

自律移動体の位置推定のロバスト性向上を目指した
センサ融合に関する研究

大 橋 臨

目次

第1章 序論	1
1.1 自律移動体の利用環境の変化	2
1.2 自律移動における位置推定	4
1.3 位置推定誤差の分類	6
1.4 本研究の目的とアプローチ	7
1.5 本論文の構成	10
第2章 自律移動体における位置推定に関する既存研究	13
2.1 位置推定に利用されるセンサと位置推定法	13
2.1.1 GNSS	13
2.1.2 カメラ	14
2.1.3 LiDAR	15
2.1.4 車輪オドメトリ・IMU	17
2.2 位置推定誤差の低減法	17
2.2.1 時系列処理	17
2.2.2 複数センサの活用	20
2.3 本章のまとめ	24
第3章 位置推定法の多重化における外れ値処理に基づく融合法の検証	25
3.1 はじめに	25
3.2 検証した統計的融合法	25
3.2.1 平均	26
3.2.2 メディアン	26
3.3 データ検証	27
3.3.1 利用した位置推定法	27
3.3.2 検証結果と考察	28
3.4 本章のまとめ	40
第4章 確率的な位置情報における外れ値処理に基づく融合法	41
4.1 はじめに	41

4.2	先行研究	42
4.2.1	パーティクルによる離散存在確率分布表現と融合	42
4.2.2	相対評価による選択法	43
4.3	先行研究のシミュレーション検証	45
4.3.1	シミュレーション条件	45
4.3.2	シミュレーション結果	46
4.3.3	先行研究の問題点	49
4.4	提案する選択法	49
4.4.1	類似性評価指標	50
4.4.2	選択法	51
4.4.3	シミュレーション検証	52
4.5	実環境における検証	54
4.5.1	検証条件	54
4.5.2	検証結果	59
4.6	まとめ	61
第5章	外れ値処理に基づく融合法を付与したベイズフィルタによる位置推定法	63
5.1	はじめに	63
5.2	パーティクルフィルタによる外れ値処理を含む位置推定法	63
5.3	実環境における検証	65
5.3.1	実験条件	65
5.3.2	ビルの谷間における実験	66
5.3.3	広場における実験	68
5.3.4	駐車場における実験	70
5.3.5	考察	72
5.4	本章のまとめ	72
第6章	位置推定法の信頼性マップ構築に向けた相対評価法の応用	73
6.1	はじめに	73
6.2	信頼性マップ構築の手順	73
6.3	実環境における検証	74
6.3.1	確率的位置情報の融合法	76
6.3.2	結果と考察	80
6.4	本章のまとめ	82

第7章 実世界データ循環学との関係	85
7.1 はじめに	85
7.2 本論文におけるデータの取得・解析・実装	85
7.3 データ循環による位置推定のロバスト性向上	86
7.4 本章のまとめ	87
第8章 結言	89
8.1 本研究のまとめ	89
8.2 今後の展望	93
付録 A 異種デバイス間の情報共有によるセンシング情報の増加	95
A.1 はじめに	95
A.2 協調歩行者トラッキングのフレームワーク	96
A.2.1 Prediction ブロック	97
A.2.2 通信デバイスの GNSS ドップラーによる速度推定	97
A.2.3 移動体による歩行者の認識	99
A.2.4 通信デバイスの IMU による角速度推定	99
A.3 実機実験	100
A.3.1 実験条件	100
A.3.2 シチュエーション1：歩行者のみ歩行	100
A.3.3 シチュエーション2：移動体が動く場合	103
A.4 本章のまとめ	103
参考文献	105

目次

1.1	無人搬送車の納入実績	3
1.2	位置推定の流れ	5
1.3	位置推定における誤差の分類と対策	6
1.4	センサおよび位置推定手法の多重化のイメージ	8
1.5	本論文の構成	10
2.1	位置推定のモデル	18
2.2	センサの切り替えのイメージ	21
2.3	センサの観測を統合のイメージ	22
2.4	センサから得る位置情報の融合のイメージ	23
3.1	平均とメディアンによる推定位置の融合例	26
3.2	各シーケンス内で最も誤差が小さい位置推定法に対する各位置推定法の誤差の比率	30
3.3	シーケンス 02 における NDT, ORB, LIMO の推定経路	31
3.4	$200 < x < 400, 600 < y < 800$ の区間で得たセンサの観測	31
3.5	シーケンス 02 における平均, メディアンの推定経路	32
3.6	シーケンス 02 における推定誤差	32
3.7	シーケンス 02 においてメディアンで選択された位置推定法	32
3.8	シーケンス 07 における NDT, ORB, LIMO の推定経路	34
3.9	$(x, y) = (-150, -80)$ の位置で得た LiDAR の点群をカメラの画像に投影した図	34
3.10	シーケンス 07 における平均, メディアンの推定経路	35
3.11	シーケンス 07 における推定誤差	35
3.12	シーケンス 07 においてメディアンで選択された位置推定法	35
3.13	シーケンス 01 における NDT, ORB, LIMO の推定経路	37
3.14	$(x, y) = (1035, -630)$ の位置で得た LiDAR の点群をカメラの画像に投影した図	37
3.15	シーケンス 01 における平均, メディアンの推定経路	38

3.16	シーケンス 01 における推定誤差	38
3.17	シーケンス 01 においてメディアンで選択された位置推定法	38
3.18	シーケンス 01 の真の位置が $(x, y) = (1035, -630)$ の地点における推 定位置と経路の拡大図	39
4.1	相対評価によるセンサ融合システム	42
4.2	先行研究における選択器 (Block B)	44
4.3	存在確率分布の使用率	47
4.4	バイアス量 $b_x = 0.7$ で得た存在確率分布	48
4.5	シミュレーションにおける推定誤差	48
4.6	KL 情報量が大きくなるケース	49
4.7	似ている存在確率分布	51
4.8	異なる存在確率分布	52
4.9	提案する選択器 (Block B)	52
4.10	提案法における存在確率分布の使用率	53
4.11	図 4.4 の散布図	54
4.12	提案法における推定誤差	55
4.13	使用した移動体	56
4.14	実験環境	57
4.15	存在確率分布の一例	60
5.1	パーティクルフィルタを用いた相対比較に基づくセンサ融合のイメージ 64	
5.2	実験環境 (ビルの谷間)	66
5.3	図 5.2 における位置推定誤差	67
5.4	図 5.2 の 330 秒で得た存在確率分布	67
5.5	実験環境 (広場)	68
5.6	図 5.5 における位置推定誤差	69
5.7	図 5.5 の 152 秒で得た存在確率分布	69
5.8	実験環境 (駐車場)	70
5.9	図 5.8 における位置推定誤差	71
5.10	図 5.8 の 254 秒で得た存在確率分布	71
6.1	走行環境 (名古屋大学 IB 館周辺)	75
6.2	使用した移動体	75
6.3	センサの観測の同期と非同期	76
6.4	車輪オドメトリのデッドレコニングによる信頼性マップ	81
6.5	NDT による信頼性マップ	81

6.6	ORBによる信頼性マップ	82
7.1	実世界データの取得・解析・実装と本論文の関係	86
7.2	データ循環による位置推定のロバスト性向上	88
A.1	V2Pによる協調歩行者トラッキングフレームワーク	97
A.2	実験環境	101
A.3	シチュエーション1における推定結果. 上から順に, 歩行経路と推定誤差を表す.	102
A.4	シチュエーション1における推定結果. 上から順に, 推定速度と推定進行方向を表す.	102
A.5	シチュエーション2における推定結果. 上から順に, 推定経路, 推定速度, 推定進行方向を表す.	104

第1章

序論

本論文は、自律移動体の位置推定のロバスト性向上を目指したセンサ融合に関する研究の成果をまとめたものである。

コンピュータ技術の小型化、高性能化、低価格化、高信頼化を背景に、ロボットの知能化が進んでいる。それに伴い、ロボットの活用範囲は、生産現場において素早く正確にもものづくりをこなす産業用ロボットから、災害現場や人の生活環境などで、人の生活や行動を支援するロボットへと広がりつつある [1]。中でも、人の操縦によらず自動で移動してタスクをこなす自律移動体への期待は大きい。物品の自動搬送、オフィスビルの自動警備・清掃、社会インフラ・プラントの自動保全・点検、農作業を自動で行う移動体に加え、自動運転車 [2-4] など、極めて広い分野での利用が検討されている。労働力不足が懸念される本国にとって、自律移動体による人の作業の代替による効果は大きい。

移動体が自律的に移動するためには、移動体の現在位置を把握する位置推定技術が重要である。位置推定により算出される現在の位置は、自律移動における経路生成や障害物回避で利用される。しかし、算出される位置情報に非常に大きな誤差が含まれると、誤った経路が算出されて移動体が目的地に辿り着けないのみならず、進行すべきでない方向に移動体が進行することで、重大事故を引き起こす危険性がある。そのため、自律移動における位置推定技術には、高いロバスト性が要求される。

本章では、本研究の背景となる自律移動体の位置推定¹の現状と課題について述べ、本研究の目的とアプローチを述べる。1.1 節で自律移動体の利用環境の変化、1.2 節で自律移動における位置推定の役割、1.3 節で位置推定で生じる推定誤差について述べる。1.4 節で本論文の目的とアプローチについて述べ、1.5 節で本論文の構成について述べる。

¹本論文では、環境地図や Global Navigation Satellite System (GNSS) を用いて位置を推定する自己位置推定と共に、環境地図構築と位置推定を同時に行う Simultaneous Localization And Mapping (SLAM) も位置推定技術の一つとして捉え議論する。

1.1 自律移動体の利用環境の変化

人間が操縦せず、自律的に移動してタスクを達成する自律移動体への期待が高まっている。自律移動体が初めて導入された 1980 年代ごろ、移動体は、生産現場や倉庫における物品の自動搬送を行っていた。これは、Automatic Guided Vehicle (AGV, 無人搬送車) として知られ、人の作業を代替する移動体として活躍してきた。移動体の制御方式には、「固定経路方式」、「半固定経路方式」、「無経路方式」がある [5]。固定経路方式は、電磁誘導装置や光学テープが設置された環境内を、環境からの誘導に従って移動する方式である。無人搬送車の導入初期では最も利用実績が多い本方式であるが、移動体は決められた経路上しか移動できない欠点を持つ。半固定経路方式は、移動体にカメラを取り付け、コース上に設置されたマーカなどを検出しながら移動する方式である。固定経路方式に比べ、移動経路を柔軟に変更できる利点から、2020 年現在でも利用が拡大している。無経路方式は、環境に設置された設備からの指示を受けずに移動する方式である。この方式では、移動体は自身に搭載されたセンサにより環境を認識しながら移動しなければならない。2000 年代初頭までに実用化された自律移動体の中では、固定経路方式による活用実績が最も多い。例えば、2005 年に行われた愛・地球博では、トヨタ自動車による自動運転バスが実用化されている [6]。この自動運転バスは、愛・地球博における長久手・瀬戸会場間の移動を目的とし、自動運転用の専用道路では、自律走行し、一般道（会場内管理用道路）では有人によるマニュアル走行を行った。専用道路では、環境中に設置された電磁誘導装置を利用して移動体を目的地まで誘導しており、人の生活環境とは完全に隔離することで安全性が保たれていた。このように、2000 年代までの自律移動体は、自律移動を支援する装置を環境に設置する固定経路方式や半固定経路方式により運用されてきた。

一方、小型・高性能なセンシングデバイスの発展やコンピュータの処理技術の向上に伴い、自律移動体の活用範囲は、人と生活空間を共にする環境や災害現場に拡大している。日本産業車両協会がまとめた無人搬送車システムの導入実績の推移 [7] を図 1.1 に示す。1986 年から 2006 年あたりまでは導入実績が横這いであるのに対し、2010 年以降、導入数が右肩上がりに転じている。2018 年度は納入システム数が 1,029、台数が 3,382 台と過去最高となり、2010 年と比べ、約 3.6 倍と約 3.4 倍となっている。利用が拡大している背景には、Google 社の自動運転車両を皮切りに盛んな研究開発が繰り広げられている自動運転技術やサービス・ロボット分野における自律移動体の導入がある。また、2011 年の福島第一原子力発電所の事故以降、人の作業が困難な災害現場で活躍できる自律移動体の研究・開発の促進がある。このように、自律移動体の活用範囲は、従来の生産現場や倉庫における物品の搬送のみならず、人と生活空間を共にする環境や災害現場に広がっている。




図 1.1. 無人搬送車の納入実績

人の生活空間や災害現場といった環境は、従来、自律移動体が活用されてきた生産現場や専用道路に比べると、以下の二点が大きく異なる。一つ目は、自律移動を支援するための機器を環境に設置することが望ましくない点である。例えば、人の生活空間に支援装置を設置してしまうと、景観を損ねてしまう。また、人や物の移動によって、環境から移動体への指令が阻害され、自律移動に影響を及ぼす危険性がある。災害現場では、一刻も早い課題の解決が求められるため、自律移動を支援する装置を環境に設置する時間的余裕はない。このような環境下で自律移動体を運用するためには、自律移動を支援するための機器を環境に設置しない無経路方式を取らざるを得ない。移動体は自身に搭載されたセンサの観測を頼りに自律移動するこの方式では、非常に高性能な環境のセンシング技術と環境情報の処理能力が求められる。二つ目は、人の動き、物の配置、天候、温度、季節といった非常に多くの環境要因が多種多様に変化する点である。これら環境要因は、時間的・空間的に予測不能なものが多く、自律移動体は、物理世界に存在する非常に多くの不確実性に対処しなければならない。自律移動の破綻は、移動体の周囲に重大な損害を巻き起こす危険性があるため、環境が変わっても安全・確実に動作する自律移動技術が求められる。

人の生活空間や災害現場など、自律移動のために整備されていない環境における自律移動体の活用に向けて、様々な取り組みがなされている。先進的な取り組み例に、

米国国防高等研究計画局 (DARPA) が主催した自動車の無人運転競技がある [8]. DARPA Grand Challenge I, II [9, 10] や DARPA Urban Challenge [11] と呼ばれる本競技では, 砂漠や米軍基地内の自律走行がタスクとして課せられ, 自律移動体の開発が大きく進んだ. 日本でも, 屋外における人の生活空間で活躍できる自律移動体の実現を目指した公開実験であるつくばチャレンジが開催されている [12]. つくばチャレンジに参加する移動体は, つくば市内の遊歩道等の実環境において, 移動体が自身で信号検出や障害物回避を行いながら目的地まで自律的に移動している. これらの取り組みは, 自律移動のために環境が整備されておらず, 時間的・空間的に予測不能な環境要因の変化が激しい環境における運用を前提としている. このような環境で, 安全・確実に動作する自律移動体を開発するには, 環境変化に対するロバスト性が高い自律移動技術が求められる.

1.2 自律移動における位置推定

自律移動のために整備されていない環境下で活動する自律移動体は, 自身に搭載されたセンサの観測を頼りに自律的に移動しなければならない. センサの観測を利用した自律移動における要素技術は, 「環境地図構築」「位置推定」「経路生成」「障害物回避」に分けられる. 中でも, 位置推定技術により算出される移動体の位置情報は, 他の要素技術でも活用される重要な情報である.

例えば, 環境地図構築では, 移動体が活動する環境に関する地図をセンサの観測をもとに構築する. 推定位置を起点として移動体のセンサの観測をマッピングすることで, 環境地図が作られるため, 構築する環境地図の精度は位置推定の精度に大きく依存する. 位置推定誤差によって環境地図に歪みが生じてしまうと, 移動体が目的地まで移動するための経路を生成することができなくなってしまう.

経路生成では, 推定された現在の位置から目的地までの経路を生成する. ダイクストラ法や A*法などが知られており, 走行距離や環境などの条件をコスト関数として表現し, 移動のコストが最小となるような経路を生成する [13]. 推定位置が間違っていると, 目的地に辿り着かないのみではなく, 本来走行すべきでない方向に進行する可能性があり, 重大事故を巻き起こす危険がある.

障害物回避では, 自身に近づく物体を回避する. 自身に衝突する可能性がある物体を検知した場合, 経路生成で算出した経路から少し外れたローカル経路を生成し, 移動する. 推定位置が間違っている場合, 不適切なローカル経路に従って誤った方向に進行してしまい, 事故を起こす危険性がある.

このように自律移動に必要な技術のほとんどは, 推定された位置情報を利用しており, 壊滅的に大きな位置推定誤差は, 自律移動体の制御の破綻を招く. そのため, ロバスト性が高い位置推定技術が重要となる.

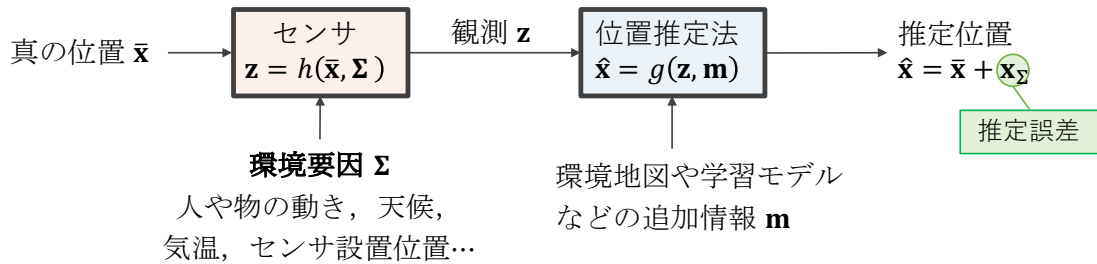


図 1.2. 位置推定の流れ

センサの観測を利用した位置推定の流れを図 1.2 に示す。位置推定では、移動体に搭載されたセンサの観測をもとに、位置推定法を利用して移動体の位置を推定する。

位置推定では、多種・多様なセンサが利用される。衛星からの受信信号をもとに位置を観測する Global Navigation Satellite System (GNSS) は、開けた屋外においてよく利用される。環境に照射したレーザの反射光により周辺環境の点群を観測する Light Detection And Ranging (LiDAR) は、周辺環境の形状を点群として高精度に取得できる点から利用が拡大している。環境中のイメージを観測するカメラは、小型化・低価格化が進んでおり、一つの移動体に複数台設置して利用されることがある。他にも、移動体の運動を計測する Inertial Measurement Unit (IMU, 慣性計測装置) や車輪オドメトリもよく利用される。これらセンサの観測は、移動体が存在する位置によって変わる。他にも、天候、人や物の動き、センサの設置位置、路面状況といった多くの環境要因によって変化する。

位置推定法では、環境地図や学習モデルなどの追加情報を利用してセンサの観測を処理することで、移動体の推定位置を算出する。センサの観測を利用した位置推定法には、マップマッチングやデッドレコニングなどがある。マップマッチングでは、事前に構築した地図と自律走行時のセンサの観測を対応づけて移動体の位置を推定する。デッドレコニングでは、IMU や車輪オドメトリなどの運動を計測するセンサの値を利用して初期位値からの相対位置を推定する。

位置推定法から算出される推定位置は、真の位置と環境要因による位置推定誤差を足し合わせた値となる。観測の特性に合わせた多くの位置推定法が提案されており、同一のセンサを利用しても、位置推定法によって環境要因が推定位置誤差に及ぼす大きさは異なる。センサの観測に含まれる環境要因を適切にモデル化できているほど、環境要因による位置推定誤差が小さく、真の位置に近い推定位置を算出することができる。

