにより式(43)の通り得られる。ここで ω_p は設定した極を表す。また、インナーに積分特性をもたせたことから、定常外乱の抑圧が不要なアウターループのコントローラ $C_p(s)$ は、式(44)の通り比例コントローラとした。

$$C_{pi}(s) = \frac{(J\omega_p^2 + 2J\omega_p s)}{s} \quad \dots \quad (43)$$

$$C_p(s) = K_p \quad \dots \quad (44)$$

本稿において、Jは操舵用モータのイナーシャ設計値(カタログ値)を用いた。また ω_p 、 K_p はそれぞれ安定して速度制御・角度制御が行えるよう試行錯誤的に決定し、 $\omega_p = 40 \text{ rad/s}$ 、 $K_p = 1.5$ とした。

操舵制御の応答性向上のため、フィードフォワード補償を行っている。フィードフォワードコントローラ $C_{FF}(s)$ は、式(45)の通り擬似微分を用いた。

$$C_{FF}(s) = \frac{s}{\tau s + 1} \quad \dots \quad (45)$$

ここで τ は擬似微分の時定数であり、目安としては制御周期より1桁大きい値に設定する。本稿では制御周期10 msに対し、 $\tau = 0.1 \text{ s}$ とした。

2.5 本章のまとめ

本章では、本研究の対象となる自動運転システムにおいて適用した手法について述べた。まず、本研究に用いる実験車両と、車両に搭載されているセンサ、特に車載カメラについて詳細に示した。次に、自動運転システムの根幹を担う自己位置推定手法を示した。さらに、自動運転において最も基礎的な機能となる操舵角の角度サーボ、前方注視モデルに基づく軌道追従制御等を示した。本研究ではこれらシステムをベースプログラムに適用しつつ、第 4 章以降で述べる提案手法を新たに実装し、実車により検証を進める。

第3章 市街地道路環境における自動運転の課題

3.1 はじめに

本章では、市街地道路環境における自動運転の課題を抽出する。第1章で述べたように、市街地道路環境における自動運転実証試験において、自動運転が継続困難となった状況として、主に以下の点が挙げられている [31]。

- (a) 住居等が立ち並び歩行者等の行き交う人家連坦部等における道路上の路上駐車回避場面
- (b) 狭隘路におけるすれ違い場面
- (c) 歩行者・自転車の回避場面
- (d) 積雪や雑草等を障害物と誤認識し回避した場面
- (e) GPS による自己位置特定ができず、高精度の自己位置推定技術が不可欠となる場面
- (f) LiDAR 等の車載センサを用いた自己位置推定手法では、降雪や霧等の気象条件により機能低下が発生する場面

第1章で述べたように、本研究では(d)(f)のセンシング・認識の課題は将来的に解決されるという前提で、主に判断の部分の課題となる(a)(b)(c)(e)について取り組むこととする。そして本章では、それぞれの課題を深掘りする。まず、3.2節では、(e)の課題に対応して自動運転用地図の生成・整備における課題について示す。そして、3.3節では、(a)(b)(c)の課題に対応して、市街地道路環境が歩行者・自転車の混在環境である点に着目し、そのような道路環境で自動運転を行うにあたって課題を抽出する。課題抽出にあたっては、市街地道路環境で実際に発生した事故一步手前の事象であるヒヤリハットデータに着目する。3.4節では実際にヒヤリハットデータを分類し、自動運転システムが対処する必要があるシーンを抽出して本研究の方向性について述べる。

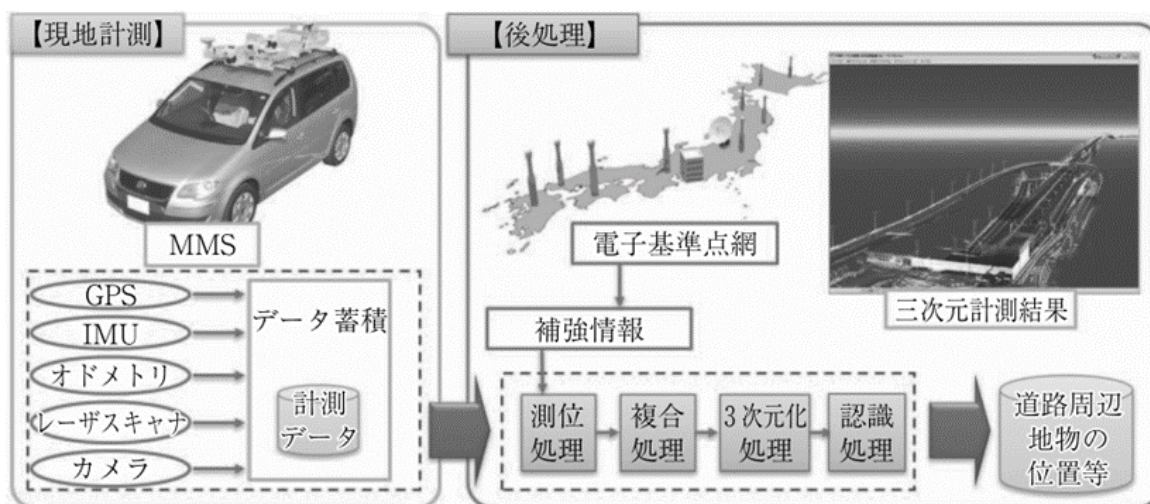



Fig. 3-1 Data processing flow of MMS [67].


3.2 地図生成における課題

まず、自動運転に必要な地図生成・整備および普及に関する課題を述べる。前章で述べたように、自車両周辺のランドマークの位置や形状を記憶した高精度な地図は、自動運転において自己位置を正しく推定し、走行経路を決定するにあたって必須である。内閣府の「戦略的イノベーション創造プログラム」の「自動走行システム」において、高精度地図データベース構築は協調領域と位置付けられており、自動車業界全体として国を挙げて取り組まれている [65]。高精度地図の生成にあたっては、航空映像解析による道路地図生成技術 [66]なども報告されているが、Mobile Mapping System (MMS) を用いて行うことが一般的となっている [67]。

MMS は、GPS、慣性航法装置 (IMU: Inertial Measurement Unit)、レーザスキャナ、カメラ等の各種センサを搭載した専用車両を移動させ、車両周辺の環境情報を計測する移動計測車両システムである。そのデータ処理フローを Fig. 3-1 に示す [67]。まず、MMS は現地計測において各センサ情報をロガーに保存する。そして、計測終了後に解析用 PC で後処理解析を行う。GPS は前後に 2 つ取り付けることで車両の進行角を正確に取得する。また、基準点に固定した GPS 基地局の情報も用いて搬送波位相を利用した干渉即位により、誤差数 cm 単位での自己位置計測を行う。また、GPS がとれ



(a) Overview.



(b) Detailed view.

Fig. 3-2 Example of map near Katsuta station.

ない場所で自車位置を正確に取るため、高精度な IMU センサを用いる。このように、道路形状や道路周辺の情報を正確に計測し、自動運転用地図を生成する。

自動運転用地図の一例として、ある駅前の道路を計測した地図を Fig. 3-2 に示す。Fig. 3-2(a)は広範の領域を示した画像、Fig. 3-2(b)は駅前部分を拡大した画像である。路面上の白線（車線、横断歩道、文字、矢印など）、道路および車線の中央、道路の端

の情報が表示されている。また、画像中には表示されていないが、信号機や標識の位置や種類といった情報も含んでいる。

3.2.1 量産車による地図生成手法と技術的課題

以上述べたように、一般的な地図生成は、MMS のような高精度センサを搭載した専用車両により行う。したがって、初めは高速道路や幹線道路など主要な道路から整備され、地方、郊外、過疎地など利用者の少ない道路、自宅前に通じる細い道路、私有地内では自動運転用地図の整備が後回しになるか、いつまでも整備されない可能性がある。この問題を解決するための一つのソリューションとして、本稿では地図の自動生成アルゴリズムを検討する。

Fig. 3-3 を用いて、本技術により実現したいシステムのコンセプトを説明する。現行の自動運転は、Fig. 3-3(a)に示すように、地図が存在するエリア（a major road with precise map）では自動運転可能であるが、地図が整備されていない領域（ここでは幹線道路から自宅前までの細い道路をイメージしている）では自動運転できない。これでは、自動運転で帰宅する際に自宅近くで必ず手動運転に移行することになり、利用者のニーズや利便性を損なう恐れがある。

この問題に対し、自動運転車をプローブカーとして地図を自動生成することが考えられる。MMS 用の専用車と比べると精度は低いものの、自動運転車は自動運転に必要な GPS や各種センサを備えており、自車両周辺の情報情報を取得可能である。そこで、Fig. 3-3(b)に示すように、ユーザが自動運転可能領域にしたい道路において、ユーザが手動で何度か走行してセンサデータを収集する。収集したセンサデータに基づき自動運転地図を自動で作成することで、Fig. 3-3(c)に示すように、ユーザが自動運転を望む道路での自動運転が可能となる。

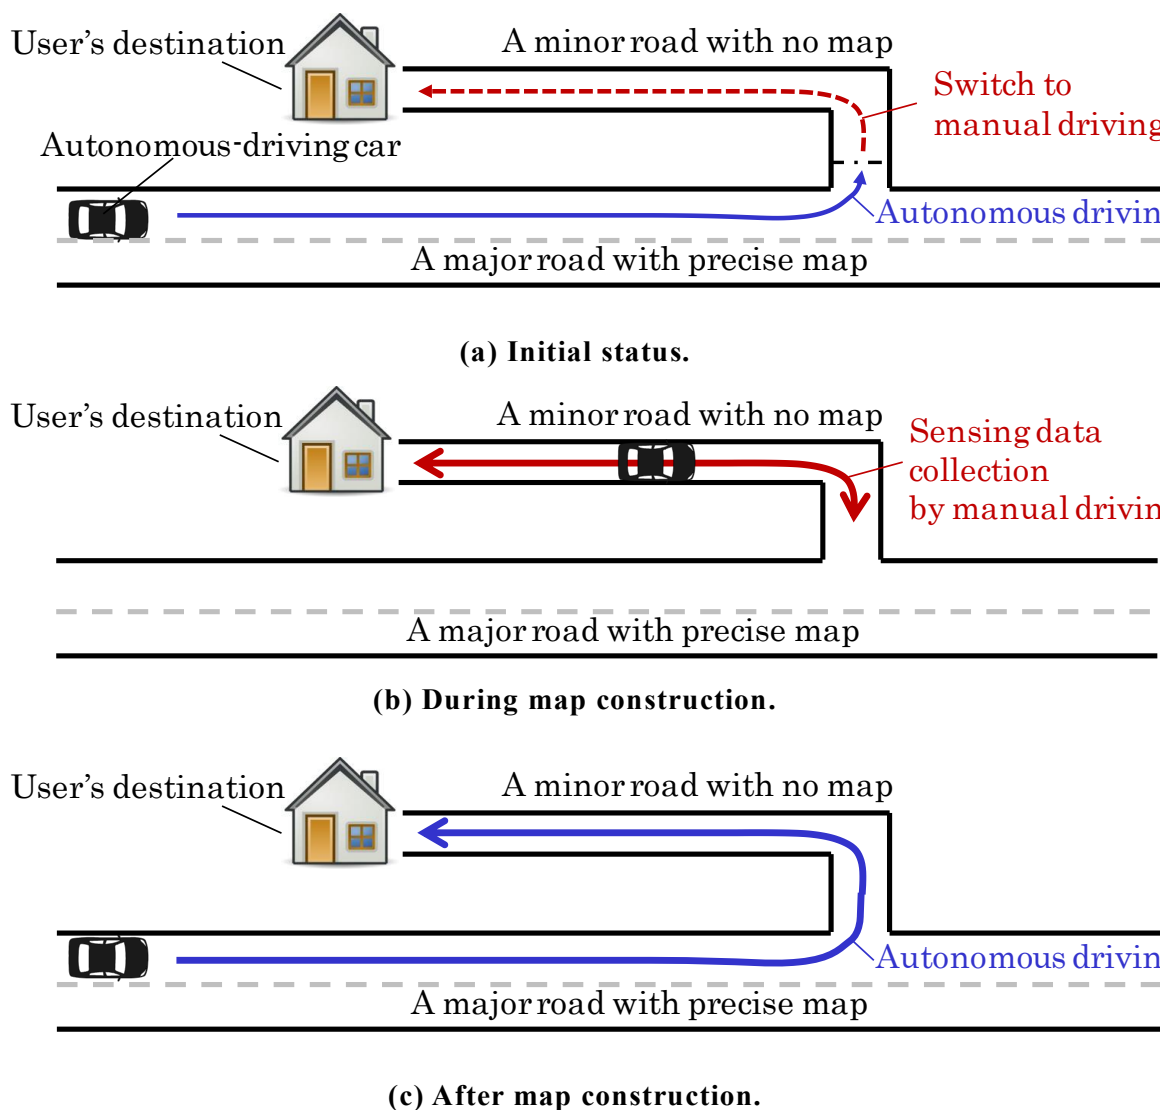


Fig. 3-3 Concept of map construction system.

自動運転車をプローブカーとして地図生成を行う場合、MMS 専用車を用いる場合と比べて、少なくとも以下(1)~(5)の技術課題が発生しうる。

(1) センサの検知精度が必ずしも高くない

プローブカーとして用いる自動運転車は、量産の廉価なセンサが必要最低限量・種類だけ搭載されている可能性がある。計測精度の低さから、対象物の不検知や誤検知が頻繁に発生しうる。また、MMS のように GPS を 2 つも搭載することは考えにくく、自車両の進行角を正確に取得することが難しい。さらに、気象条件や時間帯によってセンサの検知精度や検知内容が異なる可能性もある。

(2) 自己位置推定が困難となる可能性あり

トンネル内、橋の下、高い建物の近くなど、GPSによる自己位置が不正確となる、あるいは全く取得できない場所が存在する。センサ情報はすべて自車両に固定された相対座標系で取得されるため、地図を生成するにあたっては、これらセンサ情報をグローバル座標に変換する必要がある。その際、自車両の位置および進行角が正確に得られていることが必須条件である。しかしながら、本来、自動運転車はGPSが不正確となる場所で正確に自己位置推定を行えるように高精度地図を有するのであり、量産車での地図生成は、高精度地図がない、あるいは作成途中の不完全な状態の地図を用いた自己位置推定を行いながら地図を生成するというパラドックスに陥る。

(3) 生成した地図が自動運転に十分な情報量であるとは限らない

自動運転用の高精度地図は、自動運転車が自己位置推定を行うにあたり十分な情報量を有することが求められる。しかしながら、(1)でも述べた不検知の問題もあり、検知できない物体が多い領域では地図の情報量が不十分となる恐れがある。したがって、生成した地図の情報量や精度を評価し、自動運転の可能性を判定する必要がある。

(4) ユーザは地図修正の専門技術を持たないため、人手による修正はあまり期待できない

MMSでは、地図生成・修正の専門技術を持つ職員による後処理を実施し、不正確となった地図情報を修正して精度を保証している。一方、量産車による地図生成を行う場合、その車両を保有するユーザは地図修正の専門技術を持たない可能性が高い。そのため、人手による修正不要な手法であることが求められ、統計的処理を行うとともに、地図精度の評価を自動で行う必要がある。

(5) 手動走行時のユーザのふらつき、障害物回避の走行軌道がそのまま地図に反映される可能性

本技術は、ユーザの求める場所での自動運転を実現するものであり、ユーザの手動運転により入力された走行軌道に沿って自動運転を行うよう地図を生成する。しかしながら、ユーザの運転技量にはばらつきがあり、過度にふらつくユーザが存在する。そのような状況下でも安定して自動運転を行うために、生成した地図の統計的処理手法の確立を要する。また、その時にたまたま存在した

第3章 市街地道路環境における自動運転の課題

障害物を回避するための操舵なのか、常に存在する障害物（静止物）を避けての操舵なのかを判定する必要がある。

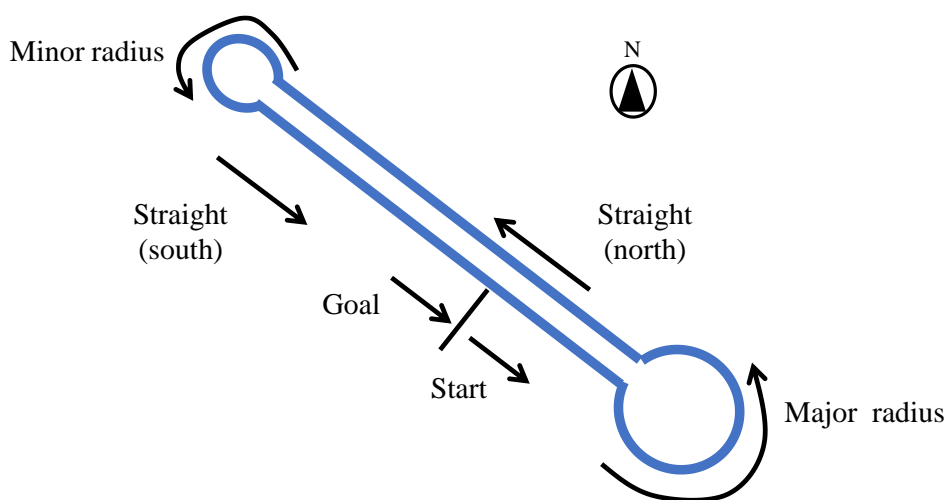
本節では、以上述べた課題のうち、(1)(2)について検討を行う。(3)(4)については4.3節および第5章で検討する。なお、(5)については実用面の課題として本稿では検討対象から除外する。

3.2.2 実験車における地図生成の課題

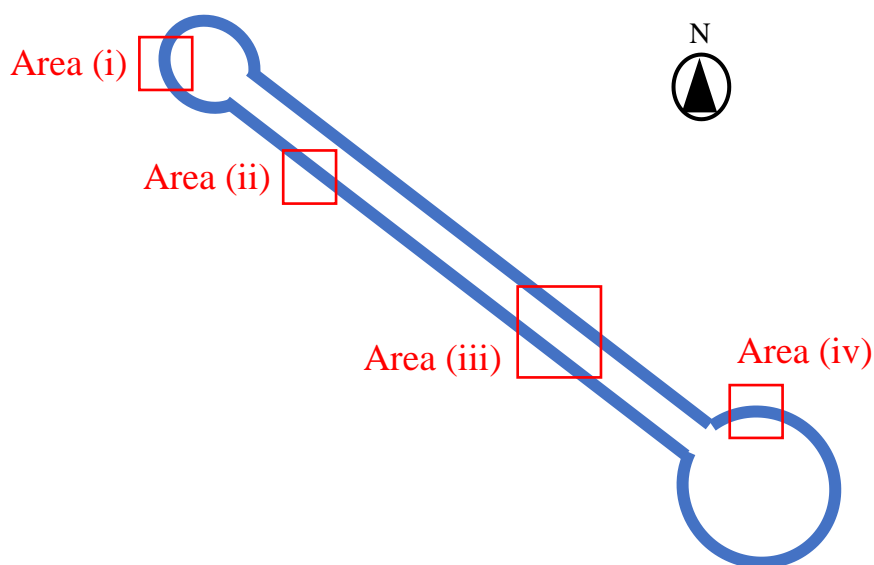
本項では、敷地内のテストコースで走行データを収集し、地図生成技術の基礎検討を行う。Fig. 3-4 にテストコースの概要を示す。Fig. 3-4(a)はテストコース全体の概形および走行方法を示す。コースは北西から南東にかけて細長い形状となっており、1周約2 kmの反時計回り一方通行のコースとなっている。領域(i)～(iv)は、本稿において注目する4箇所を表している。それぞれ、以下の特徴を持つ。

- ・ 領域(i)：曲率の大きいカーブのため、Long-range camera が白線を捕らえることができない
- ・ 領域(ii)：車線を覆うように木が茂っているため、GPS の精度が悪い
- ・ 領域(iii)：GPS は精度良く取得できるが、白線・黄線を検出できないことがある
- ・ 領域(iv)：上空を通過する送電線の影響からか、GPS が毎回同じ場所でオフセットする

片側2車線のうち、道路の端（路端）部分は黄色の実線、中心線は白色の破線となっている。実際の車線は白線・黄線ともに明瞭に存在するが、今回使用した Long-range camera はこの場所で線を見失うことが多かった。



(a) Overview.



(b) The areas to be watched close.


Fig. 3-4 Overview of the proving ground.

Fig. 3-5 は、本テストコースを 5 周、いずれも内側車線を手動走行した際の GPS による自転車位置を重ねてプロットしたものである。ここで、横軸・縦軸はそれぞれ、本テストコースの南西 80 km 程度離れた位置を原点とし、東西方向を横軸、南西方向を縦軸にとったメートル単位の直交座標系に変換した自転車位置を示している。


Fig. 3-5(a) はコース全体の概観であり、Fig. 3-4 で示したようなコース形状を見ることができる。同じコースを 5 周したデータであるため、本図では 5 回の走行でほぼ GPS 位置が一致しているように見える。しかしながら、領域(i)~(iv)部分を拡大した

第3章 市街地道路環境における自動運転の課題


Fig. 3-5(b)～(e)を参照すると状況は異なる。領域(i)を拡大した Fig. 3-5(b)では、5回の走行によって最大2 m程度の誤差が発生している。領域(ii)を拡大した Fig. 3-5(c)では、コースを覆うように生えている木によって GPS のマルチパスが発生し、直進しているにも関わらずふらつくような走行軌跡が得られている。領域(iii)を拡大した Fig. 3-5(d)では、GPS 取得条件が良いにも関わらず、なお走行ごとに最大1 m程度の偏差が生じている。そして、領域(iv)を拡大した Fig. 3-5(e)では、毎回同じ場所で最大1 m程度、位置が飛んでいることが分かる。この場所の上空には送電線があり、GPS の測位に何らかの影響を与えた可能性がある。このように、GPS は常に位置誤差が存在し、条件によっては急に誤差が生じる可能性もある。




(a) Whole area.




(b) Area (i).



(c) Area (ii).



(d) Area (iii).



(e) Area (iv).

Fig. 3-5 GPS detection results for each lap.

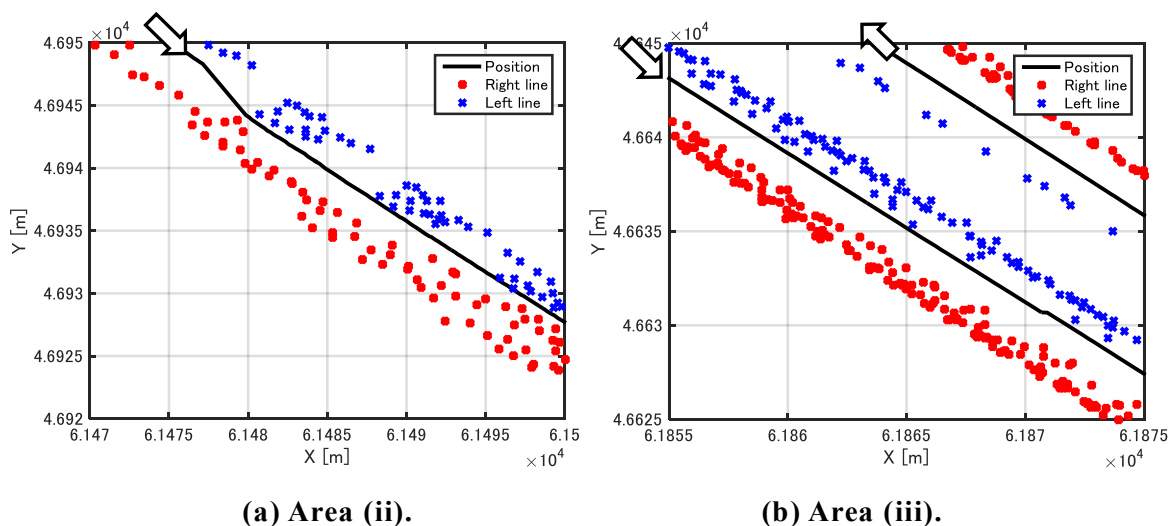


Fig. 3-6 Map construction results with simple integration.

前述するような GPS 位置誤差が存在する状況下で、自車両が検出した環境情報をそのままランドマークとして地図に統合すると、同じ位置に存在するはずのランドマークに位置誤差が生じ、ランドマークが多重に登録されることになる。Fig. 3-6 は、ランドマークとして白線を用いた場合に、GPS 検知結果を用いて、4 周目までの白線位置をすべて単純に統合した結果を示す。Fig. 3-6(a)は領域(ii)，Fig. 3-6(b)は領域(iii)の拡大図であり、実線は4周目の走行におけるGPSにより検出した自己位置、xおよび*の記号はそれぞれ、自車両の左側、右側に検出された白線の位置を示している。4周とも同じ場所を通過したため、本来であれば白線位置は幅30 cm程度の一本の線として統合されるはずである。ところが、Fig. 3-6(a)は右側の白線が最大5 mの幅で広がっており、GPS 取得条件の良い Fig. 3-6(b)であっても、1.5 m程度の幅で白線が広がっている。なお、本実験において、白線情報は Long-range camera を用いて取得している。白線がどのように取得できるかについては2.2.2 項の Fig. 2-3 を参照されたい。

このように、GPS 単独では地図生成および自車位置特定が困難であり、地図生成と自己位置推定技術が重要である。

3.3 歩行者・自転車等の混在環境における課題

次に、歩行者・自転車の混在環境における課題を述べる。自動運転車にとって、歩

行者・自転車に対する事故を回避することは至上命令である。本研究では、どのような場面で事故が起きやすいかを調べることで歩行者・自転車等の混在環境における課題が抽出できると考えた。そこで本節ではヒヤリハット事例に着目する。ヒヤリハットは事故件数よりはるかに件数が多く、どのような場面で歩行者・自転車との事故が起きうるかを示唆する重要な情報が得られると考えられる。次項から詳しく述べる。

3.3.1 課題抽出のためのドライブレコーダデータベースの利用

本研究で利用したドライブレコーダ映像は、ドライブレコーダデータベースセンター(DBセンター)に蓄積されたものである。DBセンターは現在、東京農工大学の小金井キャンパスにあるスマートモビリティ研究拠点に設置されており、専門スタッフがデータ登録・運營業務を担っている。データベースに登録されたドライブレコーダ映像の総数は2012年8月時点で65,300件に達し [68]、本研究を行った2014年9月時点で95,000件、2019年4月時点で15万件を越えている。

本DBセンターはタクシー会社との連携によりデータベース収集を行っている。それゆえ、DBセンターに登録されているヒヤリハットデータは全て、Fig. 3-7に例示するように、タクシーに搭載されたドライブレコーダ映像である。速度、加速度、操舵角などの情報が常時記録され、事故やヒヤリハット発生時とその前後の映像・情報がデータとして蓄積される。その際、ブレーキ操作時の加速度の大きさからヒヤリハット度を高・中・低の3つに分類している。

データベースに蓄積されたデータの内訳は、Fig. 3-8に示すようにピラミッド状となっており、「1つの重大事故の背後には29の軽微な事故があり、その背景には300のヒヤリハットが存在する」というハインリッヒの法則を物語っている。本研究で着目するヒヤリハットレベル「中」以上のデータは2012年8月時点で18,836件であった。うち、自動車同士の事例が約半数(9,330件, 49.5%)を占めており、対歩行者、対自転車はそれぞれ2,441件(13.0%)、2,996件(15.9%)、合計すると全体の30%程度であった [68]。

第3章 市街地道路環境における自動運転の課題



Fig. 3-7 Example of near-miss driving data.

	事故	高レベル	中レベル	低レベル	合計
1カメラ型	310 (0.6%)	3 000 (5.9%)	10 000 (19.6%)	38 000 (74.5%)	51 000 (100%)
2カメラ型	50 (0.3%)	950 (6.6%)	3 200 (22.3%)	10 100 (70.6%)	14 300 (100%)
合計	360 (0.6%)	3 950 (6.0)	13 200 (20.2%)	48 100 (73.7%)	65 300 (100%)

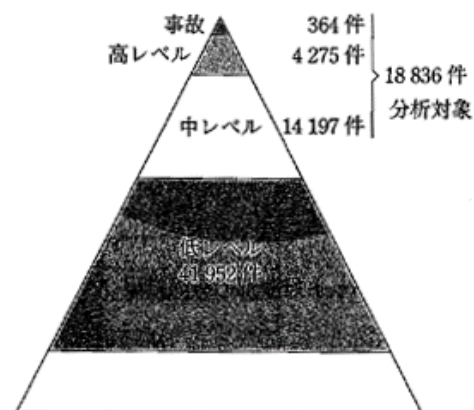
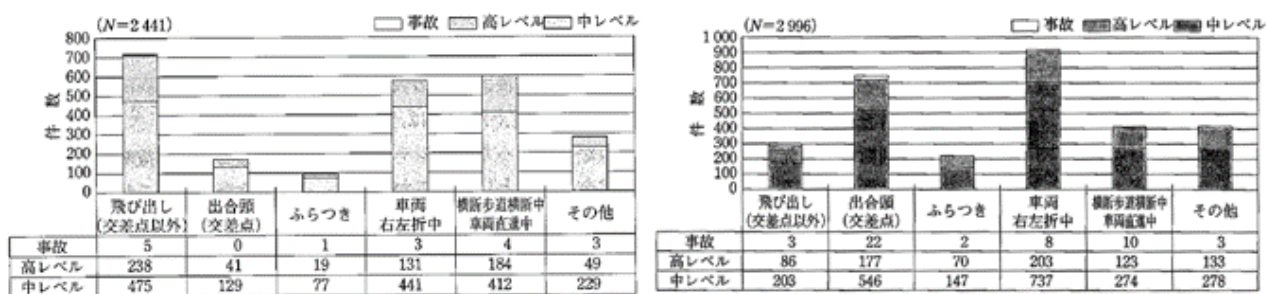


Fig. 3-8 Statistics of drive recorder database (as of 2012/8) [68].



(a) Classification near-miss with pedestrians.

(b) One with bicycles.

Fig. 3-9 Classification above middle-range near miss [68].

Fig. 3-9 に、ヒヤリハットレベル「中」以上となった事例の、対象ごとのヒヤリハット要因分類を示す。本研究の対象とする対歩行者、対自転車のヒヤリハット要因分類を参照すると、どちらも①飛び出し・出会い頭、②車両右左折中、③横断歩道横断中かつ車両直進中の3つがヒヤリハットの主要因であり、①～③で全体の8割以上を占めている。①の要因は主に死角が関係していると考えられ、②は交差点右左折、③は単路直進中である。詳細は後述するが、①のヒヤリハット事例はセンシングの問題に帰着するため、本研究では全体の半数近くを占める②③に着目する。

3.3.2 先行研究におけるヒヤリハットデータ活用例

大量に蓄積されたヒヤリハットデータは、その分析・活用を通じて交通安全教育の充実に役立ったり、予防安全技術の発展に役立ったりすることが期待されている。ヒヤリハットデータ分析結果は、永井、ポンサトーンらの研究グループにより、自転車・歩行者の飛び出し速度の統計 [69]、信号交差点におけるヒヤリハット要因となった歩行者・車両の行動分類 [70]などの分析結果が報告されている。

ヒヤリハットデータの分析から、交通事故対策に有効な情報の抽出を行った研究成果も報告されている。文献 [71]では、経験不足ドライバの交通事故防止対策を主目的として、交差点右折時のヒヤリハットデータ分析を行い、周辺状況の危険度およびドライバの安全確認行動の評価指標作成を行っている。また、文献 [72]では、交差点での出会い頭事故への対応として対自転車のヒヤリハット事例の詳細分析を行い、急制動時の車両速度、運転者の足の位置、ヒヤリハットのタイプなどの分類を通じて、出会い頭事故の要因を明らかにしている。国土交通省がまとめる交通事故データは、事故に至ったケースのみの統計となっており、事例数も決して多くはない。一方、後一

第3章 市街地道路環境における自動運転の課題

歩で事故に至らなかったヒヤリハットケースは事故数と比べて件数が圧倒的に多く、統計的により優れたデータが得られる。また、事故類型とヒヤリハット類型の間には関連性があり、ヒヤリハットデータ分析が交通事故対策に有効であることが指摘されている [1]。

3.3.3 本研究におけるヒヤリハットデータ活用方法

ヒヤリハットデータは、ドライバーがなんらかの要因で他移動体の行動予想を誤った場面であると考えられ、その原因を詳しく分析することにより、

- ・ 自転車や歩行者のどのような行動がヒヤリハットに結びつくのか
- ・ そのような行動はシステムが事前に予測可能か
- ・ どのような情報（センサ値）が得られれば予測可能か
- ・ 一次元予測（速度変化のみ）で良いか、二次元予測（速度変化＋進路変化）が必要か

という観点から、移動体行動予測モデル構築にあたっての課題を抽出できる。特に、自動運転に適した行動予測モデルを構築する上で、予測可能性の検討は重要である。

DBセンタに登録されているヒヤリハットデータは「ヒヤリハット危険度（高・中・低）」「ヒヤリハット対象（四輪車・二輪車・歩行者・自転車など）」「自車行動（直進・右折開始時・右折中など）」「道路形状（交差点・交差点以外など）」等の検索条件から、視聴するドライブレコーダ映像を絞り込むことが可能である。3.3.1項で述べた通り、本研究では交差点右左折および単路直進中の走行シーンに着目し、自転車・歩行者などの移動体行動予測モデルの構築を進める。したがって、ヒヤリハット場面は「交差点右折時」「単路走行時」、ヒヤリハットレベルは「中」以上に設定し、ヒヤリハット事例の分類と、移動体行動傾向の分析を行う。

3.4 ヒヤリハットデータに基づく歩行者・自転車等に対する課題分析

本章では、ヒヤリハットデータの確認結果から、ヒヤリハット事例の分類を行う。ここでは、明らかにドライバに過失（操作ミス）のあるヒヤリハット事例（ドライバの信号見落とし、スピード違反等が直接原因となったもの）を除外し、自転車・歩行者の行動変化が原因となったヒヤリハット事例に限定して分類する。その際の検索条件および検索にヒットした動画の総数は Table 2 の通りである。なお、この件数は本研究を行った 2014 年 9 月時点のものである。

3.4.1 交差点右折時のヒヤリハット事例

交差点右折時にヒヤリハットとなった事例を確認したところ、主に以下の 2 パターンが存在した。

- (1) 歩行者用信号の変化（青→青点滅、青点滅→赤）等による歩行者の駆け出し
 - (2) 交差点に向かっている歩行者・自転車の交差点横断のための急な方向転換
- 以下、それぞれのパターンの詳細について述べる。

Table 2 Searching options of near-miss data.