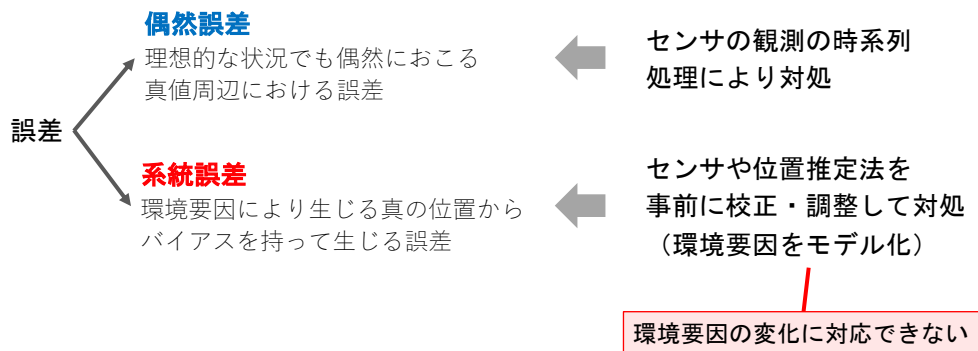


図 1.3. 位置推定における誤差の分類と対策

1.3 位置推定誤差の分類

センサの観測により算出される推定位置には、常に誤差が含まれる。そのため、誤差への対処が重要になる。

位置推定における誤差の分類と対策方法を図 1.3 に示す。計測工学では、物体計測において生じる誤差を、「偶然誤差」と「系統誤差」に分類している² [14, 15]。偶然誤差は、理想的な位置推定環境でも偶然に起こりうる誤差である。これは移動体の真値付近に生じる誤差であり、センサの観測の時系列処理により対処できる。例えば、時系列処理の代表であるベイズフィルタでは、観測の誤差や位置推定誤差を確率分布で表現することで、偶然誤差が位置推定に及ぼす影響を低減している。系統誤差は、センサの設置位置ずれやセンサの特性により生じる一定方向のバイアス誤差である。センサ・車輪などの位置・寸法誤差の他に、磁気、温度、気圧などの環境要因による誤差がある。通常、移動体を利用する環境下でセンサの観測を事前に取得し、それをもとにセンサの校正や位置推定法の調整といった「環境要因のモデル化」を行うことで、系統誤差に対処する。

偶然誤差に対しては、時系列処理で対処可能である一方、系統誤差に対しては、環境要因のモデル化をする必要がある。しかし、自律移動のために整備されていない環境では、時間的・空間的に予測不能な環境変化が生じる。そのため、事前に環境要因をモデル化することが難しい。

例えば、GNSSを利用した位置推定における系統誤差には、電離層・大気圏による信号遅延や、ビルでの反射波を直接波と誤って処理するマルチパスがある [16]。時々刻々と変化する電離層・大気圏の変化やマルチパスを、全て事前にモデル化した位置推定法を構築することは難しく、推定誤差は数 m～数十 m に及ぶ。また、マップ

²計測工学では、計測器のデータの読み間違いや記録したデータの記入ミスなど、人手によるミスとして定義される「まちがいの誤差」もあるが、自律移動体の位置推定では起こり得ないため除外する。

マッチングにおけるデータの誤対応による誤差も重大な課題である。2019年、名古屋大学は、LiDARを利用したマップマッチングによる位置推定において、データの誤対応による位置推定誤差を原因とする自動運転車の事故を引き起こした [17]。本事故の調査チームのレポートによると、事前に構築した環境地図と自律走行時のセンサの観測の対応づけにおいて、観測した点群が車両の真の進行方向から56度離れた環境地図内のデータに誤って対応づけされたために起きたとしている。誤対応が起きた原因として、計算機の遅延による初期推定値の誤差増大、センサ情報受信処理の遅延による形状計測の誤り、前時刻に生じた誤差の伝搬などが複合的に生じたとしているが、本レポートにおける事後解析からは誤対応のプロセスを完全に解明しモデル化するに至っていない。対策として、車輪オドメトリなど他のセンサにより誤差を補正する方法が考えられるが、それすらも、他の環境要因の複雑な複合により動作しない可能性がある。

自律移動のために整備されていない環境は、時間的・空間的に変化する環境要因が非常に膨大である。そのため、環境要因を事前にモデル化することは難しく、系統誤差を抑制できないことがある。モデル化されていない環境要因の変化により壊滅的な推定誤差が生じた場合、自律移動系全体の動作が破綻し、重大事故につながる危険性がある。

1.4 本研究の目的とアプローチ

自律移動体の活用範囲は、自律移動のために整備されていない環境に拡大している。安全・確実に動作する自律移動体を実現するには、位置推定のロバスト性向上が求められる。位置推定における誤差は、「偶然誤差」と「系統誤差」に分類される。一般的な位置推定系の開発では、センサの観測の時系列処理により偶然誤差に対処し、環境要因のモデル化により系統誤差に対処してきた。しかし、移動体が活動する実環境は、非常に多くの環境要因が予測不能に変化してしまうため、モデル化されていない環境要因の変化により壊滅的な位置推定誤差が生じてしまう場合がある。モデル化されていない環境要因の変化により壊滅的な推定誤差が生じた場合、自律移動系全体の動作が破綻し、重大事故につながる危険性がある。位置推定の破綻を防ぐためには、環境要因のモデル化に加え、それとは異なるアプローチにより系統誤差に対処する必要がある。

本研究では、環境要因のモデル化に加え、「センサと位置推定法の多重化により得る複数の位置情報を外れ値処理を施して融合する」ことで系統誤差に対処し、位置推定のロバスト性向上を目指す。移動体に搭載されるセンサの数は、センサの小型化や多様化を背景に増加傾向にあり、これらセンサを利用した位置推定法も多種多様な手法が提案されている。2019年のIEEE/RSJ International Conference on Intelligent

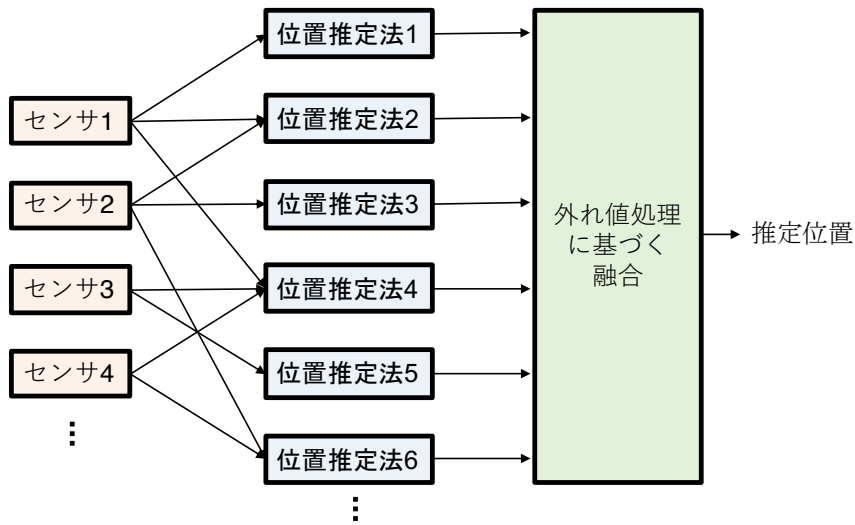


図 1.4. センサおよび位置推定手法の多重化のイメージ

Robots and Systems (IROS2019) では、全 1127 件のオーラル発表のうち、106 件とほぼ 1 割の発表が自己位置推定および SLAM にかかわる発表であった [18]. それら位置推定法は、オープンソース化が進んでおり、Robot Operating System (ROS) などの共通プラットフォームで容易に利用することができる。各位置推定法は、それぞれ異なった観点からセンサの観測を処理していることから、環境要因による推定誤差の大きさや壊滅的な誤差が生じる頻度は、センサや位置推定法によって異なると思われる。このことから、本研究では、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定をおく。この仮定のもとでは、壊滅的な推定誤差を含む位置情報は、他の推定位置に対して著しく離れた外れ値になることが想定される。壊滅的な系統誤差を含んだ位置情報を外れ値処理により検出・排除、残りの位置情報を融合する手法を提案する (図 1.4)。これにより、モデル化されていない環境要因の変化により壊滅的な系統誤差が生じた場合でも、提案する外れ値処理で対処することで、ロバスト性が高い位置推定を行えるシステムの実現を目指す。

本論文では、上記仮定のもと、「系統誤差」と「偶然誤差」に対処できる位置推定法の提案を目指し、1. 「系統誤差」に対する外れ値処理の有効性の検証、2. 「系統誤差」と「偶然誤差」への対処を目指した、外れ値処理法を利用したベイズフィルタによる位置推定法の提案に取り組む。さらに、3. 位置推定のロバスト性向上を目指した 2. の応用として、位置推定法の信頼性マップ構築法の提案を行う。以下詳細を述べる。

1. モデル化されていない環境要因の変化により生じる「系統誤差」に対する外れ値処理の有効性の検証

複数の位置推定法から得る位置情報を外れ値処理により融合することの有効性を検証する。位置を融合する方法には、平均やメディアンがある。平均は、全ての位置を均等に融合した位置となるが、融合する位置情報の中に一つでも壊滅的な推定誤差を含む位置が含まれると、平均の位置に大きな影響を及ぼすことが懸念される。一方、メディアンは、他の位置との距離の和を最小にする位置として定義される。これは、他の位置に対して著しく離れた外れ値の影響を受けにくいとされる。モデル化されていない環境要因の変化により系統誤差が生じてしまった場合において、外れ値の影響を受けにくいメディアンにより位置を融合することで、位置推定のロバスト性が向上するかどうかを検証する。

2. 「系統誤差」と「偶然誤差」への対処を目指した外れ値処理法を利用したベイズフィルタによる位置推定法の提案

ベイズフィルタに代表される確率的位置推定法は、「偶然誤差」に対処できることから、位置推定の分野で広く活用されている。確率的位置推定法では、各位置推定法から得る位置情報を位置の存在確率分布として算出することで、位置の不確実性を表現する。各位置推定法から確率分布を積により融合することで、位置の不確実性を考慮して融合できる。しかし、積により融合される分布の中に、真の位置における存在確率が著しく低い分布（バイアス分布）が含まれると、位置推定が破綻する例が報告されている [19]。バイアス分布は、モデル化されていない環境要因の変化により生じる「系統誤差」が反映された分布であり、確率的位置推定法では対処できない。そこで、確率的位置情報において、存在確率分布の相対比較により外れ値を排除し、融合することで、系統誤差に対処可能な手法を提案する。これにより、「系統誤差」と「偶然誤差」へ対処できる、外れ値処理法を利用したベイズフィルタによる位置推定法の実現を目指す。

3. 位置推定法の信頼性マップ構築に向けた相対評価法の応用

相対比較による外れ値処理法の応用として、位置推定法の信頼性マップ構築法について述べる。位置推定法の信頼性マップは、相対比較の結果を可視化することで、位置推定法の信頼性が低い領域を位置推定法ごとに教示するものである。複数の位置推定法で信頼性が低いと判定された領域は、「同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定を満たさず、外れ値処理に基づく融合システムにおいて誤差を含む位置情報を適切に排除できない可能性が高い領域である。複数の位置推定法の信頼性が低い領域を信頼性マップから読み取り、その領域で機能する位置推定法を移動体に増

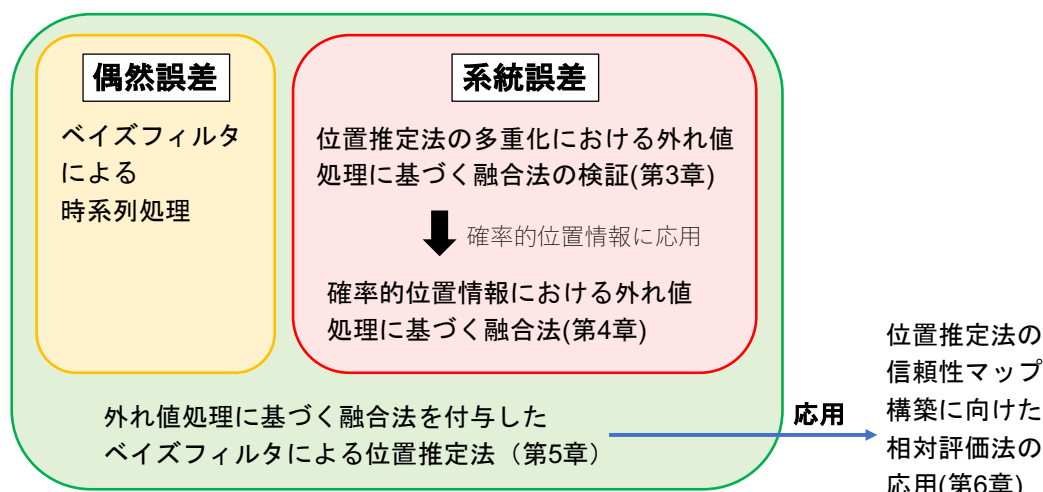


図 1.5. 本論文の構成

設するか、環境に位置推定を補助するセンサを設置することで、その領域における位置推定の信頼性を向上させることができる。そこで、位置推定法の信頼性マップの構築法と、これを活用して位置推定のロバスト性を向上させる方法について言及する。

1.5 本論文の構成

以下に本論文の構成を記す (図 1.5)。

第 2 章では、移動体の位置推定のロバスト性向上に向けた既存の取り組みを紹介する。まず、位置推定に利用されるセンサと位置推定法について紹介し、推定誤差が生じる要因について述べる。推定誤差を軽減させる取り組みとして、センサの観測の時系列処理とセンサの多重化による取り組みを紹介し、それぞれの利点と限界について言及する。

第 3 章では、「系統誤差」の減少を目的として、センサと位置推定系の多重化により得る複数の位置情報の外れ値処理に基づく融合法について検討する。検証では、カメラと LiDAR から得る観測データから、LiDAR による位置推定法、カメラによる位置推定法、LiDAR とカメラによる位置推定法を通して複数の推定位置を算出する。モデル化されていない環境要因の変化による系統誤差が生じてしまった場合において、外れ値の影響を受けにくいメディアンにより推定位置を融合することで、位置推定のロバスト性が向上するかどうかを検証する。

第 4 章と第 5 章では、「系統誤差」と「偶然誤差」への対処を目指した、外れ値処

理法を利用したベイズフィルタによる位置推定法を提案する。第4章では、確率的
位置情報における外れ値処理法を提案する。第5章では、第4章で提案する「系統
誤差」に対処できる外れ値処理法を、「偶然誤差」を減少させるパーティクルフィル
タによる時系列処理に適用した位置推定法を提案する。

第6章では、確率的な位置情報における外れ値処理法の応用として、位置推定法の
信頼性を領域ごとに可視化し、位置推定が破綻する可能性がある領域を教示する方
法を提案する。

第7章では、実世界データ循環の枠組みにより、本論文で目指す位置推定のロバ
スト化を実現する方法について述べる。

第8章は、結言である。

第2章

自律移動体における位置推定に関する 既存研究

本章では，自律移動体における位置推定に関する既存研究についてまとめる．2.1節では，位置推定に利用されるセンサと位置推定法を紹介したのち，環境要因により生じる推定誤差について言及する．2.2節において，偶然誤差に対する対策として時系列処理の事例を，系統誤差に対する対策として複数のセンサを活用することによる位置推定のロバスト化の事例を述べる．

2.1 位置推定に利用されるセンサと位置推定法

2.1.1 GNSS

複数の人工衛星から発信された信号を受信器で受けて自身の位置を推定する Global Navigation Satellite System (GNSS) は，屋外を移動する移動体でよく利用されるセンサである [20, 21]．4個以上の衛星から信号を受信，信号が衛星から発信された時刻と受信器が受け取った時刻の時間差から各衛星までの擬似距離を算出，移動体の三次元位置と受信器・衛星間のクロックバイアスを変数とする最適化問題を解き，移動体の位置を推定する．アメリカの衛星を利用した位置推定システムである GPS の他にも，ロシアの GLONASS，中国の Beidou，欧州連合の Galileo，日本の準天頂衛星などさまざまな衛星測位システムがある．自動車のナビゲーションやスマートフォンなど幅広い分野で利活用が広がっている．

GNSS の誤差は，偶然誤差と系統誤差がそれぞれ存在する．GNSS の偶然誤差は，観測衛星数の不足や観測衛星の偏りにより生じる誤差である．GNSS は，観測した衛星信号から構成される連立方程式によって，四つの未知変数を解く．最低限四つの衛星を観測すれば方程式の解より位置を推定できるが，受信した衛星信号が偏っていた場合，パラメータが類似した連立方程式が複数存在してしまい，解を一意に定

められなくなる。結果、真値周辺でランダム的な誤差が生じてしまう。この誤差への対処として、観測衛星数や衛星配置から算出される Duplication of Precision (DOP) を利用する方法がある。また、日本の衛星測位システムである準天頂衛星システム (みちびき) の運用開始に伴い、日本上空で観測可能な衛星数は増加し、偶然誤差の減少が期待できる [22]。GNSS の系統誤差に、電離層・大気圏で生じる信号遅延により、真の位置からバイアス的に生じる誤差がある。電離層・大気圏は、空間的には大きく変化しないものの、時間的に変化するため、事前の環境走行におけるセンサの校正や補正は意味をなさない。対策として、すでに座標がわかっている基準局で GNSS を利用した位置推定を行うことで、その時刻における大気圏・電離層遅延による誤差を見積もり、補正信号を発信する Differential GPS (D-GPS) [23] がある。これは、海上保安庁が日本近海における GNSS の精度向上を目指し 1997 年より運用してきたシステムである。2020 年現在では、D-GPS の代替をみちびきが担っており、一般的な GNSS 受信器で受信可能な L1 信号にて、大気圏・電離層による信号遅延の補正信号を送っている [24]。サブメータ級測位補強サービスと呼ばれる本サービスであるが、後に述べるマルチパスによる誤差を低減することはできない。最後に、GNSS の系統誤差にマルチパスによる誤差がある。これは、GNSS における位置推定において、ビルによる反射波を衛星からの直接波として誤って処理するために生じる誤差である。マルチパスの発生は、周辺環境、衛星配置、大気圏・電離層の遅延等により複雑に変化するため、事前のモデル化が非常に困難となる。数十 m 以上の壊滅的な推定誤差を生じる場合もあり、自律移動の破綻を招いてしまう。衛星信号受信器と基地局間の相対距離を信号の波数差により推定する RTK-GPS [25] や、同じ原理をみちびきにて実現するセンチメータ級補強サービス [26] により誤差数 cm の測位が可能となる。しかし、波数差を決定する初期化に時間がかかり、信号受信が頻繁に途絶える都市部などでの利用は現実的ではない。GNSS を利用した測位は、非常に多くの環境要因により、偶然誤差、系統誤差が複合的に生じるため、GNSS 単体によるロバスト化は難しい。

2.1.2 カメラ

カメラは、車両の外界を輝度情報として認識するセンサとして、物体認識、障害物回避など幅広い分野で活用される。全方位カメラや距離画像センサ、ステレオカメラがある。比較的安価なため、一つの移動体に複数台搭載されることもある。

カメラを利用した位置推定には、環境に関する画像のデータベースを利用する方法と地図なしで行う Visual Odometry がある。前者は、事前計測した画像をデータベースに保存し、位置推定では、カメラから得る観測画像とデータベース上の参照画像を照合して位置を推定する。飯村らは、環境中の数箇所参照画像を撮影、参

照画像中の特徴量をベクトルに圧縮して Bag of Feature(BoF) を作成し、観測画像内の特徴量のベクトルの方向を頼りに、多数の参照画像から類似する画像を探索する手法を提案した [27]. 内山は、市街地の街並みから人や物の移動などを排除した参照画像によるデータベースを構築し利用することで、高精度な位置推定を行う手法を提案している [28]. 後者は、観測画像内の特徴量を三次元空間にマッピングしながら位置を推定する方法であり、Visual SLAM と呼ばれることもある。Taguchi らは、距離画像センサを利用する手法を開発した。カラー画像内から Speeded-Up Robust Features (SURF) 特徴量を、距離画像内から平面領域を抽出し、抽出した SURF 特徴点と平面領域を利用して位置を推定する手法を開発した [29]. Mur-Arta らは、画像から回転やスケールに不変なエッジ特徴である Oriented FAST and Rotated BRIEF (ORB) 特徴量を利用し、バンドル調整、ポーズ調整等を駆使したロバストな Visual Odometry を開発した [30,31]. さらに、Elvira らは、ORB SLAM において、環境に特徴が少なく位置推定が失敗した場合、新しいマップを新たに構築し直し、古いマップと新しいマップの類似点を結合することで環境に特徴が少ない場合にもロバストに機能する SLAM を提案している [32]. Wang らは、ステレオビジョンにおける特徴点の三次元復元において、カメラから遠い特徴点ほど復元精度が低下してしまう問題に対して、複数の視点から得る画像を組み合わせる手法を提案している [33]. 他にも、OpenVSLAM [34], LSD-SLAM [35], Cube SLAM [36], D3VO [37] など非常に多くの手法が提案されており、それぞれ独自のアイデアにより画像を解析することで位置を推定している。

カメラを利用した位置推定では、系統誤差が課題となる。カメラによる系統誤差に、画像の白飛びや夜間画像における特徴量の抽出不足がある。位置推定に十分な数の特徴点を取得できない期間が続くと、位置推定は次第に破綻してしまう。対策として、特徴点の抽出数によって位置推定に利用するセンサを切り替えるなどが挙げられる。他にも、観測した特徴点と環境地図との対応づけの誤りで生じる誤差がある。データの誤対応に対して、事前に環境を走行しセンサの観測に合わせて位置推定法のパラメータを調整することで対処する。しかし、時間的・空間的に予測不能な環境変化が生じる実環境において、事前走行時の観測データにパラメータが最適化された位置推定法が自律走行時も完璧に機能するとは限らない。RANSAC [38], M 推定 [39] などの手法を併用することにより、誤対応を低減することができる。

2.1.3 LiDAR

周辺環境に複数のレーザを照射し、物体に反射したレーザを受信するまでの時間 (Time of Flight) を計測することで、センサから反射物までの距離を取得する Light Detection And Ranging (LiDAR) は、周辺環境の高精度な点群を観測できる。高

精度な3D LiDARの出現により、処理できる環境情報が多くなり、利用が拡大している。

LiDARを利用した位置推定には、事前にLiDARで作成された環境に関する地図を利用する方法と、位置推定と環境地図構築を同時に行うLiDAR SLAMがある。前者の位置推定法では、LiDARを搭載した移動体で環境を事前に計測し、高精度な位置推定ができるように地図を加工して利用する。Kimらは、事前作成された環境地図に対してガラス領域を割り当て、ガラス領域とそれ以外の領域でレーザモデルを使い分けることにより、ガラスによるレーザの反射が不確定な環境における位置推定のロバスト性向上を目指した手法を提案した[40]。山田らは、環境地図中の点群を正規分布によりモデル化し、パーティクルフィルタにおける統計的観測モデルとして利用する手法を提案した[41]。自動車の位置推定では、道路上の構造物を利用したものが多く提案されている[42,43]。白線や道路標識といった構造物は、夜間の視認性を高めるために再起性反射材を利用したものが多く、他の物体よりも反射強度が強い点群を取得できる。観測した点群の中から反射強度が他よりも強い物体を検出、道路上の構造物が登録された環境地図との対応づけを行うことで位置を推定する。後者は、LiDARの点群をマッピングしながら位置を推定するSLAM型である。Deschaudは、LiDARが観測する膨大な数の点群から位置推定に有用な点（移動体から遠隔にある、移動体の進行方向を厳密に同定できる点）のみを抽出しマップマッチングを行うことで、計算コストが小さく精度の良いSLAMを目指した手法を提案している[44]。Sunらは、LiDARが観測する点群を水平面上のグリッドで分割、各グリッド内の点群の高さ方向を平均で圧縮した2.5次元地図を構築することで、三次元地図を直接構築するよりも計算負荷が軽い手法を提案した[45]。Chenらは、LiDAR点群中の物体を車、道路などのラベルでセグメンテーションする学習モデルを事前に構築し、セグメンテーションされた点群を利用してSLAMを行う手法を提案している[46]。Khanらは、事前にモデル化したレーザの反射強度を直接SLAMに利用する手法を検討している[47]。他にも、NDT Mapping[48]、Lego-LOAM[49]、DH3D[50]など非常に多くの手法が提案されており、それぞれ独自のアイデアにより点群を解析し位置を推定している。

カメラと同様に、LiDARによる位置推定でも系統誤差がある。系統誤差として、霧・雨などにより周辺環境の点群を適切に取得できない場合がある[51,52]。天候の影響でLiDARの点群に雑音が含まれることにより、点群と環境地図との誤対応による壊滅的な位置推定誤差を招く恐れがある。また、文献[17]の事例でも示した通り、LiDARにとって理想的な観測環境であっても、計算機の遅延による初期推定値の誤差増大、センサ情報受信処理の遅延による形状計測の誤り、前時刻に生じた誤差の伝搬などが複合的に生じることによる誤対応により、系統誤差が生じる可能性がある。

2.1.4 車輪オドメトリ・IMU

車輪の回転数から移動体の速度と角速度を推定する車輪エンコーダや、加速度計測器とジャイロから加速度と角速度を計測する Inertial Measurement Unit (IMU) がある。また、IMU と地磁気センサを組み合わせた Attitude Heading Reference System (AHRS) も位置推定に利用される。これらセンサは、移動体の運動を計測するセンサ群であり、速度や加速度・角速度を積分するなどして移動体の移動量を推定する。運動を計測するセンサのみで位置を推定する方法は、慣性航法もしくはデッドレコニングとして認知されている。これらセンサは内界センサと呼ばれることもあり、環境を観測する外界センサと区別して扱われる。

内界センサで生じる推定誤差は、積分の過程で次第に蓄積するため、事前の校正や補正がより重要となる。車輪オドメトリには、路面の形状や素材により生じる系統誤差がある。山田は、移動体が走行する環境を事前に走行しレーザを利用してオドメトリの系統誤差を推定、環境地図中に系統誤差量を登録したオドメトリ誤差地図を活用することで系統誤差を低減する方法を提案した [53]。しかし、車輪オドメトリや IMU の校正では、偶然誤差を低減することはできず、誤差の蓄積により非常に大きな推定誤差が生じる。一般的に、内界センサは、のちに述べる時系列処理において外界センサと併用されることが多い。

2.2 位置推定誤差の低減法

推定位置には、常に誤差が含まれる。壊滅的な推定誤差は自律移動系全体の破綻を招く恐れがあるため、適切に対処しなければならない。先に紹介した通り、位置推定誤差は、偶然誤差、系統誤差に分類される。偶然誤差は、時系列処理による確率的な手法によって低減できる。その他、環境要因による系統誤差への対処として複数のセンサを利用する方法がある。

2.2.1 時系列処理

真の位置周辺でランダムに生じる偶然誤差を低減する方法に、センサの観測の時間的な繋がりから処理する方法がある。時系列を考慮した位置推定法で利用されるモデルを図 2.1 に示す。ここで、 $\mathbf{x}_t, \mathbf{u}_t, \mathbf{z}_t$ は、それぞれ時刻 t における移動体の位置、移動体への制御指令、センサの観測を表し、 \mathbf{m} は、環境に関する地図を表す。位置推定では、制御 \mathbf{u}_t 、観測 \mathbf{z}_t 、地図 \mathbf{m} の値は既知として、移動体の位置の変数 \mathbf{x}_t を算出する (SLAM では、位置 \mathbf{x}_t と地図 \mathbf{m} を変数として扱う)。時系列を考慮した位置推定では、移動体の位置を遷移関数と観測関数を利用して推定する。遷移関数

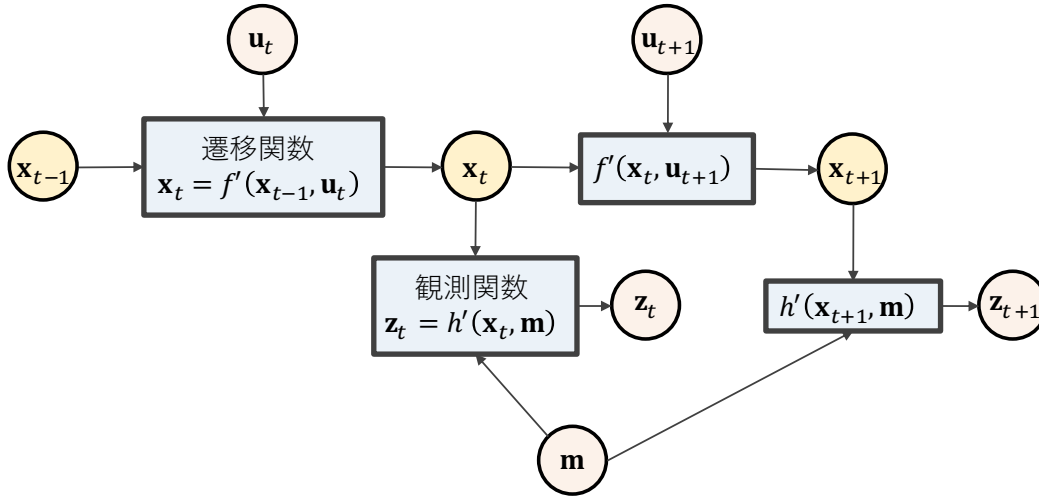


図 2.1. 位置推定のモデル

では、時刻 $t - 1$ における移動体の位置 x_{t-1} から制御 u_t を通して時刻 t における移動体の位置 x_t を予測する。移動体の位置推定では、制御 u_t として車輪オドメトリや IMU など内界センサを利用することが多い [54]。観測関数では、地図 m 中において、時刻 t における移動体の位置 x_t からセンサの観測 z_t をモデル化している。これらを利用して位置 x_t に関する問題を解く方法には、フィルタアプローチと最適化アプローチがある。

2.2.1.1 フィルタアプローチ

真の位置付近でランダムに生じる偶然誤差を過去のデータ系列によって軽減することを目指した方法にベイズフィルタがある [55]。ベイズフィルタでは、移動体の位置がセンサの観測に基づく条件付き確率によって、存在確率分布として表現される。存在確率分布は、実際の状態に関して、あり得る全ての仮説に対して確率を割り付ける。これは、得られた全てのデータで条件づけられた事後確率分布であり、状態変数で構成される空間上で $p(x_t | z_{1:t}, u_{1:t})$ と表現される。ベイズフィルタでは、以下の式により、存在確率分布 $p(x_t | z_{1:t}, u_{1:t})$ が再帰的に計算される。

遷移

$$p(x_t | z_{1:t-1}, u_{1:t}) = \int p(x_t | x_{t-1}, u_t) p(x_{t-1} | z_{1:t-1}, u_{1:t-1}) dx_{t-1} \quad (2.1)$$

観測

$$p(\mathbf{x}_t | \mathbf{z}_{1:t}, \mathbf{u}_{1:t}) = \eta \cdot p(\mathbf{z}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{z}_{1:t-1}, \mathbf{u}_{1:t}) \quad (2.2)$$

ここで、 $p(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{u}_t)$ は、制御 \mathbf{u}_t と位置 \mathbf{x}_{t-1} から位置 \mathbf{x}_t を得る遷移確率を、 $p(\mathbf{z}_t | \mathbf{x}_t)$ は、位置 \mathbf{x}_t で観測 \mathbf{z}_t を得る観測確率を表し、 η は確率分布とするための正規化係数である。遷移では、時刻 $t-1$ における存在確率分布 $p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}, \mathbf{u}_{1:t-1})$ と遷移確率 $p(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{u}_t)$ を利用して、時刻 t で予測される事前確率分布が計算される。観測では、事前確率分布と観測確率を利用して、時刻 t における存在確率分布 $p(\mathbf{x}_t | \mathbf{z}_{1:t}, \mathbf{u}_{1:t})$ を算出する。

ベイズフィルタは連続空間で表現されており、そのままでは実装することができない。現実の問題を解く手法の一つにカルマンフィルタがある。カルマンフィルタは、二つの仮定を設けて、推定対象の状態を推定する。一つ目は、位置の存在確率分布 $p(\mathbf{x}_t | \mathbf{z}_{1:t}, \mathbf{u}_{1:t})$ が平均 $\hat{\mathbf{x}}_{t|t}$ 、共分散行列 $\mathbf{P}_{t|t}$ の正規分布に従うという仮定である。二つ目は、遷移と観測のそれぞれの式が線形であるという仮定である。これら仮定により、式 (2.1),(2.2) は、次式に変換される。

遷移

$$\hat{\mathbf{x}}_{t|t-1} = \mathbf{F}_t \hat{\mathbf{x}}_{t-1|t-1} + \mathbf{u}_t \quad (2.3)$$

$$\mathbf{P}_{t|t-1} = \mathbf{F}_t \mathbf{P}_{t-1|t-1} \mathbf{F}_t^T + \mathbf{R}_t \quad (2.4)$$

観測

$$\mathbf{K}g_t = \mathbf{P}_{t|t-1} \mathbf{H}_t^T (\mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T + \mathbf{Q}_t)^{-1} \quad (2.5)$$

$$\hat{\mathbf{x}}_{t|t} = \hat{\mathbf{x}}_{t|t-1} + \mathbf{K}g_t (\mathbf{z}_t - \mathbf{H}_t \hat{\mathbf{x}}_{t|t-1}) \quad (2.6)$$

$$\mathbf{P}_{t|t} = (\mathbf{I} - \mathbf{K}g_t \mathbf{H}_t) \mathbf{P}_{t|t-1} \quad (2.7)$$

ここで、 $\mathbf{K}g_t, \mathbf{F}_t, \mathbf{H}_t, \mathbf{Q}_t, \mathbf{R}_t, \mathbf{I}_t$ は、それぞれ、時刻 t におけるカルマンゲイン、遷移行列、観測行列、遷移に関する共分散行列、観測に関する共分散行列、単位行列である。存在確率分布の平均 $\hat{\mathbf{x}}_{t|t}$ が、時刻 t における推定位置として算出される。

位置推定では、カルマンフィルタを非線形化した拡張カルマンフィルタやアンセンテッドカルマンフィルタがよく利用される。また、ベイズフィルタを離散近似したヒストグラムフィルタやパーティクルフィルタもある。

2.2.1.2 最適化アプローチ

最適化アプローチは、位置 \mathbf{x}_t 、制御 \mathbf{u}_t 、観測 \mathbf{z}_t 、地図 \mathbf{m} に関する連立方程式を最小二乗問題として解く方法である [15]。最適化アプローチの一つであるグラフベース SLAM で利用される評価関数を次式に記す。

$$J = \sum_t (\mathbf{x}_t - f'(\mathbf{x}_{t-1}, \mathbf{u}_t))^T \Sigma_{f'} (\mathbf{x}_t - f'(\mathbf{x}_{t-1}, \mathbf{u}_t)) + \sum_t (\mathbf{z}_t - h'(\mathbf{x}_t, \mathbf{m}))^T \Sigma_{h'} (\mathbf{z}_t - h'(\mathbf{x}_t, \mathbf{m})) \quad (2.8)$$

右辺第一項は、遷移モデルによる移動体の位置の評価関数、右辺第二項は、観測関数による移動体の位置の評価関数を表し、 $\Sigma_{f'}$ 、 $\Sigma_{h'}$ は、それぞれの重みを表す。自己位置推定問題では位置 \mathbf{x} のみを変数として、SLAM 問題では位置 \mathbf{x} と地図 \mathbf{m} を変数として、評価関数 J が最も小さくなる値を求める。この関数を解くのに、ガウス・ニュートン法や、最急降下法などが利用される。大規模な環境地図構築の問題を効率よく解けることから、SLAM における利用が拡大している。

2.2.2 複数センサの活用

観測を時系列処理することで、真値付近にランダムに発生する偶然誤差の低減が期待される。しかし、環境要因により連続・バイアス的に生じる系統誤差に対処するには、観測関数の中で系統誤差を引き起こす環境要因を適切にモデル化しなければならない。本章では、複数のセンサを活用することにより、環境要因による系統誤差を低減する既存研究についてまとめる。「複数のセンサを利用してあるタスクを達成すること」は、センサフュージョンと呼ばれ、センサの利用方法によって、いくつかの種類に分類される。分類の詳細は分野や研究対象によって多少異なる [56–58]。本論文では、位置推定における複数のセンサを活用方法を、「センサの切り替え」、「センサの観測を統合」、「センサから得る位置情報を融合」にわけ、それぞれ、「利用するセンサを切り替えて位置を推定すること」、「センサの観測の特性に合わせた統合系を構築し位置を推定すること」、「センサの観測を位置情報に変換して統一的な枠組みで融合し位置を推定すること」と分類した。以下に、各活用方法の概要と誤差に対するロバスト性について述べる。

2.2.2.1 センサの切り替え

センサの切り替えは、環境要因が位置推定誤差に与える影響が少ないセンサに切り替える方法である (図 2.2)。切り替えの法則として、移動体が活動する領域ごと

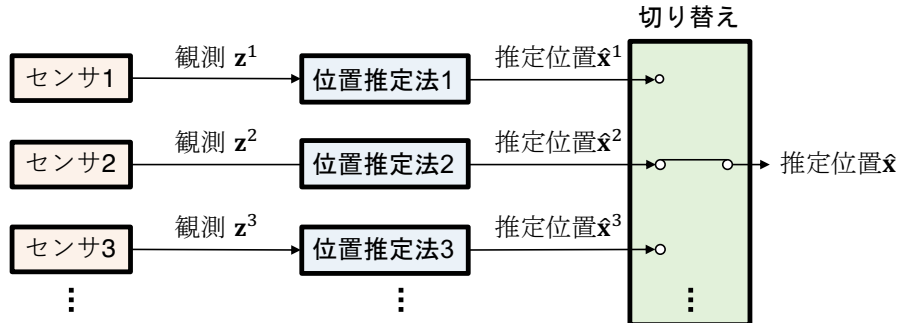


図 2.2. センサの切り替えのイメージ

に利用するセンサを事前に割り当てる方法や、センサから何かしらのセンシングの信頼性を評価する指標を算出して切り替える方法がある。例えば、つくばチャレンジ 2016 に参加した芝浦工業大学の自律移動ロボットの例では、周辺に物体が多い環境では LiDAR により位置を推定し、開けた環境下では GNSS を利用して位置推定している [59]。また、篠原らは、磁気センサと LiDAR を複合した位置推定において、LiDAR で物理的なランドマークが得られない場合に地磁気に切り替える手法を提案している [60]。自動車では、GNSS 信号を良好に受信できる環境では GNSS を利用して位置を推定し、トンネル内など GNSS 信号を受信できない環境では、IMU や車輪オドメトリを利用した慣性航法で移動軌跡を推定する [61]。この方法では、環境ごとに精度が高いと思われるセンサを利用して位置推定できる。

しかし、GNSS を利用した位置推定は、衛星信号を多く受信できたとしても、大気圏・電離層遅延やマルチパスによる系統誤差の影響で壊滅的な推定誤差が生じる場合がある。また、LiDAR を利用した位置推定についても、観測と参照地図との対応づけ誤りにより誤った位置を算出する可能性がある。センサの切り替えでは、切り替えられたセンサによる位置推定が確実に機能しなければならないが、時間的・空間的に予測不能に変化する実環境において、切り替えの法則を適切にモデル化することは容易ではない。

2.2.2.2 センサの観測を統合

各センサの特性に応じてセンサの観測を統合するシステム (図 2.3) がある。センサの観測ごとに特定の統合系を構築する方法では、それぞれのセンサの特性を活かした位置推定系を組み合わせることで、高精度な位置情報の算出が期待できる。GNSS, LiDAR, カメラ, IMU, 車輪オドメトリのそれぞれの利点を生かした統合法の例を紹介する。Takeyama らは、GNSS 信号のドップラー効果を利用した最小二乗問題における進行方向推定に、IMU と車輪エンコーダによる制約を加えることで、時間

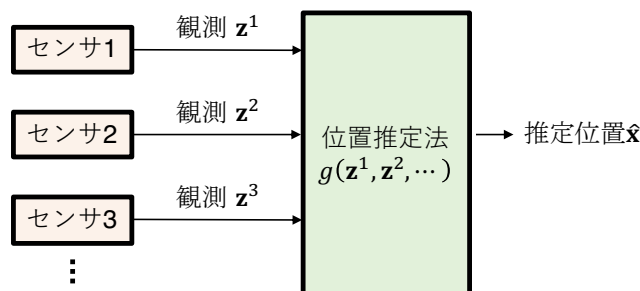


図 2.3. センサの観測を統合のイメージ

を考慮した最小二乗問題をとき、解を求めるのに利用できる衛星数を増やす手法を提案している [62]. 小島らは、拡張カルマンフィルタの観測関数を、GNSS の絶対位置推定とレーザのランドマーク計測に基づいて行う方法を開発し、GNSS で地球座標系における位置推定を行いながらレーザで詳細な位置補正を行う手法を提案している [63]. GNSS と他のセンサを統合した例として、GNSS, 車輪オドメトリ, カメラを統合した Tao らの手法 [64], GNSS, LiDAR, IMU を統合した Wan らの手法 [65] がある. LiDAR とカメラを統合した手法も多く提案されている. Zhang らは、観測周期が遅いが精度が良い LiDAR による SLAM と観測周期が早い精度が劣るカメラによる SLAM を組み合わせた手法を提案している [66]. 60Hz で取得したカメラ画像を利用した Visual SLAM で大まかな位置を推定し、1Hz で取得した LiDAR の点群を利用して詳細な位置補正を行なっている. また、Graeter らは、カメラと LiDAR の計測周期を同期させ、LiDAR の点群をカメラ画像に投影することで、LiDAR 点群の高精度 3次元情報とカメラの強力な特徴点マッチングを統合する手法を提案した [67]. Zhang らの手法と Graeter らの手法は、どちらもカメラと LiDAR を利用した SLAM でありながらも着眼点や利用方法が異なっており、同じ環境要因の変化でも誤差の現れ方が異なる可能性がある. 他にも、ViLiVO [68] や、カメラ, LiDAR, IMU を統合した SLAM [69, 70], LiDAR とカメラで共通の環境地図をもちランドマークを統合した観測関数を設計する手法 [71] が提案されている. 各センサの観測の特性に合わせた統合手法が数多く提案される.