場面	ヒヤリハットデータ検索条件	動画総数
交差点右折時	ヒヤリハット危険度 : 中・高 対象 : 歩行者・自転車 自転車行動 : 右折開始時・右折中 道路形状 : 交差点（信号あり）	530 件
単路走行時	ヒヤリハットレベル : 中, 高 対象 : 歩行者, 自転車 自転車動作 : 直進 道路形状 : 交差点以外	455 件

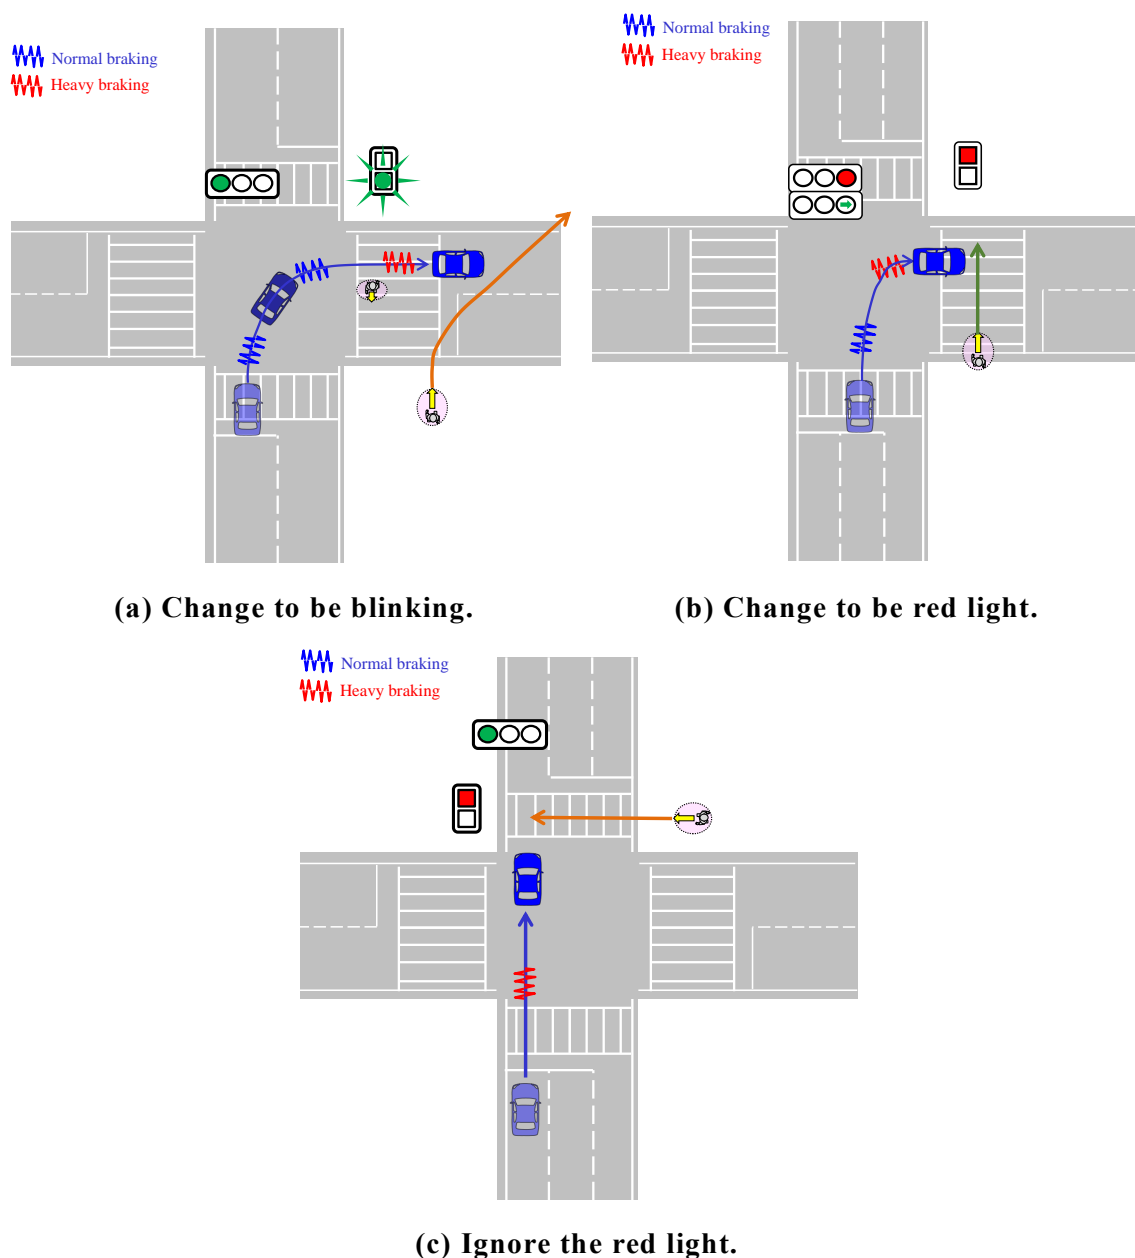


Fig. 3-10 Indication change of crosswalk signal.

< 歩行者用信号の変化および信号無視 >

Fig. 3-10 に示す事例は、信号のある交差点を右折時、道路を横断する歩行者が歩行者用信号の変化により駆け出し、あるいは赤信号を無視して横断したことで自車両と衝突しそうになったヒヤリハット事象である。

Fig. 3-10(a)は信号のある 2 車線道路で、自車両は 1 人の歩行者の横断を待ってから右折を開始した。その直後、信号が青から青点滅に変化し、背後から別の歩行者が駆

け足で横断してきたため、ドライバが急ブレーキを踏みヒヤリハットとなった。この事象では、背後から走ってくる歩行者がドライバにとって見えにくかったこともヒヤリハットの一因となっている。また、ここでは歩行者が斜めに横断しているが、これは自車両の接近に気づいた歩行者が、接触を回避しようと自車両から離れたためと推測する。

一方、Fig. 3-10(b)は信号と右折専用レーンのある2車線道路で、自車両は右折信号の表示に従って右折開始したところ、横断歩道上の歩行者を発見して急ブレーキを踏んだヒヤリハット事象である。右折信号表示時、歩行者用信号は赤であり、歩行者は横断途中で赤信号に気づいて駆け出したと推測する。類似の事例として、自身が信号無視していることに気づいた歩行者が途中で横断を止めた例もある。

Fig. 3-10(c)は交差点直進時、信号無視で横断する歩行者を発見して急ブレーキを踏んだヒヤリハット事象である。本事例では、自車両が交差点に近づく段階で車道側の信号は青になっており、歩行者側が信号を完全に見落としている。ここでは交差点直進時に例を挙げたが、右左折時にも信号無視によるヒヤリハット事例があった。

本節で示したヒヤリハット事例の要因は、歩行者側の完全な信号無視の事例を除けば、信号変化による歩行者の速度変化をドライバが予測できなかったことにある。また、交差点は目視確認すべき範囲が広く、ドライバが他のことに気をとられて横断中の歩行者を見落としやすいことも一因となっている。

信号変化をトリガとする歩行者の速度変化に関して、実際に被験者が同様のケースで歩行し、その速度を調査した結果が文献 [73]に示されている。本文献によると、歩行者用信号の青⇒青点滅変化により、歩行者の歩行速度が平均 1.7 m/s から 2.4 m/s に増加し、横断終了の直前に元の速度に戻るという傾向が実験的に得られている。なお、この結果は健常な大学生（若年層）が被験者となっており、他世代の歩行速度より高めとなっている可能性がある。

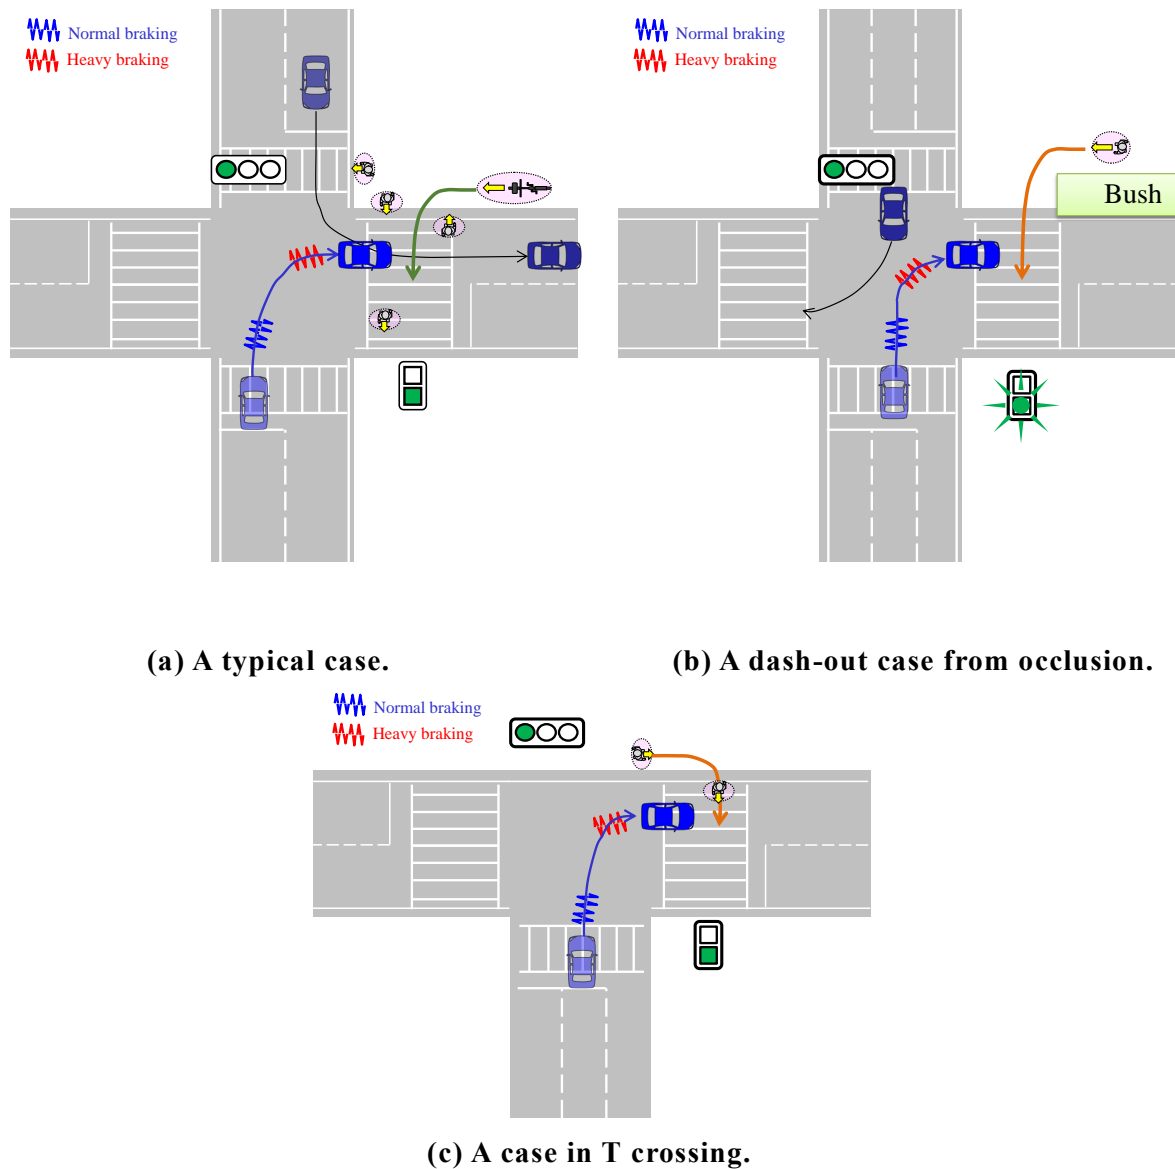


Fig. 3-11 Sudden movement change of a pedestrian with will of crossing.

<横断意志のある移動体の急な進路変更>

Fig. 3-11 に示す事例は、自車両の交差点右折時、交差点に近づいてきた歩行者・自転車が進路を 90° 変更して交差点を横断し、自車両が衝突回避のために急ブレーキを踏んだヒヤリハット事例である。それぞれ、Fig. 3-11(a)は典型的な 2 車線道路での事例で、多数の横断者、赤信号による横断待機者がいる中を自車両が縫うように横断してきた例である。また、Fig. 3-11(b)は車道と歩道の境界に設置された植込みの死角から歩行者・自転車が現れた事例、Fig. 3-11(c)は同じ右折場面でも、丁字路において

歩行者・自転車が反対側から進路変更した事例である。Fig. 3-11(b)は歩行者用信号が点滅しており、歩行者が駆け足に横断を開始したためドライバが歩行者の発見に遅れ、ヒヤリハットにつながった。

本事例のヒヤリハット要因は、歩行者・自転車の進路変更を予測することの難しさである。一部の事例では歩行者・自転車の顔の向きから横断を予見できたが、大部分の事例では、歩行者・自転車の横断意思を映像から読み取ることは難しい。同じように交差点に近づいてきても、進路を変えずそのまま信号待ちで止まる歩行者も多く、歩行者・自転車が交差点に到達する前に両者を見分けることは、人間の目で見ても困難である。このような事例において、移動体行動予測モデルが果たせる役割は小さい。衝突回避の確度を担保するためには、横断する可能性が0ではない歩行者に対して、万が一進路変化があった際に急制動で停車すれば衝突が回避できるような速度計画を立てる（いわゆる『かもしれない』運転）など、制御ロジック側での対策が必須となる。

3.4.2 単路走行時のヒヤリハット事例

単路走行時にヒヤリハットとなった事例を確認したところ、主に以下の4パターンが存在した。

- (1) 静止物を避けて横移動を起こした移動体との接近
- (2) 移動体同士の交差による移動体の横移動
- (3) 自車両の接近に気づかない背走移動体の急な斜め横断
- (4) 左方からの自転車の接近

以下、それぞれのパターンの詳細について述べる。

<静止物追い越しのための横移動>

Fig. 3-12 に示す事例は、駐車車両などの静止物を避けて歩行者・自転車が車道側にはみ出してきたヒヤリハット事例である。その典型例は Fig. 3-12(a)に示すように、背走する自転車・歩行者が自車両の接近に気づかずに横移動し、自車両は衝突回避のための急ブレーキを踏んだという事例である。




Fig. 3-12 Movement change of pedestrian to avoid obstacles.

Fig. 3-12(b)は Fig. 3-12(a)と同様，背面歩行する歩行者の横移動がヒヤリハットにつながった例である。本事例の場合，車同士の行き違いが困難な狭い路地で，自車両の前に先行する1台目の車があり，歩行者は1台目の車の接近に気づいて電柱前でしばらく待機した後，自車両が接近する瞬間に横移動を起こした。このことから，歩行者は先行車両が通過した後に立て続けに車両が接近しているとは思わず，後方確認を怠って横移動したと推測できる。

Fig. 3-12(c)も上記と同様事例であるが，ここでは柵のある歩道が存在し，歩行者は歩道を歩いている。歩行者の目の前に電柱があり，電柱付近が建物の出入り口となって歩道が消失している。そこで歩行者は電柱を避けて，歩道の切れ目から車道にはみだし，後方から接近してきた自車両が衝突回避のために急ブレーキを踏んだ。この事例以外にも，歩道の切れ目から自転車・歩行者が車道側にはみ出してきたヒヤリハット事例が複数見受けられた。

これらの事例において、自転車・歩行者が自車両の接近に気づかなかったことが、ヒヤリハットの主因となっている。また、ヒヤリハットとなるような道路は道幅が狭いものも多く、自転車・歩行者が横移動した際に自車両がすり抜けられる隙間がないためブレーキを踏まざるを得ないことも、ヒヤリハットを起こしやすい一因である。

<移動体同士の交差・干渉による横移動>

Fig. 3-13 に示す事例は、移動体同士の交差による横移動、もしくは自車両含む移動体が別の移動体を追い越すための横移動に起因するヒヤリハット事例である。Fig. 3-13(a)(b)が前者の事例を、Fig. 3-13(c)(d)が後者の事例を表している。


Fig. 3-13(a)は歩行者同士の交差による横移動がヒヤリハットにつながった典型例である。ここでは背面歩行する歩行者が対向の歩行者を避けて車道にはみ出し、自車両が衝突回避のために急ブレーキをかけている。一方、Fig. 3-13(b)はヒヤリハット事例ではないが、自車両周辺を走行中の自転車の行動が特徴的であるため紹介する。本事例において、背走する自転車は自車両の接近中に自車両の方を見るしぐさをしており、自車両の存在に気づいている。そのため、対向の自転車が接近してきた際に車道側によけることなく、自車両の通過を待つように減速・停止した。対向してくる自転車もまた、はじめは自車両の目標走行軌跡と明らかに干渉するような道路の真ん中を走行していたが、自車両の接近に伴って道路端に避けていった。このように、自車両の存在に気づいている歩行者・自転車は、自車両との衝突を避けて行動する傾向にある。

Fig. 3-13(c)は、歩行者を自転車が追い越す際の横移動に起因するヒヤリハット事例、Fig. 3-13(d)は自車両が自転車・歩行者を追い越す際の横移動に起因する事例である。前者は、自転車が自車両の接近に気づかず横移動した例で、Fig. 3-13(a)で示した静止物追い越しと状況は似ている。一方、後者は自車両が歩行者を追い越して反対車線にはみだした直後、対向車の接近に気づいて自車線に戻り、先行していた自転車との衝突を回避するため急制動した例である。本事例は、移動体の行動変化が原因となったヒヤリハット事例ではなく、タクシードライバ特有の大胆な運転行動が背景要因にあると推測するが、市街地走行においては比較的によく見られるシーンである。

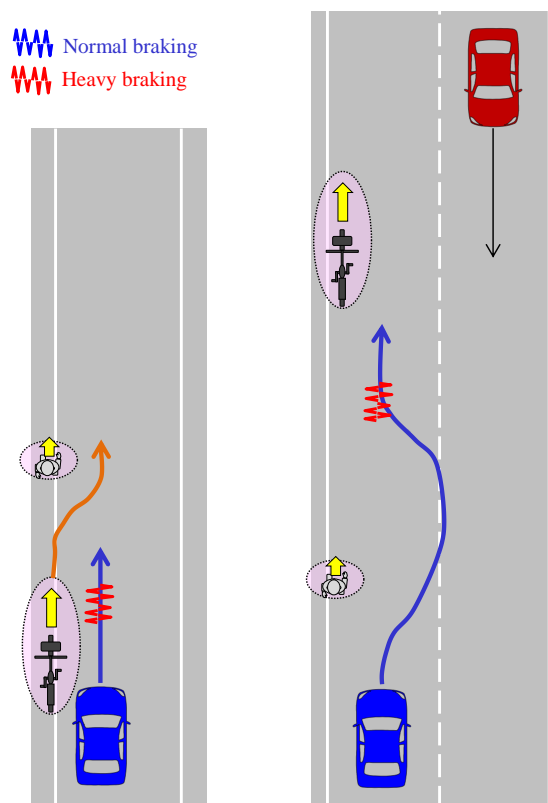
Fig. 3-13(c)の類似事例として、自車両（タクシーが客を降ろした後に一時停止中）の左から自転車が通過し、背面歩行中の歩行者を追い越そうと横移動したのと同時に自車両が発進し、ヒヤリハットとなった事例もある。この場合、自転車は自車両の存

第3章 市街地道路環境における自動運転の課題

在は認識しているものの、動き出すとは予測していなかったと推測できる。すなわち、移動体は自車両の「存在」を認識しているだけでは衝突回避行動をとるとは限らず、移動体側が自車両の将来の動きをどのように予測しているかが重要なポイントである。



(a)(b) Pedestrian/bicycles passing by another one.



(c) Pedestrian/bicycles overtaking another one. (d) Vehicle overtaking pedestrian.

Fig. 3-13 Movement change according to overtaking or passing by.




Fig. 3-14 Movement change of pedestrian/bicycle without noticing ego-car approach.

<自車両接近に気づかない移動体の急な斜め横断>

Fig. 3-14 に示す事例は、いずれも自車両の接近に気づいていない自転車・歩行者の横断が招いたヒヤリハット事例である。その典型例は Fig. 3-14(a)に示すとおり、自転車または歩行者が自車両の目の前で突然斜め横断を開始し、自車両が衝突回避のための急ブレーキをかけるというものである。Fig. 3-14(c)の背面走行する移動体が横移動した例と類似しているが、本節における事例は移動体の単独行動で、かつ突然の横断開始という点に特徴がある。

Fig. 3-14(b)も同様に、歩行者の突然の横断が招いたヒヤリハットであるが、本事例において、歩行者は横断開始直前に横断先のほうへ顔を向けるしぐさをとっており、歩行者の顔の向きが検知できれば急な横断を予測できる可能性を示している。一方、Fig. 3-14(c)の事例では、雨天下で傘を差している歩行者の急な斜め横断である。この場合、傘のため自車両からは歩行者の顔の向きやしぐさをとらえることはできず、逆に歩行者にとっても後方から接近してくる車の存在に気づきにくい状況である。すなわち確度の高い移動体行動予測が困難な状況であり、万が一に備えて速度を落とす運




Fig. 3-15 Wandering of bicycle.

転行動をとらざるを得ない場面である。

類似のヒヤリハット事例として、Fig. 3-15 に示すように、路側帯を走行する自転車が急にふらつく事例が複数見受けられた。これは、一見すると急な斜め横断を起こしかねないことから、ドライバーは危険を感じて急ブレーキを踏んだもので、速度が下がると不安定になるという自転車の性質がヒヤリハットの一因である。道路が上り勾配となっている場合、もしくは自転車を操縦する人が子ども、子どもをカゴに乗せた女性、年配の方という事例が多く見られた。

<左方からの自転車の接近>

Fig. 3-16 に示す事例は、自車両が交差点を直進中に左方から自転車が近づいてきた事例である。いずれの事例も、ドライバーは自転車が自車両の目の前を横切る可能性を考慮して、衝突回避のための急ブレーキを踏み、ヒヤリハット事例となった。特に信号のない交差点での事例が目立ち、ほとんどの場合自車両は直進中であるため、単路走行中の場面として分類する。




Fig. 3-16 Approach of bicycle from left.

本事例のヒヤリハット要因は、自転車の進路変更を予測することの難しさが挙げられる。Fig. 3-16において、左方から接近してきた自転車が①の経路をとるか、②の経路をとるかを正確に判断することは困難である。ヒヤリハット事例の場合、たいていの場面では自転車は②の経路をとってそのまま自車両の左側の路側帯もしくは歩道を走行するが、ドライバーは万が一の衝突回避の観点から、自転車が①の経路をとる可能性があることを考慮に入れざるをえない。その点は自動運転でも同様である。

3.4.3 両者に共通するヒヤリハット事例

ここまで、交差点右折時および単路走行時に特有のヒヤリハット事例について述べたが、両者に共通するヒヤリハット事例も存在した。主には以下の2パターンが挙げられる。

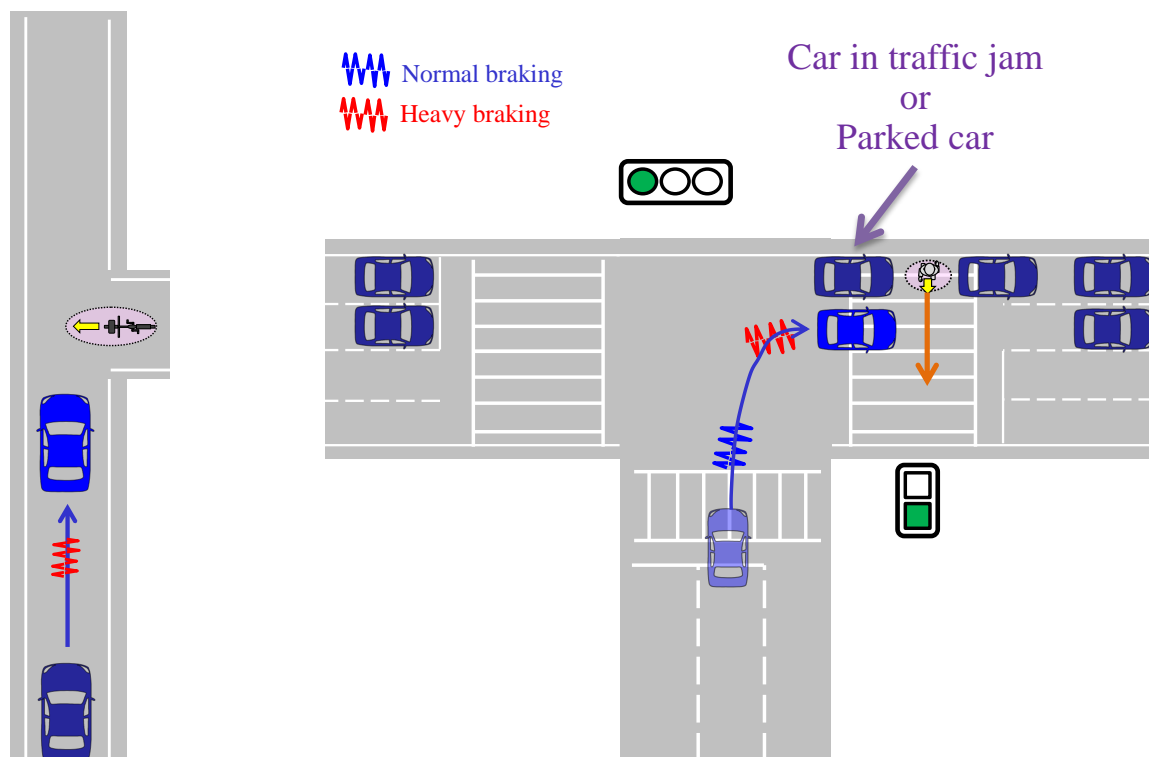
- (1) 死角からの移動体飛び出し
- (2) 手信号による停止指示

以下、それぞれのパターンの詳細について述べる。

<死角からの移動体飛び出し>

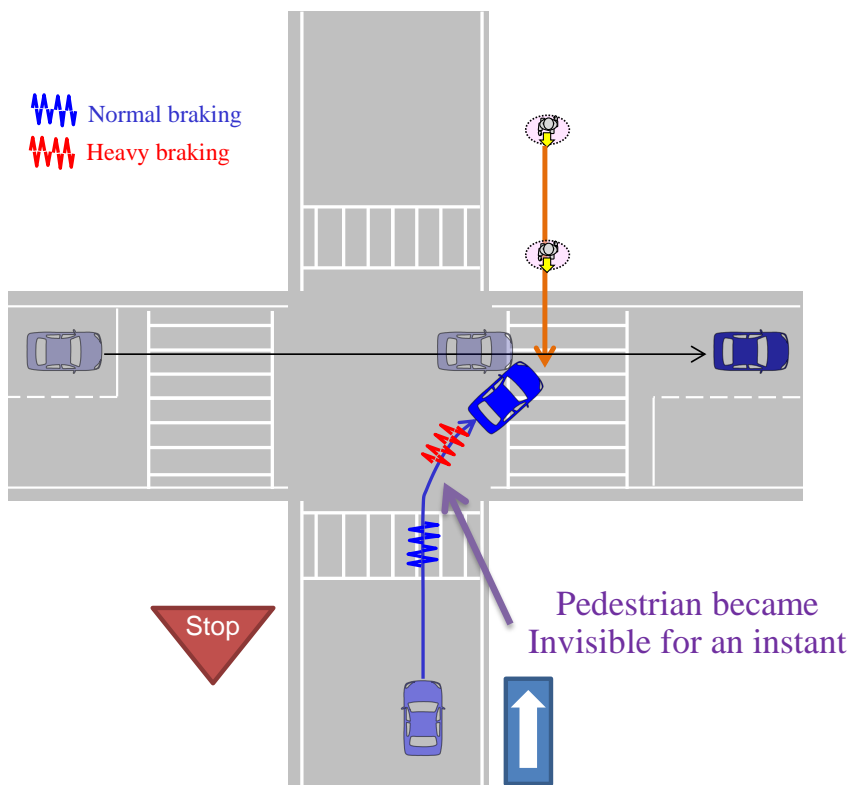
Fig. 3-17 に示す事例はすべて死角がからむヒヤリハット事例であり、ヒヤリハットデータベースにおいても多くの割合を占めている。その典型事例は Fig. 3-17(a)に示す通り、単路走行時には民家の塀などの死角から突然移動体が飛び出してくる事例、2車線以上の道路においては Fig. 3-17(b)に示すように、停車している車の陰からの飛び出し事例が多い。渋滞している対向車の間から横断者が飛び出してくる事例も多数見受けられた。

道路形状的には死角が存在しない場面でも、Fig. 3-17(c)のように他車両が原因となる事例が存在する。本事例は、自車両の前を通過した他車両に隠れて歩行者が一瞬見えなくなり、ドライバーが歩行者の接近に気づかず右折しようとして衝突の危険を招いた例である。その前段階で、交差点に向かって進む歩行者の姿は見ており、他車両で見えなくなっている間も歩行者は一定速度で直進していた。自動運転において本事例に対応するためには、歩行者が検知できた時点から速度ベクトルを取得し、検知不能となった間に歩行者の等速度直進を仮定するなどの行動予測が必要である。



(a) Typical case.

(b) Blind spot caused by stopped cars.



(c) Blind spot caused by passing & crossing vehicle.

Fig. 3-17 Pedestrian/bicycle dashing out from occlusion.




Fig. 3-18 Stop order by induction staff.

<誘導員の手信号による停止指示>

Fig. 3-18 に示す事例は、車両の入出構や道路工事など、何らかの理由で誘導員が手信号により停止を要求した場面である。その要求がドライバにとって唐突であった、あるいは不明瞭であったことが急ブレーキにつながり、ヒヤリハットとなった。本事例は市街地走行においては少なからず遭遇する事例であり、自動運転の実証試験を進めている研究グループがスコープ内として公表している事象である [74]。

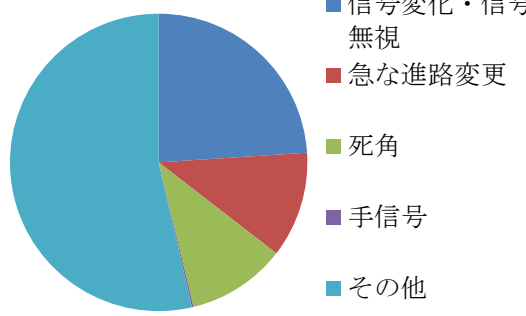
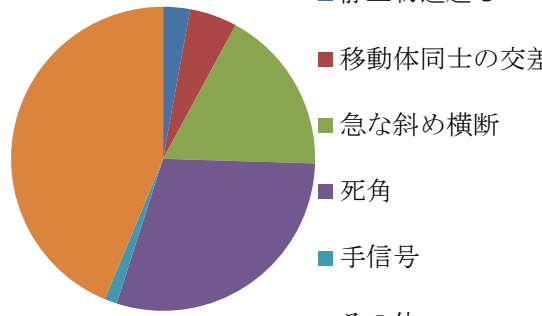
3.4.4 ヒヤリハット事例の分類

本項では、前項までで例示したヒヤリハット事例の分類と課題抽出を行い、行動予測モデル構築にあたっての方針について考察する。それぞれにおける移動体の行動傾向および行動予測可能性をまとめた表を Table 3 に、それぞれの事例の件数を Table 4 に示す。

Table 3 Classification of near-miss cases.

場面	事例	移動体の行動傾向	行動予測可能性
交差点 右折時	歩行者用信号の変化 および信号無視	・速度変化 ・トリガとなる環境 変化有	一次元行動予測 +速度変化予測
	横断意思のある移動 体の急な進路変更	・進路変化 ・横断意思の判別困難	行動予測困難
単路走行時	静止物追い越しのため の横移動	・進路変化 ・自転車接近認識の有無 によって行動変化	二次元行動予測 +斥力モデル +自転車接近認識予測
	移動体同士の交差・ 干渉による横移動		二次元行動予測 +自転車接近認識予測
	自車両接近に気づか ない移動体の急な斜 め横断	行動予測困難	
	左方からの自転車の 接近	・進路変化 ・横断意思の判別困難	行動予測困難
両者に共通	死角からの移動体 飛び出し	・互いにセンシング 不能	センシングできる前 は行動予測不能
	誘導員の手信号によ る停止指示	・環境的要因	センシング +パターンマッチ

Table 4 The number of near-miss cases.

場面	事例	件数	分布
交差点 右折時	歩行者用信号の変化 および信号無視	127	 <ul style="list-style-type: none"> ■ 信号変化・信号無視 ■ 急な進路変更 ■ 死角 ■ 手信号 ■ その他
	横断意思のある 移動体の急な進路変更	61	
	死角からの移動体 飛び出し	57	
	手信号による停止指示	1	
	その他（運転ミス等）	284	
単路 走行時	静止物追い越しのための 横移動	13	 <ul style="list-style-type: none"> ■ 静止物追越し ■ 移動体同士の交差 ■ 急な斜め横断 ■ 死角 ■ 手信号 ■ その他
	移動体同士の交差・ 干渉による横移動	23	
	自車両接近に 気づかない移動体の 急な斜め横断	80	
	死角からの 移動体飛び出し	134	
	手信号による停止指示	6	
	その他（左方からの自転車の 接近，ドライバの不注意 等）	199	

<交差点右折時>

Table 4 によれば、交差点右折時に移動体の行動変化が原因となったヒヤリハット事例は、死角からの飛び出しを除くと全体の35%となっている。35%のうち、信号変化による走り出しおよび信号無視が68%、横断のための進路変更が32%となっている。移動体行動予測モデルで対処可能なシーンは全体の24%、移動体の行動変化に関わるシーンの68%をカバーする。

交差点右折時において、歩行者用信号の変化（青→青点滅、青点滅→赤）等によるヒヤリハット事例は、横断の始めまたは途中で移動体が速度変化を起こしたことが主因となっており、移動体の方向転換がヒヤリハットに結びついた例は少ない。これは、信号のある交差点が、横断歩道、信号といった交通法規により移動体の移動方向をある程度束縛することが原因と推測する。このことから、自動運転における交差点右折時の行動予測モデルは、移動体の現在の速度と方向が継続するという次元行動予測を基本とし、道路周辺の状況、移動体の属性、現在の行動等に基づく速度変化予測を加えた形が適している。ただし、交差点形状によっても異なり、横断歩道無し、信号無しなど、移動体の行動を束縛する交通ルールが少ないほど、高密度下の単路走行時（次節で詳細を述べる）に状況が近くなり、二次元行動予測の必要性は高まると推測する。

一方、交差点に向かっている歩行者・自転車の交差点横断のための急な方向転換に接近に関して、移動体の横断意思有無の正確な判定は困難である。従って、これら事例に対応する行動予測モデルはあくまで確率的なものとなり、予測が外れた際にも急制動の衝突回避を確実なものとするような、自車両の速度計画手法が重要な課題となる。

<単路走行時>

Table 4 によれば、単路走行時に移動体の行動変化が原因となったヒヤリハット事例は全体の25%となっている。これは死角からの飛び出しの割合とほぼ同数である。死角の事例が多く見受けられるのは、民家の塀などで見通しの悪く、かつ車両のすれ違いが困難な細い路地が検索に引っかかりやすいことに起因する。移動体の行動変化が原因となった25%のうち、自車両接近に気づかない移動体の急な斜め横断が69%、残りの31%が移動体の横移動に関連したシーンである。

単路において、移動体の行動変化に関わるヒヤリハット事例は、いずれも移動体の横移動に起因している。静止物を避けて横移動を起こした移動体との接近、移動体同士の交差による移動体の横移動に関しては、移動体同士の相互作用による行動変化である。また、背走移動体の急な斜め横断は自車両接近に気づかなかったことが原因であり、移動体が自車両接近に気づいている場合には自車両との衝突を回避するような行動を起こすという傾向が、ヒヤリハット事例から得られた。この事例も、自車両を移動体の一つと考えれば、移動体同士の相互作用による行動変化といえる。これら事象に対応した移動体行動予測モデルは、進路変化の予測が重要であることから、道路周辺の状況、移動体の属性、現在の行動等に基づく二次元行動予測が必要不可欠である。その際、静止物と移動体の相互作用、あるいは移動体同士の相互作用を表現するために、移動体同士の接近時に斥力が働くとみなした斥力モデルの導入が有効と考えられる。さらに、自車両接近認識の有無の判定も行動予測の鍵となる。

一方、左方からの自転車に関して、移動体の横断意思有無の正確な判定は困難であり、走行制御により衝突回避を確保するような対策が必要である。

<死角からの飛び出し・手信号による停止指示>

交差点右折時、単路走行時の両者に共通するヒヤリハット要因として、死角からの移動体飛び出し、手信号による停止指示の事例が見受けられた。前者は移動体がセンシングできていない状況であることから、移動体行動予測モデルの適用は困難であり、死角の検知に基づき予め速度・軌道に回避マージンを持たせる等の対策が一般的である。また、後者はカメラ等による手信号のセンシングおよびパターンマッチングが鍵となる。すなわち、これらの事例に対して移動体行動予測モデルの適用は困難であり、周辺環境認識技術が肝要である。

3.4.5 歩行者・自転車等の存在に対する解決方針

前節までの考察により、本研究では、移動体の二次元行動予測モデルが最も有効となる高密度道路環境下の単路走行時に焦点を当て、移動体同士の相互作用による行動変化のモデリングを進める。ここでは高密度環境として、Fig. 3-19に示すようなドライブレコーダの映像 [75]を典型例として例示する。本映像では、駅前の商店街で、車の行き違いが困難な単路に多数の歩行者・自転車が存在する道路環境を、自車両がゆ



(a) Ego-car's direction is covered by obstacles. (b) Cleared direction after 10 sec.

Fig. 3-19 Assumed road environment with highly congestion [75].

ゆっくり進む様子が記録されている。

自車両が道路を進行していくと、Fig. 3-19(a)のように先方の経路が移動体で完全にふさがれるような場面が何度も現れる。ここで、移動体行動予測を行わない従来の経路生成では、物理的に通過可能な経路が生成できず、停止を選択する可能性がある。一方、Fig. 3-19(b)は 10 秒程度後の光景であり、自車両が他移動体と同じ速度でしばらく進むうちに、自車両の前に経路が開けた様子を映している。本研究における移動体行動予測は、このように自車両が近づくと自然と経路が生成される現象をモデル化することで、経路生成における「解なし」を防止し、走破性を高められる可能性がある。

移動体同士の相互作用を考慮に入れた行動モデルとして、パーソナルスペースの考え方を採用したものがある [76]。本文献では、Fig. 3-20(a)に示すように、歩行者が自分の周囲に他者の存在を許容しないスペースとして定義されるパーソナルスペースを想定し、歩行者は Fig. 3-20(b)のようにパーソナルスペースに基づき自身の進行方向を決定するという行動予測モデルを構築している。さまざまな属性の歩行者（車椅子利用者含む）や障害物を配置した流動シミュレーションの様子を Fig. 3-20(c)に示す。高密度環境下で、歩行者はばらばらに進行するのではなく、列を成して進む傾向にあるという経験則が再現されている。

本文献は、マクロな人流の流動予測を行っているもので、個々の移動体の動きをとらえることは想定していない。本研究では車両・自転車・歩行者が混在する環境にお

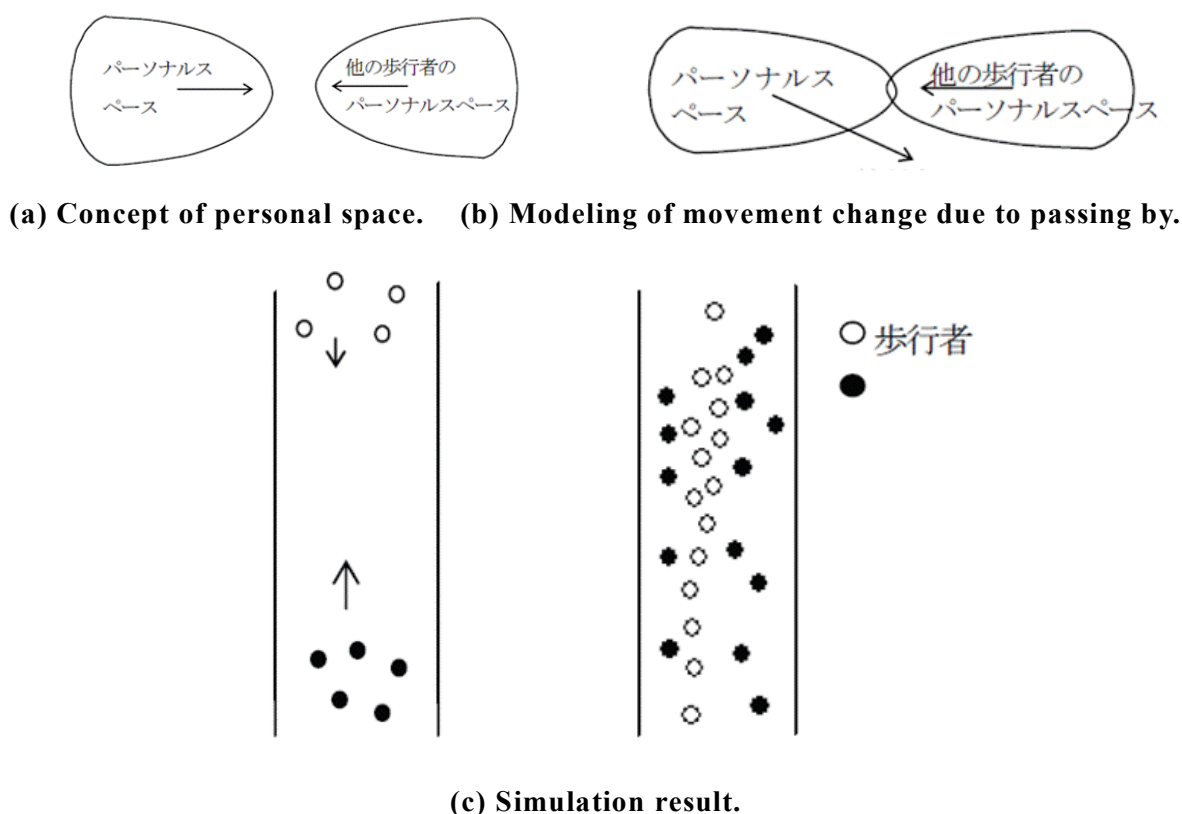


Fig. 3-20 A movement prediction method based on personal space concept [76].

ける，個々の移動体の将来の行動変化を予測する行動予測モデルの構築を進める。

3.5 本章のまとめ

本章では，市街地道路環境における自動運転実現にあたって特に課題となる事象を述べた。その中で，自動運転用の地図生成における課題と，歩行者・自転車混在環境における課題の2つに着目した。

まず，自動運転用地図に対しては，自動運転車が自己位置を推定するために高精度な地図が必要であること，その生成コストが高いという課題を示した。その課題に対処するため，安価な車載センサのみを用いた地図生成技術が必要となる。自己位置の取得手段として広く一般に使われている GPS/GNSS は数 m オーダーの誤差が用意に生じ，条件によってはそれ以上の誤差が乗ったり誤差の出方が変わったりする。そのことを，テストコースにおける走行データを用いて具体的に示した。

第3章 市街地道路環境における自動運転の課題

次に、歩行者・自転車に対する課題を示すために、本章ではヒヤリハットデータに着目し、交差点右折時、単路走行時のヒヤリハット映像の視聴・分類を行った。その結果を以下にまとめる。

交差点右折時において、ドライバの運転操作ミスを除いたヒヤリハットの主な原因は、①歩行者用信号の変化（青→青点滅，青点滅→赤）等による歩行者の駆け出し，②交差点に向かっている歩行者・自転車の交差点横断のための急な方向転換である。①は進路変更を伴う場合が少ないため，一次元行動予測に道路周辺の状況等に基づく速度変化予測を加えた行動予測モデルが適している一方，②は横断意思有無の正確な判定が困難であることから，確度の高い行動予測モデルの構築は困難である。

単路走行時において，ドライバの運転操作ミスを除いたヒヤリハットの主な原因は，①静止物を避けて横移動を起こした移動体との接近，②移動体同士の交差による移動体の横移動，③自車両の接近に気づかない背走移動体の急な斜め横断，④左方からの自転車の接近である。①②は移動体同士の相互作用による行動変化であり，③は移動体が自車両接近に気づいている場合には自車両との衝突を回避するような行動を起こすという傾向が得られた。これら移動体の行動変化に対して安全性を確保するためには，道路周辺の状況，移動体の属性，現在の行動等に基づく二次元行動予測が必要不可欠である。一方，④は移動体の意思判定が困難であることから，確度の高い行動予測モデルの構築は困難である。

両者に共通するヒヤリハット要因として，①死角からの移動体飛び出し，②手信号による停止指示が挙げられる。①は移動体がセンシングできていない状況であることから，移動体行動予測モデルの適用は困難であり，死角の検知に基づき予め速度・軌道に回避マージンを持たせる等の対策が一般的である。また，②はカメラ等による手信号のセンシングが鍵となる。

以上の考察により，自動車の自動運転において，移動体の二次元行動予測モデルが最も必要となるのは高密度環境下の単路走行時であり，従来研究ではあまり考慮されてこなかった，移動体同士もしくは静止物体と移動体の相互作用による行動変化のモデリングが肝要である。

第4章 地図生成手法及びカメラ特性による比較

4.1 はじめに

本章では、Local dynamic map 内における地図を拡張する手法について述べる。ここまで述べた一般的な自動運転システムでは、Fig. 2-1 で示した認知ブロックにおける上記地図情報は予め用意された高精度地図を用いて自動運転制御を行うことが多い。それに対し、本研究では高精度地図を用いず、走行データをベースに自己地図生成する手法について検討、開発を進める。

2.3 節で述べた通り、自動運転用の地図は一般に「自己位置推定しながら地図を生成する」という SLAM の考え方で行われている。そして、構築される地図をさらに高精度なものとするため、SLAM の技術開発が先行する自律移動ロボティクスの分野では多数の研究が報告されている。例えば、物体の配置が変化する非静的環境において、投票法をベースとする手法により変化していない物体を検出する手法 [77]、局所ボロノイ分割に基づき、地図を修正しながら自律移動ロボットの経路を逐次計画する手法 [78]などが多数提案されている。周辺の物体を検出するためのセンシング技術も多岐にわたり、ステレオカメラを用いる手法 [79] [80]、投光型距離センサを用いる手法 [81]などが提案されている。

複数のロボットを協調的に移動させ、より広範かつ正確な地図生成を試みた手法も提案されている。群ロボットによる協調ポジショニングシステム(CPS)による三次元形状や地図を生成する手法 [82] [83]、D-SLAM アルゴリズムにおいて逐次最小二乗法により局所地図を統合する手法 [84]などが挙げられる。さらに、地図の形式に関する議論も存在する。物体の存在確率のファクタを含んだ地図情報を生成する手法 [85]、汎用性の観点からユニバーサルマップを生成し、それぞれの仕様に適した個別の地図情報へ変換する手法 [86]、レーザレンジファインダとカメラを組み合わせ、二次元のグリッドマップに段差情報を加えて 2.5 次元マップを生成する手法 [87]などが提案されている。

以上述べたロボティクスの分野で用いられている手法は、豊富な情報量が得られる

LiDAR の使用を前提としたものが多い。近年こそ LiDAR は世界中で開発が進みコストも下がってきているが、自動運転の普及においてはまだ現状の LiDAR は高価である [88]。したがって、より廉価で ADAS 用に普及している車載カメラを用いた自動運転用の地図生成研究も広く行われており [89] [90] [91]，無人移動ロボティクスの分野にも広がっている [92] [93]。それゆえ本稿では、第 2 章で述べた車載カメラ (Long-range camera / Fisheye camera) を用いた低コスト自動運転アルゴリズムを研究対象とする [94]。

一方、廉価な自動運転を実現するにあたって解決が必要なコスト問題は HD 地図にも存在する。3.2.1 項でも述べた通り、現状の HD 地図は MMS のような特別な装置を搭載した専用車両により高精度に取得されているが、その生成コストは高価であるのが現状である [95]。このコスト問題を解決するため、本研究では HD 地図に頼らない地図生成手法を検討する。その手法の前提として、路面上の白線に代表されるランドマークを取得可能な車載カメラと GPS/GNSS を使用し、自車両の自己位置推定に必要な地図を生成する。地図生成はまず、同一のルートを何度か手動走行することにより車載センサ情報を収集したのち、路面上の白線などをランドマークとする地図情報が既存の地図情報に逐次追加されてゆき、最終的に自動運転に必要な地図が自動的に構築される。

廉価な車載カメラを前提とした地図構築手法に関しても先行研究はあり、例えば Schreiber らはスマートフォンのカメラとステレオカメラを組み合わせ、複数回の手動走行データを用いた自己位置および地図精度の定量的解析を行っている [90]。本論文では自動運転の性能を下げる可能性のある環境要因について詳細に述べているが、車載カメラ側の要求仕様に関しては述べられていない。それに対し、著者の研究グループではさまざまなタイプの車載カメラを有しており、これらカメラが自動運転用地図の生成にあたってどのような要件を満たすべきかを検証することが本研究の目的の一つである。一般にカメラは画角 (FOV) と可視領域 (認識可能距離) にトレードオフがあり、それゆえ 2.2.2 項でも述べたように、Long-range camera [96] と Fisheye camera [97] が用途によって使い分けられている。カメラ認識技術に関しては多数の先行研究が報告されているが [98] [99] [100] [101] [102]，著者の研究グループにおける画像技術の特徴的なアプローチはステレオ視による高精度測距と物体認識の両立である [96]。また Fisheye camera に関しては、白線などの検知精度を高めるためのさまざま

な技術開発を進めており、魚眼特有の画像ゆがみを抑えつつ、環境からの外乱光を抑えることで対象物の検知精度を向上させている [97]。

本章では、これら2つのカメラについて、地図生成および自己位置推定の性能という観点で比較をする。4.2節において、まずテストコース手動走行時のそれぞれのカメラの検知データから地図を生成し、その特徴を比較する。そして、結果的には Fisheye camera を用いることで当該のテストコースを自動走行可能であるという見通しを得たことから、4.4章において自動運転実験の結果を示す。

本章ではさらに、構築された地図が自動運転に利用可能な情報量を有するか否かを判定する地図精度判定方法についても検討する。そもそも自動運転用の地図生成においては、センシングが100%検知できることは決して保証されず、したがって自己位置推定にも誤差が必ず生じる。それに加えて GPS/GNSS の自己位置にも誤差があることから、結局生成した地図が「真値」にどこまで近いかを知ることは不可能である。そこで、構築した地図の判定にあたっては、地図が自己位置推定に必要な情報量を十分に有しているか否かを判定することが考えられる。4.3節において本研究で検討した手法を述べる。

なお、本章では路面上の白線を自己位置推定におけるランドマークとして用いるが、3.2.1項の Fig. 3-3 で示したようなラストワンマイルにおける地図生成において、白線のない道路を走行するシーンが多数であることが予測される。これはあくまでセンシング上の課題であり、道路画像から路端などの情報をセンシングする手法も検討が進んでいる [96]。本稿で検討する手法は、白線だけでなく路端などの情報にも適用可能である。また、本稿では白線を点群として取り扱うことで、LiDAR などの情報との互換性を実現可能である。文献 [103] では白線を点群情報として、視野をオーバーラップさせていないステレオカメラと LiDAR の両方を用いて SLAM を行う手法が提案されている。さらに、白線を点群として扱うことで、第5章で示すように統計学に基づく白線精度判定が可能となる。

4.2 地図生成手法

まず、地図生成の基礎検討として、白線情報に基づく地図生成手法を検討する。3.2.1項で検討した通り、GPS は容易に誤差が生じ、計測条件の良い場所であっても走行回

次ごとに値が変わる可能性がある。したがって、地図の単純結合を行うだけでは正確な地図とはならないことから、「自己位置を推定しながら地図を生成する」という SLAM の原理を利用する。

4.2.1 地図生成ステップ


Fig. 4-1 は、白線地図生成手法の概要を示す。大きく 3 つのステップに分かれており、それぞれについて述べる。

Fig. 4-1(a)は 1 つめのステップを表す。小型ステレオカメラを用いて自車両前方に存在する白線を検出し、自車両を基準とする相対座標系からグローバル座標系に変換する。この時、座標変換に用いる自車両の位置および進行角は、2.3.2 項で述べた通りオドメトリを用いて予測する。

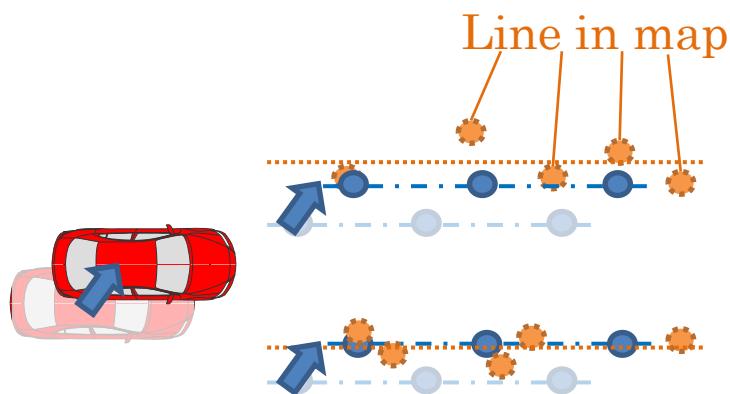
Fig. 4-1(b)は 2 つめのステップを表す。地図として蓄積した白線位置を線ランドマークとして、自車両の位置を修正する。まだ地図が全く存在しない初回走行時の走り出し時は、検出した白線をそのまま地図に反映する。その後は、1 タイムステップ前に検出した白線を地図として用いて自己位置修正を行いながら、白線情報を地図に統合する。2 回目以降の走行では、1 回目の走行で生成した白線地図情報をフルに用いることができる。

Fig. 2-3 および Fig. 2-4 に示した通り、本稿で使用する車載カメラの白線の位置は自車両前方に左右 3 点ずつの点列として得られる。本稿では、これら点列をそのまま地図に蓄積する仕様としたが、白線地図が点群データとなることから、白線地図の点群を線ランドマークに変換する必要がある。そこで本稿では、特定の範囲（例えば自車両の前後 50 m）に存在する白線の点群に対して最小二乗法により線分を導出し、この線分を線ランドマークとして用いる。また、自己位置の誤差により別の白線同士（例えば左側と右側の白線）がマッチングされることを防ぐため、白線地図は左側と右側で分けて蓄積することとした。なお、地図における白線のデータ型のあるべき姿については今後の検討課題である。


Fig. 4-1(c)は 3 つめのステップを表す。修正した自己位置に基づき、グローバル座標における白線の位置を修正し、白線地図に情報を追加（統合）する。本稿では基礎検討として単純統合を選択したが、文献 [85]等でも提案されているように、検出したオブジェクトの統合に確率論的扱いを行うことが今後の課題である。



(a) Lane detection.



(b) Localization.



(c) Map integration.

Fig. 4-1 Scheme of lane-map construction.

4.2.2 テストコースの白線を用いた地図生成結果

次に本項では、手動走行による白線地図生成の実車検証結果を示す。実験において、ドライバは同一のコース（内側の車線）を計5周走行した。1周目から4周目の走行データは白線地図生成手法の検証使用し、5周目のデータで生成した白線地図に基づく自己位置推定の検証（後述）を実施した。なお、ここでは「白線」と記述しているが、今回使用したカメラは白線と黄色線を区別しないため、路面上にペイントされた線の意味で「白線」と表記する。

Fig. 4-2 は地図生成結果、Fig. 4-3 はこのうち大 R 部分を拡大した図である。ここでは、グローバル座標系（緯度・経度）で表現された地図を、テストコースの南西約100 kmの地点を基準とするxy座標系に変換しており、x軸が東方向、y軸が北方向を表す。以降の検討では全て同一の座標系でプロットしている。Fig. 4-2, Fig. 4-3 とともに(a)は Long-range camera による白線地図生成結果、(b)は Fisheye camera による白線地図生成結果である。赤＊、青 x は統合された白線位置であり、Long-range camera の結果においては自車両に対して右側及び左側の白線位置を表す。Fisheye camera の結果においては左側が赤＊、右側が青 x である。実線は自己位置の平均軌跡を表しており、1周目から4周目にかけての自己位置の点群を空間上で重心点をとって平滑化したものである。

Long-range camera による地図生成結果と、Fisheye camera による結果を比較すると、Fig. 4-3 に示すように、カーブ部分における検出状況が異なる。Fig. 4-3(a)では、カーブ部分において白線位置を示す＊および x が存在しない領域がある。ここでは白線位置がカメラの画角外となるため、白線位置が一度も統合されてなかった。一方、Fig. 4-3(b)では、主にカーブの内側の白線位置が安定して統合されている。これは Fisheye camera が自車両近傍の白線を検出可能であることから、カーブ中であっても白線がカメラの画角に入ったためである。このように、画角の違いによって統合される地図の形は異なる。




Fig. 4-2 Map expansion result.




Fig. 4-3 Map expansion result (zoomed at major radius curve).

4.3 自己位置推定誤差を用いた地図精度判定手法

本節では、地図精度判定手法について述べる。「はじめに」で述べた通り、構築された地図は自動運転において利用するにあたっては一つ問題がある。それは、生成された地図に関して「真値」を得ることは不可能であるという点である。というのも、ランドマークとして登録された地図情報は推定された自己位置に基づいて生成されており、常に誤差を持つからである。そこで、次項から示す考え方に基づき地図精度判定手法を構築する。

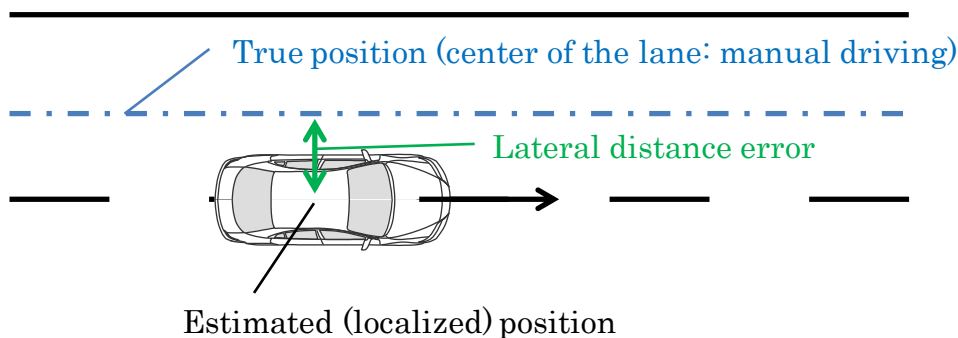



Fig. 4-4 Definition of “lateral distance error.”

4.3.1 地図精度判定の考え方

まず、地図精度判定の考え方を述べる。生成した地図は、自動運転において主に自己位置を推定するために用いられる。したがって、生成した地図の中に、自己位置推定のための情報が十分に含まれているかを判定する、すなわち自己位置推定への「利用可能性」評価が必要となる。このような考え方は先行研究においても存在し、GwonらはLiDARベースで生成レーン地図生成において、自動運転へ使用可能な要件について「精度」「データ効率」「利用可能性」の3つを挙げている [104]。ただし本文獻における「利用可能性」はレーン地図をどのライン補完手法で行えば効率的であるかに言及したものである。ほかにもLiDARの点群を用いてオーバーラップ量に基づき自己位置推定の誤差を推定する手法 [105]、state estimation errorに基づき自己位置推定性能を予測する手法 [106]などが提案されている。これら手法はLiDARにより取得可能なリッチな点群情報の利用を前提としており、それに対して車載カメラから取得可能な検知情報はよりスパースであることが多いと考えられる。したがって、オーバーラップの量などを用いることは難しいと考えられる。

そこで本稿では、Fig. 4-4に示すように自己位置の真値（車線中央）と推定した自己位置との横方向偏差として定義される「横方向偏差」を用いて「利用可能性」を評価する。この距離は、自車両が車線からはみ出さないという条件を満たすため、0.5 m以下であることが求められる。そこで本稿では横方向偏差0.5 m以下を「利用可能性」の基準値とする。ここで0.5 mという基準値は以下のように算出した。まず、日本国内において比較的狭い車線幅は3 mである。そして、乗用車の一般的なサイズは、大きいもので2 m弱であることから、車線からはみ出ないための最小限必要な自己位置推定精度として上記を設定した。



(a) Bird's-eye view. (b) Longitudinal distance corresponding to x coordinate.

Fig. 4-5 Definition of each evaluation area (A)~(D).

本稿で検討する地図生成手法は、まず手動走行中に車載カメラでとらえた情報に基づきオフラインで自己位置推定を行う。そして、同じコースを何度か手動走行を行う中で、自己位置推定の誤差が0.5 mを下回る場合に、自動運転に「利用可能」と判定する。

なお、ここでは地図精度判定における自己位置推定誤差として横方向のみを考慮したが、これは本章においてはまず白線を研究対象としたことによる。前後方向の自己位置修正のためには、標識等の点ランドマーク、自車両の進行方向に対して角度をもった路面ペイント(停止線等)の情報が必要である。前後方向の自己位置推定誤差は、直線道路(あるいは曲率の小さいカーブ)を走行する際には問題にならないが、交差点等の 90° カーブでは問題となる可能性がある。前後方向に対しても、自己位置推定誤差の明確な基準値を、前述した横方向と同様に算出する必要があると考えるが、現時点では未考察であり、今後の課題とする。

4.3.2 テストコースの白線情報を用いた検証

Fig. 4-2 より、地図の情報量は直線部と曲線部で異なることから、自己位置推定結果も直線部と曲線部で異なる結果が出ると予測される。そこで、Fig. 4-5(a)に示すように、テストコースを(A)~(D)の4つのエリアに分けた。すなわち、大R部分、北側直線路、小R部分、南側直線路の4つである。スタート位置を、エリア(A)とエリア(D)

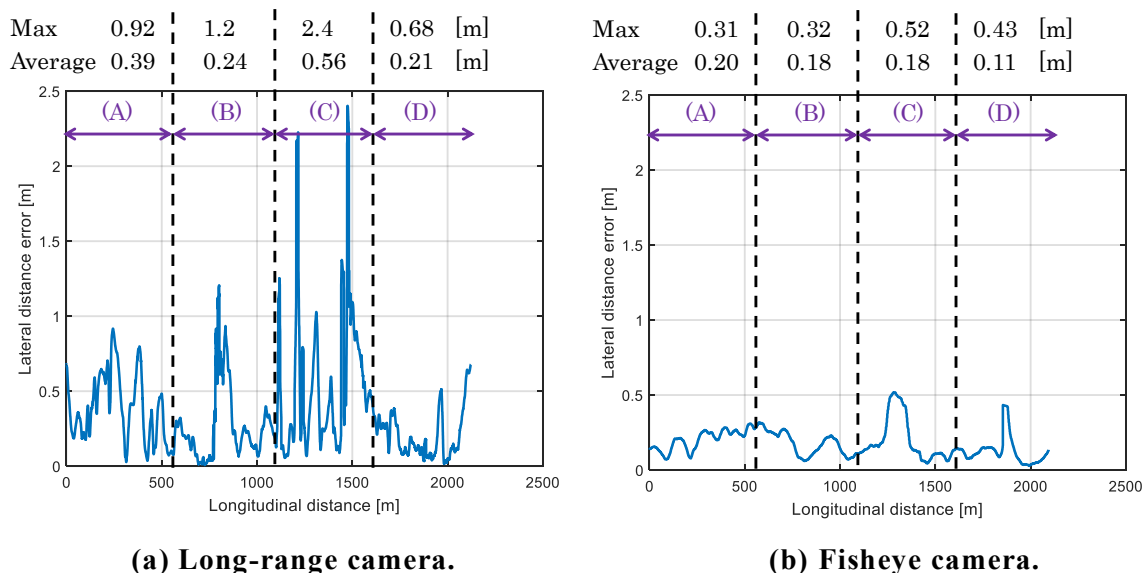


Fig. 4-6 Localization result: comparison of lateral distance error.

の境界とする時，スタート位置からのそれぞれのエリアまでの走行距離は Fig. 4-5(b) に示す通りとなる。以降，横方向偏差は横軸をスタート位置からの走行距離としてプロットする。

Fig. 4-6 に横方向偏差の結果を示す。Fig. 4-6(a)は Long-range camera による結果，Fig. 4-6(b)は Fisheye camera による結果を示しており，いずれも 1～4 周目の走行データにより生成した地図に基づき，5 周目の走行データにより自己位置推定を行った結果である。図の上部には，それぞれのエリア(A)～(D)における最大および平均の横方向偏差を記載している。

Fig. 4-6(a)の Long-range camera による走行結果を参照すると，曲線部分となるエリア(A)およびエリア(C)で横方向偏差の平均が大きくなっており，特に小 R 部分のエリア(C)では平均値が基準値0.5 mを超過している。これは，白線が画角内に入らないことに加え，このエリアにおける GPS の検知状況が悪く，自己位置の誤差が生じやすい環境である点が挙げられる。

一方，Fig. 4-6(b)の Fisheye camera による走行結果を参照すると，横方向偏差はほぼ全てのエリアで目標値の0.5 mを下回っている。小 R 部分のエリア(C)で最大0.52 mとなっているが，これは曲線部における白線位置の検出誤差と GPS 検出誤差が重なって生じたと考える。この2つの結果から，少なくとも本テストコースを一周するためには，曲線部でも白線が検出可能な Fisheye camera の使用が必要であることが結論づ

けられる。つまり、自動運転を常に安定して（経路から逸脱することなく）実施するためには、ランドマークが継続して見えることが必要条件と結論づけられる。

なお、直線部であるエリア(B)(D)において、Fig. 4-6(a)に示す Long-range camera による自己位置推定誤差が、Fig. 4-6(b)に示す Fisheye camera による自己位置推定誤差より平均値・最大値ともに大きくなっている。特にエリア(B)ではこの傾向が顕著である。一般に、横方向の誤差修正においては、より前方の白線を検知可能な Long-range camera の方が有利であると考えられるが、本結果は逆となっている。これについては別途詳細な解析が必要であるが、Long-range camera の方が、より遠方が見える分だけ白線の横方向の位置検知精度自体は Fisheye camera より落ちる、自車の進行角を積極的に修正する結果として位置誤差が大きい傾向になる、等が要因として推察される。

4.4 Fisheye camera を用いた自動運転実験

最後に、テストコースにおいて自動運転実験を行った。前節で示した結果は、Long-range camera による自動運転は成功せず、Fisheye カメラによる自動運転は成功する可能性があることを表していた。実際、Long-range camera のみを用いた自動運転を本テストコースで試行したところ、毎回カーブ部分でコースアウトし一度も成功しなかった。そこで、本節では自動運転にあたって Fisheye camera のみを用いることとし、前節にて Fisheye camera で作成した白線地図を用いてテストコースを周回した。Fig. 4-7 に自動運転実験の様子を示す。実験において、自動運転システムは Fisheye camera からの白線位置、GPS からの自己位置、車両 CAN からの速度、操舵角などの情報を受信する。自動運転システムは 2.2.1 項で述べた外部コントローラに実装し、自己位置推定はラップトップ PC に実装した。



Fig. 4-7 Photo of autonomous driving test.

4.4.1 自動運転実験における評価ポイント

ここでは、拡張した地図による自動運転の「走行可能性」を評価する。地図が過大な誤差を含んでいたり、自動運転にあたって十分量を含んでいなかったりすると、自動運転はレーンから逸脱する、不安定にふらつく、等の継続不能な状況となりうる。したがって、本節では以下2つの指標で自動運転の走行結果を評価する。

- ・自動運転車が安定してコースを周回できたか
- ・操舵角が過大に振動せず安定したか

1つ目のポイントについては、合計5周自動運転実験を行ったうち、周回に成功したラップ数で評価する。ここで「成功」とは、レーンを逸脱することなく一周できたと定義する。実験中、レーンを逸脱しそうになった場合、試験者がその時点で走行を中止し、当該の周回を「失敗」と評価した。2つ目のポイントについては、後述するエリア(B)における操舵角の二乗平均平方根 (Root Mean Square: RMS) で評価する。このRMSの値が小さいほど、操舵角の振動が小さく、自動運転はより安定であったと結論づけられる。詳細は後述するが、ここでは2つの自己位置推定手法について上記2つの指標を比較する。

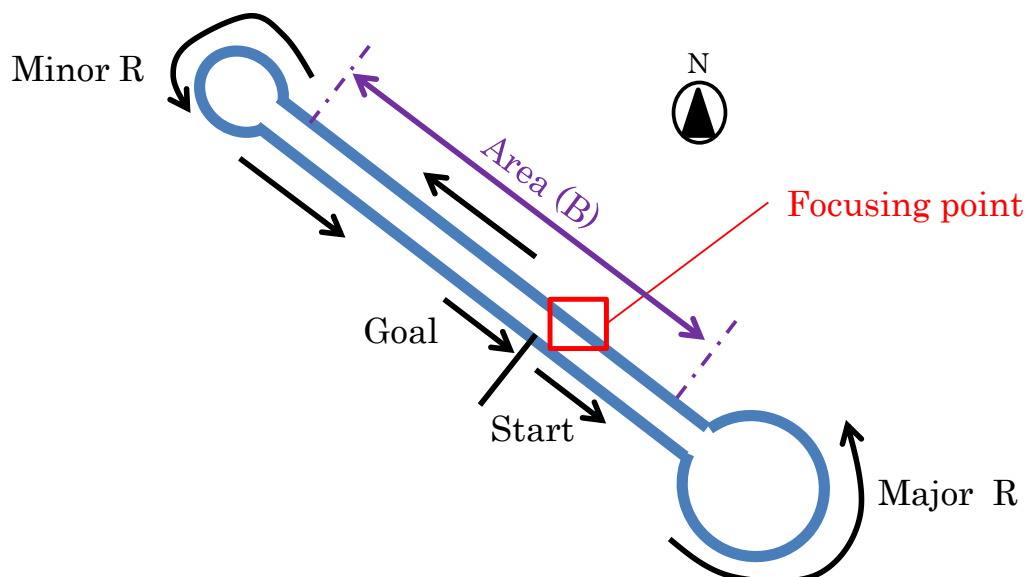


Fig. 4-8 Driving procedure and focusing point in the test field.


Fig. 4-8 に、自動運転実験によるスタート・ゴール位置、エリア(B)において特に注目したポイント（注目点：focusing point）を示す。エリア(B)を選んだ理由は、この場所において後述する 2 つの手法間での操舵角の挙動が大きく異なっていたためである。特に注目点においては、毎回特徴的な操舵角のふらつきが生じた。したがって、本節では特に注目点における挙動に着目して自動運転結果を評価する。

4.4.2 自己位置推定手法をそのまま適用した自動運転結果


Fig. 4-9 に、3.1 章で述べた自己位置推定手法をそのまま適用した自動運転システム（ここでは『手法 1』とする）の走行結果を示す。後述するが、手法 1 による走行は 5 周中 1 周しか「成功」しなかったため、ここでは唯一成功したラップにおける実験結果を示している。

Fig. 4-9(a)はコース一周走行時の操舵角時間変化を示している。テストコースは反時計回りであり、左方向に旋回する際に正の操舵角が生じる。したがって、正方向に 60° 以上の操舵角が出ている 2 か所は順に大 R 部分、小 R 部分であり、その間の、操舵角が 0° 付近になっている部分は順に南側直線部のスタート位置以南、北側直線部、そして南側直線部の北側からスタート位置までを表している。注目すべきポイントは直線部で、南側直線部に比べて北側直線部で操舵角の振動幅が大きくなっている。


次に、Fig. 4-9(b)は自己位置の軌跡および白線位置プロットしたものである。本図



(a) Steering angle (overall).