これらセンサの観測の特性に合わせた統合系を構築し位置を推定する手法では、事前に環境を走行し、観測したデータに基づいて位置推定のパラメータを調整し環境要因のモデル化を行う. しかし、時間的・空間的に予測不能な実環境において、統合系で十分にモデル化されていない環境要因の変化が生じた場合、壊滅的な推定誤差が生じる可能性がある. 壊滅的な推定誤差が生じた場合に備え、環境要因のモデル化に加え、それとは異なるアプローチによる系統誤差への対処法が求められる.

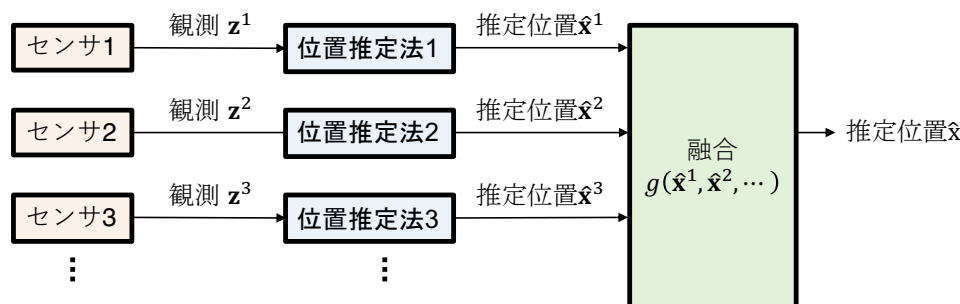


図 2.4. センサから得る位置情報の融合のイメージ

2.2.2.3 センサから得る位置情報の融合

センサから得る位置情報の融合では、各センサの観測から位置推定法を利用して算出した位置情報に対する融合系を構築する（図 2.4）。センサの観測に合わせた統合系を設計する必要がないので、各センサの観測から位置情報さえ算出できれば、融合できる。各センサの観測から位置情報を算出する手法は、多種多様な手法が提案されており、オープンソース化が進んでいることから、容易に融合するセンサを増設できることが期待される。センサから得る位置情報を融合する代表的な手法に、位置情報を存在確率分布で表現し融合する方法がある。各センサから得る位置の存在確率分布は、センサの観測の不確実性を反映された分布となる。存在確率分布間の積を算出することで、各センサの観測の不確実性を考慮した融合を実現できる。さらに、2.2.1.1 節で述べたベイズフィルタと結合することで、偶然誤差に対してもロバストな位置推定を行うことができる。

Hossein らや Caron らは、パーティクルによって表現された離散確率分布において、積により統合する手法をもとに位置推定系を構築している [72, 73]。Wei らは、GNSS、カメラ、LiDAR、車輪オドメトリの各センサから位置の存在確率分布を正規分布で算出、積による融合に相当する情報化フィルタを利用して融合し位置推定を行う手法を提案している [74]。しかし、積による融合は、融合する存在確率分布の中に、真の位置における存在確率が著しく小さい分布（バイアス分布）が含まれると、位置推定が破綻する例が報告されている [19]。既存の位置推定法では、バイアス分布が生じないように、センサや位置推定法を事前に校正・調整する。しかし、時間的・空間的に予測不能な実環境においては、環境の変化によりバイアス分布が生じてしまう可能性がある。

一方で、センサの小型化やプロセッサの高性能化により、移動体に多くのセンサや位置推定法を搭載できるようになってきた。多重化されたセンサや位置推定法から得る複数の位置情報において、手法ごとに壊滅的な推定誤差が生じる環境が異なるならば、複数の位置情報を外れ値処理に基づいて融合することで、ロバストな位置

推定を実現できる可能性がある。しかし、位置推定法を多重化した例は少なく、複数の位置情報を取得できる融合系において、どのような融合法が適切か明らかになっていない。

2.3 本章のまとめ

本章では、自律移動体における位置推定に関する既存研究と位置推定誤差に対する対処法についてまとめた。次章では、「系統誤差」の低減を目的とし、位置推定法の多重化における外れ値処理の有効性を検討する。

第3章

位置推定法の多重化における外れ値処理に基づく融合法の検証

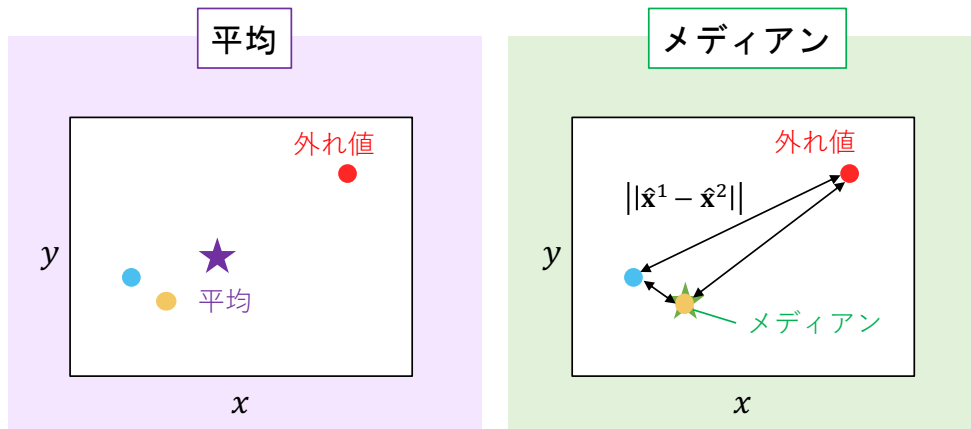
3.1 はじめに

「系統誤差」の低減を目的とし、位置推定法の多重化における外れ値処理の有効性を検討する。系統誤差を低減するためには、一般的に、事前に環境を走行した時のセンサの観測を利用して環境要因のモデル化を行う。しかし、自律移動体が走行する環境は、時々刻々と予測不能に変化するため、モデル化されていない環境要因の変化により壊滅的な位置推定誤差が生じてしまう場合がある。本章では、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定のもと、外れ値処理に基づく融合により系統誤差に対処し、位置推定のロバスト性向上を目指す。

検証では、カメラと LiDAR から得る観測データを提供する KITTI Odometry Benchmark を利用し、LiDAR による位置推定法、カメラによる位置推定法、LiDAR とカメラによる位置推定法を通して複数の推定位置を算出する。モデル化されていない環境要因の変化による系統誤差が生じてしまった場合において、外れ値の影響を受けにくい方法で位置情報を融合することで、位置推定のロバスト性が向上するかどうかを検証する。

3.2 検証した統計的融合法

全 K 個の位置推定法から得る推定位置の集合 $\{\hat{x}^1, \dots, \hat{x}^K\}$ を、一般的な統計処理である平均と外れ値に強いメディアンを利用して融合した。



- : 手法1の推定位置 \hat{x}^1 , ● : 手法2の推定位置 \hat{x}^2 , ● : 手法3の推定位置 \hat{x}^3
 ☆ : 平均, ☆ : メディアン (\hat{x}^3 と同じ位置)

図 3.1. 平均とメディアンによる推定位置の融合例

3.2.1 平均

平均は、データ系列に対して、個々のデータを足し合わせたのち、データの個数で割った値である（式(3.1)）。

$$\hat{\mathbf{x}} = \sum_{k=1}^K \frac{\hat{\mathbf{x}}^k}{K} \quad (3.1)$$

平均は、全てのデータを等価に重み付けし融合した値（図3.1）であり、最も一般的なデータの融合法である。全ての位置推定法から得る推定位置を反映させた融合後の位置を算出できる反面、図3.1に示すように、データ系列の中で他のデータに対して著しく離れた外れ値が含まれている場合、平均の位置が外れ値の影響を受ける。

3.2.2 メディアン

メディアン（中央値）はデータ系列の代表値の一つであり、外れ値にロバストな特徴を持つ。一次元のメディアンは、実数値を昇順に並べたとき中央に位置する値として定義される。データ系列が多次元のときのメディアンは、他のデータとの距離の和を最小にするデータとして次式により算出される [75]。

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x} \in \{\hat{\mathbf{x}}^1, \dots, \hat{\mathbf{x}}^K\}} \sum_{k=1}^K \|\mathbf{x} - \hat{\mathbf{x}}^k\| \quad (3.2)$$

多次元におけるメディアン（式 (3.2)）は、一次元にも適用可能である。図 3.1 に示すように、平均は、他のデータに対して著しく離れた外れ値の影響を受けた推定位置が算出されるのに対し、メディアンは外れ値の影響を受けにくい。各位置推定法から得る推定位置系列を式 (3.2) により融合することで、メディアンの有効性を検証する。

3.3 データ検証

位置推定法の多重化の有効性とそれに適した融合法を KITTI Odometry ベンチマークデータセット [76] を利用して評価した。自動運転車に搭載された LiDAR (Velodyne HDL-64)、ステレオカメラで取得したセンサデータや、高精度な GNSS 位置情報 (RTK-GPS) に関するデータを提供している。KITTI データセットは、特性が異なる 11 の環境 (フリーウェイや、都市部、郊外) を走行して得たセンサデータを提供しており、位置推定法の環境特性を検証するのに適しているため利用した。本章では、LiDAR を利用した位置推定法として NDT Mapping を、ステレオカメラを利用した位置推定法として ORB SLAM を、LiDAR とカメラを利用した位置推定法として LIMO を利用する。これらは、SLAM による位置推定法であり、位置推定を行いながら同時に環境地図を作成する。SLAM により算出される推定位置には、走行距離が伸びるほど次第に誤差が蓄積する。そのため、位置推定誤差は以下の式により評価する。

$$\sum_{t=1}^T \frac{e(t)}{l(t)} \times 100 \quad (3.3)$$

$e(t)$ は時刻 t における真の位置と推定位置間の誤差、 $l(t)$ は時刻 t までの走行距離である。これは、SLAM による蓄積誤差の影響を考慮した誤差の評価方法である。各センサの観測を三つの位置推定法にてオフラインで処理し、GNSS による推定値を真の位置として評価した。

3.3.1 利用した位置推定法

NDT Mapping

Normal Distribution Transformation (NDT) Mapping は、LiDAR から得る点群を利用したスキャンマッチングによる位置推定法である [48]。膨大な数の LiDAR 点群を正規分布で近似しデータ量を圧縮して処理することで、高速な処理を可能としている。NDT Mapping では、地図の空間がボクセルグリッドにより分割される。それぞれのボクセル内にある点群 (参照点群) は、平均と分散を持つ正規分布に近似

される。LiDARで観測した点群（観測点群）は、各ボクセルに割り当てられ、観測点群と参照点群が最も一致する位置を探索する。探索には、正規分布を元にした評価式が利用され、ガウス・ニュートン法を利用して評価関数の値が収束するまで再帰的に計算される。高精度・高密度な3D LiDARの点群を効率よく処理できることから、利用が拡大している。一方、直線のような単調な経路では、移動体の位置を推定するに足る特徴を得られず、位置推定が破綻する場合がある。

ORB SLAM

ORB SLAMはカメラから得る画像を利用した Visual Odometry の一般的なものである [31]。抽出されたORB特徴量は、スケール・回転不変なFASTコーナ特徴である。KITTIで提供される 1241×376 の画像から2000個以上のORB特徴量が抽出される。膨大な量のORB特徴量の抽出によりロバストな位置推定ができる。ORB特徴量を抽出したのちに、ステレオビジョンにより特徴量を三次元復元し、PnP問題やRANSAC、バンドル調整、ポーズ調整などのアルゴリズムを介して移動体の位置を推定する。強力な画像特徴のマッチングを利用することで位置推定が破綻してしまう場合が少ない一方で、ステレオビジョンによる三次元復元の精度の問題により全体的な位置推定精度に問題がある。ステレオビジョンによる三次元復元誤差は、ステップごとで見れば微小であるが、累積するほど大きな誤差となる。

LIMO

LiDAR-Monocular Visual Odometry (LIMO)は、カメラの画像とLiDARの点群の両方を利用した位置推定法である [67]。基本的なアイデアは、Visual Odometryと同一であり、画像から特徴点を抽出、移動体から特徴点までの奥行きを算出、特徴点を三次元復元し位置を推定する。LIMOの特徴として、特徴点の奥行きを算出するときにLiDARの点群を活用する点がある。さらに、自動車・トラックといった移動物体や路面上の特徴点といった、位置推定誤差を増大させる可能性がある物体上の特徴点を排除する処理により高精度な位置推定を行っている。本位置推定法は、LiDARによる高精度な環境点群情報と画像による強力な位置追跡能力を掛け合わせた位置推定法といえる。しかし、位置推定に利用できる特徴点が不足してしまう場合がある点が問題として挙げられる。LIMOは、位置推定精度を下げる可能性がある点（移動体上の特徴点や路面上の点）を排除するため、位置推定に利用できる特徴点が減少してしまう。

3.3.2 検証結果と考察

位置推定結果を表3.1に示す。表3.1では、横列が各位置推定法と融合法を、縦列

表 3.1. NDT, ORB, LIMO, 平均, メディアンによる位置推定誤差

Sequence	NDT	ORB	LIMO	Mean	Median
00	0.81	0.95	0.58	0.66	0.63
01	6.44	4.73	1.98	3.21	3.00
02	4.12	0.51	0.47	1.38	0.40
03	0.94	0.86	0.97	0.43	0.55
04	1.59	1.70	0.77	0.77	0.80
05	0.54	1.38	0.47	0.57	0.35
06	0.90	1.65	0.76	0.88	0.71
07	1.10	1.38	2.62	1.27	0.94
08	2.95	3.79	2.82	3.08	2.97
09	0.95	2.46	0.48	0.95	0.55
10	1.60	2.18	2.05	1.26	0.98
Average error	1.99	1.96	1.27	1.31	1.08

unit: [%], **Red**: Worst, **Green**: Best, **Blue**: 2nd Best

がそれぞれ異なる環境のシーケンスを表している。各シーケンス内で、最も推定誤差が大きかった位置推定法を赤セル、最も推定誤差が小さかった位置推定法を緑セル、二番目に推定誤差が小さかった位置推定法を青セルで表している。また、シーケンスごとに、最も推定誤差が小さかった位置推定法に対する他の位置推定法の推定誤差を比率で表現したグラフを図 3.2 に示す。図 3.2 において、横軸にシーケンス、縦軸にシーケンス内の最小誤差に対する各位置推定法の位置推定誤差の比率を表している。例えば、図 3.2 のシーケンス 00 では、最も推定誤差が小さい LIMO の値が 1 となり、LIMO の誤差に対する NDT の誤差の比率は 1.41、ORB の誤差の比率は 1.65、平均の誤差の比率が 1.14、メディアン の誤差の比率が 1.09 となっている。

以下に、シーケンス 02, 07, 01 の結果と全体の考察をまとめる。

シーケンス 02

シーケンス 02 では、NDT から得る推定誤差が、他の位置推定法に比べて二倍以上の誤差となっている。シーケンス 02 で得た NDT, ORB, LIMO の推定経路を図 3.3 に示す。黒の点線で真の経路、赤が NDT, 黄が ORB, 青が LIMO をそれぞれ表している。ORB と LIMO は真の経路に追従しているのに対し、NDT は、真の経路から大きく外れてしまった。特に、 $200 < x < 400, 600 < y < 800$ の区間で大きな NDT の推定経路に大きな誤差が生じている。この区間で得た画像と点群を図 3.4 に示す。この区間は、車両周辺が生垣で覆われており、LiDAR で得る点群は、単調な直線に




図 3.2. 各シーケンス内で最も誤差が小さい位置推定法に対する各位置推定法の誤差の比率

なっている。周辺環境の進行方向成分が単調であったために、移動量を推定できなかった。一方、画像を利用した位置推定は、画像内の特徴を捉えることで、移動量を適切に推定できた。この区間における真の移動距離と NDT, ORB, LIMO の推定移動距離は、それぞれ、179.2m, 15.05m, 178.5m, 179.5m であり、NDT だけ非常に短いことが確認できる。結果として、LiDAR を利用した NDT による位置推定法において、単調な直線環境を十分にモデル化できていないために、NDT の推定誤差が増加してしまった。

一方、メディアンによる推定誤差は、NDT の推定誤差に比べ非常に減少している。シーケンス 02 で得た平均、メディアンの推定経路を図 3.5 に、各位置推定法の推定誤差を図 3.6 に、メディアンで選択された位置推定法を図 3.7 に示す。図 3.5 において、黒の点線で真の経路、紫が平均、緑がメディアンをそれぞれ表している。また、図 3.6 では、横軸に時刻 t における真の走行経路長 $l(t)$ 、縦軸にその時の誤差を表し、図 3.7 では、横軸に走行経路長 $l(t)$ 、縦軸にその時メディアンで選択された位置推定法を表している。図 3.5 より、平均の経路は歪んでいるのに対し、メディアンの経路は、真の経路に追従できていることが分かる。図 3.6 より、平均の推定誤差は NDT を受け大きくなっているのに対して、メディアンは、ORB と LIMO に対して外れ値となる NDT の影響を除外して、誤差が小さくなっていることが分かる。また、図 3.7 より、メディアンでは、NDT 以外の位置推定法による推定位置を利用していることが確認できた。平均に対し、メディアンは誤差を低減することで、位置推定精度が向上していることが確認できる。外れ値処理により、モデル化されていない環境要因の変化による系統誤差が NDT で生じてしまった場合でも、ロバストな位置





図 3.3. シーケンス 02 における NDT, ORB, LIMO の推定経路



(a) ステレオカメラの左画像



(b) LiDAR の点群の俯瞰図

図 3.4. $200 < x < 400, 600 < y < 800$ の区間で得たセンサの観測




図 3.5. シーケンス 02 における平均，メディアン の推定経路




図 3.6. シーケンス 02 における推定誤差




図 3.7. シーケンス 02 においてメディアンで選択された位置推定法

推定ができることがわかった。

シーケンス 07

シーケンス 07 では、LIMO の誤差が大きくなった。シーケンス 07 で得た走行経路を図 3.8 に示す。NDT と ORB は真の経路に追従しているのに対し、LIMO は、 $(x, y) = (-150, -80)$ あたりを起点として大きくズレてしまった。これは、 $(x, y) = (-150, -80)$ で車両の進行方向に大きな誤差が生じたために、後の経路が大きくズレたと考えられる。 $(x, y) = (-150, -80)$ の地点で得た LiDAR の点群を画像上に投影した画像を図 3.9 に示す。この図は主に、道路、トラック、家というオブジェクトによってできている。3.3.1 節で述べたとおり、本位置推定法は高精度な位置推定に適した特徴点のみを画像内から抽出し位置推定に利用している。位置推定誤差の要因となることから LIMO では、画像内の移動体上の特徴点は利用しない。また、水平面となる道路上の特徴点も車両の水平面上の位置を特定するのに寄与しない。つまり、図 3.9 内のトラック上（紫枠）と道路上（赤枠）の特徴点は排除される。また、LiDAR の点群の射影は画像下方のみであり、画像上方の領域（黄枠）は LiDAR の点群が存在しない。位置推定に利用できる領域は緑枠で囲った領域のみであり、位置推定に利用できる特徴点が不足し、位置推定が破綻してしまっただけでなく、結果として、LiDAR とカメラを利用した LIMO による位置推定法において、車両前方のほとんどが移動物体や道路で遮られてしまっている場合を十分にモデル化できていないために、LIMO の推定誤差が増加してしまっただけでなく、

一方、メディアンによる推定誤差は、減少している。シーケンス 07 で得た平均、メディアンの推定経路を図 3.10 に、各位置推定法の推定誤差を図 3.11 に、メディアンで選択された位置推定法を図 3.12 に示す。図 3.10 より、平均の経路は LIMO の影響を受けて $(x, y) = (0, -50)$ のあたりでズレているのに対して、メディアンの経路は、真の経路に追従できていることが分かる。図 3.11 より、平均の推定誤差は LIMO の影響を受けて大きくなってしまったのに対して、メディアンの推定誤差は、NDT、ORB に対して外れ値となる LIMO の誤差を抑制できている。また、図 3.12 より、メディアンでは、LIMO がほとんど選択されなかったために、位置推定誤差の影響を受けなかったことが確認できた。以上より、平均は LIMO の影響を受けてしまっているのに対し、メディアンは誤差を低減することで、位置推定精度が向上していることが確認できた。外れ値処理により、モデル化されていない環境要因の変化による系統誤差が LIMO で生じてしまった場合でも、ロバストな位置推定ができることがわかった。

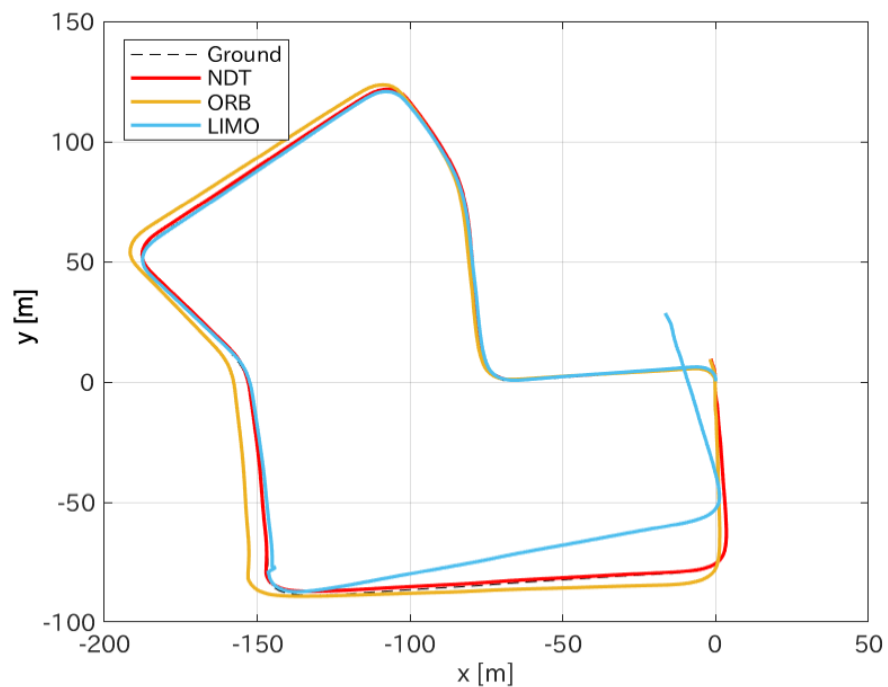


図 3.8. シーケンス 07 における NDT, ORB, LIMO の推定経路

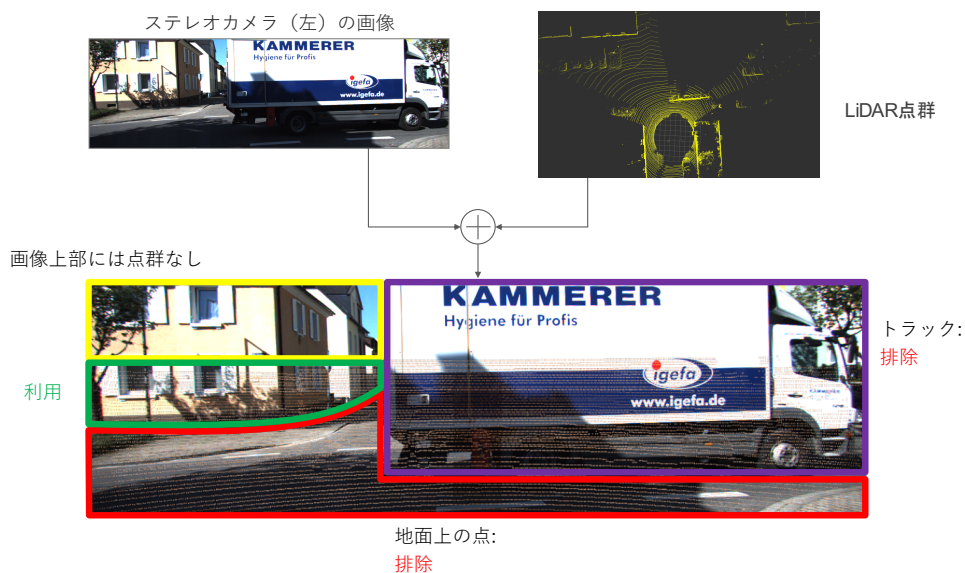


図 3.9. $(x, y) = (-150, -80)$ の位置で得た LiDAR の点群をカメラの画像に投影した図




図 3.10. シーケンス 07 における平均, メディアンの推定経路




図 3.11. シーケンス 07 における推定誤差




図 3.12. シーケンス 07 においてメディアンで選択された位置推定法

シーケンス 01

シーケンス 01 では、NDT と ORB の誤差が LIMO に比べて二倍以上生じている。シーケンス 01 で得た走行経路を図 3.13 に示す。LIMO は真の経路に追従しているのに対し、ORB と NDT は真の経路から外れていることがわかる。図 3.13 の、 $(x, y) = (1035, -630)$ の区間で得た画像と LiDAR の点群を図 3.14 に示す。シーケンス 01 は、周囲が開けた環境下を高速で移動できるフリーウェイである。ステレオカメラの画像の変化が激かったために、ORB の特徴量マッチングで誤差が出てしまったと思われる。また、LiDAR の点群が周辺に特徴的なものが少なく、NDT でも誤差が生じてしまった。

シーケンス 01 では、各推定位置を平均やメディアンで融合しても推定誤差が LIMO の 1.5 倍以上となってしまっている。シーケンス 01 で得た平均、メディアン の推定経路を図 3.15 に、各位置推定法の推定誤差を図 3.16 に、メディアンで選択された位置推定法を図 3.17 に示す。図 3.15 より、 $(x, y) = (100, -600)$ あたりまでは、メディアン の経路が真値に追従しているのに対し、それ以降は、大きくズレていることが確認できる。図 3.16 より、平均とメディアン の推定誤差は NDT や ORB の影響で誤差が大きくなってしまっていることが確認できる。また、図 3.17 より、メディアンでは、走行距離が 1300m 以降で ORB の推定位置が選択されてしまっていることが確認できた。真の位置が $(x, y) = (1035, -630)$ の地点における推定位置と経路の拡大図を図 3.18 に示す。真の位置が $(x, y) = (1035, -630)$ の黒丸の地点における NDT、ORB、LIMO の推定位置をひし形で、平均とメディアン の推定位置を丸で示している。車両は左上から右下に進行している。LIMO は、真の位置近くで推定位置を算出しているのに対し、赤の NDT は、真の位置に対して大きく遅れをとっている。また、黄色の ORB は y 軸正方向に大きな誤差を持っている。各推定位置間の距離が最小となる推定位置を選択するメディアンでは、ORB の推定位置が他の推定位置との距離が最小になってしまい選択されてしまった。結果として、メディアン の推定位置は ORB の推定位置と同一の値となっている。このように、実装した位置推定法の過半数以上で壊滅的な誤差が生じ、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定を満たしていない場合、メディアンによる外れ値処理では誤差の影響を排除できないことがわかった。

全体の考察

表 3.1 より、NDT、ORB、LIMO などの単一の位置推定法では、推定誤差が最小となるシーケンスがあるものの、一部のシーケンスで大きな誤差が生じてしまっている。各位置推定法から得る推定位置を平均を利用して融合した場合、ある程度の精度改善は見られるものの、シーケンス 02 やシーケンス 07 など、大きな推定誤差を


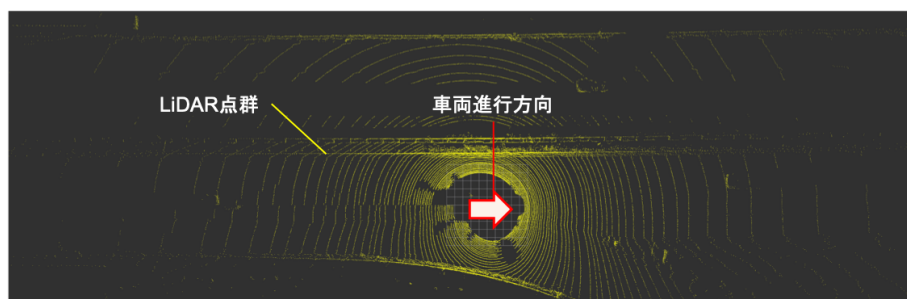


図 3.13. シーケンス 01 における NDT, ORB, LIMO の推定経路



(a) ステレオカメラの左画像



(b) LiDAR の点群の俯瞰図

図 3.14. $(x, y) = (1035, -630)$ の位置で得た LiDAR の点群をカメラの画像に投影した図




図 3.15. シーケンス 01 における平均, メディアンの推定経路




図 3.16. シーケンス 01 における推定誤差




図 3.17. シーケンス 01 においてメディアンで選択された位置推定法




図 3.18. シーケンス 01 の真の位置が $(x, y) = (1035, -630)$ の地点における推定位置と経路の拡大図

持つ推定位置が一つでも含まれると、それらの影響を受けて推定誤差が大きくなってしまう。一方、メディアン（中央値）の推定誤差は、シーケンス 02, 05, 06, 07, 10 において最小となり、最も推定誤差が大きくなるシーケンスは一つもなかった。表 3.1 の最下段にある各位置推定法と融合による推定誤差の全シーケンスの平均を比べると、メディアンを利用した場合に最も小さくなった。さらに、図 3.2 より、メディアン（中央値）の誤差が最小ではないシーケンスでも、メディアン（中央値）の誤差はそのシーケンスで最も小さい誤差に対して 1.5 倍未満に収まっている。一方、シーケンス 01 のように、仮定を満たしていない環境では、個々の位置情報が持つ壊滅的な推定誤差をメディアン（中央値）により排除できないことがわかった。このシーケンスにおいて誤差の影響を排除するためには、LIMO と同じ精度で位置推定可能な手法を実装する必要がある。

以上より、位置推定法の多重化において、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定を満たしていれば、外れ値処理により、モデル化されていない環境要因の変化による系統誤差が生じてしまった場合でも、ロバストな位置推定ができることがわかった。

3.4 本章のまとめ

本章では、位置推定法の増設により推定誤差が減少することを確認した。KITTI Odometry Benchmark を利用した実データによる検証によって、複数の位置推定法から得る位置情報を平均とメディアンにより融合し、効果を検証した。結果、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定を満たしていれば、他の推定位置に対して著しく離れた外れ値の影響を受けにくいメディアンにより融合することで、位置推定のロバスト性が向上することを確認できた。次章では、確率的な位置表現に適した外れ値処理法を検討する。

第4章

確率的な位置情報における外れ値処理に基づく融合法

4.1 はじめに

ベイズフィルタに代表される確率的な位置推定法は、「偶然誤差」に対処できることから、位置推定の分野で広く活用されている。センサ融合では、各位置推定法から得る確率分布を積により融合することで、位置の不確実性を考慮して融合できる。しかし、積により融合される分布の中に、真の位置における存在確率が著しく低い分布（バイアス分布）が含まれると、位置推定が破綻する例が報告されている [19]。バイアス分布は、モデル化されていない環境要因の変化により生じる「系統誤差」が反映された分布であり、確率的な位置推定法では対処できない。第3章における実験にて、「系統誤差」に対して外れ値処理が有効であることを確認した。そこで、第4,5章では、ベイズフィルタを利用したセンサの観測の時系列処理による「偶然誤差」への対処と、外れ値除去による「系統誤差」への対処を複合した手法を提案する。本章では、確率的な位置情報における外れ値除去法について述べる。

先行研究では、確率的な位置情報の相互評価による外れ値処理法が提案され、「系統誤差」に対する一定の効果を示した [19]。具体的には、位置推定に広く適用されているパーティクルフィルタをベースに、各位置推定法から算出される位置情報を離散存在確率分布で表現、各位置推定法から得る存在確率分布間の類似性評価を行い、それを基に存在確率分布を多数決的に選択・融合する手法を提案した。存在確率分布間の類似性評価には、確率分布間の類似性評価で一般的に利用される KL 情報量を利用し、基準分布に対する KL 情報量をもとに融合する分布を選択していた。先行研究の実環境における検証において、相対評価による外れ値除去の枠組みはおおむね有効に機能したが、KL 情報量と基準分布に起因する問題により、環境によっては外れ値の排除を誤る事例が見られた。本章では、先行研究で外れ値除去を誤る要因を明確にし、位置推定に適した存在確率分布間の類似性評価法、および、位置情

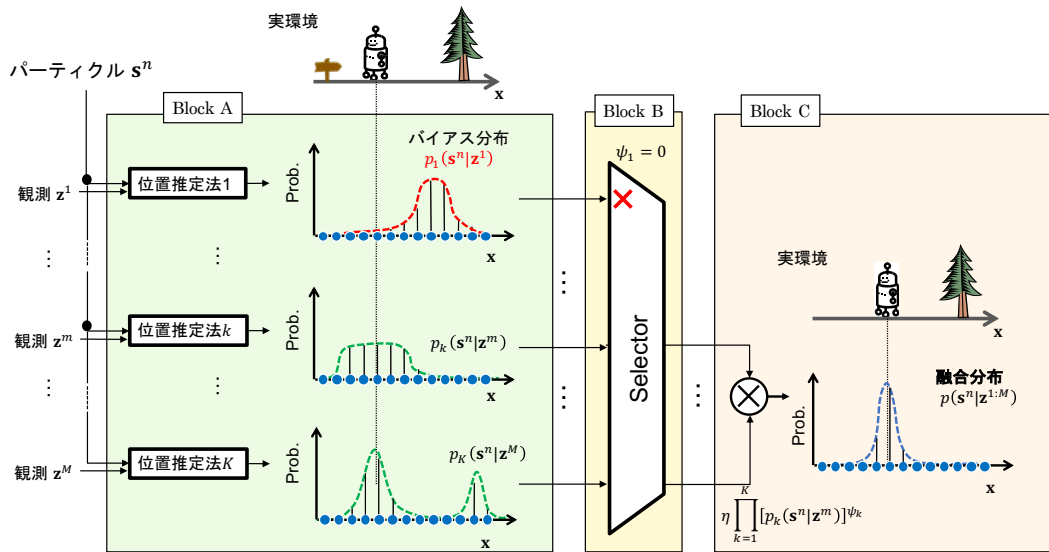


図 4.1. 相対評価によるセンサ融合システム

報の選択法を提案する。シミュレーションと実環境における検証により、提案融合システムにより有用な存在確率分布が正しく選択され、位置推定のロバスト性が向上することを示す。

4.2 先行研究

先行研究の相対評価に基づくセンサ融合システムを図4.1に示す。図4.1では、各センサから得る位置情報をパーティクルを用いた存在確率分布で表現 (Block A)、各存在確率分布の相対評価により分布の類似する位置推定法を選択 (Block B)、選択された位置推定法から得る分布を積により融合する (Block C)。以下詳細を記す。

4.2.1 パーティクルによる離散存在確率分布表現と融合

確率的な位置情報の表現では、センサ m の観測 z^m から位置推定法 k を通して算出される位置情報を、位置の存在確率分布 $p_k(\mathbf{x} | \mathbf{z}^m)$ で表現する。Block A では、位置の存在確率分布 $p_k(\mathbf{x} | \mathbf{z}^m)$ を、パーティクル群 $s^n (n = 1, \dots, N)$ を用いて、離散存在確率分布 $p_k(s^n | \mathbf{z}^m)$ の形式で表現する。なお、パーティクル群 s^n は、移動体

の位置と同次元の位置の候補点である。表現能力の高いパーティクルにより、確率的な位置推定法において研究された既存の観測確率 [27, 77, 78] を活用できる。すなわち、センサの種類・特性に応じた既存の観測確率を併用することで、位置推定のロバスト化を試みる。

Block C では、各位置推定法から得る存在確率分布 $p_k(\mathbf{s}^n | \mathbf{z}^m)$ を次式で融合する。

$$p(\mathbf{s}^n | \mathbf{z}^{1:M}) = \eta \prod_{k=1}^K [p_k(\mathbf{s}^n | \mathbf{z}^m)]^{\psi_k} \quad (4.1)$$

ここで、 $\mathbf{z}^{1:M}$ はセンサ 1 から M の集合、 η は正規化係数である。また、 ψ_k は 0 か 1 をとる選択係数であり、Block B の選択器で決定される値である。 $\psi_k = 0$ のとき、 $[p_k(\mathbf{s}^n | \mathbf{z}^m)]^{\psi_k} = 1$ となるため存在確率分布 $p_k(\mathbf{s}^n | \mathbf{z}^m)$ は融合に影響せず、 $\psi_k = 1$ となる存在確率分布 $p_k(\mathbf{s}^n | \mathbf{z}^m)$ のみ積算融合される。積算融合は同時確率の算出に相当し、位置候補の絞り込みに適している。融合した $p(\mathbf{s}^n | \mathbf{z}^{1:M})$ の加重平均 (式 (4.2)) により推定位置 $\hat{\mathbf{x}}$ を算出する。

$$\hat{\mathbf{x}} = \sum_{n=1}^N \mathbf{s}^n \cdot p(\mathbf{s}^n | \mathbf{z}^{1:M}) \quad (4.2)$$

ここで、モデル化されていない環境要因による系統誤差により、図 4.1 の $p_1(\mathbf{s}^n)$ のように、壊滅的な推定誤差を含んだ存在確率分布 (バイアス分布) を得る場合がしばしばある。真の位置付近の確率値が低いバイアス分布を積算融合すると、大きな位置推定誤差を招く。Block B 内でバイアス分布を検出・排除し、残りの分布を積算融合 (式 (4.1)) することを目指す。これにより、位置の絞り込みによる高精度化と位置推定のロバスト化を期待できる。

以降、煩雑化を避けるため、位置推定法 k から得る存在確率分布 $p_k(\mathbf{s}^n | \mathbf{z}^m)$ を $p_k(\mathbf{s}^n)$ と表現する

4.2.2 相対評価による選択法

Block B では、位置推定法 k に対する選択係数 ψ_k を、存在確率分布 $p_k(\mathbf{s}^n)$ の他の分布に対する特異性から求める。これは、「同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定のもとに設計した。その仮定の下では、同時に類似したバイアス分布が生じることは稀となることから、存在確率分布 $p_k(\mathbf{s}^n)$ の相対的な特異性からバイアス分布を外れ値として検出する。