(b) Localization (expand).



(c) Steering angle (expand)

Fig. 4-9 Autonomous driving result (without heading error ignoring method).

は、前述した注目点の部分を拡大している。マゼンタの実線は推定した自己位置の軌跡を、黒色の一点鎖線は GPS による自己位置の軌跡を、ライトブルーの破線は地図から取得した目標走行軌道をそれぞれ表す。また、赤*および青xはそれぞれ地図における右側、左側の白線位置をそれぞれ表す。本図は北側直線部であり、自車の移動方向は右下から左上の方向である。

GPS による自己位置は常にオフセットしているが、GPS のオフセット量は短時間では大きく変化しないため、軌跡の形状自体は信頼できるとみなせる。この観点からみると、GPS による自己位置の軌跡に対し、推定した自己位置の軌跡は大きくふらつい

ていることが分かる。この時の操舵角の推移を Fig. 4-9(c)に示す。ここでは評価し易さを考慮して横軸を Fig. 4-9(b)と同じ x 座標としており、操舵角は右から左に推移している。この場所は直線部でありながら、操舵角が $\pm 40^\circ$ のふらつきを生じており、自車両の不安定なふらつきを招いている。Fig. 4-9(b)と Fig. 4-9(c)を比較すると、推定した自己位置の軌跡と目標走行軌道の偏差が、進行方向に対して右方向（自車両を基準とする相対座標に対して負の方向）にずれたところで操舵角が正に触れており（ $x = 6.192 \times 10^4$ m付近）、逆もまた同様である。このことから、操舵角のふらつきは、推定した自己位置が目標走行軌道から逸脱するのを防止するようにフィードバック制御がかかったことで生じている。そして、GPS から取得した自己位置の軌跡に比べて、推定した自己位置の軌跡のふらつきが大きいことから、このふらつき減少は自己位置の推定誤差から生じている。

自己位置の推定誤差が生じた原因として、Fig. 4-9(b)において、矢印で示したポイントに注目すると白線位置を示す青*が、進行方向に対して角度がついていることが見て取れる。この場所において白線は進行方向に対して平行であり、本来角度はつかないはずである。この角度の誤差が、Fig. 4-9(a)に示すように自己位置推定の誤差につながったと考えられる。すなわち、2.3.2 項で述べた線ランドマークマッチングは自車両の進行方向の推定値を修正しようとするため、検出した白線位置に角度の誤差が生じると、その誤差に影響されて自車の進行角推定値にも誤差が生じ、結果として Fig. 4-10(a)に示すように自己位置の推定誤差につながると考えられる。白線位置の角度誤差は Fisheye camera の画像認識部の仕様により生じたものである。

4.4.3 自己位置推定手法の変更による実験結果

前項で述べた問題は、画像認識の改良により対処すべきであるが、本稿では制御側の対策として、Fig. 4-10(b)に示すように自己位置推定手法に改良を加えることとした（手法2）。すなわち、Fisheye camera で取得した白線は常に自車の進行方向に対して平行であるとみなし、線ランドマークマッチングによる自車の進行角の修正を行わない（角度の誤差を無視する）ことにした。

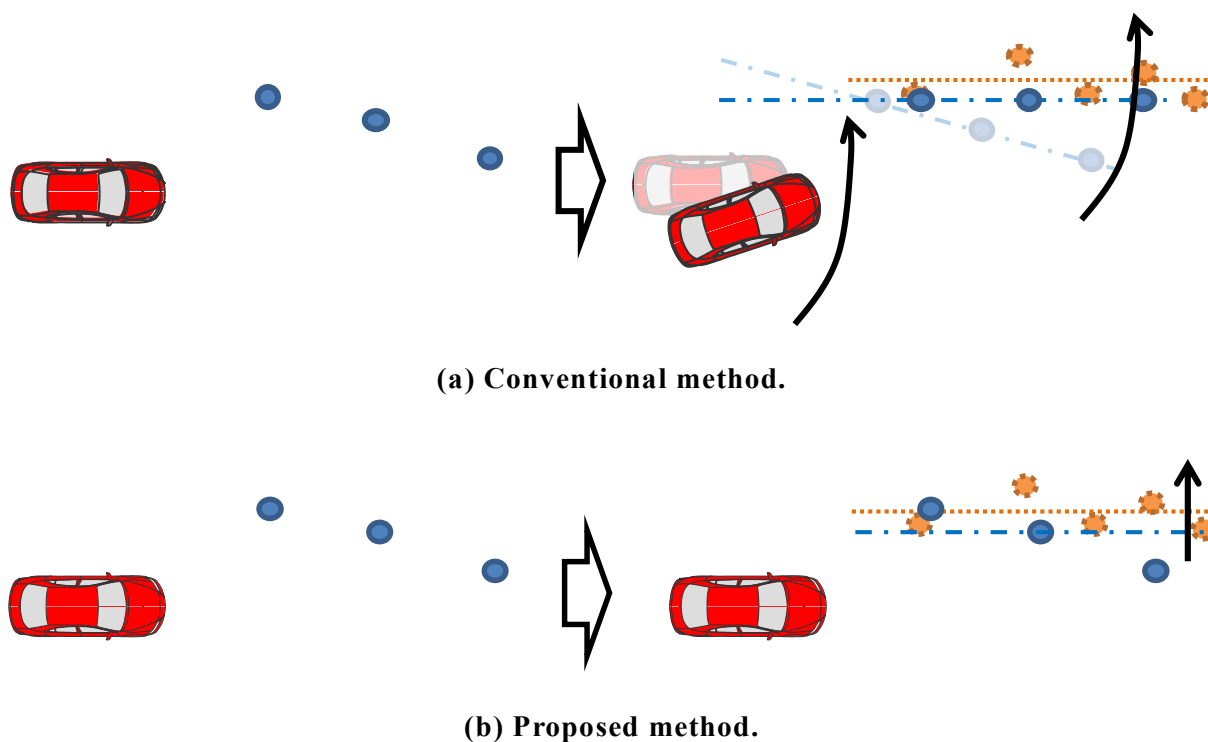




Fig. 4-10 Heading error ignoring method.


変更した自己位置推定手法（手法 2）により，再度自動運転実験を行った結果を Fig. 4-11 に示す。プロットの仕方は Fig. 4-9 と同様である。Fig. 4-11(a)の操舵角の時間推移をみると，Fig. 4-11(a)に比べて直線部での操舵角のふらつき幅が小さくなっている。注目点に拡大した Fig. 4-11(b)でも，自己位置軌跡のふらつきが小さくなっており，Fig. 4-11(c)では操舵角のふらつきが手法 1 の半分の $\pm 20^\circ$ となっている。このことから，手法 1 に比べて手法 2 はより安定した（ふらつきの少ない）自動運転が実現できている。



(a) Steering angle (overall).



(b) Localization (expand).



(c) Steering angle (expand)

Fig. 4-11 Autonomous driving result (with heading error ignoring method).

4.4.4 実験結果まとめ

Table 5 は、先述した 2 つの評価指標に従って、手法 1 及び手法 2 の実験結果をまとめた表である。横列はそれぞれ 5 周中何周「成功」したか、エリア(B)における操舵角の RMS をそれぞれ表しており、縦列は手法 1, 手法 2 で結果を比較している。手法 1 は 5 周中 1 周しか成功しなかったのに対し、手法 2 は 5 周全てで自動運転による集会に成功している。また、操舵角の RMS に関しても、手法 2 の方が手法 1 に比べて RMS 値が 2/3 程度に小さくなっている。このことから、手法 2 は手法 1 に比べてより安定して自動運転できたと結論づけられる。

第4章 地図生成手法及びカメラ特性による比較

ただし、この結論は手法2が優れていると評価されるわけではない。今回の自動運転実験において、車線変更など、自車両の進行角が白線の角度と平行でない走行パターンの実験は実施していない。線ランドマークマッチングにおいて白線の角度を無視したことで、車線変更時などに自己位置の推定誤差が大きくなる可能性があり、引き続きの検討が必要である。また、今回は検知範囲が非常に近距離の **Fisheye camera** を用いており、白線位置の検出結果の誤差が大きな角度誤差となる。その点、検知範囲がより遠距離となる **Long-range camera** を用いた線ランドマークマッチングの方がより安定であると考えられ、今後は両者の組み合わせ等も検討する必要がある。さらに、現在高価な **LiDAR** も将来的には低廉化すると見込まれており、より安定した自動運転システムの実現に向けてはカメラと **LiDAR** を適切に組み合わせることも必要と考える。

4.5 本章のまとめ

本章では、高コストな **LiDAR** に代わって車載カメラのみを用いた地図生成手法と地図精度判定手法について論じた。地図生成手法の検証にあたり、画角とレンジの異なる2種類のカメラを使用し、それぞれのカメラを用いた地図生成の結果を比較することで、自動運転における外界認識センサの最低要件の抽出を試みた。2種類のカメラとして準備したものは、一つは長レンジで狭い画角を持つ **Long-range camera**、もう一つは 180° の広い画角をもつ **Fisheye camera** である。どちらのカメラも自車両前方の白線が同様のデータ形式で検知可能であり、検知距離のみが異なるという特徴を持つ。

地図生成手法の検証にあたり、「横方向偏差」を定義し、自己位置推定精度（横方向

Table 5 Summary of driving test result.

	Method 1 (w/o error ignore)	Method 2 (w/ error ignore)
Number of laps: success / total	1 / 5	5 / 5
RMS of steering angle in area (B)	11.7 deg	8.8 deg

偏差が 0.5 m を超えるか否か) に基づき地図生成性能を評価する地図精度判定手法を提案した。構内テストコースを手動運転で走行した際の白線検知結果を用いてオフライン検証を行った。結果、Long-range camera による走行では横方向偏差が 0.5 m を超過する箇所がカーブ部分を中心に存在したのに対し、Fisheye camera では全ての領域で横方向偏差が 0.5 m 以内に収まった。そして、Long-range camera のみを用いた自動運転を本テストコースで試行したところ、毎回カーブ部分でコースアウトし一度も成功しなかった。これらの結果から、少なくとも提案する地図精度判定手法により横方向偏差が 0.5 m 以下となることが、構築した地図が「使用可能」と判定するうえでの必要条件であることが示唆された。センサ要件としては、ランドマークがコンスタントに検出されることが自動運転継続にあたってのキーとなることが示されたことになる。

次に、地図精度判定手法の妥当性をさらに評価するため、テストコースにおいて Fisheye camera のみを用いた自動運転の走行試験を行った。試験にあたって、自動運転が毎回不安定となってコースアウトする箇所が存在した。この不安定性は Fisheye camera の白線検知が不正確になっていたこと、具体的には検知された白線の角度に誤差が生じていたことが原因であり、白線による自車両の進行角修正を行わないことで自動運転継続が可能となった。このことから、地図精度判定にあたっては、横方向偏差だけでなく他の要素でも検証を行う必要があると考えられる。換言すれば、横方向偏差が 0.5m 以下となることは必要条件であっても十分条件とは言えない。以上のことから、地図精度判定手法に関してはさらなる検討が必要であり、次章ではその一つの可能性について述べる。また、今回は検討しなかった自己位置推定誤差に関する検討は今後の課題である。

第5章 地図情報精度判定手法

5.1 はじめに

前章では、路面上の白線をランドマークとする自己地図生成手法を提案した。その際に課題となったのが、生成した地図が自動運転可能か否かを適切に判定する方法であり、前章では生成した地図による自己位置推定のシミュレーションを行い、その推定誤差を自動運転可能性判定の指標とした。しかし、前章の手法では、自動運転可能か否かの判定をするために自動運転制御またはシミュレーションを試行する必要がある、時間とコストがかかるという点が課題であった。また、横方向偏差に基づく評価方法は必要条件としては使えても十分条件とは言えなかった。

そこで本章では、地図情報そのものを統計学的に検証する新たな地図精度判定手法を検討する。まず5.2節では提案手法の考え方と手法内容を述べる。本手法は、生成した白線地図自体の情報量およびばらつきが、位置誤差0.5 m以内を実現するための許容値以内であるかを統計学的に判定する手法である。この方法により、自動運転制御またはシミュレーションを行うことなく自動運転可能性の判定が可能であり、地図精度判定の時間やコストを低減可能である。次に5.3節において、前章と同じテストコースにおける走行データを用いて地図精度判定手法のオフライン検証を行い、本手法により、既報と同等レベルの97%（目標値）の領域で自動運転可能と判定可能かどうかを検証する。また、地図自体のばらつきが大きいところを適切に「自動運転不可能」と判定可能かどうかを検証する。

なお、「真値」を得る方法の一つとして、利用者が自ら地図情報を登録・拡張していくフリーの地図データベース OpenStreetMap (OSM) [107]の利用も提案されている。OSMの地図はXML形式で記述され、自動運転に利用しやすいデータ構造であることからさまざまなユースケースにおける Path planning への利用が検討されており、Valet parking に向けて駐車場の設計図面に基づく OSM 形式の正確な地図を作製する手法 [108]、OSM に登録されているオープンソースデータを用いて HD 地図に頼らずにスムーズな Path planning を行う手法 [109]などが提案されている。しかしながら、OSM

に関しても地図情報の精度が登録者に依存する部分があり、「真値」として信用できるとは限らない。OSMを地図精度判定に利用する方法は著者も提案している [110]が、本章では上述した統計的手法にフォーカスする。

5.2 地図精度判定手法の検討

5.2.1 地図精度判定の基本的方針

まず、地図精度判定における基本的な方針を説明する。前節で述べたように、本稿は白線地図を点群として扱う。したがって、地図精度判定はある区間における白線の点群の数が閾値より多いか否か（＝十分な情報量を持っているか否か）に基づき判定を行う。この閾値をどのように算出するかが本手法の鍵となる。

前章では、地図精度判定の指標として自己位置推定精度を使用した。これは、ランドマーク地図が主に自己位置推定に使用されること、特に進行方向に向かって横方向の自己位置のずれが自動運転の安全性に悪影響を与える点に着目したものである。既報の手法では、手動走行時の自車両の本来の軌跡が毎回同じ場所（車線の中央）を走行しているという前提をおいた。すなわち、新たに走行したデータと既作成の地図を用いて自己位置推定を試行し、既作成の地図内の目標走行軌道（＝過去の自己位置推定結果）と結果を比較するという方法をとった。そして、自己位置誤差が所定値（0.5 m）を超えているか否かで地図精度判定を行った。しかしながら、手動走行時に毎回同じ走行軌跡を厳密に通過できている保証はないという点で、本手法には問題がある。

本稿では、統計学的に、白線情報が自己位置推定誤差を所定値以内にできるほど十分な情報量かどうかを判定する手法を考案した。本手法は、自己位置推定の横方向誤差を所定値以内に収めるという考え方は生かし、白線の点群情報自体のばらつきが横方向誤差の許容値以内に収まるか否かを判定する。Fig. 5-1 に示すように、地図上に登録された白線（図中の破線で示す）と実際の白線位置の横方向誤差は、自車両の自己位置推定においてそのまま横方向誤差として生じることになる。従って、統合した白線の点群の横方向ばらつきが統計的に所定値（0.5 m）を下回っていることが、自己位置推定の横方向誤差を所定値以内に収めるための必要条件とみなすことができる。次節において手法の詳細を述べる。

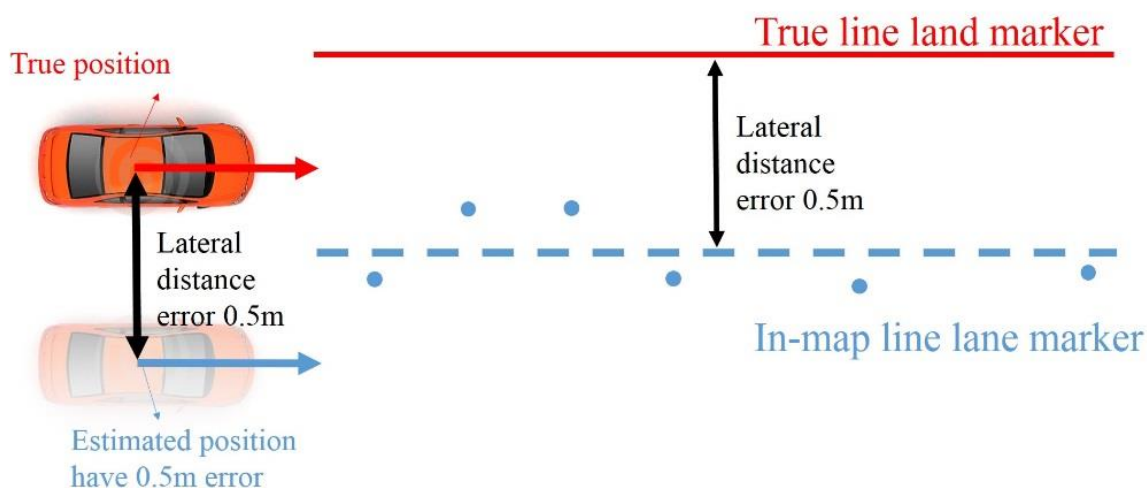


Fig. 5-1 “Lateral distance error” between in-map lane marker and true lane marker.

5.2.2 線形回帰モデルに基づく閾値設定

本節では、閾値設定の方法を述べる。ここでは Fig. 5-2 に示すように、路面上の白線の真値が数式 $y = ax + \beta$ と表現される直線であるとする。ここで x, y はそれぞれ自車両の進行方向と平行・垂直な成分、 α, β は傾きおよび y 切片を表す。ここでは簡単のため、白線は自車の進行方向に対して垂直方向ではないという仮定をおいており、図中では白線の真値が自車両の進行方向と平行である場合 ($\alpha = 0$) を描画している。この時、「横方向誤差 0.5 m 以内」を実現するための白線位置の上限と下限は、数式 $y = ax + \beta \pm 0.5$ で表される 2 つの直線（図中では破線として描画）である。そして、地図上に登録された白線の点群の最小二乗近似線を数式 $\hat{y} = ax + b$ と表現すると、ある区間 $(0, x_k)$ において、最小二乗近似線（Fig. 5-2 中の破線）は 2 つの直線 $y = ax + \beta \pm 0.5$ の間に収まることが必要である。

Fig. 5-2 を用いて、最小二乗近似線が横方向誤差 0.5 m 以内に収まっているか否かを統計的に判定する考え方を説明する。いま、手動走行にて十分多数の点群（Fig. 5-2 中の多数の黒点：ここでは N 個とする）が得られたと仮定する。この時、この N 個の点群による最小二乗近似線 $\hat{y} = ax + b$ （Fig. 5-2 中の斜めの破線）は限りなく真値の白線 $y = ax + \beta$ （Fig. 5-2 中の x 軸と重なっている実線）に近づくはずである。しかしながら、実際には手動走行の回数、すなわち取得できる点群の数には限りがあり、ある点数の点群（Fig. 5-2 中の青点：ここでは n 個とする）が取得される。この時、 n 個の点群により推定される最小二乗線 $\hat{y} = ax + b$ は、真値の白線 $y = ax + \beta$ に対して誤差




Fig. 5-2 Condition of lane map to be within required lateral distance error.

が生じる。言い換えれば、最小二乗線の傾き a は α に対して、 y 切片 b は β に対してそれぞれ誤差を持っている。

上述した誤差が横方向誤差0.5 m以内に収まっているか否かを統計学的に判定する方法を説明する。いま、取得された n 個の点群から得られる最小二乗線 $\hat{y} = ax + b$ において、真値との誤差、すなわち、 α と a および β と b の誤差が閾値 Δa および Δb より小さくなる条件、すなわち、式(46)および式(47)の条件を満たすかどうかを検定する。

$$a - \Delta a \leq \alpha \leq a + \Delta a \quad \dots \quad (46)$$

$$b - \Delta b \leq \beta \leq b + \Delta b \quad \dots \quad (47)$$

Δa および Δb は、最小二乗線 $\hat{y} = ax + b$ が条件式(46)(47)を満たす確率が統計学的に十分高くなるように決定する。ここでは上記確率が、 t 検定において有意水準 p を満たすような確率となるように、Simple Linear Regression Model [111]に基づき Δa および Δb を式(48)および式(49)の通り決定する。




Fig. 5-3 Example of student's t-distribution.

$$\Delta a = \frac{1}{\sqrt{n-2}} \frac{\sqrt{\sum_{i=1}^n (y_i - ax_i - b)^2}}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} t_{p, n-2} \quad \dots \quad (48)$$

$$\Delta b = \frac{1}{\sqrt{n(n-2)}} \frac{\sqrt{\sum_{i=1}^n (y_i - ax_i - b)^2}}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} \sqrt{\sum_{i=1}^n x_i^2} t_{p, n-2} \quad \dots \quad (49)$$

ここで x_i , y_i はそれぞれ観測された i 番目の白線点群の x , y 座標, \bar{x} は観測された全 n 個の点群の x 座標の平均, a , b は観測された全 n 個の点群から最小二乗法により求めた傾き及び y 切片, $t_{p, n-2}$ は Fig. 5-3 に示すような有意水準 p , 自由度 $n-2$ の t 分布における t 値を表す。すなわち, 「現在までに得られた点群から推定した直線 $\hat{y} = ax + b$ と真値との誤差が閾値 Δa および Δb より小さい」(式(46)および式(47)で与えられた条件を満たす) という命題が, 統計学的に $1-p$ の確率 (信頼度) で真となるような Δa および Δb が(48)式および(49)式で得られる。 t 検定において, p は一般的に 0.05 などの数値が用いられる。(48)式および(49)式により, 取得した白線点群の数が十分大きければ ($n \gg 1$) $\Delta a \approx 0$, $\Delta b \approx 0$ となり, 得られた最小二乗線 $\hat{y} = ax + b$ は限りなく真値に近づくことが分かる。

次に, 誤差が「横方向誤差 0.5 m 以内」に収まるための閾値 Δa_{th} および Δb_{th} を決定する。Fig. 5-4 に示す通り, 最小二乗線 $\hat{y} = ax + b$ が 2 つの直線 $y = ax + \beta \pm 0.5$

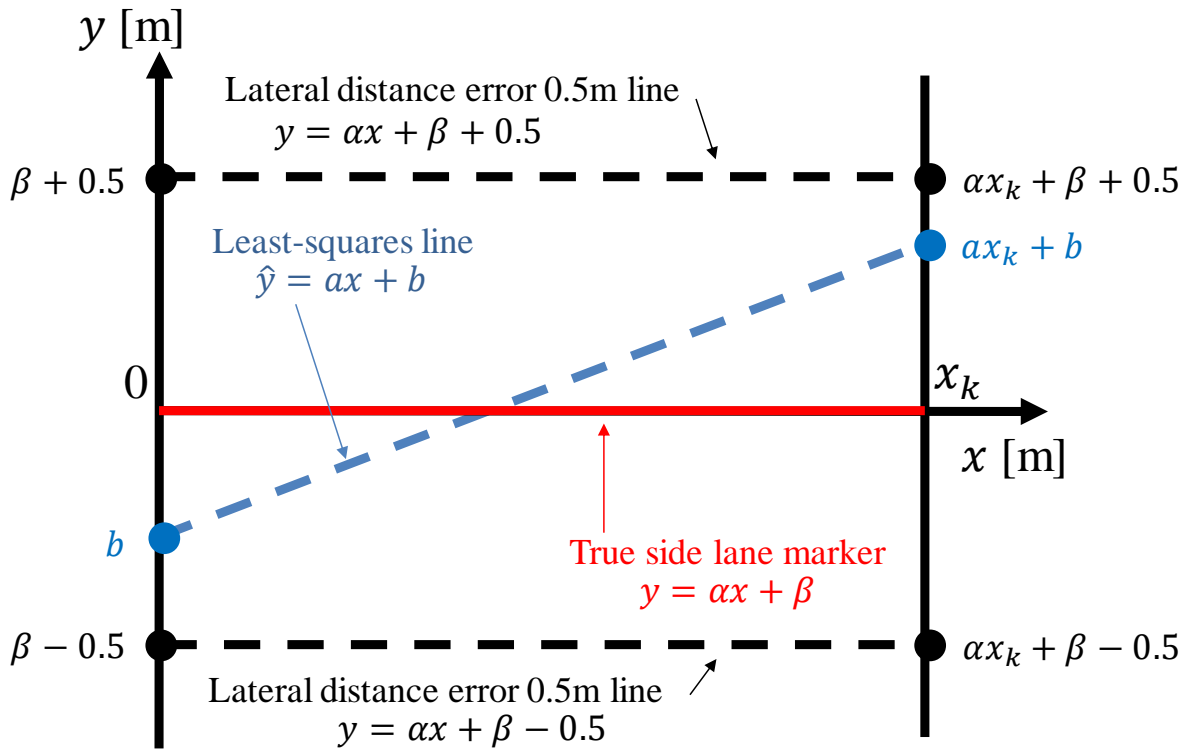


Fig. 5-4 Condition of least-squares line to satisfy lateral distance error < 0.5 m.

の間に収まるための条件は、 $x = 0$ および $x = x_k$ における y 座標の値が 2 つの直線の間
に収まることである。すなわち、式(50)かつ式(51)を満たす必要がある。

$$\alpha x_k + \beta - 0.5 \leq \alpha x_k + b \leq \alpha x_k + \beta + 0.5 \quad \dots \quad (50)$$

$$\beta - 0.5 \leq b \leq \beta + 0.5 \quad \dots \quad (51)$$

従って、式(46)(47)(50)(51)を整理し、 $\Delta a = \Delta a_{th}$ 、 $\Delta b = \Delta b_{th}$ とおくことにより、 Δa_{th}
および Δb_{th} は式(52)を満たせばよいことが分かる。ただし、 $0 < \Delta a_{th}$ 、 $0 < \Delta b_{th}$ であ
る。 Δa_{th} 、 Δb_{th} は閾値（上限値）であることから、 $\Delta a_{th}x_k$ と Δb_{th} の和が 0.5 となるよう
に Δa_{th} と Δb_{th} を設定すればよい。

$$\Delta a_{th}x_k + \Delta b_{th} \leq 0.5 \quad \dots \quad (52)$$

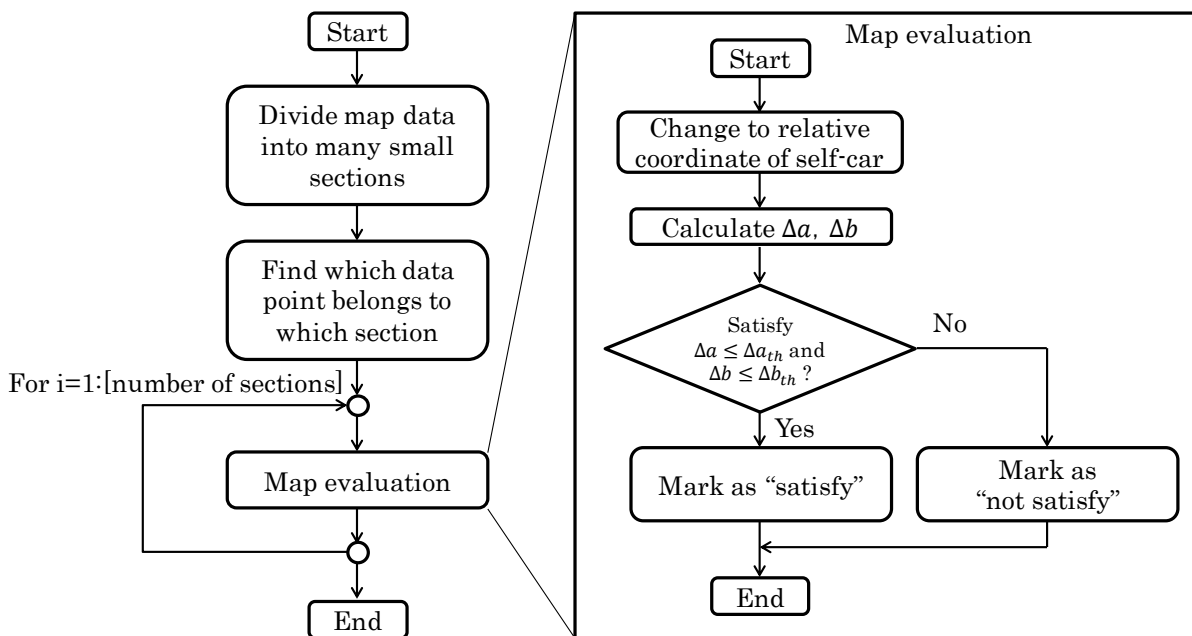


Fig. 5-5 Flowchart of map evaluation.

以上の検討により、 Δa_{th} および Δb_{th} は式(52)を満たす範囲で調整可能であり、かつ両者の合計値が決まっていることからトレードオフの関係にあることが分かる。すなわち、 Δa_{th} を大きくするほど白線の角度（傾き）のばらつきを許容する一方で横方向のばらつきにシビアになり、逆に Δb_{th} を大きくするほど角度のばらつきにシビアになる。 Δa_{th} および Δb_{th} を決定したら、現在の点群データを用いて式(48)および式(49)式から Δa , Δb を算出し、 $\Delta a \leq \Delta a_{th}$ かつ $\Delta b \leq \Delta b_{th}$ の条件が満たされれば点群の精度が高い（＝ばらつきが小さい・自動運転に使用可能）とみなすことが可能であり、逆に上記条件が満たされない場合は点群の精度が低い（＝ばらつきが大きい・自動運転に使用不可）とみなせる。

5.2.3 白線点数の閾値に基づく地図精度判定方法

前節の検討から、地図精度判定方法のフローをまとめると Fig. 5-5 の通りとなる。まず、白線の点群地図をある小さな区間に分ける。次に、新たに白線の点群地図が追加されたら、それぞれの点群がすでに登録されている地図上の区間のどこに属するかを判定する。そして、一つ一つの区間において、点群を自車両からの相対座標に変換して Δa , Δb を計算し、あらかじめ決定した閾値に対して $\Delta a \leq \Delta a_{th}$, $\Delta b \leq \Delta b_{th}$ の条件が

同時に満たされるかを確認する。条件が満たされる場合は当該区間を「自動運転可能 (Satisfy)」と判定し、少なくとも1つの条件が満たされない場合は「自動運転不可能 (Not Satisfy)」と判定する。なお、ここではレーンマーカが長い実線であることを念頭に、一定の区間に分割することとしたが、破線のレーンマーカに対しては文献 [112] などで提案されているクラスタリング手法を適用し、破線の一つ一つの区間に対して本手法を同様に適用する。

5.3 地図精度手法の検証

本節では、前節で述べた地図精度判定方法の検証結果を示す。なお、ここではテストコース全域にわたってコンスタントに検出可能であった左側の白線に対して検証を行う。

5.3.1 検証方法

4.2.2 項で述べた構内テストコースの白線地図を用いて、提案する地図精度判定手法の検証を行った。スタート位置は北側の直線部の途中で、走行時と同じく反時計まわりに所定の間隔で白線地図を区切り、No.1 から順にインデックスをつけた。そして、主に以下のパラメータを変更して結果を比較した。

- ・ 地図生成に用いる走行データの周回数 (1~6)
- ・ 閾値 Δa_{th} および Δb_{th}
- ・ 白線地図を区切る区間の長さ

Fig. 5-6 に、1 周目から 6 周目までのすべての走行データを統合した白線地図を 10 m ごとに区切った例として、結果を示す。Fig. 5-6(a)は全体図、Fig. 5-6(b)はこのうち一部分を拡大したものである。Fig. 5-6(b)を見れば、白線が 10 m ごとに区切って色分けされ、番号が順に付与されていることが見て取れる。




Fig. 5-6 Division of lane map into each section of 10 m.

Table 6 は、代表的なパラメータ ($\Delta a_{th} = 0.3/x_k$, $\Delta b_{th} = 0.2$, 区間の長さ 10 m) における走行データの周回数ごとの「自動運転可能 (Satisfy)」と判定した区画数および「自動運転不可能 (Not Satisfy)」と判定した区画数を表す。全長約 2 km のテストコースのため、区間の長さ 10 m に設定した際の区画数が 203 となっている。一番左 (Lap 1) は 1 周目の走行データのみを用いて生成した白線地図に対する評価結果を表している。右に行くほど地図生成に用いた走行データの周回数は増加し、一番右 (Lap 1 to Lap 6) 1 周目から 6 周目までのすべての走行データを用いた白線地図に対する評価結果である。また、上段から順に「全区間数 (203)」, 「自動運転可能 (Satisfy) と判定した区画数」, 「自動運転不可能 (Not Satisfy) と判定した区画数」, 「白線が全く存在しなかった区画数」を表す。白線の存在しない区画は、例えば白線そのものがないか掠れていて検知できない箇所を表しており、周回数に関わらず同じ数値となっている。

Table 6 を参照すると、「自動運転可能 (Satisfy) と判定した区画数」が周回を重ねるごとに増加していることが分かる。これは、白線の点群数が増えるごとに、白線位置の誤差が統計的に縮小するという想定に合致する結果である。ただし、4 周目以降は自動運転可能 (Satisfy) 区画の増加がほぼなくなっており、統計的な統合だけでは自動運転可能とならない場所があることが示唆されている。


5.3.2 パラメータ設定による傾向

パラメータを様々に変更して、全区画数に対する「自動運転可能 (Satisfy)」と判定した区画数の割合を比較した結果を Fig. 5-7 に示す。Fig. 5-7(a)は地図生成に用いた周回数を横軸にとったもので、閾値 Δa_{th} および Δb_{th} を凡例の通り変更している。いずれの例も「自動運転可能 (Satisfy)」の割合は周回数を重ねるごとに増加傾向にある。また、 $\Delta a_{th} = 0.3/x_k$ に設定したほうが、 $\Delta a_{th} = 0.4/x_k$ に設定した場合に比べて「自動運転可能 (Satisfy)」が多い結果となった。本図では 6 周分のデータを用いて最終的に全体の 87% の領域で自動運転可能と判定された。


$\Delta a_{th} = 0.4/x_k$ の例に着目すると、1 周目のみを用いた結果に対し、1~2 周目を用いた結果は「自動運転可能 (Satisfy)」と判定した区画が一旦下がっている。これは、1 周目のみを用いた場合に比べて、1~2 周目の 2 つのデータを用いた場合に、自己位置推

Table 6 Summary of evaluation results ($\Delta a_{th} = 0.3/x_k$, $\Delta b = 0.2$, width: 10 m).

	Lap 1	Lap 1 & Lap 2	Lap 1 to Lap 3	Lap 1 to Lap 4	Lap 1 to Lap 5	Lap 1 to Lap 6
Total number of sections	203					
Num. of section marked as “satisfy”	158	170	173	175	175	176
Num. of section mark as “Not satisfy”	32	20	17	15	15	14
Num. of section that have no data point	13					



(a) Compare with number of laps. (b) Compare with $x_k \Delta a_{th}$ (width: 10 m).



(c) Compare with width of section ($\Delta a_{th} = 0.3/x_k$).

Fig. 5-7 Ratio of "satisfy" sections.

定誤差から生じるばらつきが，統計学的な平均化の効果よりも大きくなったと考えられる。同じ傾向は $\Delta a_{th} = 0.3/x_k$ の結果には見られないが，こちらは横方向のばらつきに対する許容値 Δb_{th} が $\Delta a_{th} = 0.4/x_k$ の場合に比べて大きいためと考えられる。

次に，Fig. 5-7(b)は，全 6 周分の走行データを用いた白線を 10 m 間隔で区切り，閾値 Δa_{th} および Δb_{th} の値を変えて「自動運転可能 (Satisfy)」区画の割合をプロットしたものである。先にも述べた通り， Δa_{th} と Δb_{th} はトレードオフの関係にあり，両方を同時に増加させることはできない。Fig. 5-7(b)では $\Delta a_{th} = 0.3/x_k$ で最も多くの領域が自動運転可能となっており，閾値 Δa_{th} および Δb_{th} の設定には最適点が存在することが示唆されている。

さらに、Fig. 5-7(c)は、全6周分の走行データを用いた白線を、 $\Delta a_{th} = 0.3/x_k$ 、 $\Delta b_{th} = 0.2$ に固定した上で区画の長さを変更した結果を示している。後述するが、区画を過度に狭くすると傾き方向のばらつき判定に誤差が乗りやすい一方、区画を過度に広くすると曲線部分の判定が不正確になる。本図によれば、区画の長さを20 mに設定した際に自動運転可能領域の割合が最も高く、全体の93%が自動運転可能と判定されている。この結果は、区画の長さにも最適値が存在し、今回検証に用いたテストコースの白線地図では20 m付近が最適であることが示唆されている。

5.3.3 直線部・曲線部における精度判定結果

本節では、直線部および曲線部における精度判定結果を詳細に分析する。Fig. 5-8は、 $\Delta a_{th} = 0.3/x_k$ 、区画の長さ10 mで地図精度判定を行った結果であり、白線地図のうち直線部のある一部分を拡大したものである。順に、Fig. 5-8(a)は自動運転可能(Satisfy)と判定した区画、Fig. 5-8(b)は自動運転不可能(Not satisfy)と判定した区画を抜き出したものである。また、図中の斜めの実線は道路中心線のおおよその位置を表したものである。Fig. 5-8(a)を参照すると、自動運転可能(Satisfy)と判定した区画 No.143, 144 はいずれも道路方向に対して平行に並んでおり、道路方向に対して垂直方向のばらつきが小さい。一方、Fig. 5-8(b)を参照すると、自動運転不可能(Not satisfy)と判定した区画 No. 142 は道路方向に対して水平方向の長さが短く(5 m程度)、道路方向に対して垂直方向にばらついていることが見て取れる。このように、本稿で提案する地図精度判定手法は、このようなばらつきの大きさによって自動運転可能か否かを判定する手法であることが示されており、本手法の有効性を確認した。




Fig. 5-8 Result of map evaluation at straight road ($\Delta a_{th} = 0.3/x_k$, width: 10 m).




Fig. 5-9 Challenges of map evaluation at curving roads.

次に、曲線部における精度判定結果を分析する。本稿で提案する手法は、Fig. 5-9 に示すようにもともと直線を想定している。したがって、特に旋回半径の小さい（曲率の大きい）曲線部においては、曲線の形がそのまま横方向のばらつきと判定されうるため、直線部同様の判定が行えない可能性がある。そこで、テストコースの北西部における旋回半径の小さい曲線部分（小 R）において精度判定結果を分析する。




Fig. 5-10 Result at curving road ($\Delta a_{th} = 0.3/x_k$, $\Delta b_{th} = 0.2$, width: 10 m).

Fig. 5-10 は、 $\Delta a_{th} = 0.3/x_k$ 、区画の長さ 10 m で地図精度判定を行った結果であり、白線地図のうちテストコースの北西部における曲線部分(小 R)を拡大したものである。順に、Fig. 5-10(a)は自動運転可能 (Satisfy) と判定した区画、Fig. 5-10 (b) は自動運転不可能 (Not satisfy) と判定した区画を抜き出したものである。全体的な傾向として、直線部分 (区画 No.45~47, 57~63) は自動運転可能と判定されており、曲線部分 (No.48~56) は自動運転不可能 (Not satisfy) と判定した区画が多い。また、その際の傾向として、白線が細かく分断されている箇所 (No.48, 49, 52 等)、広がり大きい箇所 (No.53, 56) で自動運転不可能 (Not satisfy) と判定される傾向にある。ただし、曲線部分がすべて自動運転不可能と判定されているわけではないため、この曲線半径で区画の長さ 10 m であれば問題無く判定可能と判断できる。

Fig. 5-11 は、 $\Delta a_{th} = 0.3/x_k$ で地図精度判定を行い、区画の長さを変更して自動運転可能 (Satisfy) と判定した区画をプロットしたものである。それぞれ Fig. 5-11(a), (b), (c), (d) は区画の長さを 5 m, 10 m, 20 m, 30 m に設定したものである。本図によって、区画の長さによって曲線部分の地図精度判定の傾向が見て取れる。

まず、全体的な傾向として、直線部分は区画の長さによる影響を受けにくいことが分かる。それぞれの図において (a)No. 111~124, (b)No. 57~63, (c)No. 29~32, (d)No. 20~21 が同じ個所の白線を表し、いずれも自動運転可能と判定されている。一方、曲線部分に着目すると、(a)No. 105~106, (b)No. 54 は、区間の長さ 20 m 以上では自動運転可能

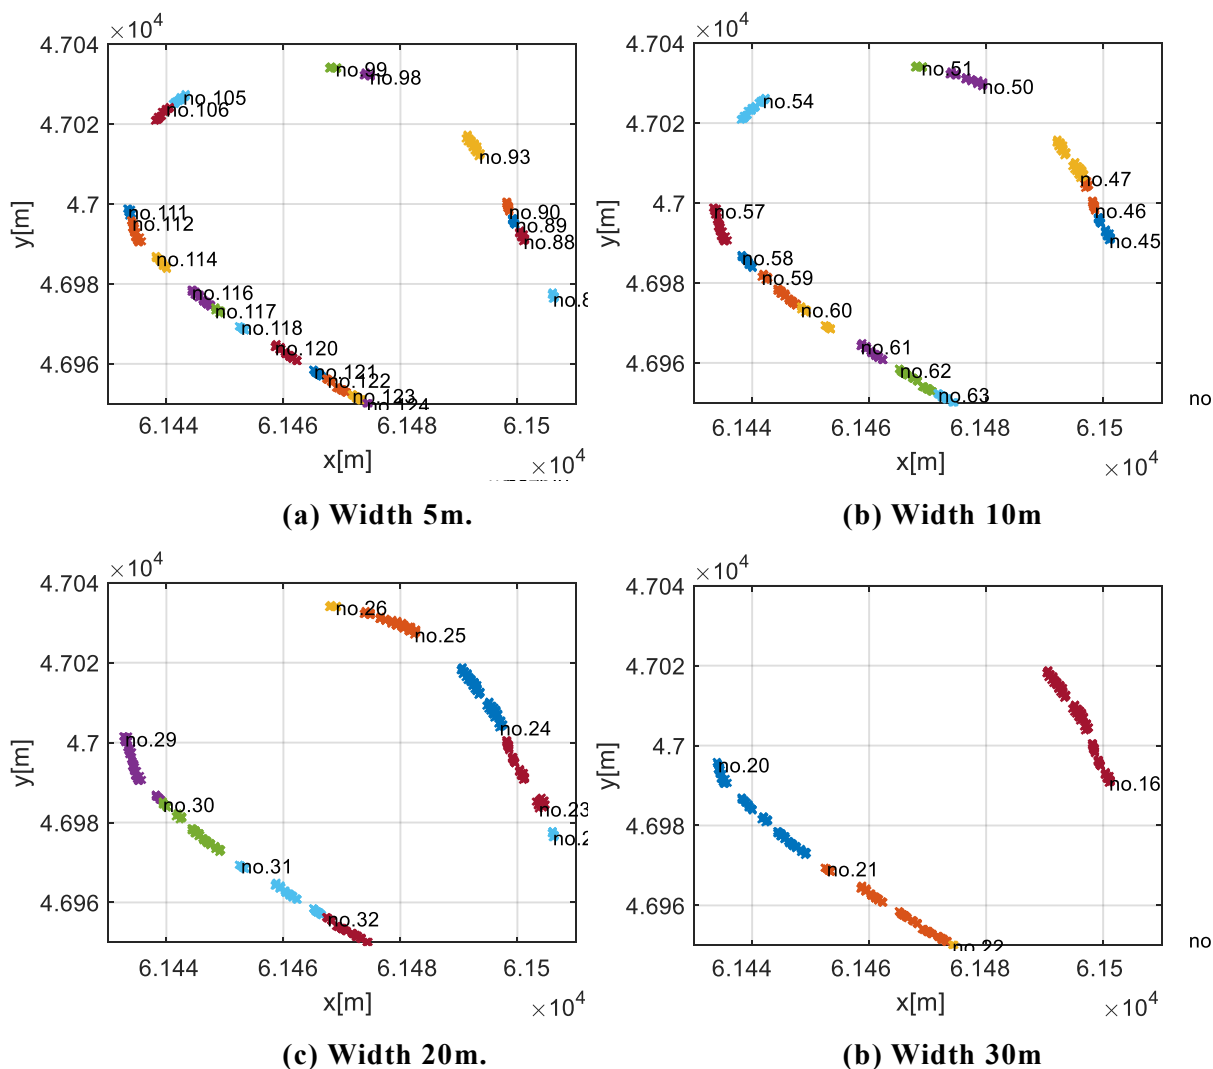


Fig. 5-11 Comparison of satisfy sections with the width ($\Delta a_{th} = 0.3/x_k$, $\Delta b_{th} = 0.2$).

とは判定されていない。同様に、(a)No. 98~99, (b)No. 50~51, (c)No. 25~26 は区間の長さ30 mで自動運転可能とは判定されていない。Fig. 5-9 でも説明したように、区間の長さが大きくなるほど曲線部分での地図精度判定に影響が出ることがこの結果から見て取れる。

5.3.4 考察及び残課題

以上の検証から、本稿で提案する地図精度判定手法は以下の特徴を抽出可能である。

まず、前章では既に生成した地図で自己位置推定を試行し、その誤差によって自動運転可能か否かの判定を行う考え方を示した。本章と同じ走行データを用いて検証を

行っており、直線部ではおおむね自己位置推定精度が目標値の0.5 m以内に収まる一方、特に北西部の曲線半径が小さい箇所（小 R）で自己位置推定誤差が0.5 mを超える箇所が存在した。本稿の結果でも、同じ個所で「自動運転可能（Not Satisfy）」と判定される傾向にあり、両者で同様の結果が得られたことになる。

今回用いた走行データはもともと傾き方向のずれがあまりなかったことから、主に進行方向に対して横方向のばらつきが小さいと判定した場合に「自動運転可能」と判定している。そのため、 $\Delta a_{th} = 0.3/x_k$ 、 $\Delta b_{th} = 0.2$ の方が、 $\Delta a_{th} = 0.4/x_k$ 、 $\Delta b_{th} = 0.1$ に比べて自動運転可能と判定した領域が大きかった。これは横方向のばらつきに対する許容値 Δb_{th} が大きかったためと考えられる。Fig. 5-7(b)からも示唆される通り、精度判定する対象の地図の種類によって Δa_{th} 、 Δb_{th} の値には最適値が存在すると考えられる。また、区画の長さに対しても精度判定結果が変わることを示した通り、本手法においては多様なパラメータをどのように設定すべきか（最適な設計方法）に関する検討が必要となる。

本手法の特徴として、「自動運転可能（Satisfy）」条件を満たすための点群の数は固定値ではなく、統合された点群のばらつきによって異なるという点が挙げられる。式(48)および式(49)からわかるように、 Δa 、 Δb は入力された白線地図点群の x, y 座標にも依存する。特に y 座標が分子にあることから、 y 方向にばらつきがあるほど Δa 、 Δb は大きい値として算出されることになる。一方で、この性質は、新たな点群の登録に応じて閾値が変わることを意味している。したがって、新たに点群が入ってくる場合に「あと何個点群が増えれば閾値が増えるか」という点に明確な答えを与えてくれないという課題をはらんでいる。

本稿で検討した地図精度判定手法自体のアプローチの問題として、「自動運転可能（Satisfy）」という判断が本当に妥当かどうかの判定が難しいという課題がある。本手法は、統合された白線地図が統計学的に確からしいかどうかを判定するものであり、決して真値であることを保証はしない。これは自己地図生成手法における永遠の課題である。先述の通り、前章では既に生成した地図で自己位置推定を試行し、その誤差によって自動運転可能か否かの判定を行う考え方を示した。これもやはり、「自己位置推定の誤差」の評価には本来真値が必要である。ナビ地図や、先述した OSM (OpenStreetMap) などのデータを第三者的に取り入れ、真値性を判定する手法の確立が今後の課題の一つである。

5.4 本章のまとめ

本稿では、自動運転の走行可能範囲を自律的に拡張する自己地図拡張技術の研究の一環として、生成した地図が自動運転に十分な情報量と精度を含んでいるか否かを判定する地図精度判定手法を検討した。本手法では、まず車載カメラの白線検出に基づく地図生成を行った。そして、生成した地図を所定長の区画に分割し、それぞれの区画で自車両の進行方向に対する垂直方向の誤差が 0.5 m 以下となっているか否かを Simple Linear Regression Model に基づき統計学的に判定した。

テストコース上 6 周分の手動走行データを用いて、開発した地図精度判定手法を検証し、最大 93% の領域で自動運転可能と判定した。周回の回数を重ねるごとに自動運転可能 (Satisfy) と判定した区画が増加する傾向を確認した。また、自動運転可能 (Satisfy) と判定した区画と自動運転不可能 (Not satisfy) と判定した区画の白線地図を比較し、開発した手法が、特に垂直方向のばらつきが大きい区画で自動運転不可能と判定していることから、本手法の有効性を確認した。さらに、白線の傾きの許容量を表す閾値パラメータ (Δa_{th})、垂直方向ばらつきの許容量を表す閾値パラメータ (Δb_{th})、区画の長さをそれぞれ変更し、地図精度判定を適切に行うためにはそれぞれのパラメータに最適値がある傾向を確認した。パラメータとしての最適値はこれら条件の組み合わせにより変化すると考えられ、最適設計手法の確立は今後の課題である。

第6章 地図情報応用技術としての歩行者行動予測

6.1 はじめに

本章では、第3章で述べた市街地道路環境における自動運転実現のための課題のうち、もう一つの歩行者・自転車（本章ではこれを『移動体』と総称する）が混在する道路環境における課題に対するアプローチを述べる。具体的には、これまで述べた地図生成手法により作られる地図情報を応用し、移動体、特に歩行者の将来（数秒先）の行動変化を予測する歩行者行動予測手法を構築する。

2.1節の Fig. 2-1（自動運転システムフロー）でも示したように、「認識」ブロックの中では検知した外界情報を Local Dynamic Map (LDM) に登録し、静止物体位置と地図内にあらかじめ登録した物体位置を比較することによる自己位置推定手法を行う。静止物体として路面上の白線情報が得られれば2.3.2項で述べた手法を使用し、その他、周辺の建築物や道路形状など情報が得られれば2.3.3項で述べた手法により自己位置推定を行う。また、本研究では地図自体も車載センサにより生成することを研究目的としており、白線情報であれば4.2節で述べた方法により生成し、その他の静止物は2.3.3項で述べた SLAM により地図を生成する。それら生成した地図の精度を判定するためには4.3節や第5章で述べた方法を適用する。

1.3節でも述べたように、LDM は地図情報をその種類に応じて、Fig. 1-6 に示す Type1~4 の階層構造で管理する。2.3.3項および4.2節で述べた地図生成手法は、このLDM における Type 1~2 の静的地図情報を構築することになる。一方、LDM は Type 3~4 に示す移動物体も同時に一つのプラットフォームで管理することが特徴であり、本研究はこの事実に着目する。すなわち、移動体の将来の行動変化を予測することは一般に困難であるが、LDM より道路形状などの静止情報と、道路工事などの一時的な障害物、一時的な静止物（駐車車両など）や移動体の準動的～動的な情報を同時に得られることにより、移動体の将来の行動変化の可能性が高いシーンにおいて行動予測が可能となる。本章で示す歩行者行動予測は、この事実を利用したものである。

移動体（歩行者・自転車）の行動を予測するためには、そもそもまず移動体が車載

第6章 地図情報応用技術としての歩行者行動予測

センサによって検知できる（または通信により他車やインフラから共有される）ことが必要である。この認知に関する研究は多数の先行研究があり、第2章や第4章で触れた以外にも、魚眼カメラを用いた歩行者検知 [113]、LiDARを用いた複数歩行者の検知とトラッキング [114]など多数挙げられる。また、2.2.1項でも述べたように、本研究で使用する実験車両に搭載された LiDAR は、点群から歩行者を識別する機能がインストールされている。第1章でも述べたように、自動緊急ブレーキなどの運転支援システムが歩行者を検知することは今や広く普及しており、製品レベルの技術が確立されていると言える。

一方、予測手法に関しては、死角に存在するリスク予測の研究が多数行われている [115][116]。本研究は3.4.5項でも述べたように、歩行者・自転車の検知が妥当に行われているという前提に立ち、今すでに見えている歩行者・自転車の今後の行動変化をいかに予測するかをフォーカスする。その点で、「見えている」物体に対する先行研究としては、3.4.5項でも取り上げたパーソナルスペースの考え方を採用したものがある [76]が、この手法は高密度な人流のマクロ的な予測では一定の成果を挙げているものの、個々の歩行者の行動に着目したものではない。個々の歩行者にフォーカスした手法としては、確率モデルや機械学習に基づく手法が広く行われている。例えば、サービスエリア等の限定された歩車混在環境で、ある程度パターン化されている歩行者の行動を確率的に予測する手法 [117]、横断歩道という文脈によって横断のための行動変化を確率的に予測する手法 [118]、見えている物体を RNN (Recurrent Neural Network) で予測する手法 [119]、横断歩道を渡ろうとする歩行者の5秒程度の将来軌跡を Variational Gaussian Mixture Model で予測する手法 [120]、無信号交差点において横断歩道に立っている歩行者の自車両接近に対する反応を Gaussian Mixed Model により予測する手法 [121]などである。Poolらは、自転車を研究対象とし、交差点における道路形状と過去の移動結果のデータセットからの確率モデル構築 [122]、自転車の行動や位置関係、自車両に対するリアクションなどの文脈を取り込んだ RNN による予測手法 [123]を提案している。

これら機械学習ベースの方法は、一度予測モデルを構築すると当該のユースケースでは高い予測精度が実現可能であるが、一般に予測結果に対する検証が難しいというブラックボックス性の問題がある。行動予測に基づき衝突回避システムを構築する際、予測が外れることで安全性が損なわれることはあってはならない。また、予測が外れ


た場合に、なぜ外れたかを検証することも自動車応用にあたっては重要な要素であると著者は考えている。

そこで本章では、重ね合わせの原理によりさまざまなユースケースへの対応可能性を持ち、かつルールベースで結果が検証しやすい方法としてポテンシャル法に着目し、歩行者の5秒後までの将来の行動を予測する歩行者行動予測手法を構築する。まず6.2節では、3.4節における歩行者・自転車等に対する課題分析を受けて、本研究で想定する自動運転シーンについて述べる。次に6.3節では、対歩行者の衝突回避（安全性）を担保する安全速度の考え方を導入し、6.4節において、ポテンシャル法に基づく歩行者の将来の移動経路を予測する歩行者行動予測手法を示す。6.5節では、歩行者の将来の移動経路に基づき自車両がなめらかに減速するための速度計画方法について示す。そして、6.6節において高密度道路環境を模擬したシミュレーションにより提案手法の有効性を示した後、6.7章ではダミー歩行者を用いた実車試験を行い、本提案手法がリアルワールドでも有効な手法であることを示す。

6.2 想定する自動運転シーン

6.2.1 歩行者・自転車の行動傾向

3.3節において、ドライブレコーダデータベースセンタ（DBセンタ）に蓄積されたドライブレコーダ映像に基づく分析を行った。本データベースにおいて、ヒヤリハットとは、事故に至らなかったもののドライバが急ブレーキで衝突回避を行った事例を指す。単路（交差点外の直線区間）走行時において事故・ヒヤリハット要因の分析を試みた結果、Fig. 6-1に示すような移動体（自転車・歩行者）の行動変化が事故・ヒヤリハットを招きやすいことが明らかとなった。具体的には、Fig. 6-1(a)のような移動体同士の移動経路干渉による横移動、Fig. 6-1(b)のような静止障害物を避けるための横移動、そしてFig. 6-1(c)のような予想外の横移動である。



(a) Overtaking. (b) Crossing between pedestrians. (c) Sudden lateral movement.

Fig. 6-1 Typical examples of pedestrians' and bicycles' lateral movements.

3.4.4 項で整理した単路走行時における事故及びヒヤリハットの要因内訳を Fig. 6-2 に再掲する。Fig. 6-1 のような移動体の横移動に起因するものは全体の 25%であり，死角などの環境要因にかかわるものが 29%，運転ミス・速度出し過ぎ・移動体見落としなど，ヒューマンエラーに関する要因（その他）が 44%である。このうち，ヒューマンエラーに起因するヒヤリハット事例は，自動運転システムを導入することで移動体見落としなどを防止し，急ブレーキの低減が可能である。一方，歩行者の横移動に起因する 25%，死角に起因する 29%は，自動運転システムを導入しただけでは急ブレーキのリスクを回避できない。死角に関してはそもそも車両単体でのセンシングが不可能であり，インフラ協調等による対策が必要である。本研究では，移動体の横移動に起因する 25%の事例に対し，移動体の行動変化を予測して予め速度計画を生成することで，急ブレーキの防止を試みる。つまり，移動体行動予測モデルを自動運転システムに導入することで，単路走行時の事故・ヒヤリハット事例のおよそ 70%（ヒューマンエラー起因の 44%，移動体の横移動起因の 25%）を解決することを目指す。




Fig. 6-2 Cause of accident and near-miss on basic road section.

6.2.2 想定する道路環境

第 1 章でも述べたように、本研究では市街地（一般道）を想定し、歩行者、自転車など多数の移動体が高密度に存在する高密度道路環境における自動運転の実現を目標としている。高密度道路環境の一例として、3.4.5 項でも取り上げた、Fig. 6-3 に示すドライブレコーダ映像 [75] のようなシーンを想定する。このシーンは自車両が横方向に移動する余地がほとんどない狭路であり、Fig. 6-4 に示す模式図の通り、歩行者・自転車が自車両の進路をふさぐ状況が容易に発生し、歩行者の急な斜め横断や、駐車車両などの障害物を回避するための横移動が頻繁に発生する。このような道路環境では歩行者との衝突回避のための急ブレーキが頻発しやすく、ドライバは一般に、歩行者の動きを予測しながら適切な速度で走行する。



Fig. 6-3 Typical example of high-density situation [75].




Fig. 6-4 Schematic diagram of high-density situation.

6.3 安全性を確保する速度計画方法

前節で想定した高密度道路環境下での安全性を確保するため、本節では「安全速度」に基づく速度計画方法について述べる。

6.3.1 安全速度の考え方


安全速度とは、Fig. 6-1 のような移動体の横移動に対する衝突回避が可能な速度、すなわち、移動体との衝突の恐れがある場合に自車両がブレーキをかけて衝突前に停止するための速度上限値を意味する。原理自体は文献 [124]でも検討されている基本的な考え方であり、自動運転や運転支援システムにおいて、各社とも同様の考え方を

導入していると推測する。

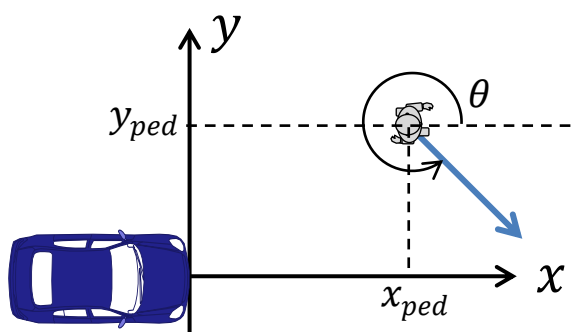
安全速度は定性的に、自車両が歩行者に近づくほど低下し、歩行者から遠いほど高くなる。これは、歩行者が急に進路を変更した際の自車両の制動距離に起因し、自車両が歩行者に近いほど短い距離での停止が要求されることから、それを満たすために低速での通過が必要となる。また、歩行者の急な進路変化に対するブレーキの強さによっても安全速度は変化し、ブレーキを弱める（加速度の絶対値を小さくする）ほど制動距離が伸びることから、安全速度も小さくなる。このように、設定加速度が安全速度における設計パラメータの一つとなる。

6.3.2 安全速度の算出方法および算出結果

本節では、安全速度の具体的な算出方法について述べる。まず、Fig. 6-5 に示す通り安全速度における各パラメータを定義する。時刻 $t = t_0$ において、自車両は速度 V_{car} で進行し、左側の路側帯を歩行者が速度 V_{ped} で直進している。この時、Fig. 6-5(a)のように歩行者が突然進行方向を変更したと仮定し、Fig. 6-5(b)に示す通り、自車両の進行方向に対する歩行者進行方向のなす角（時計回り：正）を進路変更角 θ と定義する。また、自車両の中央前面を基準とする歩行者の相対位置について、 (x_{ped}, y_{ped}) と定義する。



(a) Overview of situation.




(b) Relative displacement between ego-car and pedestrian.

Fig. 6-5 Definition of “safe velocity” parameters.


相対位置 (x_{ped}, y_{ped}) に居る歩行者が、突然速度 V_{ped} 、進路変更角 θ で歩行を開始した状況を想定する。自車両が速度 V_{car} で走行している場合、現在の速度を維持して走行し続けた場合に自車両と歩行者の衝突が予測されるならば、自車両は加速度 $a_x (< 0)$ のブレーキで減速・停止して衝突を回避する。この時、歩行者と衝突する前に止まることができる最大の速度を安全速度として算出する。安全速度は歩行者の相対位置 (x_{ped}, y_{ped}) に依存し、かつ進路変更角 θ の値によっても変化する。したがって、様々な θ について安全速度を算出し、最も安全速度が低く算出されたものを該当位置 (x_{ped}, y_{ped}) における安全速度とする。安全速度の算出には以下の 2 ステップを実行する。

- ・ ステップ 1：自車両が等速で走行した場合の衝突可能性評価 (Fig. 6-6)
- ・ ステップ 2：自車両が一定加速度 $a_x (< 0)$ で減速した場合の衝突可能性評価 (Fig. 6-7)

まず、ステップ 1 において、歩行者が自車両の経路との干渉点に到達するまでの時



(a) Initial position.



(b) Future position.

Fig. 6-6 Collision possibility judgment (step 1).


刻 t_p , この時刻における自車両を基準とした歩行者の x 方向相対位置 x_{ped_p} を以下の通り求める。

$$t_p = \frac{y_{ped}}{V_{ped} \sin \theta} \quad \dots (53)$$


$$x_{ped_p} = x_{ped} - V_{car} t_p + V_{ped} t_p \cos \theta \quad \dots (54)$$

この時, $x_{ped_p} < 0$ であれば, 自車両が歩行者より先に干渉点 (Fig. 6-6 中の点 C) を通過することを意味するため, 減速せずそのままの速度で通過可能である。また, $t_p < 0$ となる場合も, 歩行者が自車両から遠ざかっていることを意味するため減速は不要である。一方, $t_p > 0$ かつ $x_{ped_p} \geq 0$ であるとき, 干渉点 C では歩行者が自車両と同時もしくは自車両より先に通過することになり, このままの速度では衝突の危険が生じることを意味するため, ステップ 2 に進む。

ステップ 2 では, 歩行者の行動変化が生じた瞬間から自車両が加速度 $a_x (< 0)$ で減速



(a) Initial position.



(b) Future position.

Fig. 6-7 Collision possibility judgment (step 2).

した場合に、自車両が停止した点における歩行者の相対座標を導出する。自車両の初速度 V_{car} 、加速度 a_x より、制動時間 t_s および制動距離 D_{stop} は下式の通りとなる。

$$t_s = -\frac{V_{car}}{a_x}, \quad D_{stop} = -\frac{V_{car}^2}{2a_x} \quad (\because a_x < 0) \quad \dots (55)$$

ステップ1同様に、時刻 t_s における自車両を基準とした歩行者の x 方向相対位置 x_{ped_s} を求めると、下式の通りとなる。

$$\begin{aligned} x_{ped_s} &= x_{ped} - D_{stop} + V_{ped} t_s \cos \theta \\ &= x_{ped} - \frac{V_{car}^2}{2a_x} - V_{ped} \frac{V_{car}}{a_x} \cos \theta \end{aligned} \quad \dots (56)$$

自車両と歩行者の衝突を防ぐための条件は $x_{ped_s} > 0$ であることから、衝突回避可能


な上限速度，すなわち安全速度 $V_s(\theta)$ は，式(56)において $x_{ped_s} = 0$ を解くことにより式(57)の通りとなる。

$$V_s(\theta) = -V_{ped} \cos \theta + \sqrt{(V_{ped} \cos \theta)^2 - 2a_x x_{ped}} \quad (\because a_x < 0) \quad \dots (57)$$


式(57)より， $V_s(\theta)$ は進路変更角 θ に応じて変化するが，安全性の確保という趣旨から，ここでは全ての $\theta(\pi \leq \theta < 2\pi)$ についてステップ 1，ステップ 2 を実行し，その中で $V_s(\theta)$ の最小値を，歩行者の現在位置 (x_{ped}, y_{ped}) における安全速度 $V_s(x_{ped}, y_{ped})$ と定義する。

全ての位置 (x_{ped}, y_{ped}) について安全速度を算出し， $V_s(x_{ped}, y_{ped})$ をテーブル化することによって，自車両と歩行者の相対位置関係から決まる安全速度マップが生成可能である。Fig. 6-8 に， $V_{car} = 30 \text{ km/h}$ (8.3 m/s)， $V_{ped} = 1.5 \text{ m/s}$ ，加速度 a_x をそれぞれ -0.2 G ($= -2.0 \text{ m/s}^2$)， -0.6 G ($= -5.9 \text{ m/s}^2$)に設定した場合の安全速度マップ（コンター図）を示す。このマップは見易さの観点から，Fig. 6-9 に示すように歩行者の現在位置を原点とした自車両の相対座標系 (x_{rel}, y_{rel}) でプロットしたものであり， $(x_{rel}, y_{rel}) = -(x_{ped}, y_{ped})$ という関係にある。なお，加速度 -2.0 m/s^2 は，後述する良好な乗り心地の基準「加速度 -2.2 m/s^2 以上」を満たしており，加速度 -2.0 m/s^2 設定の安全速度は乗り心地を優先した速度計画となる。一方，加速度 -5.9 m/s^2 は雨などで路面が濡れている状態を出しうる急ブレーキの限界値であり，加速度 -5.9 m/s^2 設定の安全速度は目的地への速達性を優先し，歩行者の行動変化に対して急ブレーキで止まる。これはすでに実用化されている自動緊急ブレーキなどの技術に相当する。

Fig. 6-8(a)を例にとると，歩行者の 15m 手前時点 ($x_{rel} = -15 \text{ m}$) で，歩行者の右方 1.5m ($y_{rel} = -1.5 \text{ m}$) に自車両がいる場合，安全速度はおよそ 20 km/h である。これは，歩行者が仮に現時点から進行方向を変化した際に，歩行者の進路変更角 θ がいかなる値であっても自車両が直ちに加速度 -2.0 m/s^2 でブレーキをかけて衝突を回避するためには，自車両の速度を 20 km/h 以下とする必要があることを意味する。なお，安全速度の右下の領域では安全速度が定義されていないが，この領域は，自車両の速度が $V_{car} = 30 \text{ km/h}$ (8.3 m/s)である場合，そのままの速度を維持すれば，歩行者のどのような進路変化に対しても自車両が先に干渉点を通り過ぎることを意味する。



(a) $a_x = -2.0 \text{ m/s}^2$.



(b) $a_x = -5.9 \text{ m/s}^2$.

Fig. 6-8 Safe velocity map.

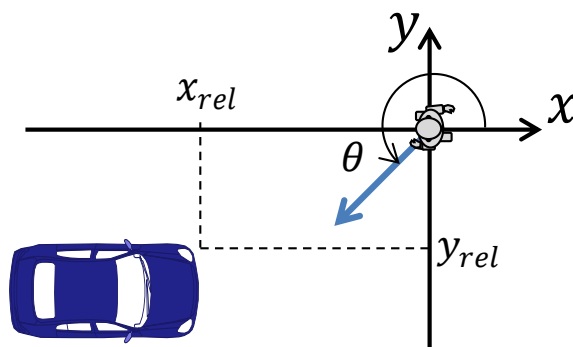
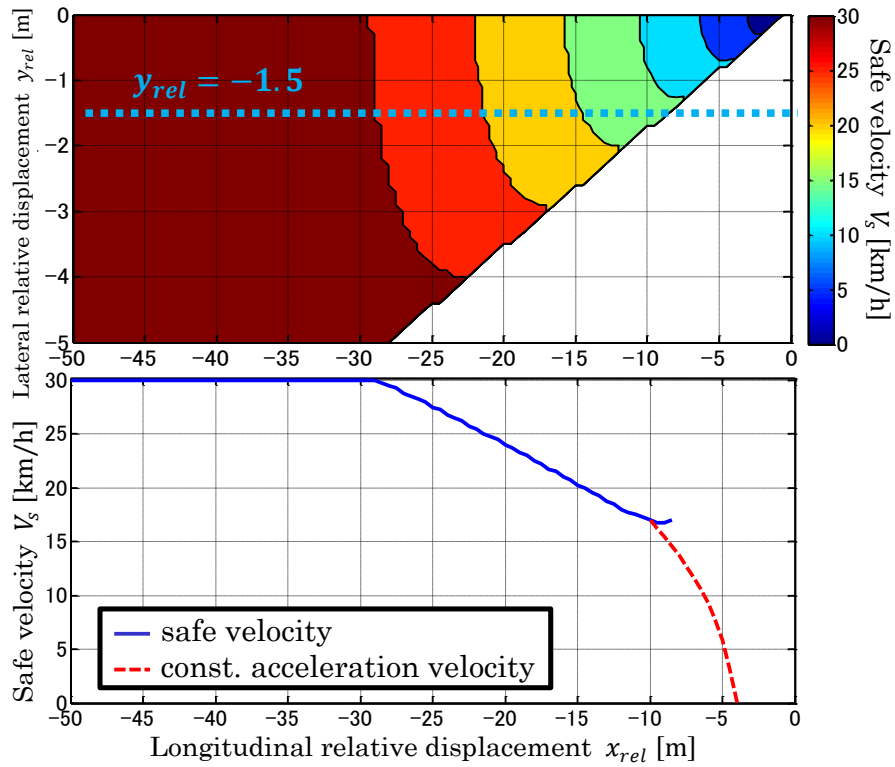



Fig. 6-9 Coordinate of safe velocity map.