処理の概略を図 4.2 に示す。全 K 個の存在確率分布 $p_k(\mathbf{s}^n)$ から基準分布 $q(\mathbf{s}^n)$ を求め、存在確率分布 $p_k(\mathbf{s}^n)$ と基準分布 $q(\mathbf{s}^n)$ の相違度 d_k が高い分布を外れ値とみなして $\psi_k = 0$ 、それ以外の分布を $\psi_k = 1$ として選択する。以下、相違度 d_k と選択係数 ψ_k の算出法を説明する。

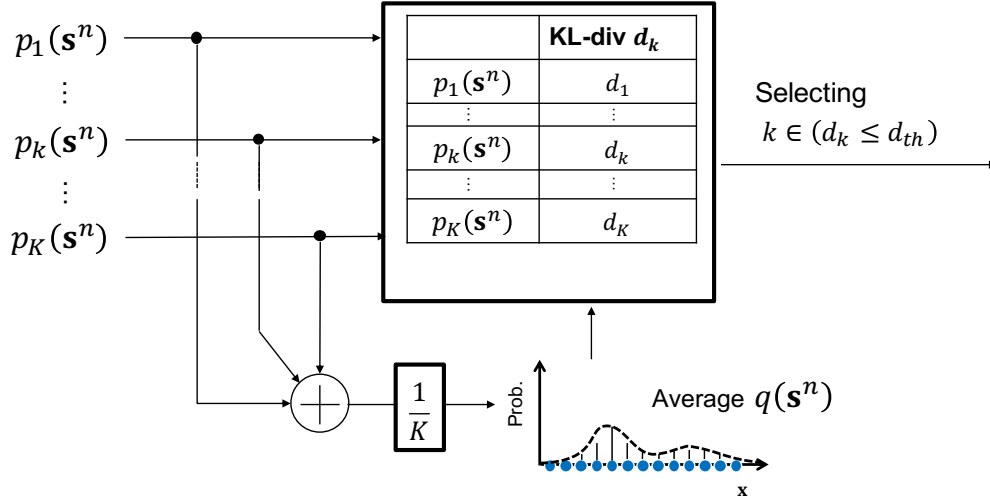


図 4.2. 先行研究における選択器 (Block B)

4.2.2.1 存在確率分布間の類似性評価

$p_k(\mathbf{s}^n)$ は存在確率分布であるから、一般的な存在確率分布間の類似性評価指標である KL 情報量を導入する。KL 情報量の定義式に従い、全 K 個の相違度 d_k を次式により求める。

$$d_k = \sum_{n=1}^N p_k(\mathbf{s}^n) \log_2 \frac{p_k(\mathbf{s}^n)}{q(\mathbf{s}^n)} \quad (4.3)$$

ここで、基準分布 $q(\mathbf{s}^n)$ を全ての k で共通にすることで、距離定義を満たさない KL 情報量から各センサの相対的な相違度を評価する。なお、KL 情報量は、全て n において $p_k(\mathbf{s}^n) = q(\mathbf{s}^n)$ が成り立つ場合に $d_k = 0$ となり、存在確率分布 $p_k(\mathbf{s}^n)$ と基準分布 $q(\mathbf{s}^n)$ の類似性が低くなるにつれて相違度 d_k は高くなる。

比較基準の基準分布 $q(\mathbf{s}^n)$ は、全 K 個の $p_k(\mathbf{s}^n)$ の平均分布とする (式 (4.4))。

$$q(\mathbf{s}^n) = \frac{1}{K} \sum_{k=1}^K p_k(\mathbf{s}^n) \quad (4.4)$$

個々の存在確率分布 $p_k(\mathbf{s}^n)$ のピーク形状を均等に反映する平均分布は、相対評価の基準分布に適すると考えられる。

4.2.2.2 センサ選択

相違度 d_k は平均分布 $q(\mathbf{s}^n)$ からの相対的な値であり，存在確率分布 $p_k(\mathbf{s}^n)$ に依存する値である．そのため，一定の閾値は設定できない．そこで，式 (4.3) で求めた全 K 個の相違度 d_k から動的な閾値 d_{th} を設定，相対的に外れた相違度 d_k を検出する．閾値 d_{th} は，二乗平均平方根（式 (4.5)）によって算出する．

$$d_{th} = \sqrt{\frac{1}{K} \sum_{k=1}^K d_k^2} \quad (4.5)$$

相違度が $d_k > d_{th}$ を満たす存在確率分布 $p_k(\mathbf{s}^n)$ は，相対的に特異な外れ値となったと考え，選択係数 $\psi_k = 0$ とする．相違度が $d_k < d_{th}$ となる位置推定法 k を選択係数 $\psi_k = 1$ として選択し，存在確率分布 $p_k(\mathbf{s}^n)$ を融合に用いる．

4.3 先行研究のシミュレーション検証

先行研究では，多数決的な融合法の枠組みの有効性は確認したものの，環境によっては有用なセンサの選択を誤る事例があった．本節では，シミュレーションにより先行研究を再度検証し，問題点を明らかにする．

4.3.1 シミュレーション条件

二次元空間 ($x = -1 \sim 1$, $y = -1 \sim 1$) において，バイアス分布を適切に検出・排除できるかを確認するシミュレーションを行った．1000 個のパーティクル $\mathbf{s}^n = (x^n, y^n)^T$ により ($N = 1000$)，位置推定法 k から算出される存在確率分布 $p_k(\mathbf{s}^n)$ を算出する．存在確率分布の中に，一つだけバイアス分布が含まれるとして，バイアス分布を検出・排除できるかを確認した．存在確率分布の数 K は，外れ値処理が機能する最低限の 3 とした．

真の位置を含む分布（真の位置における確率値が高い分布）の存在確率分布を多変量 Gaussian Mixture Model（式 (4.6)）で模擬した．

$$p_k(\mathbf{s}^n) = \phi_1 \mathcal{N}(\mathbf{s}^n; (\bar{x}, \bar{y})^T, \Sigma_1) + \sum_{c=2}^C \phi_c \mathcal{N}(\mathbf{s}^n; \mu_c, \Sigma_c) \quad (4.6)$$

$$\mu_c = \begin{pmatrix} \mu_{x,c} \\ \mu_{y,c} \end{pmatrix}, \quad \Sigma_c = \begin{pmatrix} \sigma_{x,c}^2 & 0 \\ 0 & \sigma_{y,c}^2 \end{pmatrix} \quad (4.7)$$

表 4.1. シミュレーションパラメータ

	C	ϕ_c	$\mu_{x,c}, \mu_{y,c}$	$\sigma_{x,c}, \sigma_{y,c}$
True	1-5	$\begin{cases} \sum_c \phi_c = 1 \\ \phi_1 > \phi_c \quad (c \neq 1) \end{cases}$	0-1	0.01-0.3
Bias	-	-	-	0.01-0.3

ここで、 $(\bar{x}, \bar{y})^T$ は移動体の真の位置、 C は混合数、 $\mathcal{N}(\mathbf{s}^n; \mu_c, \Sigma_c)$ は平均 μ_c 、分散 Σ_c を持つ多変量正規分布の確率密度関数、 ϕ_c は c 番目の正規分布の混合比であり、 $\sum_{c=1}^C \phi_c = 1$ を満たす。式 (4.6) の右辺第一項は真の位置 $(\bar{x}, \bar{y})^T$ を平均とする正規分布であり、 $\phi_1 > \phi_c (c \neq 1)$ とすることで、真の位置の確率値が最も高い分布の観測確率とした。また、バイアス分布の存在確率分布を次式で定義する。

$$p_k(\mathbf{s}^n) = \mathcal{N}(\mathbf{s}^n; (\bar{x} + b_x, \bar{y})^T, \Sigma_1) \quad (4.8)$$

ここで、 b_x はバイアス量であり、単峰性の正規分布の平均が、真の位置 $(\bar{x}, \bar{y})^T$ から x 軸方向に b_x だけズレているとしてモデル化した。単峰性の正規分布モデルとすることで、積算融合においてバイアス量 b_x に応じて誤差を増加させるモデルとなる。位置推定法 $k = 1, 2$ の存在確率分布 $p_k(\mathbf{s}^n)$ を式 (4.6) で、バイアス分布となる位置推定法 $k = 3$ の存在確率分布 $p_3(\mathbf{s}^n)$ を式 (4.8) で算出した。これにより、 b_x が増加するほど、バイアス分布 $p_3(\mathbf{s}^n)$ は、他の分布に対して顕著な外れ値として現れる。実空間での多様な存在確率分布を再現するために、表 4.1 のパラメータをランダムに変化させ、多様な存在確率分布を生成する。バイアス量 b_x を 0.1, 0.2, \dots , 0.9 と 0.1 刻みで変化、各バイアス量 b_x において 1000 回試行を行い、選択性を検証する。ただし、真の位置は、 $(\bar{x}, \bar{y})^T = (0, 0)^T$ で静止しているとした。

4.3.2 シミュレーション結果

真の位置を含む分布、および、バイアス分布の選択率を図 4.3 に示す。横軸がバイアス量 b_x 、縦軸が選択率を表す。バイアス分布の選択率は、 $k = 3$ の分布が、全施行回数 (1000) に対して使用された回数の比率である。真の位置を含む分布の選択率は、 $k = 1, 2$ の分布が、全施行回数の 2 倍 (2000) に対して使用された回数の比率である。バイアス量 b_x の増加に伴いバイアス分布が正しく検出できるようになり、バイアス分布の選択率が低下した。全てのバイアス量 b_x でバイアス分布の選択率が真の位置を含む分布より低い一方で、3 割程度のバイアス分布が選択されてしまった。バイアス分布が選択された事例として、バイアス量 $b_x = 0.7$ のときの存在確率分布 $p_k(\mathbf{s}^n)$ を図 4.4 に示す。横軸、縦軸は、おのこの x, y 座標を表し、各点が

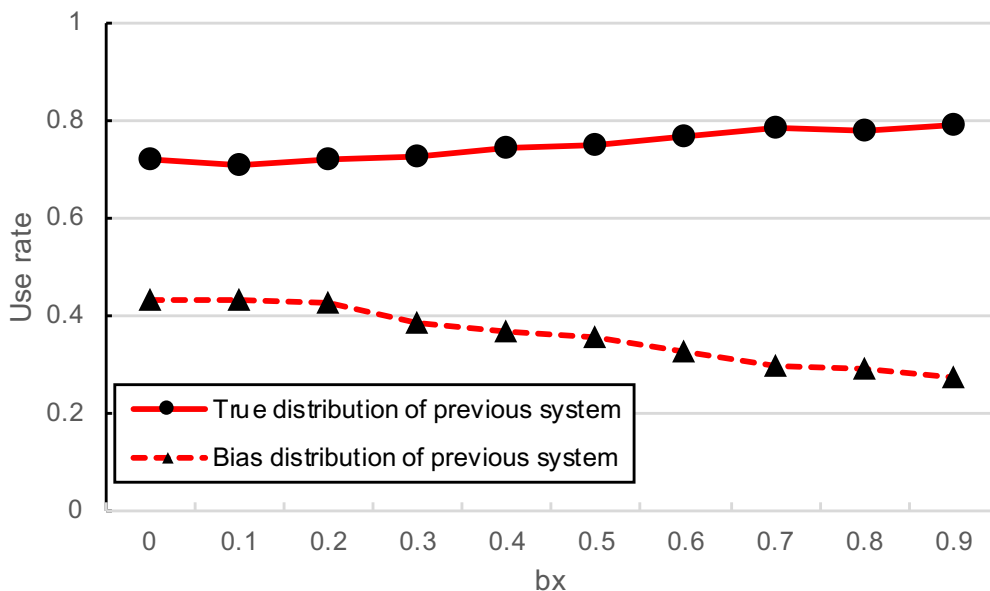


図 4.3. 存在確率分布の使用率

表 4.2. 図 4.4 の相違度 (d_k)

	KL-Div	Use or not
$p_1(s^n)$	11.6	
$p_2(s^n)$	1.70	Use
$p_3(s^n)$	4.17	Use
d_{th}	7.18	

パーティクル s^n , 赤濃度が確率値に対応する。また, 各存在確率分布 $p_k(s^n)$ に対する相違度 d_k と閾値 d_{th} を表 4.2 に示す。表 4.2 より, 真の存在確率分布 $p_2(s^n)$ に加えてバイアス分布 $p_3(s^n)$ の相違度 d_k が閾値 d_{th} を下回り, 結果としてバイアス分布も選択されてしまった。

つぎに, バイアス分布の融合が位置推定に与える影響を確認するために, バイアス量 b_x と推定誤差の関係を図 4.5 に示す。横軸がバイアス量 b_x , 縦軸が推定誤差を表す。全分布を積算融合する場合, バイアス量 b_x の増加に伴い推定誤差が増加するが, 先行研究の融合システムにより, 大きなバイアス量 b_x を持つバイアス分布を融合しないことで推定誤差の増加が抑制された。一方, バイアス量 b_x が 0.3 を超えると, バイアス分布を適切に検出できず, 全分布を積算融合した場合に対して推定誤差が増加した。

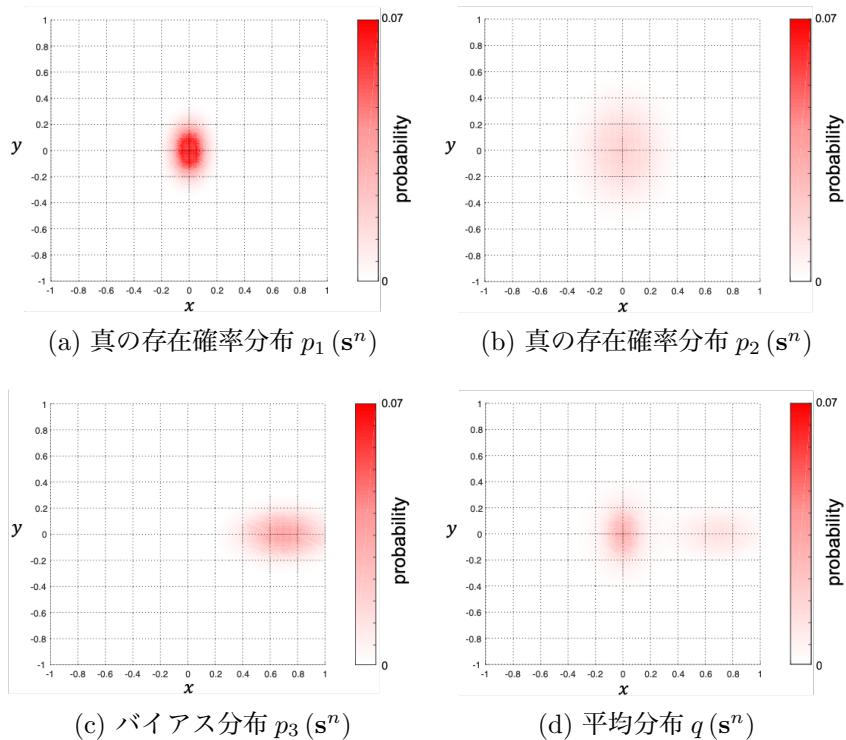


図 4.4. バイアス量 $b_x = 0.7$ で得た存在確率分布

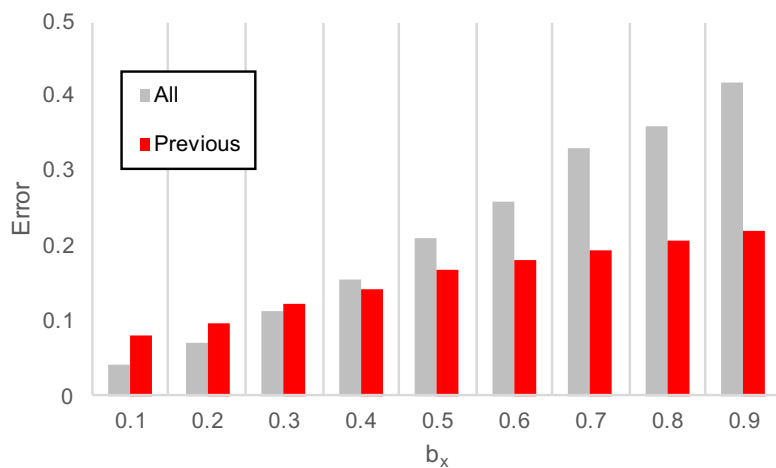


図 4.5. シミュレーションにおける推定誤差




図 4.6. KL 情報量が大きくなるケース

4.3.3 先行研究の問題点

先行研究における融合システムでは、4.2.2節で述べた選択法の類似性評価指標としてKL情報量を利用した点と、比較基準の分布として平均分布を利用した点に問題があり、外れ値のみを適切に検出・排除できない場合があった。

KL情報量の問題点は、KL情報量が存在確率分布間の分布形状の差（図4.6(a)）と分布位置の差（図4.6(b)）に基づいて相違度を算出する点である。確率的位置情報において、「類似した存在確率分布」とは、分布位置の差が小さい図4.6(a)の場合をさすべきである。しかし、KL情報量では、図4.6(a)の分布対において類似性が低いとして評価してしまうため、類似性評価の指標として適切ではないと考えられる。

また、比較記述である平均分布にも問題があった。平均分布 $q(s^n)$ は全ての存在確率分布 $p_k(s^n)$ を平滑化したなだらかな分布である。そのため、なだらかな分布形状となる存在確率分布 $p_k(s^n)$ の相違度 d_k が低くなりやすい。図4.4を見ると、平均分布 $q(s^n)$ に形状が類似した存在確率分布 $p_2(s^n), p_3(s^n)$ の相違度 d_2, d_3 が低くなり選択されてしまった。バイアス分布 $p_3(s^n)$ のように他の分布に対して分布の位置が異なる外れ値であっても、平均分布 $q(s^n)$ と形状が類似しているために相違度 d_3 が低く算出されてしまい、推定精度が低下する問題が先行研究にあった。

以上より、存在確率分布間の分布位置の差に基づく類似性評価指標と平均分布を用いない選択法が求められる。

4.4 提案する選択法

先行研究における問題点に対して、KL情報量に代わる新たな類似性評価指標と、平均分布を用いない新たな選択法について述べる。

4.4.1 類似性評価指標

類似性評価指標が、位置推定における外れ値検出に不適であった。そこで、存在確率分布をパーティクル s^n によって離散近似している点に着目し、確率値の相関性により類似性を評価する手法を提案する。

位置推定法 k から得る存在確率分布 $p_k(s^n)$ において、 i 番目のパーティクル s^i における確率値を $P_k(s^i)$ として定義する。二つの存在確率分布 $p_k(s^n), p_l(s^n)$ 間のピアソンの相関係数 [79] は次式により算出される。

$$\rho_{k,l} = \sum_{n=1}^N \frac{(P_k(s^n) - \mu_k)(P_l(s^n) - \mu_l)}{\sigma_k \sigma_l} \quad (4.9)$$

ここで、 μ_k, σ_k は、確率値系列 $\{P_k(s^1), \dots, P_k(s^N)\}$ の平均と標準偏差、 μ_l, σ_l は、確率値系列 $\{P_l(s^1), \dots, P_l(s^N)\}$ の平均と標準偏差である。ピアソンの相関係数は、2つのデータ系列が連動して変化する傾向の類似性を表す指標である。本手法では、2つの存在確率分布の確率値が連動して変化する度合いの類似性を評価する。

位置の存在確率分布の類似性評価に相関性を利用した理由として、位置の存在確率分布に真の位置がどの程度影響しているかを評価する狙いがある。1.2節で述べた通り、位置情報は、真の位置情報と環境要因による推定誤差によって算出される。ここで、位置推定法により算出される位置情報に環境要因による誤差が小さい場合、その位置情報は、真の位置に対する相関性が高くなる。一方、位置推定法により算出される位置情報に環境要因による誤差が大きき場合、その位置情報は、真の位置に対する相関性が低いことを意味する。真の位置との相関性が高い分布同士の相関係数は高くなることが想定される。逆に、真の位置との相関性が高い分布と低い分布の間の相関係数は低くなることが想定される。また、位置推定法により算出される位置情報に環境要因による誤差が大きく真の位置との相関性が低い分布同士の比較の場合でも、センサや位置推定法が異なれば、環境要因が推定位置に及ぼす影響度も異なることから、相関性が低くなると考えた。真の位置との相関性が高い分布同士の場合のみ、相関係数は高くなると想定されることから、存在確率分布間の相関性を類似性評価に利用することとした。

例として、図 4.7(a) に示すように、存在確率分布対の位置が類似する場合について考える。このとき、 i 番目のパーティクル s^i において位置推定法 k, l の確率値 $P_k(s^i), P_l(s^i)$ がともに高く、 j 番目のパーティクル s^j において確率値 $P_k(s^j), P_l(s^j)$ がともに低い。横軸 $P_k(s^n)$ 、縦軸 $P_l(s^n)$ とした図 4.7(b) の散布図で見ると、位置推定法 k の確率値 $P_k(s^n)$ の増加に伴って位置推定法 l の確率値 $P_l(s^n)$ も増加する。つまり、確率値系列 $\{P_k(s^1), \dots, P_k(s^N)\}, \{P_l(s^1), \dots, P_l(s^N)\}$ の間には正の相関があり、 $\rho_{k,l}$ の値は 1 に近くなる。一方、図 4.8(a) に示すように、存在確率分布対の位置




図 4.7. 似ている存在確率分布

が類似しない場合, i 番目のパーティクル s^i において確率値 $P_k(s^i)$ が大きいが確率値 $P_l(s^i)$ が小さく, 逆に, j 番目のパーティクル s^j において位置推定法 k の確率値 $P_k(s^j)$ が小さいが位置推定法 l の確率値 $P_l(s^j)$ が大きい. 横軸 $P_k(s^n)$, 縦軸 $P_l(s^n)$ とした図 4.8(b) の散布図で見ると, 位置推定法 k の確率値 $P_k(s^n)$ の増減に対して位置推定法 l の確率値 $P_l(s^n)$ は類似しない. 負または無相関となり, $\rho_{k,l}$ の値は -1 に近くなる. 以上のように, $\rho_{k,l}$ によって, 存在確率分布 $p_k(s^n), p_l(s^n)$ 間の位置のずれに基づいた評価が可能となる. $\rho_{k,l}$ に閾値 ρ_{th} を設けることで, 相関値に基づいた存在確率分布の類似性評価ができる.