安全速度に基づく速度計画を実施した場合、歩行者に対する自車両の相対 x 座標 x_{rel} に応じた速度の変化は Fig. 6-10 の実線に示したようになる。本グラフは、Fig. 6-8 に示したコンター図上に破線で示した部分を切り出したものであり、歩行者の右方 1.5m ($y_{rel} = -1.5$ m) を歩行者の進行方向に対して平行に通過する際の安全速度を表している。Fig. 6-10(a)(b)で加速度の設定が異なり、加速度が大きい（ブレーキが弱い）Fig. 6-10(a)に比べて、加速度が小さい（ブレーキが強い）Fig. 6-10(b)のほうが全体的に速度が高くなっている。一方、それぞれのグラフに示した破線は、 $x_{rel} = -10$ となった瞬間に歩行者の行動変化を検知して設定加速度 a_x でブレーキをかけた場合の速度推移を示す。どちらも $x_{rel} < 0$ の領域で停止しており、歩行者との衝突を回避できている。すなわち、安全速度をそのまま自車両の速度制御指令値に設定し、全ての歩行者に対して安全速度を常に下回るような速度計画を行うことで安全性を確保できる。



(a) $a_x = -2.0 \text{ m/s}^2$



(b) $a_x = -5.9 \text{ m/s}^2$

Fig. 6-10 Safe velocity in relative lateral displacement $y_{rel} = -1.5 \text{ m}$.

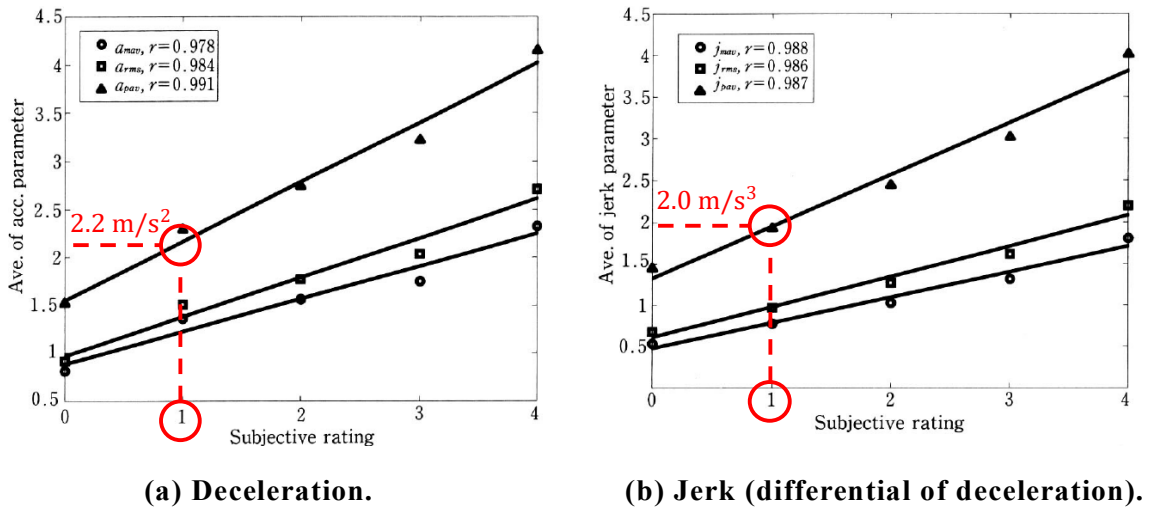


Fig. 6-11 Rating of passengers' discomfort [126].

6.3.3 技術的課題と達成目標

自動運転システムにおいて、前節で述べた安全速度の考え方を導入すれば安全性が確保可能である。しかし、加速度 a_x と安全速度 V_s の関係は式(57)によって決まり、加速度を増加（ブレーキを弱く）しながら安全速度を増加することは不可能である。目的地に早く到着できること、すなわち平均速度が高いことが自動運転の利便性向上に必要であるが、利便性を優先して速度を上げようとする歩行者の行動変化に対して急ブレーキがかかり、乗員の乗り心地を損なう恐れがある。一方、乗り心地を優先して加速度設定を高くすれば安全速度も低下し、利便性が低下する。このように、安全性を前提として安全速度に基づく速度計画を行うと、乗員にとっての利便性と乗り心地の間にはトレードオフがあり、このトレードオフを両立することが自動運転の実用性向上にあたっての課題である。

乗り心地と加速度の関係については複数の研究成果が報告されている。文献 [125] では、様々な運転暦をもつドライバの運転行動の分析結果として、ブレーキ時には「加速度 $-0.3 G (-2.9 \text{ m/s}^2)$ 以下」が急ブレーキの一つの目安になることを示唆している。一方、文献 [126]では、乗員が受ける不快感と、加速度およびジャーク（加速度の時間変化）との間に相関があることを、官能試験により明らかにしている。Fig. 6-11のグラフにおいて、横軸は、官能試験を行った結果を評価点にしたもので、0を不快感なし、1~4を不快感の強さとして被験者にレーティングさせたものである。縦軸はそ




Fig. 6-12 Considered typical use cases.

れぞれ加速度，ジャークを表し，図中の記号のうち○は平均値，□は実効値，△は絶対値の瞬間的なピーク値を意味する。この図より，瞬間的なピーク値が「加速度 2.2 m/s^2 ，ジャーク 2.0 m/s^3 」を上回ると，乗員にとっての不快感につながる可能性があることが分かる。すなわち，自動運転中に加速度，ジャークともにこれらの値を超えないことが，良好な乗り心地の実現のために必要となる。

利便性と乗り心地のトレードオフは，安全速度が現在の自車両と歩行者の相対位置関係のみで決まることに起因する。歩行者の将来位置を予測し，その予測に基づき予め走行計画を行うことで，このトレードオフを解消可能であると考えられる。そこで本研究では，歩行者の将来の行動変化を予測する歩行者行動予測モデルを構築し，加速度やジャークを良好な乗り心地のレベルとするような速度計画を行う。また，加速度 -5.9 m/s^2 設定の安全速度に基づく速度計画も併用することで，将来位置が予測困難な歩行者の急な行動変化に対しても衝突回避を可能とし，加速度 -2.0 m/s^2 設定の安全速度に基づく速度計画に比べて平均速度を向上可能である。加速度 -5.9 m/s^2 設定の安全速度に基づく速度計画で出せる平均速度を規格化して 1 としたときに，「規格化平均速度 1.0, 加速度 -2.2 m/s^2 以上，ジャーク絶対値 2.0 m/s^3 以下」を本研究の目標とする。

6.4 ポテンシャル法に基づく歩行者行動予測

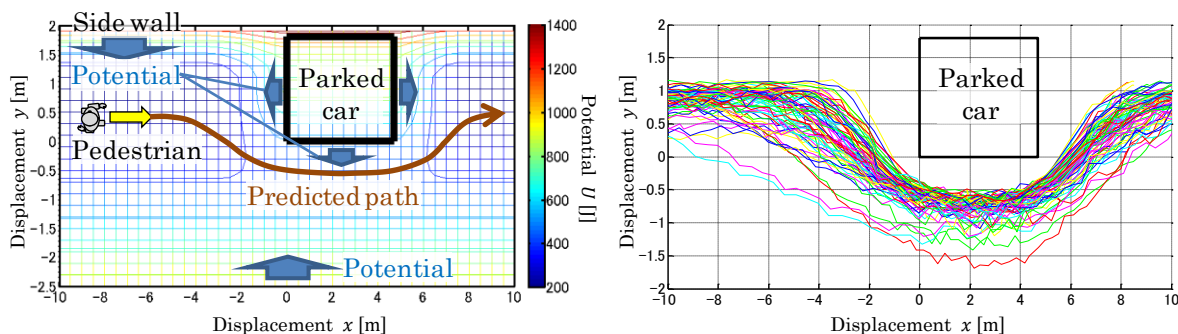
本節では，歩行者行動予測手法及び予測に基づく速度制御手法について述べる。本稿では，Fig. 6-12 のように，駐車車両の回避や対向歩行者とのすれ違いなど，歩行者が横移動しやすい場合に着目する。Fig. 6-12(a) に示す状況において，歩行者が実際に駐車車両を避けて歩いた際の歩行経路を分析した結果が文献 [127] で報告されており，

本研究ではこの実データに基づいて、行動予測モデルを構築する。

本研究では、歩行者の予測手法としてポテンシャル法に着目した。ポテンシャル法は、障害物などに仮想的な力学ポテンシャルがあると仮定し、ポテンシャルの低い箇所を目標軌道に設定する移動計画手法である。従来、自車両の軌道計画および速度計画に用いられてきたが [128] [129] [130], 歩行者の行動予測モデルに適用した例は報告されていない。一方で、ポテンシャル法は複数障害物に関して単純な重ね合わせで表現可能であり、歩行者が多数存在する高密度環境下に適していると考える。そこで本研究ではポテンシャル法に基づく歩行者の行動予測モデルを構築する。


6.4.1 仮想物理モデルの導入とパラメータ同定

本稿で提案するポテンシャル法に基づく歩行者行動予測モデルは、Fig. 6-13(a)に示すように、両端の壁や駐車車両に高いポテンシャルを設定し、歩行者はポテンシャルの低い経路をとると仮定して歩行者の予測軌道を生成する。この時、ポテンシャル場の算出方法がポテンシャル法の鍵であり、実環境における歩行者の歩行軌跡をなるべく正確に再現できることが望ましい。そこで本稿では、Fig. 6-13(b)に示す実データ [127]の分析から、歩行者が側壁、駐車車両及び他の歩行者から斥力を受けるように障害物を回避するという仮説を立て、Fig. 6-14 に示すようなバネ型ポテンシャルを採用した。斥力を表現するにあたって、バネ型は調整パラメータがバネ定数と自然長のみで見通しがよく、ポテンシャルが距離の 2 乗で定まるため平易に算出可能であるという利点がある。また、実環境データに基づき、歩行者ごとに異なるバネ定数やバネ自然長を適用することで、個人差を考慮した行動予測が可能である。



(a) Concept of potential-based prediction. (b) Real data of pedestrians' trajectory.

Fig. 6-13 Real-data-based potential map.



(a) Spring potential from parked vehicle. (b) Spring potential from side walls.

Fig. 6-14 Considered virtual physical spring model.

以下、バネ定数設計手法について述べる。まず、駐車車両が発するバネポテンシャルは、Fig. 6-14(a)のように x 方向、 y 方向で自然長(X_{nl}, Y_{nl})が異なる楕円形のバネ型ポテンシャルとする。ここで X_{cf}, X_{cr}, Y_c はそれぞれ駐車車両の前面、後面の x 座標、中央の y 座標を表し、自然長における添え字 $-cf, -cr, -cs$ はそれぞれ車両の前面、後面、側面を意味する。さらに L, D はそれぞれ駐車車両の全長、全幅を表す。駐車車両の横では一様なポテンシャルとし、それぞれ①前面の楕円ポテンシャル、②後面の楕円ポテンシャル、③側面のポテンシャルが連続的になるように設計する。位置(x, y)における駐車車両のポテンシャル $U_c(x, y)$ は、位置によって場合分けすると Table 7 の通り算

出できる。

Table 7 で得られるポテンシャル場を図示すると Fig. 6-15(a)のようになり，自車両の中央から楕円状に広がるポテンシャルが得られる。一方，側壁からのポテンシャル $U_w(y)$ は Fig. 6-15(b)より，壁が道路に対して平行であれば歩行者の y 座標のみで決まり，下式の通り算出できる。

$$U_w(y) = \begin{cases} \frac{1}{2}k_{wl}(y - Y_0)^2 & [Y_0 \leq y] \\ \frac{1}{2}k_{wr}(y - Y_0)^2 & [y < Y_0] \end{cases} \quad \dots \quad (58)$$

ここで Y_0 は，障害物の存在しない環境下での歩行者の y 座標を表す。式(58)で得られるポテンシャル場を図示すると Fig. 6-15(b)のようになり，側壁から車道側に向かって一様に広がるポテンシャルが得られる。以上より得られた 2 つのポテンシャルの重ね合わせ，すなわち $U(x, y) = U_c(x, y) + U_w(y)$ を算出することで，Fig. 6-15(c)に示すよう

Table 7 $U_c(x, y)$ from parked car.

$U_c(x, y) =$	Area
$\frac{1}{2}k_c \left\{ X_{nl-cr} - \sqrt{(x - X_{cr})^2 + \left\{ (y - Y_c) \frac{X_{nl-cr}}{Y_{nl-cs}} \right\}^2} \right\}^2$	$x \leq X_{cr} \text{ かつ } \left(\frac{x - X_{cr}}{X_{nl-cr}} \right)^2 + \left(\frac{y - Y_c}{Y_{nl-cs}} \right)^2 \leq 1$
$\frac{1}{2}k_c \left\{ (y - Y_c) \frac{X_{nl-cr}}{Y_{nl-cs}} \right\}^2$	$X_{cr} < x < X_{cf} \text{ かつ } Y_c - Y_{nl-cs} \leq y \leq Y_c + Y_{nl-cs}$
$\frac{1}{2}k_c \left\{ X_{nl-cf} - \sqrt{(x - X_{cf})^2 + \left\{ (y - Y_c) \frac{X_{nl-cr}}{X_{nl-cf}} \right\}^2} \right\}^2$	$X_{cr} \leq x \text{ かつ } \left(\frac{x - X_{cf}}{X_{nl-cf}} \right)^2 + \left(\frac{y - Y_c}{Y_{nl-cs}} \right)^2 \leq 1$

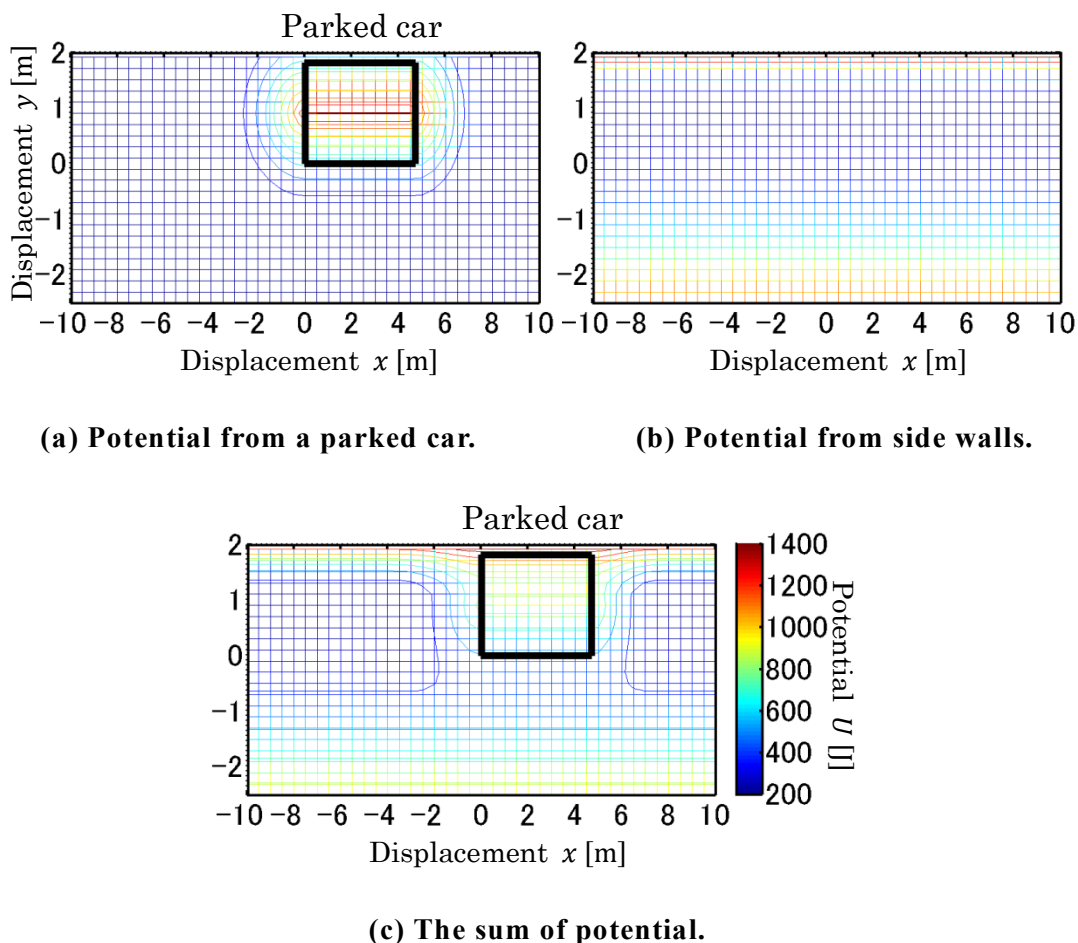


Fig. 6-15 Potential map design.

に全体のポテンシャル $U(x,y)$ が設計できる。

6.4.2 ポテンシャル法に基づく歩行者行動予測

歩行者将来位置の予測は、前節で得られたポテンシャルの合計値が最小となるような軌道を選択する問題に帰着する。様々な手法が考えられるが、本稿ではランダムウォークを用いる。この手法では、現在位置から予測サンプル（例えば 1 秒）ごとの歩行者の軌道をランダムに生成する。

Fig. 6-16 に軌道生成の概要を示す。まず、歩行者の現在速度 V_{ped} は一定であると仮定し、現在の歩行者位置から予測時間後（ここでは 5 秒後までとする）までの N 本（例えば $N = 300$ ）の軌道をランダムに生成する。その中でポテンシャルの合計値が最小となる軌道を選択し、選択した軌道上の次の予測サンプルの点を 1 秒後の予測将来位置




Fig. 6-16 Concept of future position prediction.

として決定する (Fig. 6-16 の A)。次に、その予測将来位置から予測時間後までの N 本の軌道をランダムに生成し、その中でポテンシャルの合計値が最小となる軌道を選択する。その中でポテンシャルの合計値が最小となる軌道を選択し、選択した軌道上の次の予測サンプルの点を 2 秒後の予測将来位置として決定する (Fig. 6-16 の B)。このように、予測サンプルごとに N 本の軌道をランダムに生成する操作を予測時間分行い、最終的に予測時間後までの歩行者将来位置を決定する (Fig. 6-16 の C)。

Fig. 6-17 に、実環境で計測した歩行軌跡と、行動予測手法に基づく歩行者の予測位置をプロットする。ここでは Fig. 6-16(a) のように実環境データと 1 秒ごとの歩行者予測位置をほぼ一致させるようにパラメータを試行錯誤的に調整し、Fig. 6-16(b) の通りパラメータ値を決定した。将来的には、検知した歩行者の動きなどに応じてこれらパラメータをオンタイムで同定することが必要である。

なお、本稿において、行動予測を 5 秒後までに設定したのは以下の理由からである。まず、予測は長いほど効果があるが、逆に予測精度が悪くなるという予測時間に関するトレードオフがあるため、適切な設定が必要である。ここで、歩行者・自転車との混在環境になりやすい市街地道路環境の多くは制限速度が 30 km/h (8.3 m/s) である。速度 30 km/h から、6.3.3 項で示した減速度 2.2 m/s^2 で停車するためには 3.8 秒 (約 4 秒) 必要であり、1 秒の余裕を見て 5 秒程度の予測が必要となる。




Fig. 6-17 An example of future position prediction result.

6.5 終端状態制御を用いた速度制御手法

前節で述べた歩行者行動予測手法に基づき、本節では乗り心地を向上させるための速度計画法について述べる。

6.5.1 問題設定

対歩行者の衝突回避制御として、自車両と歩行者の経路が交差する点（経路交差点）において、両者の到達時間（TTC：Time to Conflict-point）の差に基づき衝突判定する手法が提案されている [131]。本稿では、到達時間差 ΔTTC を下式の通り定義する。

$$\Delta TTC = [\text{歩行者の TTC}] - [\text{自車両の TTC}] = T_{ped} - T_{car} \quad \dots (59)$$

ΔTTC の絶対値が小さいほど自車両と歩行者の衝突の可能性が高くなるため、歩行者との衝突を回避するためには、 $|\Delta TTC| > \delta$ (δ : 所定値) となるように自車両の走行計画を決定することが必須である。特に、衝突回避のための減速制御においては、自車両が歩行者の後に通過するように、 $\Delta TTC = -\delta$ と設定する必要がある。歩行者行動予測によって、経路交差点の位置および歩行者の到達時間が予測できれば、自車両が経路交差点に歩行者より δ 秒遅く到達するように速度を制御することが可能である。こ




Fig. 6-18 Concept of velocity planning.

これは、Fig. 6-18 に示す通り、到達する位置（＝経路交差点）、速度、到達時刻が定まっており、その間の速度計画を自由に設定する問題に帰着される。提案法における速度制御手法のポイントは、この速度計画法にある。

6.5.2 経路交差点の選択

6.4 章で述べた行動予測手法で、歩行者の将来位置が時系列で得られたとき、Fig. 6-18 のように自車両の経路と歩行者の将来位置が干渉する点が複数得られる可能性がある。この際、どの点を経路交差点として制御対象にするかを選択する必要がある。以下に、経路交差点の選択方法を述べる。

まず、予測将来位置のうち、自車両の経路と干渉するすべての点について、現在の自車両の速度 V_{car} に基づき ΔTTC を算出する。Fig. 6-19 において、歩行者の予測将来位置を示す 5 つのドットの中で、丸で囲った点がこれらに該当する。この時、干渉点が存在しないか、全ての干渉点で $|\Delta TTC| > \delta$ ならば、自車両は現在の速度計画を変更する必要はない。一方、一箇所でも $\Delta TTC \leq \delta$ となる点がある場合、速度計画を変更する。ここでは歩行者より先に干渉点を通過するために速度計画を上方修正する方法と、歩行者より後に通過するために速度計画を下方修正する方法の 2 つが考えられるが、安全性の観点から下方修正とする。速度計画を下方修正すると全ての干渉点において ΔTTC が小さくなるため、経路交差点として ΔTTC が最大となっている点を選び、その点において $\Delta TTC = -\delta$ となるように速度計画を立てることで、全ての干渉点に対して $\Delta TTC < -\delta$ とできる。以上の手順で決定した経路交差点の x 座標を x_{cp} と定義する。

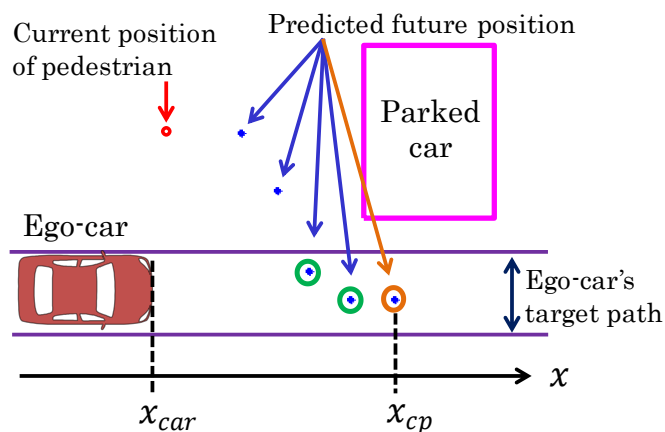


Fig. 6-19 Selecting pedestrian's future position to calculate ΔTTC .

6.5.3 終端状態制御

問題を自車両の物理量に関して定式化する。時刻 t における自車両の物理量（状態ベクトル）を

$$X(t) = [x_{car}(t): \text{自車位置}, \quad V_{car}(t): \text{自車速度}]^T \quad \dots \quad (60)$$

とおけば、式(61)のように、加速度 a_x およびジャーク \dot{a}_x に関する評価関数 $f(a_x, \dot{a}_x)$ の積算量を最小化する問題として定式化できる。なお、終端状態において自車両が歩行者の後ろを歩行者と同じ速度で追従走行することを想定し、終端状態における自車両の目標速度は歩行者速度 V_{ped} に設定した。

$$\left\{ \begin{array}{l} \text{最小化} : J = \int_{t_0}^{t_0+t_{cp}} f(a_x, \dot{a}_x) dt \\ \text{状態方程式} : \dot{X}(t) = AX(t) + Bu(t), \quad A = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \\ \text{初期状態} : X(t_0) = [x_{car}(t_0), V_{car}(t_0)]^T \\ \text{終端状態} : X(t_0 + t_{cp}) = [x_{cp}, V_{ped}]^T \\ \text{※ } t_0 : \text{現在時刻}, \quad t_{cp} = T_{ped} + \delta \end{array} \right. \quad \dots \quad (61)$$

式(61)を解くことで、加速度およびジャークを最小化する速度軌道が生成可能である。このような最小化問題を解くアルゴリズムはモデル予測制御 [132]など多数提案されているが、本稿では単純な行列計算で最適解が求まる終端状態制御 (FSC : Final-State Control) [133]を採用した。以下、終端状態制御の原理を述べる。

終端状態制御は、離散系の線形時不変システムにおいて式(62)の通り入力 u の二乗和最小化問題を定式化する。

$$\left\{ \begin{array}{l} \text{最小化 : } J = U^T Q U \quad (Q > 0, U = [u[0], u[1], \dots, u[N-1]]) \\ \text{状態方程式 : } x(k+1) = Ax(k) + Bu(k) \\ \text{初期状態 : } x(0), \text{ 終端状態 : } x(N) \end{array} \right. \quad \dots \quad (62)$$

この最小化問題を解くと、入力群 U は式(63)の通り得られる。

$$U = Q^{-1} \Sigma^T (\Sigma Q^{-1} \Sigma^T)^{-1} (x[N] - A^N x[0]) \quad \dots \quad (63)$$

ただし $\Sigma = [A^{N-1}B, A^{N-2}B, \dots, B]$ ($m \times N$ 行列)

この方法では加速度とジャークを同時に最小化することはできないが、ジャークを最小化すればその積分である加速度も小さくなると考え、制御入力 u にジャークを当てはめることにする。これを実現するために、式(64)の通り、仮想的にジャーク \dot{a}_x を制御入力とする拡大形のシステムを構成する [134]。

$$\left\{ \begin{array}{l} X(k+1) = AX(k) + Bu(k) \\ X(k) = [x(k), V(k), a_x(k)]^T, u[k] = \dot{a}_x(k) \\ A = \begin{bmatrix} 1 & T_s & 0 \\ 0 & 1 & T_s \\ 0 & 0 & 1 \end{bmatrix}, B = \begin{bmatrix} 0 \\ 0 \\ T_s \end{bmatrix} \quad T_s : \text{予測サンプル時間} \end{array} \right. \quad \dots \quad (64)$$

なお、ここでは T_s が十分短いと仮定し、ゼロ次ホールドの後退差分に基づく離散化を行っている。また、入力 u は 1 変数であるから Q はスカラーとなり、本稿では $Q = 1$ とする。終端状態のサンプル数 N は、所要時間 $T_{\text{ped}} + \delta$ およびサンプル時間 T_s から式(65)

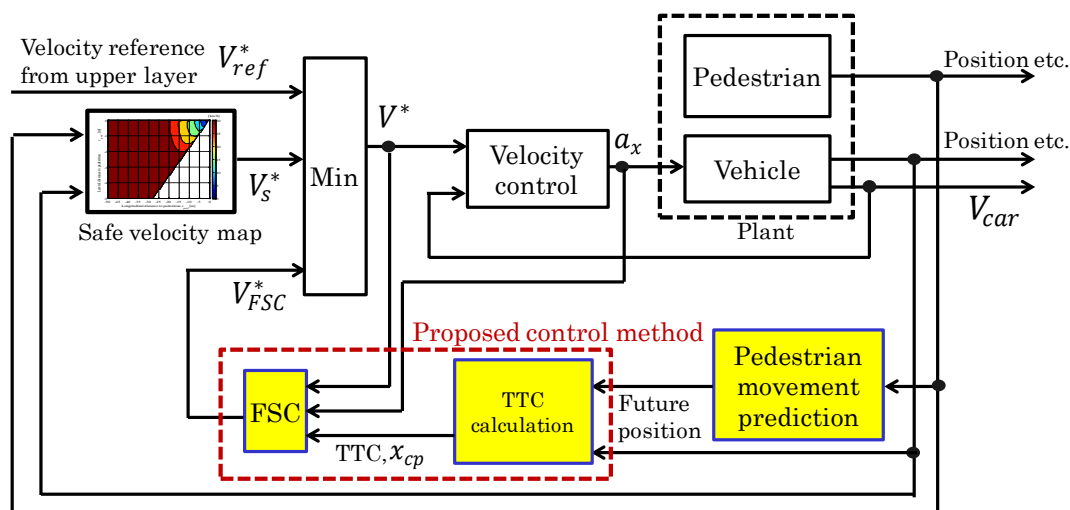


Fig. 6-20 Block diagram of whole system.

のように算出できる。

$$N = \frac{T_{ped} + \delta}{T_s} \quad \dots \quad (65)$$

式(63)により得られた最適入力列 U に従って $k = 0$ から $k = N$ まで式(64)を解き、速度指令値 V_{FSC}^* ($N + 1$ 次元ベクトル)を式(66)より算出して、後述する速度制御系に与える。

$$V_{FSC}^*[k] = [0 \ 1 \ 0] X[k] \quad \dots \quad (66)$$

以上、式(62)～式(66)の手段により、ジャークの二乗和を最小化する速度軌道が算出される。

6.5.4 全体の制御系設計

本項では、歩行者行動予測に基づく速度制御および安全速度に基づく速度制御を組み合わせた全体の速度制御系について述べる。Fig. 6-20 に速度制御系全体のブロック図を示す。Pedestrian motion prediction がポテンシャル法に基づく行動予測手法を指しており、そこから得られた歩行者の将来位置に基づき TTC を算出し、FSC に入力する。Fig. 6-20 において、Proposed control method として枠で囲った TTC 算出及び FSC




Fig. 6-21 Block diagram of velocity control.

が前項で述べた制御手法を表している。FSC に基づく速度指令値 V_{FSC}^* と、安全速度に基づく速度指令値 V_s^* のうちの最小値を最終的な速度指令値 V^* とすることで、 V^* が常に安全速度を下回り、歩行者に対する安全性が常時確保される。また、複数の歩行者が存在する環境下でも常に速度指令の最小値を選択することで、検知した全ての歩行者に対して衝突回避を確保する。 V_{ref}^* は上位のコントローラからの速度指令値を想定しており、例えば交通法規に沿った速度計画が V_{ref}^* に該当する。

Fig. 6-20 における Velocity control は、車両速度を速度指令値 V^* に追従させるような加速度指令値 a_x を生成する速度制御を表す。速度制御の中身は Fig. 6-21 に示すブロック図の通り、走行抵抗や勾配などの外乱の影響を抑圧する比例フィードバック制御と、将来 (j サンプル先) の速度指令値に基づくフィードフォワード制御の 2 自由度系となっている。また、最終段には、車両が出せる最大の加速度で停止する緊急停止ロジックを備えている。

Fig. 6-21 のような速度制御を構築した理由として、本研究で使用する実験車両の加速度制御系に、0.5 秒程度のむだ時間と時定数 0.2 秒程度の一次遅れが存在することが挙げられる。この遅れにより、フィードバックゲインを大きくすると制御が不安定となりやすく、しかも速度指令値の変化に対する追従性が悪くなる。よって、比例ゲインは 0.25 程度 (極 0.25 rad/s に相当) と小さくして制御安定性を確保し、追従性向上とプラントのむだ時間補償のため、将来の速度指令値に基づくフィードフォワード制御を設けている。ベクトル V^* が 0.1 秒サンプルで得られている場合、フィードフォワード制御に用いる速度指令値をむだ時間と同じ 0.5 秒先の速度指令値、すなわち $j = 5$ に設定する。

加速度指令値にはレートリミッタを設けている。これは、常用域の加速度指令値で目標値を超過するジャークの発生を防止するために設けており、ブレーキ時、加速度

が -2.0 m/s^2 を下回らなければ $\pm 2.0 \text{ m/s}^3$ の時間変化制限がかかる。ただし、加速度が -2.0 m/s^2 を下回る急ブレーキである場合は緊急性が高いと判断し、この時間変化制限を取り除く。

最終段に設けている緊急停止ロジックは、現在速度を維持した場合、加速度 -2.0 m/s^2 で減速した場合の2通りについて ΔTTC を算出し、双方ともに $|\Delta \text{TTC}| > \delta$ を満たすことができない場合に緊急停止フラグを立てる。検知した全ての歩行者に対してフラグの算出を行い、フラグのORをとる。そしてフラグが1である場合に、緊急停止ロジックは安全速度算出時に設定した加速度を指令する。

6.5.5 終端状態制御における初期状態の与え方

FSC はハードディスクドライブの位置決め制御などに適用され [133]、初期状態から終端状態まで、生成した軌道計画に沿って制御を行うことが一般的である。しかし、本手法において歩行者行動予測の内容は刻々と変化することから、速度計画を一定時間（例えば 0.5 秒）ごとに更新する必要がある。Fig. 6-20 で説明した通り、提案手法では安全速度に基づく速度計画など複数の速度計画ロジックが同時に機能しており、更新の際に V_{FSC}^* が必ずしも最終的な速度指令値 V^* になっているとは限らない。また、外乱等により速度指令値 V^* と実際の車両速度 V_{car} には容易に差異が生じうる。このような状況で、従来法と同様に初期状態に現在の物理量（自車位置、自車速度、自車加速度）を入力したところ、速度計画が更新ごとに不連続となる問題が生じた。

Fig. 6-22 は行動予測に基づく速度制御のシミュレーション結果の一例であるここでは自車両が速度 30 km/h で走行中、前方に歩行者を発見し、FSC に基づく速度指令値 V_{FSC}^* の生成を行っている。車両モデルには実験車両と同等のむだ時間 0.5 秒と時定数 0.2 秒の一次遅れを入れており、速度指令値 V^* の変化に対して車両速度 V_{car} は最大 0.7 秒程度の遅れが発生する。従来通り自車両の現在速度 V_{car} を初期条件として入力している Fig. 6-22(a)では、0.5 秒ごとに速度計画を更新した際に FSC の速度指令値 V_{FSC}^* が車両速度と同じ値にリセットされることで、のこぎり状の波形となり、加速度も頻繁に変動している。




Fig. 6-22 Comparison of velocity reference and acceleration from FSC.

FSC は乗り心地向上を目的として加速度及びジャークを抑える速度計画を行うが、速度計画自体に不連続性があると過大な加速度及びジャークが発生してしまい、上記目的を達成できない。それゆえ、速度計画の連続性確保のため、本稿では FSC における初期状態を式(67)の通り定義する。

$$X[0] = [x_{car}, V^*, a_x]^T \quad \dots \quad (67)$$

すなわち、初期状態における速度は、現在の車両速度 V_{car} や終端状態制御による現在の速度最適値 V_{FSC}^* の代わりに、速度制御系の最終的な速度指令値 V^* を与えることにした。Fig. 6-22(b)に、提案手法のシミュレーション結果を示す。FSC による速度指令値 V_{FSC}^* と車両速度 V_{car} に差異が生じている場合でも速度指令値 V_{FSC}^* が連続的となり、加速度も滑らかである。

6.6 机上検証

本章では、提案する歩行者行動予測および速度制御手法のシミュレーション結果を




Fig. 6-23 Considered high-density road condition for simulation.

示す。全ての歩行者は予め設定した軌道の通り、一定の歩行速度で移動する。また、歩行者および駐車車両は常に正確に検知できていると仮定し、センサ検知範囲や検知誤差等は考慮していない。

6.6.1 机上検証シナリオ

Fig. 6-3 のドライブレコーダ映像を参考に、Fig. 6-23 のような特定の高密度環境を構築した。自車両が走行可能な道路幅（2本の白線の間隔）2.5 m程度の狭い単路において、計10人の歩行者がおよそ40 m程度の範囲に密集し、障害物密度が「10個/100m²」の高密度道路環境を再現している。歩行者10人のうち、自車両の動きに直接影響を与える歩行者行動は、①車道に近づき、自車両の接近に気づいて路側帯側に戻る、②駐車車両の存在をきっかけに道路の反対側に斜め横断、③駐車車両回避のため横移動、④歩行者同士の交差のため横移動、の計4つである。なお、高密度環境で歩行者の数が多いため、③および④のシーンは複数回発生する。

シミュレーションでは従来法1（設定加速度 -5.9 m/s^2 の安全速度）、従来法2（設定加速度 -2.0 m/s^2 の安全速度）、提案法（歩行者行動予測に基づく速度制御法：安全速度は従来法1と同じ）の3通りについて、平均速度、加速度およびジャーク（加速度の時間変化）を比較する。位置 $x = 0 \text{ m}$ において自車両の初期速度および上位の速度指令値 V_{ref}^* をいずれも30 km/hに設定してシミュレーションを開始し、途中、歩行者の位置に応じて自車両の速度を自動で制御する。そしてスタート位置から $x = 100 \text{ m}$ の地点でシミュレーションを終了し、本地点に到達するまでに要した時間から規格化平均速度を算出する。加速度制限値は、加速側はいずれも 1.0 m/s^2 とし、減速側は -2.0 m/s^2 （従来法2）、 -4.0 m/s^2 （従来法1、提案法）に設定する。また、緊急停止時の加速度は安全速度算出時の設定加速度と等しく -2.0 m/s^2 （従来法2）、 -5.9 m/s^2 （従来法1、

提案法) に設定する。

6.6.2 机上検証結果

従来法 1, 従来法 2, 提案法によるシミュレーション結果を Fig. 6-24~Fig. 6-26 に示す。それぞれ(a)は車体速度, (b)は車体加速度, (c)はジャークを示す。(a)において, 実線は最終的な速度指令値 V_{ref} , 一点鎖線は自車両速度 V_{car} を表し, 図中には $x = 100$ m 到達の瞬間における時刻も記載している。

まず, $x = 100$ m到達時点での時刻から規格化平均速度を算出すると, 1.0 (従来法 1), 0.729 (従来法 2), 0.987 (提案法) となる。このことから, 提案法は従来法 2 に比べて平均速度が 35.4%向上し, 従来法 1 と同等の平均速度を実現している。これは, 横移動の可能性が低い歩行者に対して, 提案法は不必要な減速をせず, 従来法 1 と同じ速度指令値を生成したためである。目標値を僅かに下回っているのは, 歩行者④を越えた後に加速に転じるタイミングが従来法 1 に比べて遅れることが原因である。

一方, 加速度およびジャークに着目すると, 従来法 1 では Fig. 6-24(b)(c)に示す通り, 加速度 -2.2 m/s²を下回る急ブレーキが頻発し, それに応じてジャークも ± 2.0 m/s³を超える箇所が複数存在する。それに対し, 従来法 2 と提案法では, Fig. 6-25(b)(c)および Fig. 6-26(b)(c)より, 目標値である「加速度 -2.2 m/s²以上, ジャーク絶対値 2.0 m/s³以下」をほぼ全域で満たしている。特に提案法では, 歩行者の横移動予測に基づく速度制御により, 3 秒付近を除き加速度が最小 -1.3 m/s²で目標値に対して 40%低減を達成しており, ジャーク絶対値も最大 2.0 m/s³で目標値以内である。なお, 3 秒付近で加速度, ジャークともに目標値を超過しているのは, 駐車車両など横移動のきっかけとなる障害物が存在しない歩行者①および歩行者②に対して横移動を予測せず, 設定加速度 -5.9 m/s²の安全速度が反映されたためである。

以上, 高密度環境を想定した机上検証から, 提案法によって利便性の基準である「規格化平均速度 1.0」に対して規格化平均速度 0.988 と目標をほぼ達成, および良好な乗り心地の基準である目標値「加速度 -2.2 m/s²以上, ジャーク絶対値 2.0 m/s³以下」に対して「加速度 -1.3 m/s², ジャーク絶対値 2.0 m/s³」を達成し, 利便性と乗り心地を両立する見込みを得た。




Fig. 6-24 Simulation result (conventional method 1).




Fig. 6-25 Simulation result (conventional method 2).

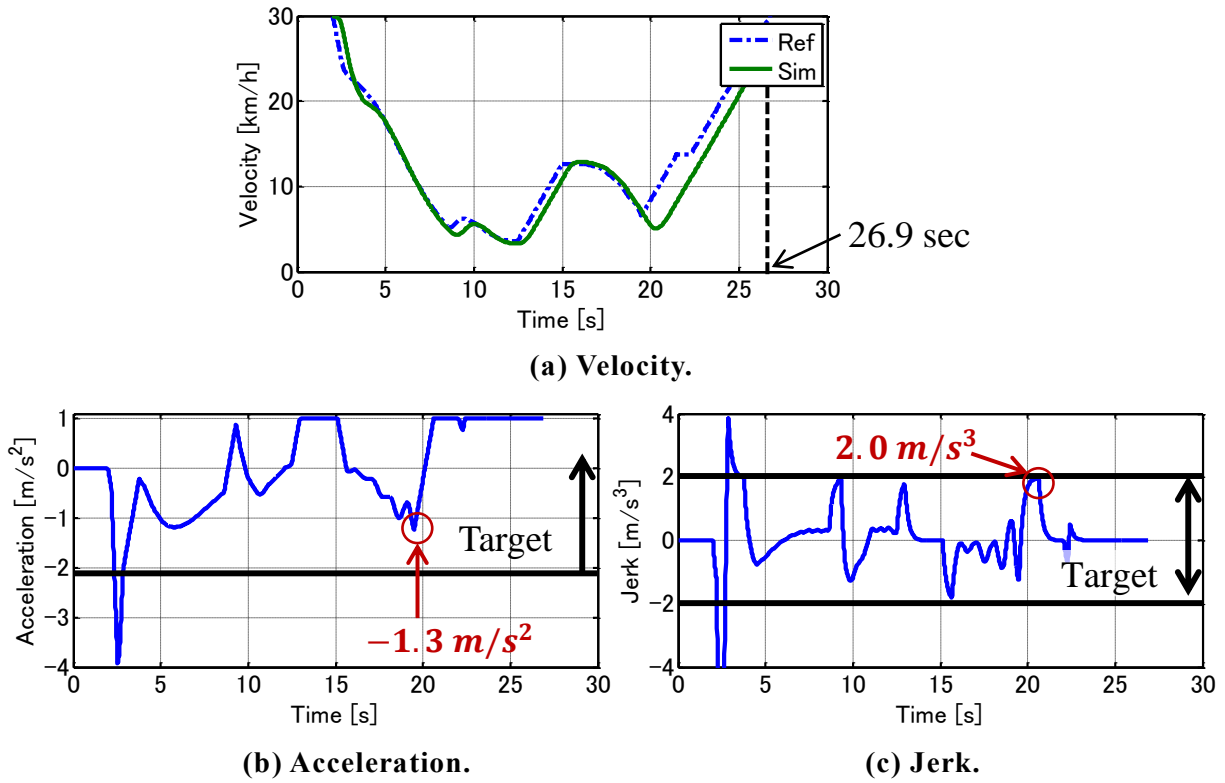
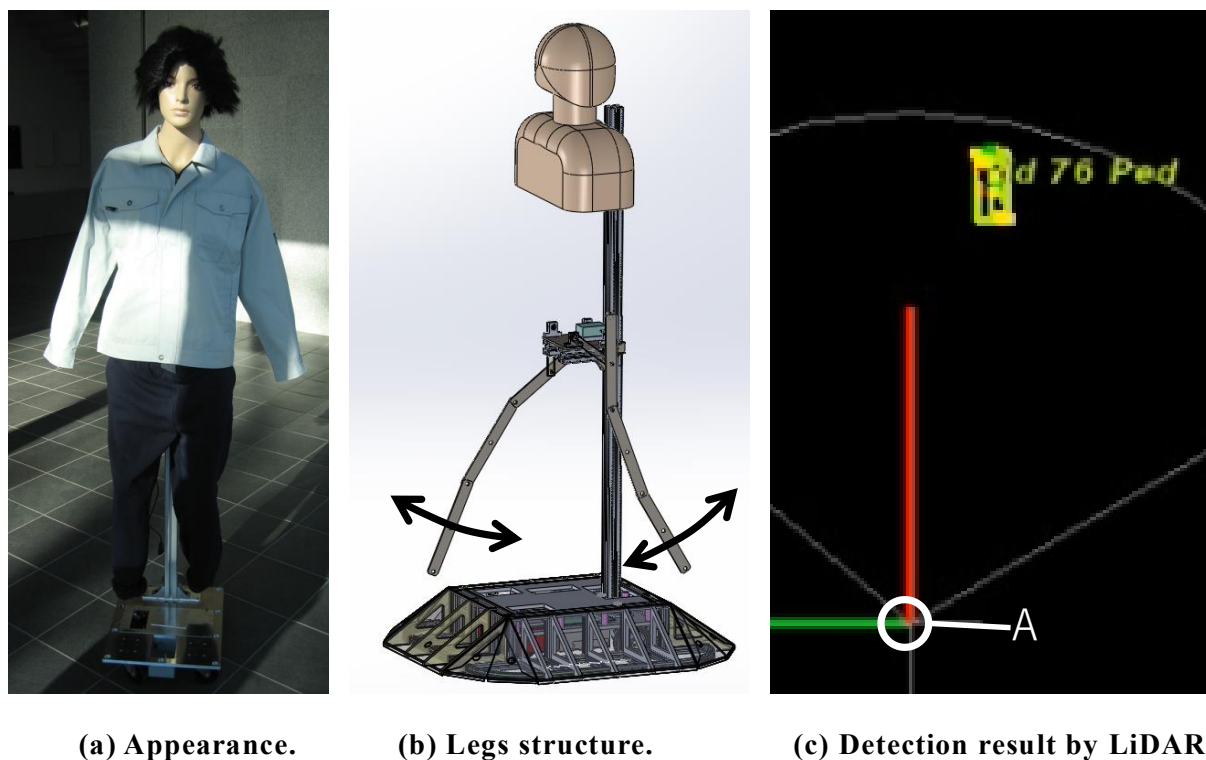


Fig. 6-26 Simulation result (proposed method).

6.7 実車検証

6.7.1 歩行者予測実験に用いるダミー人形

本研究は対歩行者の衝突回避制御の検証を行うため、安全性確保の観点からダミー歩行者を用いた。ダミー歩行者に関しては、遠隔操作可能であること、センサがダミーを歩行者として認識可能であることが求められるため、Fig. 6-27に示すダミー歩行者を製作した。Fig. 6-27(a)はダミー歩行者の外観である。今回使用する LiDAR の仕様として、足の動きを見て歩行者と認識するアルゴリズムが備わっていることから、Fig. 6-27(b)のように足を稼動できるようにした。Fig. 6-27(c)は LiDAR がダミー歩行者を検知した際の検知結果を示す。LiDAR には検知した移動体を追跡するアルゴリズムが備わっており、各検知物には最大 255 までの ID と認識結果 (unknown / pedestrian / bike / car / truck) が振られる。図における扇形の中心 (図中の点 A) が LiDAR の位置、黄色の四角で囲まれた領域がダミー歩行者の検知領域を表している。"Ped" は "Pedestrian" (歩行者) を意味し、ダミーを歩行者として認識している。



(a) Appearance.

(b) Legs structure.

(c) Detection result by LiDAR.

Fig. 6-27 Pedestrian dummy.

6.7.2 実車検証における条件

本節では、構内テストコースで行った実車検証の結果を述べる。実車検証では机上検証のような高密度環境を設定することが困難であるため、原理確認として、単路を直進する歩行者の横を自車両が通過するシーン（実験 I）、駐車車両を避けて横移動する歩行者の横を自車両が通過するシーン（実験 II）、の 2 つのシナリオを抽出して試験を行った。なお、本稿では速度制御手法に限定して実証試験を行うこととし、速度制御の実車検証にあたって自動操舵機構は使用せず、ドライバーによる操舵を行った。

実験に際して、実験車両が最大 -3.0 m/s^2 の加速度しか出せないことを考慮し、従来法 1 の設定加速度を $a_x = -0.3 \text{ G} (= -2.9 \text{ m/s}^2)$ 、従来法 2 の設定加速度を $a_x = -0.1 \text{ G} (= -1.0 \text{ m/s}^2)$ に設定し、シミュレーションと同様に従来法 1、従来法 2、提案法（安全速度は従来法 1 と同じ）の 3 通りで比較した。また、実験車両の加速度制御系に 0.5sec 程度のむだ時間が存在することから、安全速度マップはむだ時間 0.5 sec を考慮して算出した。それぞれ安全速度マップを Fig. 6-28 に示す。歩行者の横 1.0 m を通過する際の通過速度は、従来法 1 および提案法では 15 km/h 程度、従来法 2 では 10 km/h 程度

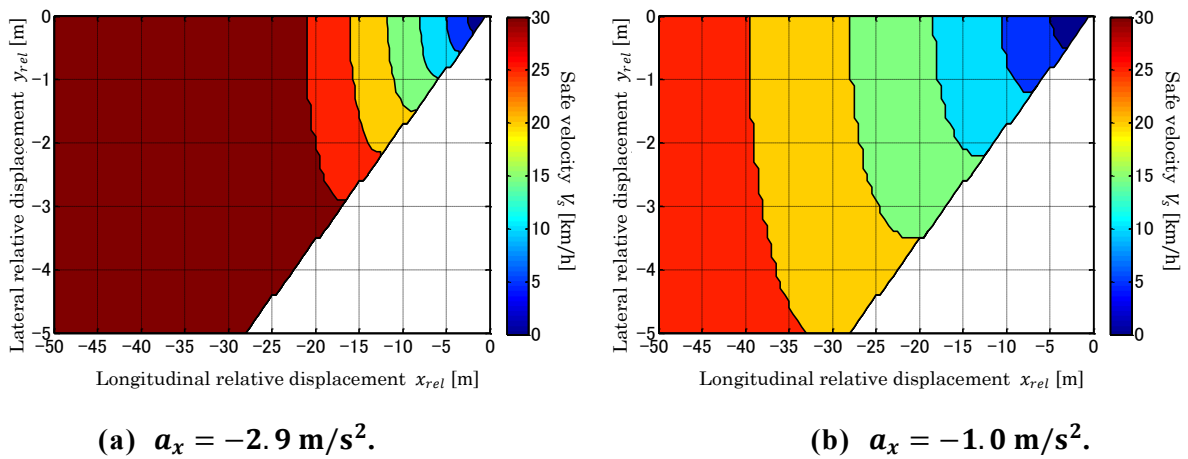


Fig. 6-28 Safe velocity map for experiment.

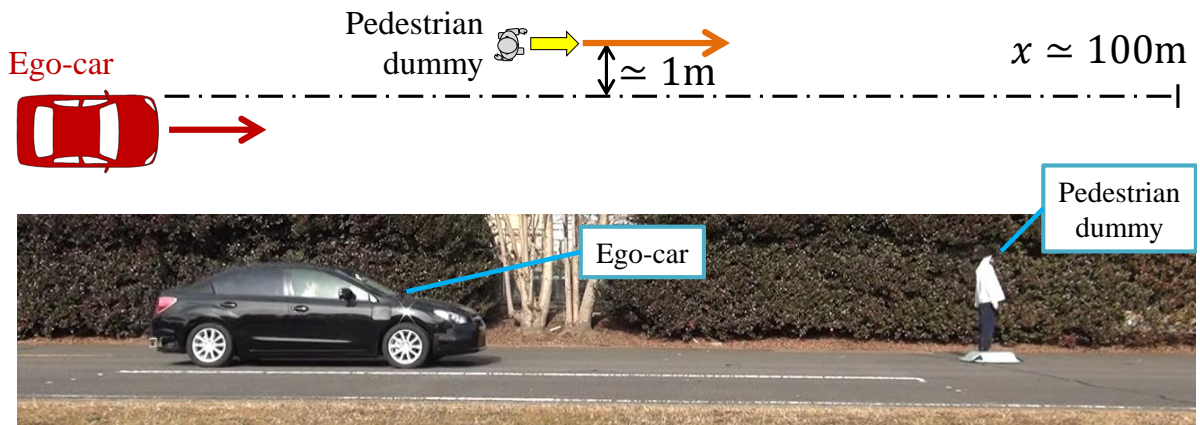


Fig. 6-29 Experimental condition of exp I.

となる。なお、実験にあたって加速度の上限値は加速側を 1.0 m/s^2 、減速側を -2.0 m/s^2 に設定し、緊急停止時は -3.0 m/s^2 の加速度を指令する。

6.7.3 単路を直進する歩行者（実験 I）

Fig. 6-29 に示すように、自車両の左側とダミー歩行者との距離が 1m 程度となるようにダミー歩行者を配置し、自車両は歩行者の右側を直進して通過する。上位の速度指令値 V_{ref}^* は 20 km/h とし、平均速度比較のため試験区間の条件を揃え、スタートから 100m の時点で停止するように速度指令値 V_{ref}^* を生成する。本実験では駐車車両などの障害物が存在しないため、歩行者行動予測アルゴリズムは歩行者の横移動を予測せず、




Fig. 6-30 Experimental result of exp I.

FSCによる速度計画は発生しない。従って、本試験方法において、提案法は従来法1と同じ挙動をすることが期待できる。

試験結果を Fig. 6-30 に示す。それぞれ、車両速度の時間推移を示しており、実線が最終的な速度指令値 V^* 、一点鎖線が自車両速度 V_{car} を示す。本グラフにおいて、各実験とも時刻 1 秒で加速を開始し、およそ 100m 時点で停止している。従来法 2 の Fig. 6-30(b)では、歩行者近傍を通過する 6 秒から 22 秒にかけて、速度指令値を 8 km/h に落としており、速度減少時間は 16 秒間にわたる。それに対し、従来法 1 の Fig. 6-30(a) および提案法の Fig. 6-30(c)では、歩行者近傍を通過する際の速度指令値が 12~14 km/h と高くなっており、速度減少時間も 5 秒間に短縮した。

それぞれのグラフの右下に記載した時刻は、100m 時点で停止した際の時刻を記載している。加速開始時刻 1 秒を差し引き、それぞれ規格化平均速度を算出すると、1.0 (従来法 1), 0.841 (従来法 2), 0.988 (提案法) となる。このことから、提案法は従来法 2 に比べて平均速度が 17.5% 向上し、従来法 1 と同等の平均速度になっている。

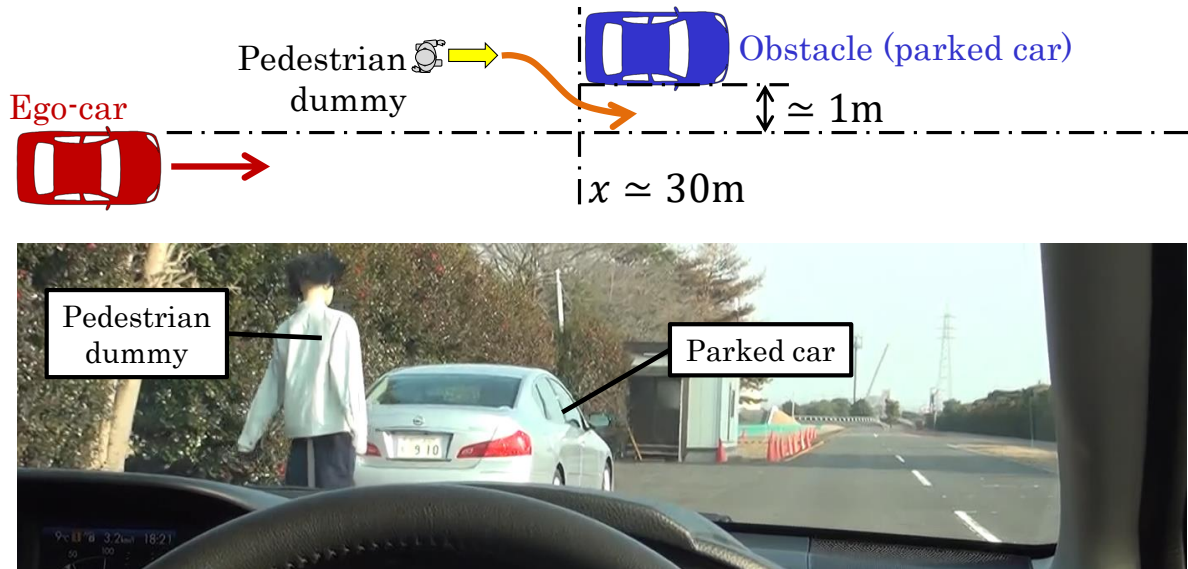


Fig. 6-31 Experimental condition of exp II.

これは、提案法が歩行者の横移動を予測せず、従来法1と同じ挙動をしたためである。ただ、提案法の規格化平均速度が1.0より僅かに低くなったが、これはダミー歩行者を手動（遠隔操作）で動かしている関係上、横位置の誤差が現れたものと推測する。

6.7.4 駐車車両を避けて横移動する歩行者（実験 II）

Fig. 6-31のように、ダミー歩行者の進路上に駐車車両があり、ダミー歩行者が駐車車両を避けて自車両側に横移動しやすい道路環境で、自車両は歩行者の右側を直進して通過する。このような状況下で、提案法は歩行者の横移動を予測し、加速度およびジャークを最小化するような速度計画を行う。

試験結果を Fig. 6-32～Fig. 6-34 に示す。それぞれ従来法1、従来法2、提案法の走行試験結果を表しており、(a)は車体速度、(b)は車体加速度、(c)はジャークを示す。(a)において、実線は最終的な速度指令値 V^* 、一点鎖線は自車両速度 V_{car} を表す。また、(b)は最終的な加速度指令値 a_x 、(c)は最終的な加速度指令値 a_x の微分値である。微分に際しては、ノイズ対策として時定数0.2秒のローパスフィルタを適用している。

速度の時間変化を参照すると、Fig. 6-32(a)、Fig. 6-33(a)、Fig. 6-34(a)はいずれも10秒から15秒にかけて車体速度を10 km/h未満に落としてしている。これは、歩行者が横移動して自車両の前を塞いだために、自車両が歩行者と同じ速度で後をついていくような走行になっているためである。したがって、実験IIにおいて規格化平均速度に差異

は生じない。

結果に差が生じるのは加速度およびジャークである。まず、加速度に着目すると、従来法1の Fig. 6-32(b)では、歩行者の横移動に対して緊急ブレーキが作動し、目標値を超過する加速度が発生している。一方、従来法2の Fig. 6-33(b)および提案法の Fig. 6-34(b)では、目標値である「加速度 -2.2 m/s^2 以上」を常に満たしている。特に提案法では、歩行者の横移動を予測し、行動予測に基づく速度制御により加速度を最小 -0.5 m/s^2 に収め、目標値に対して加速度を77%低減した。ジャークも同様の傾向であり、従来法1の Fig. 6-32(c)では緊急ブレーキ作動時にジャークが目標値を超過しているのに対し、従来法2の Fig. 6-33(c)、提案法の Fig. 6-34(c)はいずれも目標値である「ジャークの絶対値 2.0 m/s^3 以下」を満たしている。

以上、6.7.3項および6.7.4項で示した2つの実験結果から、提案する歩行者行動予測手法は、利便性の基準である「規格化平均速度1.0」に対して規格化平均速度0.987と目標をほぼ達成、および良好な乗り心地の基準である目標値「加速度 -2.2 m/s^2 以上、ジャーク絶対値 2.0 m/s^3 以下」に対し「加速度 -0.5 m/s^2 、ジャーク絶対値 2.0 m/s^3 」を達成し、利便性と乗り心地を両立できる見通しを得た。




Fig. 6-32 Experimental result of exp II (conventional method 1).




Fig. 6-33 Experimental result of exp II (conventional method 2).

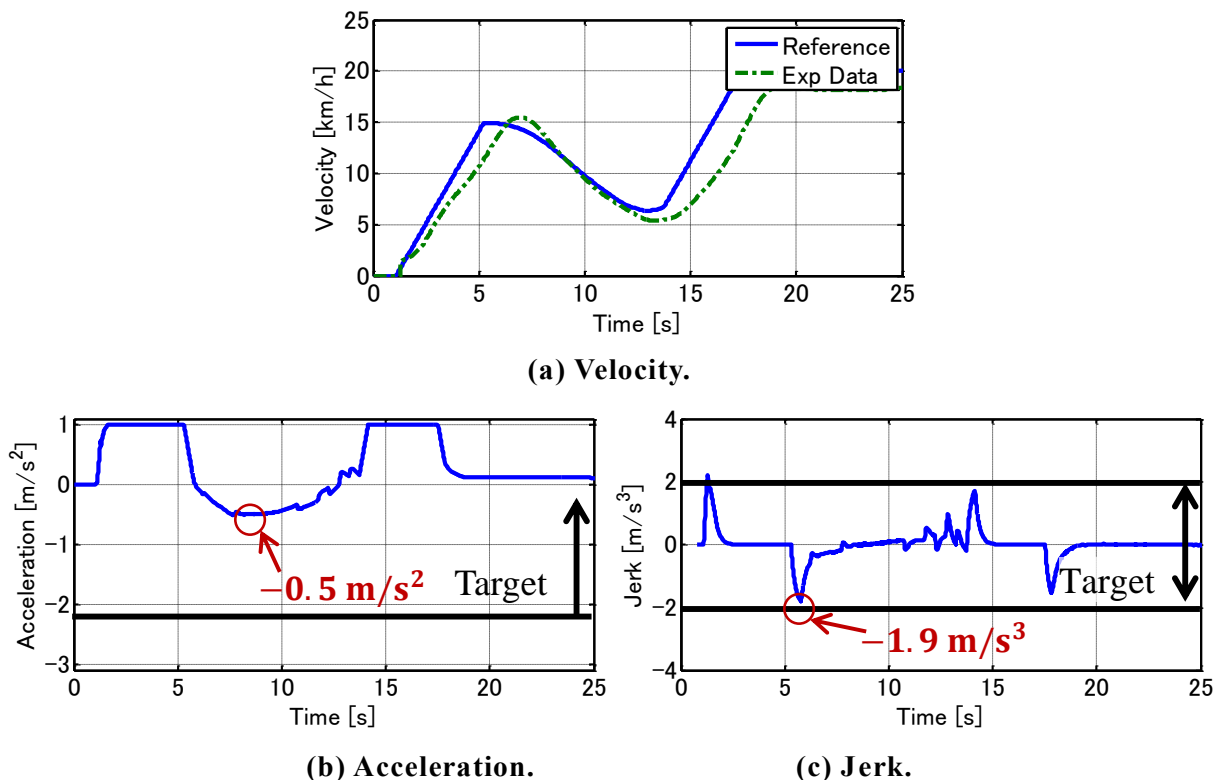


Fig. 6-34 Experimental result of exp II (proposed method).

6.8 本章のまとめ

本章では、歩行者・自転車などの移動体が多数存在する市街地道路環境において、利便性と乗り心地を両立する速度制御手法を開発した。まず、歩行者の予想外の横移動に対する安全性を確保する安全速度を算出した。次に、歩行者が駐車車両などの障害物を避けて横移動するような経路を予測する経路予測モデルを構築した。さらに、経路予測モデルに基づき将来の衝突が予測される場合に、ジャークを最小化するような速度計画手法を構築した。最後に、机上検証および実車検証により提案手法の有効性を確認した。提案手法は利便性の基準である平均速度、および良好な乗り心地の基準である加速度、ジャークのいずれも目標値を達成した。

Fig. 6-35 に、歩行者行動予測手法により実現する成果を示す。本図は横軸を歩行者衝突回避のための減速度、縦軸を歩行者そば通過時の速度に設定している。一般に、この2つの軸はトレードオフの関係である。本章において「従来法 1」とは市販車に広く搭載されるようになった ADAS の中で自動緊急ブレーキ (AEB) を想定したもの

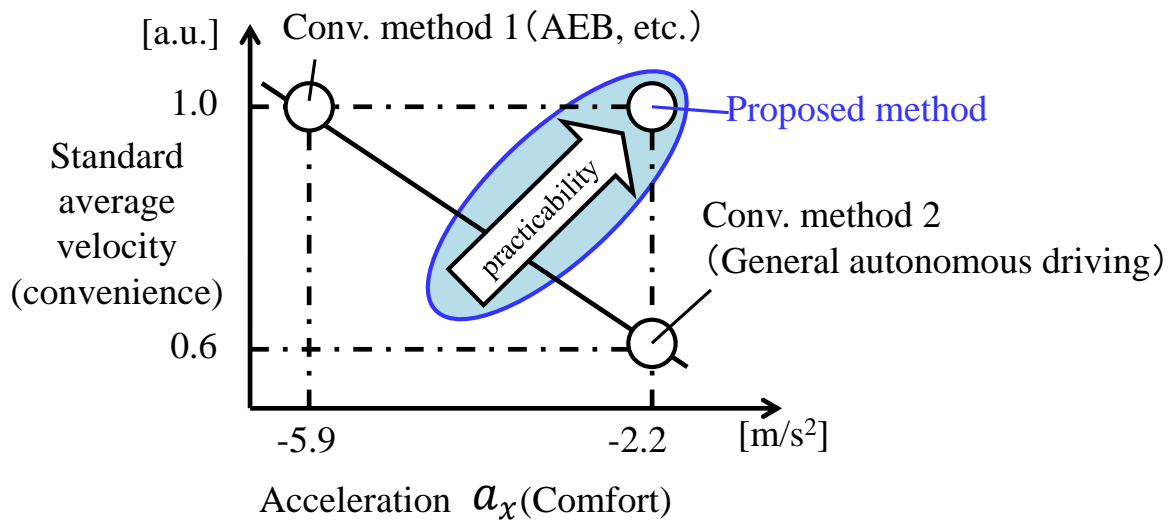


Fig. 6-35 Achievement of the pedestrian prediction method.