4.4.2 選択法

先行研究における平均分布に起因した問題を避けるために, 存在確率分布間の類似性を 1 対 1 で評価, 類似する存在確率分布の数から融合する分布を選択する. 提案する選択法を図 4.9 に示す. 各存在確率分布 $p_k(s^n)$ 間の類似性を相関係数により評価, 存在確率分布 $p_k(s^n)$ と類似する存在確率分布の数 L_k (自身を含む) を求める. 全位置推定法の数 K の過半数以上と類似 ($L_k \geq K/2$) する存在確率分布 $p_k(s^n)$ を選択 ($\psi_k = 1$) し, 式 (4.1) により融合する.

各位置推定法から得る存在確率分布 $p_k(s^n)$ に外れ値が含まれていない場合, 全ての位置推定法において $L_k \geq K/2$ と評価され, 全ての存在確率分布 $p_k(s^n)$ を積算融合することができる. また, 全ての位置推定法において $L_k < K/2$ と評価された場合, 存在確率分布 $p_k(s^n)$ はおのおの異なる位置に存在していると考え, 尤もらしい存在確率分布は全存在確率分布の積算融合を求める.




図 4.8. 異なる存在確率分布

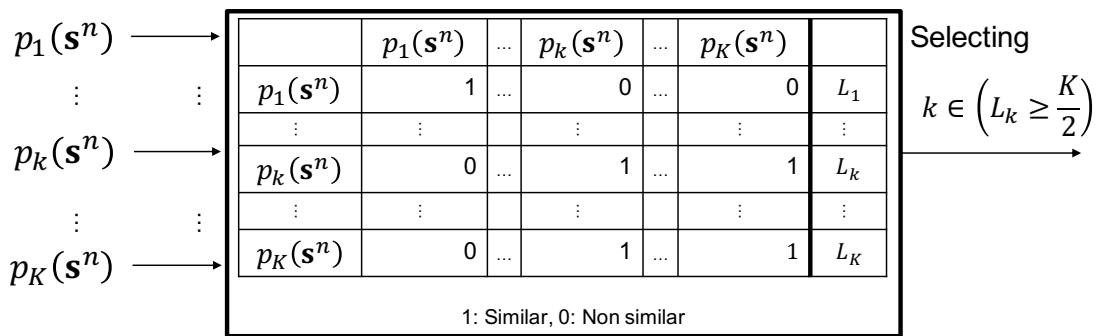


図 4.9. 提案する選択器 (Block B)

本選択法により、平均分布を必要とせず、他の分布から相対的に離れた外れ値のみを適切に検出できる。

4.4.3 シミュレーション検証

4.3節におけるシミュレーションと同様の条件により、提案融合システムの選択性を検証した。位置推定で利用されるセンサは、種類ごとに特性が大きく異なるため、算出される存在確率分布の相関性は大きくない。一般的には、相関係数 ρ が 0.2 以上で正の相関とするが、提案融合システムでは、弱い正の相関を持つ存在確率分布対でも選択できるように閾値 ρ_{th} を 0.1 とした。

結果を図 4.10 に示す。提案融合システムでは、バイアス量 b_x が増えるにしたがってバイアス分布の選択率が先行研究に比べ顕著に下がっている。




図 4.10. 提案法における存在確率分布の使用率

表 4.3. 図 4.4 におけるピアソンの相関係数 ($\rho_{k,l}$)

	$p_1(\mathbf{s}^n)$	$p_2(\mathbf{s}^n)$	$p_3(\mathbf{s}^n)$	L_k	Use or not
$p_1(\mathbf{s}^n)$	1	0.762	-0.0428	2	Use
$p_2(\mathbf{s}^n)$	0.762	1	-0.0693	2	Use
$p_3(\mathbf{s}^n)$	-0.0428	-0.0693	1	1	

バイアス量 b_x が 0.7 のときに得た存在確率分布 (図 4.4) に対して, 提案融合システムで算出された相関係数 $\rho_{k,l}$ を表 4.3 に, 存在確率分布間の散布図を図 4.11 に示す. 表 4.3 と図 4.11 より, 真の位置を含む分布である $p_1(\mathbf{s}^n), p_2(\mathbf{s}^n)$ の間で正の相関 ($\rho_{1,2} \geq \rho_{th}$) となり, 他の分布間では無相関 ($\rho_{1,3}, \rho_{2,3} < \rho_{th}$) となっている. 提案融合システムでは, 真の存在確率分布 $p_1(\mathbf{s}^n), p_2(\mathbf{s}^n)$ の分布を選択し, 適切なセンサ選択を行うことができた. 結果, 図 4.12 に示すように, 提案融合システムでは, バイアス分布 $p_3(\mathbf{s}^n)$ の適切な排除により推定誤差が減少している. これらより, 相関係数の有効性, および, 先行研究における融合システムに対する提案融合システムの原理的有効性を確認した.

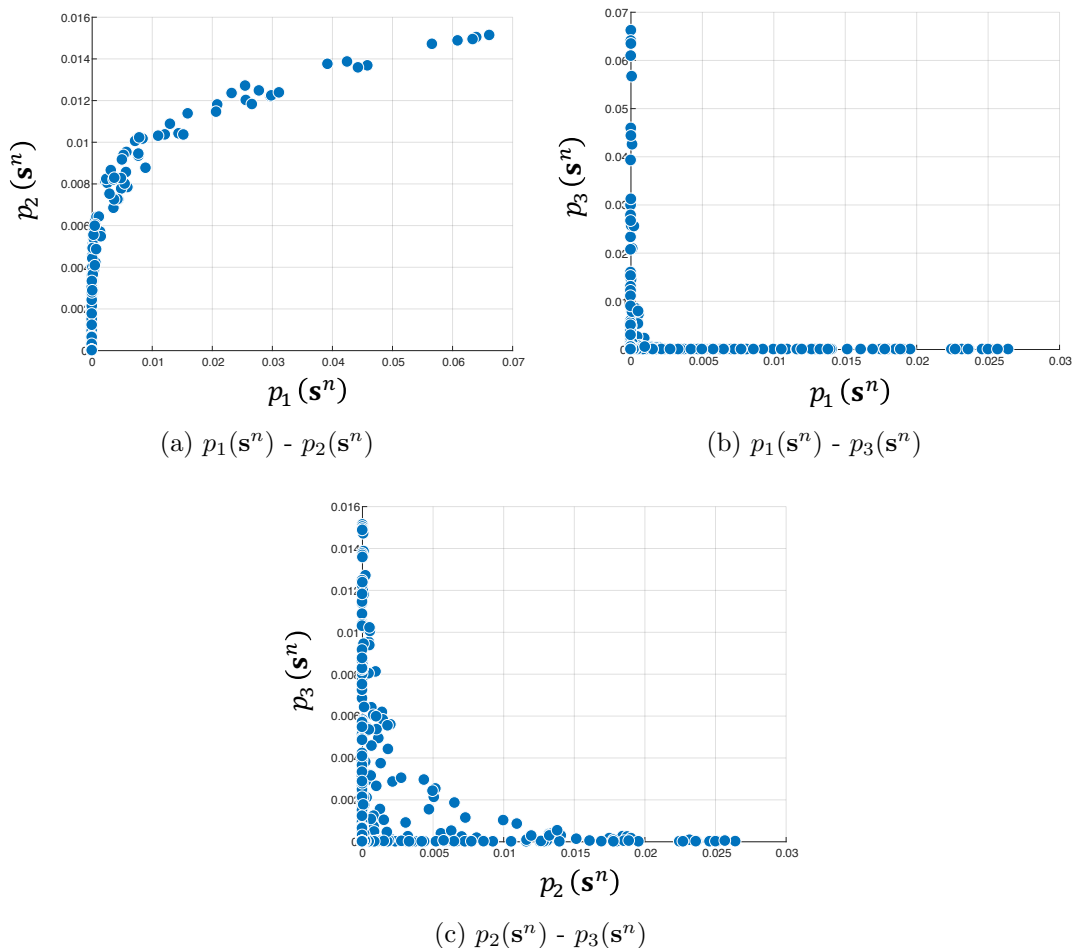


図 4.11. 図 4.4 の散布図

4.5 実環境における検証

提案融合システムの有効性を実機を用いた位置推定実験により確認した。

4.5.1 検証条件

名古屋大学東山キャンパス内と愛知工業大学八草キャンパス内において位置推定実験を行った。LiDAR (北陽 UTM-30LX), 全方位カメラ (ヴィストン VS-C450U-200-TK)・GNSS(ヘミスフィア A101 スマートアンテナ)を搭載した図 4.13 の移動体 (ドングロボット TETRA-DS IV) を用いた ($M = 3$)。各センサの存在確率分布のモデルとして, GNSS は正規分布モデル [77], 全方位カメラは Bag of Features (BoF) [27] による類似画像検索に基づく観測確率, LiDAR は花井らの手法 [78] を




図 4.12. 提案法における推定誤差

参考に点群マッチングに基づく観測確率を用いた ($K = 3$) . ρ_{th} は, 4.4.3 節と同様に 0.1 とした.

実験を行った環境を図 4.14 に示す. ビルが密集しており GNSS がマルチパスエラーを受けやすい歩道 (図 4.14(a)), 自動車の出入りが多く画像特徴が変化しやすい駐車場 (図 4.14(b)), 周辺形状特徴が単調であり LiDAR によるマップマッチングが困難な広場 (図 4.14(c)) で実験を行った.

図 4.14 における地図上の緑点を中心とした 15[m] 格子内に 1000 個の s^n をランダムで生成 ($N = 1000$), センサごとに存在確率分布 $p_k(s^n)$ を算出, 先行研究または提案融合システムにより融合後の分布 $p(s^n)$ を生成, $p_k(s^n)$ の加重平均を推定位置 \hat{x} とし, 推定位置と真の位置間のユークリッド誤差を算出した.

位置推定では, 一般的に時間遷移を組み込むが, 本検証では融合による位置推定への影響を考察することを目的とし, 時間的に独立に位置推定 (位置および独立に $p_k(s^n)$ を算出) を行った. 図 4.14(a)(b)(c) 内において, それぞれ 20, 39, 21 箇所位置推定を行った. なお, バイアス分布発生頻度や仮定可否検証のために, 真の位置を中心とした半径 2m の円内にあるパーティクルの確率値の平均が $1/N$ 以下となる分布をバイアス分布と判定した. バイアス分布の発生頻度や, 仮定の可否, 提案融合システム, 先行研究による選択性を検証した.

GNSS の観測確率




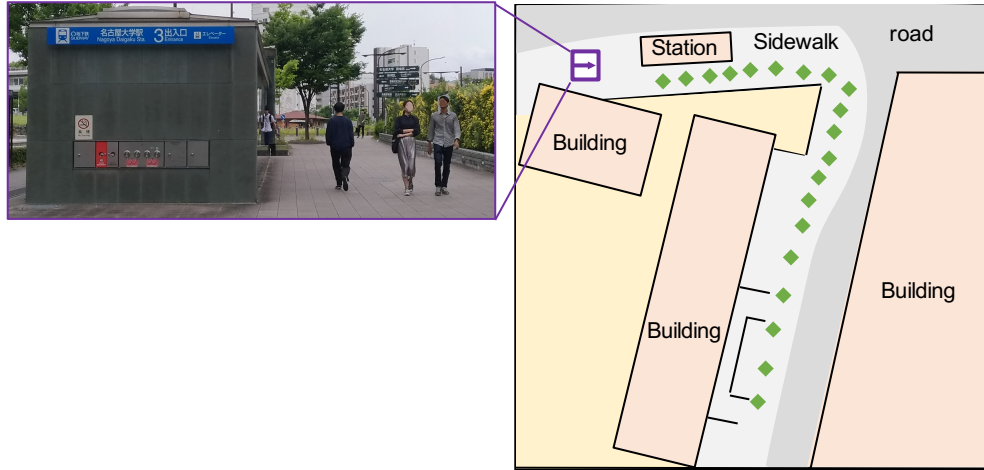
図 4.13. 使用した移動体

GNSS は広く用いられている正規分布モデル [72, 73, 77] (式 (4.10)) を採用した.


$$p_{GNSS}(\mathbf{s}^n) \propto \exp\left(-\frac{(\mathbf{s}^n - \mathbf{p}_{GNSS})^2}{2\sigma_{GNSS}^2}\right) \quad (4.10)$$

GNSS は、先に述べた正規分布モデル [72, 73, 77](式 (4.10)) を採用した. GNSS の観測から得られる位置 (式 (4.10) の \mathbf{p}_{GNSS}) を平均とする正規分布に従い存在確率を計算する. GNSS のマニュアルなどでも, *DRMS*(Distance Root Mean Square) など正規分布を仮定したパラメータ表記が多く, 自然な設計と考えられる.


正規分布の標準偏差である式 (4.10) の σ_{GNSS} は観測確率の性質を大きく左右する. 以下, σ_{GNSS} の妥当な値を議論する. 本実験で用いた Crescent A100 は, マニュアルに記載されている仕様によると, 水平精度は DGPS(Differential GPS, 相対測位方式) で 0.6m 未満, 単独測位で 2.5m 未満とされている. (DGPS では, 位置の分かっている固定基地局からの電波を受信して補正を行うことで, 一般に通常の単独測位に比べて精度の良い位置情報を得られる.) ただし, これはあくまで受信機のノイズに起因した誤差である. A100 に限らず, 実際の計測においては, マルチパスや衛



(a) Sidewalk



(b) Parking



(c) Square

図 4.14. 実験環境

星の軌道情報や衛星時計のずれ，電離層・対流圏での伝播誤差といった様々な要因から，仕様以上の誤差が生じることが知られる．そこで，実用上はこうした誤差を考慮した URE (User Equivalent Range Error, 利用者等価誤差) が用いられる． URE を $DRMS$ に変換するには，本実験で用いる GPGGA センテンスに含まれる $HDOP$ (Horizontal Dilution of Precision, 水平精度低下率) との積をとる (式 (4.11)) ．

$$DRMS = HDOP \times UERE \quad (4.11)$$

文献 [80] でも式 (4.11) で $DRMS$ を決定している．文献 [81] によると，一般的な GNSS では URE の値は 1.5~2.0 となる．Crecent A100 が比較的高級な GNSS 受信器とされていることから，本実験では $URE = 1.5$ とした．ステップ毎に得られた $HDOP$ を用いて式 (4.11) により $DRMS (= \sigma_{GNSS})$ を決定することで，観測から得られる位置の信頼性を観測確率に反映させる．観測から得られる位置の誤差が大きい場合でも， $HDOP$ の値が小さければ σ_{GNSS} が大きくなるため，位置推定への影響は小さくなる．

カメラの観測関数

全方位カメラの観測確率は，Bag of Features (BoF) による類似画像検索 [27] を用いた．BoF 構築の概要を説明する．まず，環境内で事前に画像を取得する．取得した各画像から，Scale-Invariant Feature Transform (SIFT) 特徴量を抽出し，それらをクラスタリングする．クラスタ数は 1000 個とした．画像内の SIFT 特徴量に対して，各クラスタとの類似度を計算し，属するクラスタを決める．これにより，画像毎に SIFT 特徴量のクラスタのヒストグラムを作成する．ヒストグラムを正規化することで，各画像を SIFT 特徴量のクラスタを成分とする単位ベクトルで表現できる．単位ベクトルの集合体が BoF である．

類似画像の検索には，まず観測した画像から SIFT 特徴量を抽出する．抽出した SIFT 特徴量を BoF 構築時に抽出したクラスタ群を成分とした単位ベクトルで表現する．BoF 内画像のうち，単位ベクトル同士の内積が閾値以上の画像を類似画像とする．このとき，撮像位置に閾値を設けて足切りを行う．詳細は後述する．

確率計算は，式 (4.12) により，類似画像の類似度と撮像位置を基に行う．

$$p_{Camera}(\mathbf{s}^n) \propto \prod_{l=1}^L \exp\left(-\frac{(\mathbf{s}^n - \mathbf{p}_{Camera}^{(l)})^2}{2\sigma_{Camera}^{(l)2}}\right) \quad (4.12)$$

L は類似画像数， $\mathbf{p}_{Camera}^{(l)}$ は l 番目の類似画像の撮像位置である．正規分布の標準偏差 $\sigma_{Camera}^{(l)}$ は l 番目の類似画像の類似度 $s^{(l)}$ の関数とした．

なお，この手法の用いた理由 (利点) は，強力な特徴量である SIFT 特徴量を利用できる点に加え，原理上は回転に依存しないため，全方位カメラによる計測と合わせて，位置のみに依存した確率計算ができる点である．事前計測を行う際，単一の

表 4.4. 実験結果

Environment (Bias/Total)	Fulfill precondition	Eliminate bias	
		Previous	Proposed
Sidewalk (10/20)	7 / 10	5 / 7	7 / 7
Parking (3/39)	3 / 3	1 / 3	3 / 3
Square (8/21)	8 / 8	7 / 8	8 / 8
Total (21/80)	18 / 21	13 / 18	18 / 18

ポイントでも計測方向に応じて複数の画像が必要となる通常のカメラに対し、この手法では各ポイントで一枚の画像のみを取得すればよい。実験の簡易化のみならず、実運用でも重要な利点と言える。

類似画像検索時の撮像位置の閾値について述べる。類似画像検索時の撮像位置の閾値であるが、文献 [27] では、”最後の推定位置を中心とし、オドメトリで算出した移動量の二倍を半径とする円内”とされている。これは、前回の推定位置から、移動体がいかなる方向に移動した場合でも、円内に存在することを担保するための条件と思われる。しかし、本実験では各点独立で位置推定を行うため、オドメトリの値を用いない。そのため、パーティクルの重みなし平均 (\approx 真の位置) を中心とし、パーティクルの存在範囲の約二倍である半径 15[m] の円内を類似画像の検索範囲とした。すなわち、類似画像検索時の撮像位置の閾値は 15[m] である。