であり、歩行者が行動変化を起こしてから高い減速度で減速する。そのため歩行者のそばを通過する際の速度は高いものの、歩行者との衝突回避のための減速度の大きさが大きくなり、乗り心地に影響する。一方、現在世界中で開発が進む自動運転システムは、歩行者との衝突防止と乗り心地を両立させるために歩行者のそばで速度を落とす設計にしていることが多いと考えられる。このような設計では、歩行者の行動変化に対して常用減速度で減速できるため乗り心地は良いが、歩行者の近くを通過するごとに減速するため乗員にとっての利便性を損なう恐れがある。それに対し、歩行者行動予測によって、速度は従来法1と同等を実現しつつ、歩行者との衝突回避のための減速度は従来法2と同等の滑らかさを実現した。これにより、市街地道路環境における利便性と乗り心地を両立できる見通しを得た。

本稿では、歩行者の行動変化のうち、将来の横移動を予測するモデルを構築した。今後、歩行者の顔認識から歩行者の意思を推定し、歩行者の立ち止まりを含めた速度変化を予測するなど、より多様な行動変化の予測を行い、市街地道路環境におけるよりスムーズな走行制御の実現が課題となる。

第7章 結言

7.1 本論文のまとめ

交通事故ゼロをめざす、高齢化社会において特に過疎地の足を確保する、などの社会課題の解決を目的として、ドライバ操作を代替する自動運転システムの実現を見据えた研究開発が盛んに行われている。国内外で高速道路における公道試験走行が進んでおり、ドライバがハンドルから手を離すことが認められるレベル3自動運転が日本国内で認められ、今後は市販の乗用車への搭載も進むと考えられる。一方、一般道では最近になって一部地域で公道試験走行が開始された段階である。限定エリアにおけるレベル4自動運転システムを搭載した無人運転バスの実証試験も全国で行われているが、実用化には至っていない。高速道路と比べて、自動運転に必要なHD地図の整備が一般道（特にラストワンマイル自動運転の領域）では後回しになること、一般道は歩行者・自転車などの移動体に対する衝突回避が求められるため技術的な難易度が高いことが課題となっている。

本論文では、これら課題に対して自動運転システムにおける判断・制御の観点から取り組んだ。すなわち、センシング・認識の課題は将来的に解決されるという前提で、主に判断の部分の課題となる【1】低コストな車載センサのみを用いて自動運転用の地図を生成すること、そして【2】歩行者・自転車の行動変化を予測すること、の2点を研究対象とした。

まず、第2章では、自動運転システムの一般的な構成について述べた。具体的には、本研究のために構築した実験車両および車両に取り付けられた車載センサ、本稿が適用した一般的な自己位置推定手法を示した。そして自動運転に必要な操舵制御設計として、前方注視モデルに基づく軌道追従制御と操舵角サーボについて述べた。

次に第3章では、本稿で目的とする市街地道路環境での自動運転実現に向けた技術課題を深掘りした。まず、車載センサ情報を用いて地図生成するにあたっての課題について実験車両をテストコース上で走らせた際の走行データを用いて示した。次に歩行者行動予測の課題については、ヒヤリハットデータの分類に基づき、移動体同士も

しくは静止物体と移動体の相互作用による行動変化予測モデルの構築を行うという方針を立てた。

第4章では、【1】の課題として、地図生成手法について具体的な手法を構築し、テストコースを手動で走行した際のデータを用いて検証した。その際、レンジと画角が異なる2種類のカメラを比較し、地図生成におけるセンサ要件を考察した。また、考察にあたり、横方向誤差の考え方にに基づき生成した地図の精度判定を行う手法を提案した。結果、レンジが短く画角の広い Fisheye camera でテストコースの自動運転走破に成功し、ランドマークがコンスタントに検出されることが自動運転継続にあたってのキーとなることが示唆された。一方、地図精度判定手法については、あくまで必要条件であって十分条件とは言えないという知見も得られた。

第5章では、第4章の知見を踏まえて地図精度判定手法のもう一つの考え方を提案した。すなわち、構築した地図自体の精度を統計学的に判定する手法を構築した。そして、第4章と同じくテストコースを手動で走行した際のデータを用いて検証した。その結果、周回の回数を重ねるごとに自動運転可能 (Satisfy) と判定した区画が増加し、自動運転可能 (Satisfy) と判定した区画と自動運転不可能 (Not satisfy) と判定した区画の白線地図を比較し、開発した手法が、特に垂直方向のばらつきが大きい区画で自動運転不可能と判定していることから、本手法の有効性を確認した。一方、判定結果はパラメータ設定に依存するという知見も得られた。

第6章では、【2】の課題として前章までの地図生成に関する研究を応用し、LDM内の静止物(地図)の情報と移動物体の情報を組み合わせることで歩行者・自転車の将来の行動変化を予測する歩行者行動予測を構築した。行動予測にはポテンシャル法を適用し、自車両と歩行者とが将来干渉することが予測される場合には終端状態制御を用いてなめらかに減速する速度計画法を構築した。また、歩行者がいついかなる方向に行動変化しても急ブレーキで停車可能な安全速度を導入した。ある特定の高密度道路環境を想定したユースケースにおけるシミュレーションと、テストコースにおける実車とダミー歩行者を用いた実験により、歩行者の将来の行動変化が予測されない場合には速度を維持しつつ、行動変化が予測される場合には所定内の減速度で減速可能であることを示した。すなわち歩行者・自転車が混在する市街地道路環境において、速度(利便性)と減速度(乗り心地)のトレードオフを解消する見通しを得た。

自動運転システムは、外界情報や車両情報をセンサにより取得し、取得した外界情

報を LDM で管理をする。LDM のランドマーク情報を用いて自己位置推定がされ、地図情報を用いて軌道計画および横方向制御がなされ、LDM 内の地図情報、静止物体情報及び移動物体を用いて、移動体行動予測に基づく速度計画と前後方向制御がなされる。それぞれ 2.2 節でセンサによる外界情報取得について、2.3 節で自己位置推定について、2.4 節で軌道計画および横方向制御について述べた。そして、3.2 節、第 4 章および第 5 章で LDM 内の地図情報を更新する手法について述べた。さらに、3.3 節、3.4 節および第 6 章で LDM 内の地図情報、静止物体情報及び移動物体を用いて、移動体行動予測に基づく速度計画と前後方向制御について述べた。このように、本論文で取り上げる手法・技術をすべて統合し、センシング技術を組み合わせることで、市街地道路環境を走行可能な一つの自動運転システムとなる。

7.2 今後の課題

【1】低コストな車載センサのみを用いて自動運転用の地図を自己生成すること、
【2】歩行者・自転車の詳細の行動変化を予測すること、それぞれに関する今後の課題は以下の通りである。

まず、【1】自己地図生成について、第 4 章で示した横方向偏差に基づく地図精度判定手法は、必要条件の一つであるが十分条件ではないことが示唆された。そこで、必要十分条件を得るためには、第 5 章で示した地図情報自体に対する統計学的な精度判定手法を十分条件として組み合わせることが一案と考えられる。しかしながら、今回は”satisfy”と判定された区画と”not satisfy”と判定された区画において自動運転実験により比較をするには至っておらず、今後の課題である。また、今回はカメラにより取得した白線地図を用いて地図構築および精度判定の検討を行ったが、自己位置推定に用いるランドマークは他にもさまざまな種類があり、それぞれについて同様に本手法を適用可能かどうかの検討が必要である。同時に、今回検討しなかった前後方向の自己位置推定精度判定に関する検討が必要となる。

次に、【2】の課題については、今回は 1 人の歩行者が駐車車両という静止物を避けて横方向に行動変化するという単一のユースケースで実車検証を行ったが、実際の道路環境はより複雑である。具体的には、道路形状がさまざまであり、路面上の障害物も一つではなく複数存在しうる。ポテンシャル法の原理に基づけば、複数障害物も重

ね合わせの原理により対応可能と考えられるが，検証が求められる。それ以外にも，歩行者の顔認識から歩行者の意思を推定し，歩行者の立ち止まりを含めた速度変化を予測するなど，より多様な行動変化の予測を行い，市街地道路環境におけるよりスムーズな走行制御の実現が課題となる。さらに，横断歩道など，障害物に関わらず歩行者が行動変化を起こしうる要因は他にもあり，それらを「文脈」として行動予測モデルに取り入れることも必要だと考えている。

参考文献

- [1] 永井正夫, "自動車の予防安全技術と運転者の運転行動モデル," システム/制御/情報: システム制御情報学会誌, vol. 55, no. 1, pp. 26-31, 2011.
- [2] 植木信幸, ほか, "安全走行支援システムを支える自動車運動制御技術," 日立評論, vol. 85, no. 5, pp. 47-52, 2004.
- [3] 警察庁, "交通事故発生状況," <https://www.npa.go.jp/publications/statistics/koutsuu/toukei/keiyo.html>. [Accessed 2020/5/25].
- [4] 公益財団法人 交通事故総合分析センター, 交通統計 平成 29 年版, 2017.
- [5] 内閣府, 令和元年版高齢社会白書, 2019.
- [6] 警察庁, "運転免許統計," <https://www.npa.go.jp/publications/statistics/koutsuu/menkyo.html>. [Accessed 2020/5/26].
- [7] 国土交通省, "先進安全自動車 (ASV) ," <https://www.mlit.go.jp/jidosha/anzen/01asv/aboutasv.html>. [Accessed 2020/5/26].
- [8] 奥田照幸, VOLVO シティ・セーフティ, 自研センターニュース, 2010 年 12 月号, pp. 2-8, 2010.
- [9] 富士重工業, "事故を起こさないクルマを目指し、運転支援範囲を大幅に拡大した先進運転支援システム「新型 EyeSight (アイサイト)」を開発," http://www.fhi.co.jp/news/10_04_06/10_04_22.html. [Accessed 2014/9/1]
- [10] 独立行政法人 自動車事故対策機構, "予防安全性能アセスメントの概要," https://www.nasva.go.jp/mamoru/active_safety_search/about_active_safety.html. [Accessed 2020/5/26].
- [11] 米陀佳祐, ほか, "仮想自動運転システムによるレーンチェンジ経路計画," 自動車技術会論文集, vol. 47, no. 1, pp. 165-170, 2016.
- [12] 菅沼直樹, ほか, "高齢過疎地域における自動運転自動車の市街地公道実証実験概要," 自動車技術会学術講演会講演予稿集, no. S070, pp. 390-394, 2015.
- [13] 三浦弘雅, ほか, "自動運転用情報呈示手段としてのヘッドアップディスプレイ (HUD) に対するドライバ認知特性," 自動車技術会学術講演会講演予稿集, no. S203, pp. 1064-1069, 2015.
- [14] T. Ito, M. Mio, K. Tohriyama and M. Kamata, "Novel Map Platform based on Primitive Elements of Traffic Environments for Automated Driving Technologies," I

- International Journal of Automotive Engineering, vol. 7, no. 4, pp. 143--151, 2016.
- [15] 内閣府, "戦略的イノベーション創成プログラム 自動運転 (システムとサービスの拡張) 研究開発計画," 2020. https://www8.cao.go.jp/cstp/gaiyo/sip/keikaku2/4_jidosoko.pdf. [Accessed 2020/5/26].
- [16] NHTSA, "Automated Vehicles for Safety," <https://www.nhtsa.gov/technology-innovation/automated-vehicles-safety>. [Accessed 2020/5/26].
- [17] 首相官邸, "実態に即した自動運転システム等の定義の見直し," 2019. https://www.kantei.go.jp/jp/singi/it2/jidounten_wg/dai3/siryoku3.pdf. [Accessed 2020/5/26].
- [18] 日産自動車, "新型「セレナ」を発売," 2016. <https://newsroom.nissan-global.com/releases/160824-01-j?lang=ja-JP>. [Accessed 2020/5/26].
- [19] The Huffington Post, "テスラの自動運転車で初の死亡事故。何が問題だった?," 2016. http://www.huffingtonpost.jp/2016/06/30/driver-killed-while-using-teslas-autopilot_n_10763912.html. [Accessed 2020/5/26].
- [20] 富岡恒憲, "自動運転レベル3解禁," in 日経 Automotive 2020年6月号, 日経 BP, 2020, pp. 42--61.
- [21] 日産自動車, "ProPILOT 2.0," <https://www2.nissan.co.jp/SP/SKYLINE/PROPILOT2/>. [Accessed 2020/5/26].
- [22] 深尾三四郎, モビリティ 2.0 「スマホ化する自動車」の未来を読み解く, 日本経済新聞出版, 2018.
- [23] 久米秀尚, "CASE が問う次の 100 年," in 日経 Automotive 2020年4月号, 日経 BP, 2020, pp. 32--45.
- [24] 国土交通省 自動走行ビジネス検討会, 今後の取組方針, 2016, pp. 27--31.
- [25] Response, "無人運転バスサービス、イオンモールで運行...DeNA とイーजीマイルが提携," 2016. <https://response.jp/article/2016/07/08/278152.html>. [Accessed 2020/5/27].
- [26] SIP-adus, "沖縄県石垣市でのバス自動運転実証実験," 2017. <https://www.sip-adus.go.jp/evt/ishigaki-trial/>. [Accessed 2020/5/27].
- [27] 露木伸宏, "MaaS (モビリティ・アズ・ア・サービス) について," 国土交通政策研究所報, no. 69, pp. 2--7, 2018.
- [28] トヨタ自動車, "トヨタ自動車、モビリティサービス専用 EV“e-Palette Concept”を CES で発表," 2018. <https://global.toyota.jp/newsroom/corporate/20508200.html>. [Accessed 2020/5/27].
- [29] トヨタ自動車, "トヨタ、「コネクティッド・シティ」プロジェクトを CES で発表," 2020. <https://global.toyota.jp/newsroom/corporate/31170943.html>. [Accessed 2020/5/27].

参考文献

- [30] 鯉淵健, ほか, "交通事故死傷者ゼロに向けた最新の先進安全/自動運転技術とその展望," 自動車技術, vol. 74, no. 3, pp. 10--16, 2020.
- [31] 自動運転に対応した道路空間に関する検討会, "自動運転に対応した道路空間のあり方「中間とりまとめ」～政府目標達成のために道路インフラが早急に取り組むべき事項を提言～," 国土交通省, 2019.
- [32] K. Bengler, K. Dietmayer, B. Farber, M. Maurer, C. Stiller and H. Winner, "Three Decades of Driver Assistance Systems: Review and Future Perspectives," IEEE Intelligent Transportation Systems Magazine, vol. 6, no. 4, pp. 6--22, 2014.
- [33] M. Montemerlo, J. Becker, S. Bhat, H. Dahlkamp and S. Thrun, "The Stanford Entry in the Urban Challenge," Journal of Field Robotics, vol. 25, no. 9, pp. 569--597, 2008.
- [34] C. Urmson, J. Anhalt, H. Bae, A. J. Bagnell and C. R. Baker, "Autonomous Driving in Urban Environments," Journal of Field Robotics, vol. 25, no. 8, pp. 425--466, 2008.
- [35] I. Miller, M. Campbell and D. Huttenlocher, "Map-aided localization in sparse global positioning system environments using vision and particle filtering," Journal of Field Robotics, vol. 28, no. 5, pp. 619--643, 2011.
- [36] SIP-adus, SIP『自動走行システム』進捗報告, http://www.sip-adus.jp/evt/media/file/evt_2016_media_sip_report.pdf, 2016.
- [37] 井上秀雄, ほか, "高齢者の自立を支援し安全安心社会を実現する自律運転知能システム," 2016. http://web.tuat.ac.jp/~s-innova/pdf/symposium2016_inoue.pdf. [Accessed 2020/5/27].
- [38] 国土交通省, "道路統計年報 2019," <https://www.mlit.go.jp/road/ir/ir-data/tokei-nen/index.html>. [Accessed 2020/5/27].
- [39] S. Nakamura, T. Ito, T. Kinoshita and M. Kamata, "Detection Technology of Road Marks Utilizing Combination of Partial Templates," International Journal of Automotive Engineering, vol. 9, no. 3, pp. 105--114, 2018.
- [40] ETSI, "ETSI TR 102 863 V1.1.1," 2011. https://www.etsi.org/deliver/etsi_tr/102800_102899/102863/01.01.01_60/tr_102863v010101p.pdf. [Accessed 2020/5/24].
- [41] H. Shimada, A. Yamaguchi, H. Takada and K. Sato, "Implementation and Evaluation of Local Dynamic Map in Safety Driving Systems," Journal of Transportation Technologies, vol. 2015, no. 5, pp. 102--112, 2015.
- [42] 豊島真澄, "つながる車載電子システム," SEC journal, vol. 11, no. 3, pp. 20--22, 2015.

- [43] A. Cosgun et al., "Towards full automated drive in urban environments: A demonstration in GoMentum Station, California," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 1811--1818.
- [44] I. Shim, J. Choi, S. Shin, T.-H. Oh, U. Lee, B. Ahn, D.-G. Choi, D. H. Shim and I.-S. Kweon, "An Autonomous Driving System for Unknown Environments Using a Unified Map," IEEE Transactions on Intelligent Transportation Systems, vol. 16, no. 4, pp. 1999--2013, 2015.
- [45] W. Huang, K. Wang, Y. Lv and F. Zhu, "Autonomous vehicles testing methods review," in IEEE 19th International Conference on Intelligent Transportation Systems, 2016.
- [46] N. Suganuma and T. Uozumi, "Precise position estimation of autonomous vehicle based on map-matching," in Proc. 2011 IEEE Intelligent Vehicles Symposium (IV), 2011, pp. 296--301.
- [47] N. Nagasaka and M. Harada, "Towards safe, smooth, and stable path planning for on-road autonomous driving under uncertainty," in Proc. 2016 IEEE 19th International Conference on Intelligent Transportation Systems, 2016, pp. 795--801.
- [48] 友納正裕, "移動ロボットのための確率的な自己位置推定と地図構築," 日本ロボット学会誌, vol. 29, no. 5, pp. 423--426, 2011.
- [49] P. J. Besl and N. D. McKay, "A method for registration of 3-D shapes," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 14, no. 2, pp. 239--256, 2002.
- [50] J. Rabe, M. Hübner, M. Necker and C. Stiller, "Ego-lane estimation for downtown lane-level navigation," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 1152--1157.
- [51] F. Li, P. Bonnifait and J. Ibañez-Guzmán, "Map-Aided Dead-Reckoning With Lane-Level Maps and Integrity Monitoring," IEEE Transactions on Intelligent Vehicles, vol. 3, no. 1, pp. 81--91, 2018.
- [52] N. Akai, L. Y. Morales, E. Takeuchi, Y. Yoshihara and Y. Ninomiya, "Robust localization using 3D NDT scan matching with experimentally determined uncertainty and road marker matching," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 1356-1363.
- [53] H. Fu, L. Ye, R. Yu and T. Wu, "An efficient scan-to-map matching approach for autonomous driving," in Proc. 2016 IEEE International Conference on Mechatronics and Automation, 2016, pp. 1649--1654.
- [54] N. Suganuma and D. Yamamoto, "Map based localization of autonomous vehicle

- and its public urban road driving evaluation," in Proc. 2015 IEEE/SICE International Symposium on System Integration, 2015, pp. 467--471.
- [55] 原孝介, ほか, "白線形状と軌跡の推定に基づくロバストな自己位置推定," 自動車技術会論文集, vol. 48, no. 6, pp. 1291--1296, 2017.
- [56] G. Trehard, E. Pollard, B. Bradai and F. Nashashibi, "On line mapping and global positioning for autonomous driving in urban environment based on evidential SLAM," in Proc. 2015 IEEE Intelligent Vehicles Symposium, 2015, pp. 814--819.
- [57] J. Rohde, B. Völz, H. Mielenz and J. M. Zöllner, "Precise vehicle localization in dense urban environments," in Proc. 2016 IEEE 19th International Conference on Intelligent Transportation Systems, 2016, pp. 853--858.
- [58] R. Matthaei, G. Bagschik and M. Maurer, "Map-relative localization in lane-level maps for ADAS and autonomous driving," in Proc. 2014 IEEE Intelligent Vehicles Symposium, 2014, pp. 49--55.
- [59] D. Kim, T. Chung and K. Yi, "Lane map building and localization for automated driving using 2D laser rangefinder," in Proc. 2015 IEEE Intelligent Vehicles Symposium, 2015, pp. 680--685.
- [60] H. Deusch, D. Nuss, P. Konrad, M. Konrad, M. Fritzsche and K. Dietmayer, "Improving localization in digital maps with grid maps," in Proc. 16th International IEEE Conference on Intelligent Transportation Systems, 2013, pp. 1522-1527.
- [61] 原孝介, ほか, "勾配画像処理に基づく三次元点群からの高精度地図の自動生成," 自動車技術会論文集, vol. 47, no. 1, pp. 183--188, 2016.
- [62] F. Chenavier and J. L. Crowley, "Position estimation for a mobile robot using vision and odometry," in Proc. 1992 IEEE International Conference on Robotics and Automation, 1992, pp. 2588--2593.
- [63] 魚住剛弘, ほか, "マップマッチングによる自動運転自動車の位置姿勢推定," 自動車技術会学術講演会前刷集, no. 145-10, pp. 11--14, 2010.
- [64] 安部正人, 自動車の運動と制御, 東京電機大学出版局, 2008.
- [65] 森下信, ほか, "日本の自動運転への取組み," 自動車技術, vol. 69, no. 12, pp. 46--49, 2015.
- [66] 上瀧剛, ほか, "ITS 応用のための地図作りの自動化," IEICE Fundamental Review, vol. 6, no. 2, pp. 95--101, 2012.
- [67] 石川貴一郎, "Mobile Mapping System による道路測量について," 精密工学会誌, vol. 79, no. 5, pp. 397--400, 2013.
- [68] 永井正夫, "ドライブレコーダ・データベースの現状と活用可能性," 自動車技術, vol. 67,

- no. 2, pp. 47--53, 2013.
- [69] P. Wongwaiwit and Y. Michitsuji, "Analysis on Pedestrian and Bicycle Behavior in Unsignalized Intersection Based on Near-Miss Incident Database," in Proc. The Transportation and Logistics Conference 2011, 2011, pp. 19--22.
- [70] 道辻洋平, ほか, "ヒヤリハットデータベースに基づく信号交差点における歩行者不安全行動の分析," 交通・物流部門大会講演論文集, no. 20, pp. 15--18, 2011.
- [71] ポンサトーン・ラクシンチャーンサク, ほか, "常時記録型ドライブレコーダを用いた交差点右折時の環境危険度と安全確認行動の解析--対歩行者・自転車事故危険度の評価," 自動車技術会論文集, vol. 41, no. 4, pp. 909--914, 2010.
- [72] 堤成可, ほか, "無信号交差点での対自転車ヒヤリハットデータベースの分析," 自動車技術会論文集, vol. 45, no. 6, pp. 1117--1122, 2014.
- [73] 鳩山紀一郎, ほか, "横断歩道手前空間を考慮した歩行者交通行動に関する基礎分析," 土木学会誌, vol. 11, no. 30, p. 4pages, 2004.
- [74] Google Official Blog, The latest chapter for the self-driving car: mastering city street driving, <http://googleblog.blogspot.jp/2014/04/the-latest-chapter-for-self-driving-car.html>, 2014.
- [75] YouTube, "ドラレコで撮ってみた【北千住】," 2010. <http://www.youtube.com/watch?v=lsziGRTMFtU>. [Accessed 2014/9/1].
- [76] 劉建宏, ほか, "パーソナルスペースを用いた障害物を回避する歩行者の群集流動," 土木学会論文集 D, vol. 64, no. 4, pp. 513--524, 2008.
- [77] 田中完爾, ほか, "非静的環境における不完全地図を用いたロボットによる自己位置推定法," 日本機械学会論文集 C 編, vol. 70, no. 689, pp. 113--119, 2004.
- [78] 竹澤聡, ほか, "同時自己位置地図獲得手法を用いた自律型ロボットの環境認識 (ダイナミカル局所ボロノイ分割による逐次経路計画)," 日本機械学会論文集 C 編, vol. 71, no. 703, pp. 904--911, 2005.
- [79] 加賀美聡, "ステレオカメラからのオンライン三次元 SLAM," 日本ロボット学会誌, vol. 26, no. 4, pp. 310--313, 2008.
- [80] 友納正裕, "エッジ点追跡に基づくステレオカメラを用いた三次元 SLAM," 日本ロボット学会誌, vol. 27, no. 7, pp. 759--767, 2009.
- [81] 大野和則, ほか, "投光型距離センサを用いた三次元 SLAM," 日本ロボット学会誌, vol. 26, no. 4, pp. 306--309, 2008.
- [82] 倉爪亮, ほか, "CPS SLAM の研究—大規模建造物の高精度三次元幾何形状レーザ計測システム—," 日本ロボット学会誌, vol. 25, no. 8, pp. 1234--1242, 2007.
- [83] 横矢剛, ほか, "群ロボットによる未知環境三次元地図の自動作成のための動作計画手法,"

- 電子情報通信学会論文誌 D, Vols. J93-D, no. 6, pp. 1024--1035, 2010.
- [84] 小嶋昂明, ほか, "マルチロボットの D-SLAM における環境地図統合とその理論解析," 計測自動制御学会論文集, vol. 50, no. 3, pp. 266--273, 2014.
- [85] 北島健太, ほか, "局所地図の時系列統合による大域地図の生成," ロボティクス・メカトロニクス講演会講演概要集, no. 2P1-F16, pp. 1--4, 2009.
- [86] 荒木天外, ほか, "汎用三次元環境地図を用いた移動ロボットナビゲーションのための地図生成," 日本ロボット学会誌, vol. 28, no. 1, pp. 106--111, 2010.
- [87] 庄司和晃, ほか, "画像センサと距離センサによる 2.5 次元地図の生成と評価," 電気学会論文誌 C, vol. 134, no. 2, pp. 183--191, 2014.
- [88] R. W. Wolcott and R. M. Eustice, "Visual localization within LIDAR maps for automated urban driving," in Proc. 2014 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2014, pp. 176--183.
- [89] D. Gruyer, R. Belaroussi and M. Revilloud, "Map-aided localization with lateral perception," in Proc. 2014 IEEE Intelligent Vehicles Symposium, 2014, pp. 674--680.
- [90] M. Schreiber, A.-M. Hellmund and C. Stiller, "Multi-drive feature association for automated map generation using low-cost sensor data," in Proc. 2015 IEEE Intelligent Vehicles Symposium, 2015, pp. 1140--1147.
- [91] D. Kim, B. Kim, T. Chung and K. Yi, "Lane-Level Localization Using an AVM Camera for an Automated Driving Vehicle in Urban Environments," IEEE/ASME Transactions on Mechatronics, vol. 22, no. 1, pp. 280--290, 2017.
- [92] A. Sujiwo, T. Ando, E. Takeuchi, Y. Ninomiya and M. Edahiro, "Monocular Vision-Based Localization Using ORB-SLAM with LIDAR-Aided Mapping in Real-World Robot Challenge," Journal of Robotics and Mechatronics, vol. 28, no. 4, pp. 479--490, 2016.
- [93] H. Saito, K. Kobayashi, K. Watanabe and T. Kinoshita, "New Lane Detection Algorithm that Emulates Human Color Recognition," Journal of Robotics and Mechatronics, vol. 27, no. 4, pp. 382--391, 2015.
- [94] A. Ohashi, F. Yamano, G. Masuyama, K. Umeda, D. Fukuda, K. Irie, S. Kaneko, J. Murayama and Y. Uchida, "Fisheye stereo camera using equirectangular images," in Proc. 17th International Conference on Research and Education in Mechatronics, 2016, pp. 284--289.
- [95] M. Yokozuka, N. Hashimoto and O. Matsumoto, "Low-cost 3D mobile mapping system by 6 DOF localization using smartphone embedded sensors," in Proc. 2015 IEEE International Conference on Vehicular Electronics and Safety, 2015, pp. 18

- 2--189.
- [96] M. Kudo, S. Kakegawa, T. Shima, A. Kuriyama, Y. Uchida and S. Hayase, "Advances in Vehicle Periphery Sensing Techniques Aimed at Realizing Autonomous Driving," *Hitachi Review*, vol. 67, no. 1056-057, pp. 52--57, 2018.
- [97] M. Takemura, M. Imai, M. Kiyohara, K. Irie, M. Sakata and S. Muramatsu, "Development of Lens Condition Diagnosis for Lane Departure Warning by Using Outside Camera," in *Proc. SAE 2014 World Congress & Exhibition*, 10.4271, 2014.
- [98] K. Hara and H. Saito, "Vehicle Localization Based on the Detection of Line Segments from Multi-Camera Images," *Journal of Robotics and Mechatronics*, vol. 27, no. 6, pp. 617--626, 2015.
- [99] S. Jung, J. Youn and S. Sull, "Efficient Lane Detection Based on Spatiotemporal Images," *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 1, pp. 289--295, 2016.
- [100] D. C. Andrade, F. Bueno, F. R. Franco, R. A. Silva, J. H. Z. Neme, E. Margraf, W. T. Omoto, F. A. Farinelli, A. M. Tusset, S. Okida, M. M. D. Santos and A. Ventura, "A Novel Strategy for Road Lane Detection and Tracking Based on a Vehicle's Forward Monocular Camera," *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 4, pp. 1497--1507, 2019.
- [101] C. Yuan, H. Chen, J. Liu, D. Zhu and Y. Xu, "Robust Lane Detection for Complicated Road Environment Based on Normal Map," *IEEE Access*, vol. 6, pp. 49679--49689, 2018.
- [102] Y. Lu, J. Huang, Y.-T. Chen and B. Heisele, "Monocular localization in urban environments using road markings," in *Proc. 2017 IEEE Intelligent Vehicles Symposium (IV)*, 2017, pp. 468--474.
- [103] J. Jeong, Y. Cho and A. Kim, "The Road is Enough! Extrinsic Calibration of Non-overlapping Stereo Camera and LiDAR using Road Information," *IEEE Robotics and Automation Letters*, vol. 4, no. 3, pp. 2831--2838, 2019.
- [104] G.-P. Gwon, W.-S. Hur, S.-W. Kim and S.-W. Seo, "Generation of a Precise and Efficient Lane-Level Road Map for Intelligent Vehicle Systems," *IEEE Transactions on Vehicular Technology*, vol. PP, no. 99, pp. 1--16, 2016.
- [105] S. Nobili, G. Tinchev and M. Fallon, "Predicting Alignment Risk to Prevent Localization Failure," in *Proc. 2018 IEEE International Conference on Robotics and Automation*, 2018, pp. 1003--1010.
- [106] W. Zhen, S. Zeng and S. Soberer, "Robust localization and localizability estimation

- n with a rotating laser scanner," in Proc. IEEE International Conference on Robotics and Automation, 2017, pp. 6240--6245.
- [107] M. Haklay and P. Weber, "OpenStreetMap: User-Generated Street Maps," IEEE Pervasive Computing, vol. 7, no. 4, pp. 12--18, 2008.
- [108] S. Klautdt, A. Zlocki and L. Eckstein, "A-priori map information and path planning for automated valet-parking," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 1770--1775.
- [109] J. Godoy, A. Artuñedo and J. Villagra, "Self-Generated OSM-Based Driving Corridors," IEEE Access, vol. 7, pp. 20113--20125, 2019.
- [110] 前田健太, ほか, "移動体制御装置". 特許番号: PCT/JP2018/010407, 2018.
- [111] PennState Eberly College of Science, "Lesson 1: Simple Linear Regression," [Online]. Available: <https://onlinecourses.science.psu.edu/stat501/node/250>. [Accessed 20 3 2018].
- [112] M. Billah, A. Maskooki, F. Rahman and J. A. Farrell, "Roadway feature mapping from point cloud data: A graph-based clustering approach," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 475--480.
- [113] Y. Qian, M. Yang, X. Zhao, C. Wang and B. Wang, "Oriented Spatial Transformer Network for Pedestrian Detection Using Fish-Eye Camera," IEEE Transactions on Multimedia, vol. 22, no. 2, pp. 421--431, 2020.
- [114] K. Granström, L. Svensson, S. Reuter, Y. Xia and M. Fatemi, "Likelihood-Based Data Association for Extended Object Tracking Using Sampling Methods," IEEE Transactions on Intelligent Vehicles, vol. 3, no. 1, pp. 30--45, 2018.
- [115] S. Hoermann, F. Kunz, D. Nuss, S. Renter and K. Dietmayer, "Entering crossroads with blind corners. A safe strategy for autonomous vehicles," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 727--732.
- [116] 清水司, ほか, "緊急ブレーキを仮定した衝突速度に基づく潜在リスクの定量化," 自動車技術会論文集, vol. 47, no. 6, pp. 1411--1416, 2016.
- [117] 大前学, ほか, "サービスエリア内等の歩車混在環境での自動運転における歩行者の移動予測情報を用いた路車協調型速度制御に関する研究," 自動車技術会論文集, vol. 46, no. 2, pp. 551--557, 2015.
- [118] T. Shimizu, Y. Ohama, S.-i. Nagata and J. Sakugawa, "A Computational Framework for Estimating Collision Risk against Pedestrians," R&D Review of Toyota C RDL, vol. 43, no. 1, pp. 33--42, 2012.
- [119] M. Schreiber, S. Hoermann and K. Dietmayer, "Long-Term Occupancy Grid Predi

- ction Using Recurrent Neural Networks," in Proc. 2019 International Conference on Robotics and Automation (ICRA), 2019, pp. 9299--9305.
- [120] N. Deo and M. M. Trivedi, "Learning and predicting on-road pedestrian behavior around vehicles," in Proc. 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), 2017, pp. 1--6.
- [121] B. Chen, D. Zhao and H. Peng, "Evaluation of automated vehicles encountering pedestrians at unsignalized crossings," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 1679--1685.
- [122] E. A. I. Pool, J. F. P. Kooij and D. M. Gavrila, "Using road topology to improve cyclist path prediction," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 289--296.
- [123] E. A. I. Pool, J. F. P. Kooij and D. M. Gavrila, "Context-based cyclist path prediction using Recurrent Neural Networks," in Proc. 2019 IEEE Intelligent Vehicles Symposium (IV), 2019, pp. 824--830.
- [124] 露木元, ほか, "狭路における歩行者追い越し時の危険予測運転支援システムの開発," 自動車技術会学術講演会前刷集, no. 125-13, pp. 5--8, 2013.
- [125] 木村賢治, ほか, "一時停止交差点における情報提供検討," 自動車技術会論文集, vol. 39, no. 4, pp. 137--140, 2008.
- [126] 王鋒, ほか, "自動車の加減速と乗り心地の関係に関する研究," 人間工学, vol. 36, no. 4, pp. 191--200, 2000.
- [127] K. Ezawa, P. Raksincharoensak and M. Nagai, "Hazard-Anticipatory Collision Avoidance System Based on Two-Dimensional Pedestrian Motion Prediction," in Proceedings of AVEC'14, 2014, p. 6pages.
- [128] 松實良祐, ほか, "ポテンシャルフィールドに基づく交差点右折時の歩行者衝突回避に関する研究," 自動車技術会論文集, vol. 42, no. 6, pp. 1295--1301, 2011.
- [129] 長谷川隆裕, ほか, "潜在リスク予測ドライバモデルを用いた自律運転知能システムの運動制御～駐車車両回避時の経路生成～," 自動車技術会学術講演会前刷集, no. 5-14, pp. 9--12, 2014.
- [130] F. Bounini, D. Gingras, H. Pollart and D. Gruyer, "Modified artificial potential field method for online path planning applications," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 180--185.
- [131] 岡田隆, ほか, "複数の移動体との衝突回避システム". 特許番号: PCT/JP2015/050709, 2014.
- [132] G. C. Pereira, L. Svensson, P. F. Lima and J. Mårtensson, "Lateral Model Predic

参考文献

- tive Control for Over-Actuated Autonomous Vehicle," in Proc. 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 310--316.
- [133] 平田光男, ほか, "終端状態制御によるハードディスクのショートシーク制御," 電気学会論文誌 D, vol. 125, no. 5, pp. 524--529, 2005.
- [134] 矢崎雄馬, ほか, "粗微動間連結分離機構を有する精密位置決めステージの終端状態制御法を用いた整定時間短縮法," 電気学会論文誌 D, vol. 135, no. 3, pp. 227--236, 2015.

謝辞

本研究を進めるにあたり、指導教官のポンサトーン・ラクシンチャーンサク教授には多大なるご助言・ご指導を頂きました。ポンサトーン先生には、日頃の研究内容のご指導だけでなく、入学前からの研究計画、学会投稿論文の執筆・推敲、学位論文のまとめ方などに関して、多岐にわたるご助言を賜りました。また、論文を投稿するモチベーションが高まらず停滞していた時期に何度も励ましていただき、こうして学位論文をまとめるに至ったことにも深く感謝申し上げたいと思います。

同じく本研究を進めるにあたり、東京農工大学 大学院工学府 機械システム工学専攻の毛利宏教授，田川泰敬教授，鎌田崇義教授，和田正義准教授には，本研究を公平な立場から見て頂くことで，多くの建設的なご助言を賜りました。深く感謝申し上げます。

本研究は 2014 年度から東京農工大学と(株)日立製作所の共同研究としてスタートしており，本研究の一部は共同研究時の成果です。共同研究時には 2018 年博士課程修了生の江澤和浩さんに多大なご協力をいただきました。研究方針の議論だけでなく，膨大な量のヒヤリハットデータベースの閲覧と整理，行動予測手法の理論構築，複数歩行者への拡張と実験検証など，研究推進におけるさまざまな場面でご協力いただきました。また，赤木康宏特任准教授（現・名古屋大学），齊藤裕一助教（現・筑波大学）にも研究方針の助言等をいただき大変お世話になりました。

多くの職場の皆様には，社会人ドクターとして活動する機会を与えて頂いたうえ，少なからず発生した業務への影響にもご理解・ご容赦頂きました。本研究は，それまでの研究開発活動がきっかけとなり，日頃の活発な議論を通じて実を結んだことは言うまでもありません。

改めまして，ご支援下さいました皆様に厚く御礼申し上げます。

発表文献

論文誌論文

- 前田健太, 児島隆生, 横山篤, “市街地での自動運転に向けた速度制御手法の開発”, 自動車技術会論文集, vol. 47, No. 4, pp. 955—960, 2016.
- 前田健太, 高橋絢也, 児島隆生, Pongsathorn Raksincharoensak, “自動運転用地図の自動生成における地図精度判定手法の検討”, 自動車技術会論文集, Vol. 49, No. 5 pp. 1074—1079, 2018.
- Kenta Maeda, Junya Takahashi and Pongsathorn Raksincharoensak, “Lane-Marker-Based Map Construction and Map Precision Evaluation Methods Using On-Board Cameras for Autonomous Driving”, Journal of Robotics and Mechatronics, Vol. 32, No. 3, pp. 613—623, 2020.

査読付き国際会議

- Kenta Maeda, Junya Takahashi and Takao Kojima, “Evaluation of Map-Expansion Method Using Different Cameras for Autonomous Driving”, in Proc. 4th International Symposium on Future Active Safety Technology Toward zero traffic accidents (FAST-zero 2017), TuB-P1-1, 7pages, 2017.

国内会議

- 前田健太, 児島隆生, 横山篤, “市街地での自動運転に向けた速度制御手法の開発”, 自動車技術会 2015 年秋季大会学術講演会講演予稿集, No. 20156245, pp. 1273—1278, 2015.
- 前田健太, 高橋絢也, 児島隆生, Pongsathorn Raksincharoensak, “自動運転用地図の自動生成における地図精度判定手法の検討”, 自動車技術会 2018 年春季大会学術講演会講演予稿集, No. 20185053, 6 pages, 2018.

共著論文

- 江澤和浩, Pongsathorn Raksincharoensak, 赤木康宏, 前田健太, 児島隆生, “自転車の他者追い越し場面における移動予測に基づく自動減速制御システムに関する研究”, 日本機械学会論文集, Vol. 84, No. 865, 12 pages, 2018.