LiDAR の観測関数

LiDAR の観測とパーティクル環境地図のマッチング誤差 e から、式 (4.13) で確率計算を行った。

$$p_{LiDAR}(s^n) \propto \exp\left(-\frac{e^{(l)}}{2\sigma_{LiDAR}^2}\right) \quad (4.13)$$

正規分布の標準偏差 $\sigma_{LiDAR}^{(l)}$ は、経験的に $\frac{1}{2\sigma_{LiDAR}^{(l)2}} = 1.0 \times 10^{-5}$ となるよう定めた。点群マッチングにおける点群間の対応付けの閾値は 3[m] とした。

4.5.2 検証結果

図 4.14 の計 80 箇所計測を行った際の、バイアス分布発生箇所数や、仮定の可否、選択されたセンサを表 4.4 に示す。計 21/80 箇所計測でバイアス分布が発生した。また、18/21 箇所計測で同時に類似したバイアス分布が生じないという仮定を満たしていることを確認した。仮定を満たした箇所計測で、先行研究では、バイアス分布を適切に排除できた箇所は 13/18 箇所であった。しかし、残りの 5 箇所計測では、有用でない位置推定法から得るバイアス分布を選択し融合してしまった。それに対して、提案融




図 4.15. 存在確率分布の一例

合システムでは 18/18 箇所と、全ての箇所においてバイアス分布を適切に排除でき、選択性を改善できた。先行研究に比べ選択性が改善された 5 箇所では、平均 1.5m の推定誤差減少が確認された。先行研究より、提案法では、有用なセンサを適切に選択できる箇所が増えたことから、提案融合システムのロバスト性が向上したことを確認した。

図 4.14(a) 内で得た存在確率分布の一例を図 4.15 に示す。図 4.15 は、LiDAR で作成した占有格子地図上に存在確率分布を表現した図である。白と灰の領域がそれぞれレーザの通過領域と非通過領域である。赤の点群がパーティクル s^n の位置を表し、赤の濃さで確率値の大きさを表す。緑の点が真の位置である。また、図 4.15(d)(e) の青点は、各融合手法で得た推定位置を表す。図 4.15 より、GNSS から得る存在確率分布がバイアス分布となった。先行研究では、なだらかな分布形状である GNSS とカメラが選択された (表 4.5) が、提案融合システムでは、分布位置が類似したカメラと LiDAR を適切に選択できた (表 4.6)。結果として、この位置において、先行研究における融合システムにおける推定誤差は 4.0m であったのに対して、提案融合システムにおける推定誤差は 2.2m であり、1.8m の推定誤差減少を確認した。

表 4.5. 図 4.15 で得た KL 情報 d_k

	KL-Div	Use or not
GPS	0.729	Use
Camera	0.717	Use
LiDAR	0.923	
d_{th}	0.795	

表 4.6. 図 4.15 で得たピアソンの相関係数 $\rho_{k,l}$

	GPS	Camera	LiDAR	L	Use or not
GNSS	1	-0.132	0.0912	1	
Camera	-0.132	1	0.235	2	Use
LiDAR	0.0912	0.235	1	2	Use

以上より，先行研究における融合システムに対する提案融合システムの有効性を確認した。

4.6 まとめ

本章では，自律移動移動体の自己位置推定におけるロバスト性向上のために，特性が異なる複数のセンサから得る存在確率分布の相対比較に基づく選択的融合法を提案した。先行研究では，確率分布の類似性に基づいてバイアス分布を検出・排除し残りを融合するシステムが提案されたが，類似性評価法と選択法に問題があった。本節では，新たな融合システムとして確率分布の1対比較による選択，および，新たな類似性評価指標として相関に基づく手法を提案した。シミュレーションおよび実環境における検証において，「同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定のもと，先行研究における融合システムに対する提案融合システムの有効性を確認した。次章では，パーティクルフィルタによる時系列遷移を含めた位置推定実験にて，提案融合システムの有効性を確認する。

第5章

外れ値処理に基づく融合法を付与した ベイズフィルタによる位置推定法

5.1 はじめに

前章では、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定のもと、真の位置における存在確率が著しく低い分布（バイアス分布）を外れ値として排除する手法を提案した。位置推定法ごとに位置情報を離散存在確率分布で表現し、離散存在確率分布間の相関を評価することで、存在確率分布で表現された位置情報に含まれる外れ値を検出・排除する。これにより、位置推定で生じる「系統誤差」に対策でき、位置推定のロバスト性が向上することを確認した。

本章では、先の存在確率分布間の相対比較の枠組みと、ベイズフィルタによる時系列処理の枠組みを組み合わせた手法を提案する。ベイズフィルタの中でも、離散確率分布を利用した有名な手法であるパーティクルフィルタを利用する。パーティクルフィルタの理論に基づき、各位置推定法から得る位置情報を位置の存在確率分布で表現、存在確率分布間の相対比較に基づき融合した新たな分布を生成、生成された分布をもとに次時刻のセンサの観測を処理する。これにより、位置推定で生じる「系統誤差」と「偶然誤差」への対処を目指す。

5.2 パーティクルフィルタによる外れ値処理を含む位置推定法

システムの概要を図5.1に示す。位置の存在確率分布を複数の位置候補点で離散近似するパーティクルフィルタは、そのノンパラメトリック性から、移動体の位置推定分野を中心として、状態推定に幅広く活用されている。パーティクルフィルタ

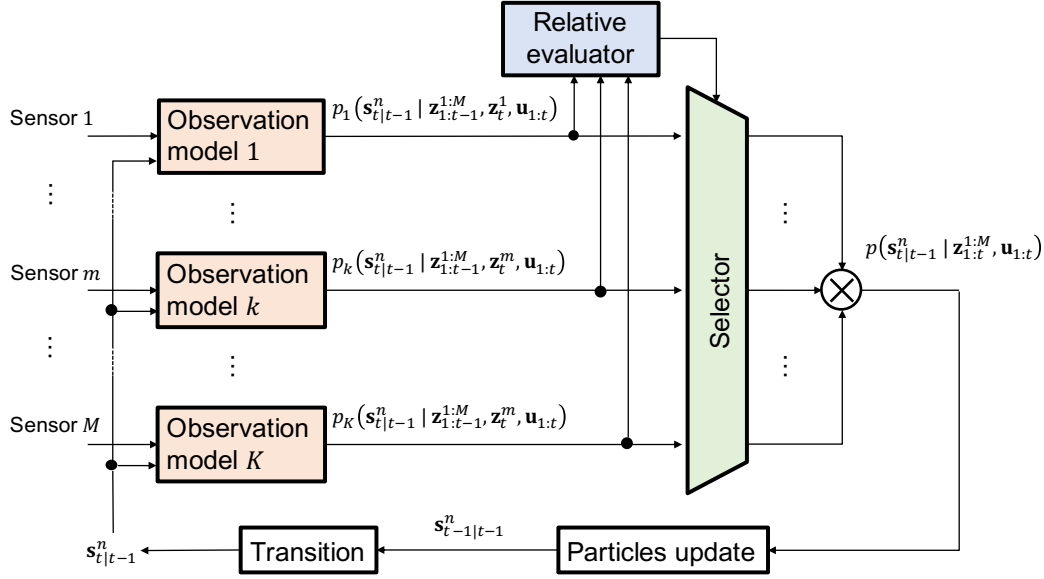


図 5.1. パーティクルフィルタを用いた相対比較に基づくセンサ融合のイメージ

では、時刻 $t-1$ における位置の存在確率分布 $p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}^{1:M}, \mathbf{u}_{1:t-1})$ をパーティクル郡 $\mathbf{s}_{t-1|t-1}^n$ の密度で離散近似する。

$$p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}^{1:M}, \mathbf{u}_{1:t-1}) \approx p(\mathbf{s}_{t-1|t-1}^n | \mathbf{z}_{1:t-1}^{1:M}, \mathbf{u}_{1:t-1}) = \frac{1}{N} \sum_{n=1}^N \delta(\mathbf{x}_{t-1} - \mathbf{s}_{t-1|t-1}^n) \quad (5.1)$$

ここで、 $\mathbf{z}_{1:t-1}^{1:M}$, $\mathbf{u}_{1:t-1}$, N , $\delta(\cdot)$ は、それぞれ、センサ 1 から M の観測の集合の時系列、移動体の制御指令の時系列、パーティクル数、ディラックのデルタ関数である。ディラックのデルタ関数 $\delta(\cdot)$ は、制御工学ではインパルス関数に相当し、次式により定義される。

$$\delta(\mathbf{x} - \mathbf{s}^n) = \begin{cases} 1 & (\mathbf{x} = \mathbf{s}^n) \\ 0 & (\mathbf{x} \neq \mathbf{s}^n) \end{cases} \quad (5.2)$$

ベイズフィルタにおける遷移 (式 (2.1)) は、遷移関数 $f'(\cdot)$ と制御 \mathbf{u}_t によって遷移されたパーティクル $\mathbf{s}_{t|t-1}^n = f'(\mathbf{s}_{t-1|t-1}^n, \mathbf{u}_t)$ と式 (5.1) を利用して次式により表現される。

$$p(\mathbf{x}_t | \mathbf{z}_{1:t-1}^{1:M}, \mathbf{u}_{1:t}) \approx p(\mathbf{s}_{t|t-1}^n | \mathbf{z}_{1:t-1}^{1:M}, \mathbf{u}_{1:t}) = \frac{1}{N} \sum_{n=1}^N \delta(\mathbf{x}_t - \mathbf{s}_{t|t-1}^n) \quad (5.3)$$

次に、位置推定法 k ごとに、パーティクル $\mathbf{s}_{t|t-1}^n$ におけるセンサ m の観測 \mathbf{z}^m の観測確率 $p_k(\mathbf{z}_t^m | \mathbf{s}_{t|t-1}^n)$ を算出し、観測確率 $p_k(\mathbf{z}_t^m | \mathbf{s}_{t|t-1}^n)$ と式 (5.3) を式 (2.2) に代入す

ることで、時刻 t における位置推定法 k から得る存在確率分布 $p_k(\mathbf{x}_t | \mathbf{z}_{1:t-1}^{1:M}, \mathbf{z}_t^m, \mathbf{u}_{1:t})$ を算出する。

$$\begin{aligned} p_k(\mathbf{x}_t | \mathbf{z}_{1:t-1}^{1:M}, \mathbf{z}_t^m, \mathbf{u}_{1:t}) &\approx p_k(\mathbf{s}_{t|t-1}^n | \mathbf{z}_{1:t}^{1:M}, \mathbf{z}_t^m, \mathbf{u}_{1:t}) \\ &= \frac{1}{N} \sum_{n=1}^N p_k(\mathbf{z}_t^m | \mathbf{s}_{t|t-1}^n) \cdot \delta(\mathbf{x}_t - \mathbf{s}_{t|t-1}^n) \end{aligned} \quad (5.4)$$

各位置推定法から得る存在確率分布 $p_k(\mathbf{x}_t | \mathbf{z}_{1:t-1}^{1:M}, \mathbf{z}_t^m, \mathbf{u}_{1:t})$ を前章で提案した選択的融合の式 (4.1) で融合し、時刻 t における存在確率分布 $p(\mathbf{x}_t | \mathbf{z}_{1:t}^{1:M}, \mathbf{u}_{1:t})$ を算出する。

$$p(\mathbf{x}_t | \mathbf{z}_{1:t}^{1:M}, \mathbf{u}_{1:t}) \approx p(\mathbf{s}_{t|t-1}^n | \mathbf{z}_{1:t}^{1:M}, \mathbf{u}_{1:t}) = \eta \prod_{k=1}^K [p_k(\mathbf{s}_{t|t-1}^n | \mathbf{z}_{1:t-1}^{1:M}, \mathbf{z}_t^m, \mathbf{u}_{1:t})]^{\psi_k} \quad (5.5)$$

ここで、選択係数 ψ_k は、前章で提案した相関係数に基づく存在確率分布の相対評価により決定する。

最後に、存在確率分布 $p(\mathbf{s}_{t|t-1}^n | \mathbf{z}_{1:t}^{1:M}, \mathbf{u}_{1:t})$ に比例する確率で時刻 t における新たなパーティクル $\mathbf{s}_{t|t}^n$ を生成する。

5.3 実環境における検証

前章と同一のセンサ構成の移動体を利用して、実環境における検証を行った。

5.3.1 実験条件

愛知工業大学と名古屋大学の三つの環境で位置推定実験を行なった。4.5節と同様の移動体 (図 4.13) を利用した。各センサの観測確率のモデルも同様のものを利用し、制御 \mathbf{u}_t には、車輪オドメトリの値を利用した。各センサの観測を 0.2 秒ごとに取得、パーティクル数 $N = 100$ として位置推定を行った。また、提案法における閾値 ρ_{th} は、0.0 とした。本節における提案手法は、偶然誤差を低減可能なパーティクルフィルタと結合した手法であり、前章の実験より閾値を緩く設定できると考えて設定した。全ての位置推定法から得る存在確率分布を融合した場合と提案法による外れ値処理を施して融合した場合で位置推定誤差を比較した。




図 5.2. 実験環境 (ビルの谷間)

表 5.1. 図 5.2 の 330 秒で得た存在確率分布間の相関係数

	GNSS	Camera	LiDAR	L_m	Selection
GNSS	1	-0.784	-0.424	1	
Camera	-0.784	1	0.344	2	Use
LiDAR	-0.424	0.344	1	2	Use

(threshold value $\rho_{th} = 0$)

5.3.2 ビルの谷間における実験

最初の実験は、図 5.2 に示すビルの谷間で行った。移動体は図 5.2 上の黄色の線上を走行した。位置推定の結果を図 5.3 に示す。図 5.3 において、横軸は時間、縦軸は推定誤差を表している。推定誤差は、移動体の真の位置と推定位置間のユークリッド距離により算出した。図 5.3 からわかる通り、全てを融合した場合における最も大きな誤差は、黄色枠で囲った 6m 以上にも及ぶ。一方、提案手法の位置推定誤差は、3m 以内に収まっている。330s においてセンサから得た確率分布を図 5.4 に、相関係数の値を表 5.1 に示す。図 5.4 に示す確率分布のイメージにおいて、灰色、白色の領域はそれぞれ占有領域と非占有領域を表し、赤の濃さで移動体の存在確率を表し、緑丸で移動体の真の位置を表現している。図 5.4 は、LiDAR とカメラから得る存在確率分布において、真の位置から半径 1m 以内の円にあるパーティクルの存在確率が高くなっている。一方で、同じ領域にある GNSS のパーティクルの存在確率は、他の領域に比べ低くなっている。これは、GNSS の観測が大きな誤差を含んでいることを意味し、融合時に排除されるべきである。表 5.1 より、LiDAR とカメ




図 5.3. 図 5.2 における位置推定誤差

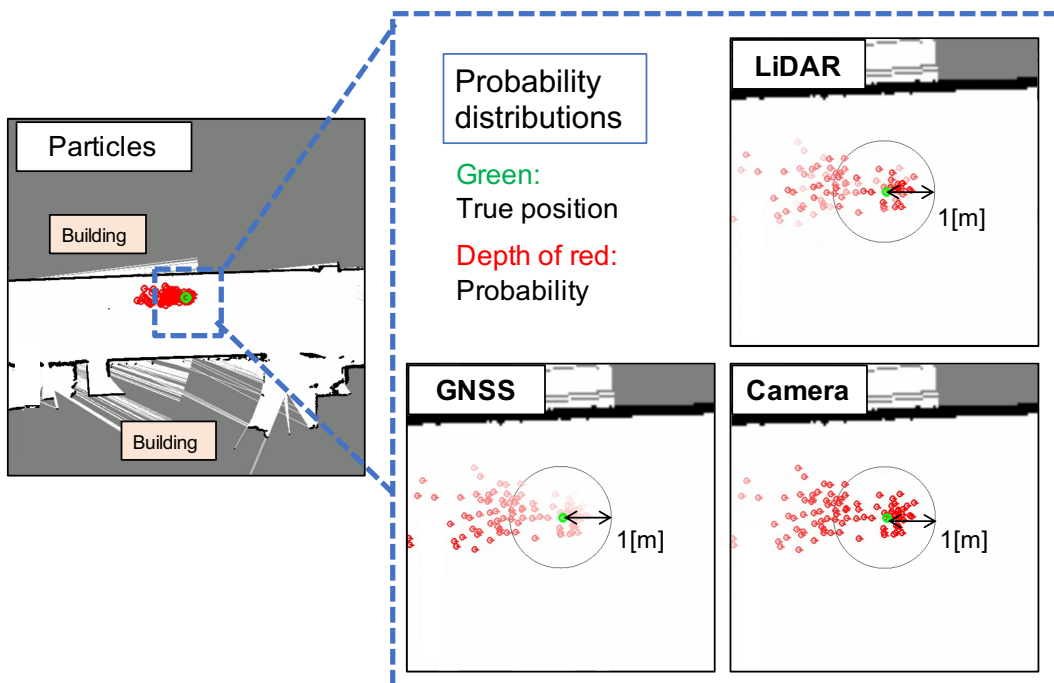


図 5.4. 図 5.2 の 330 秒で得た存在確率分布

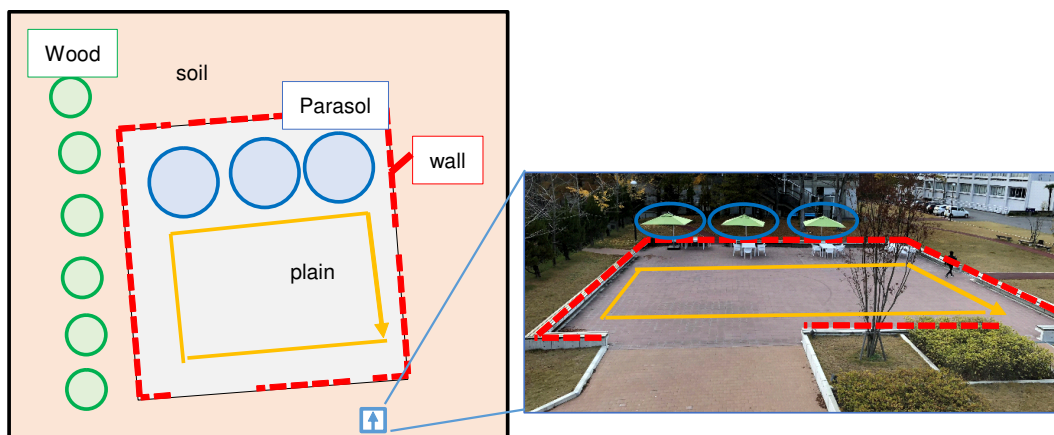


図 5.5. 実験環境 (広場)

表 5.2. 図 5.5 の 152 秒で得た存在確率分布間の相関係数

	GNSS	Camera	LiDAR	L_m	Selection
GNSS	1	0.298	-0.327	2	Use
Camera	0.298	1	-0.364	2	Use
LiDAR	-0.327	-0.364	1	1	

(threshold value $\rho_{th} = 0$)

ラとの間の相関係数が閾値より大きくなり、排除されたことを確認した。結果として、位置推定誤差を解消できた。

5.3.3 広場における実験

二つ目の実験は図 5.5 に示す広場で行い、黄色の線上を移動体が走行した。図 5.6 に位置推定結果を示す。図 5.6 内の黄色枠で囲った区間において、提案法における推定誤差が全てを融合した場合に比べ低減していることが確認できる。152s においてセンサから得た確率分布を図 5.7 に、相関係数の値を表 5.2 に示す。図 5.7 は、カメラと GNSS から得る存在確率分布において、真の位置から半径 1m 以内の円にあるパーティクルの存在確率が高くなっている。一方で、同じ領域にある LiDAR のパーティクルの存在確率は、他の領域に比べ低くなっている。これは、LiDAR の観測が大きな誤差を含んでいることを意味し、融合時に排除されるべきである。表 5.2 より、カメラと GNSS との間の相関係数が閾値より大きくなり、LiDAR から得る存在確率分布が排除されたことを確認した。結果として、位置推定誤差を解消できた。




図 5.6. 図 5.5 における位置推定誤差

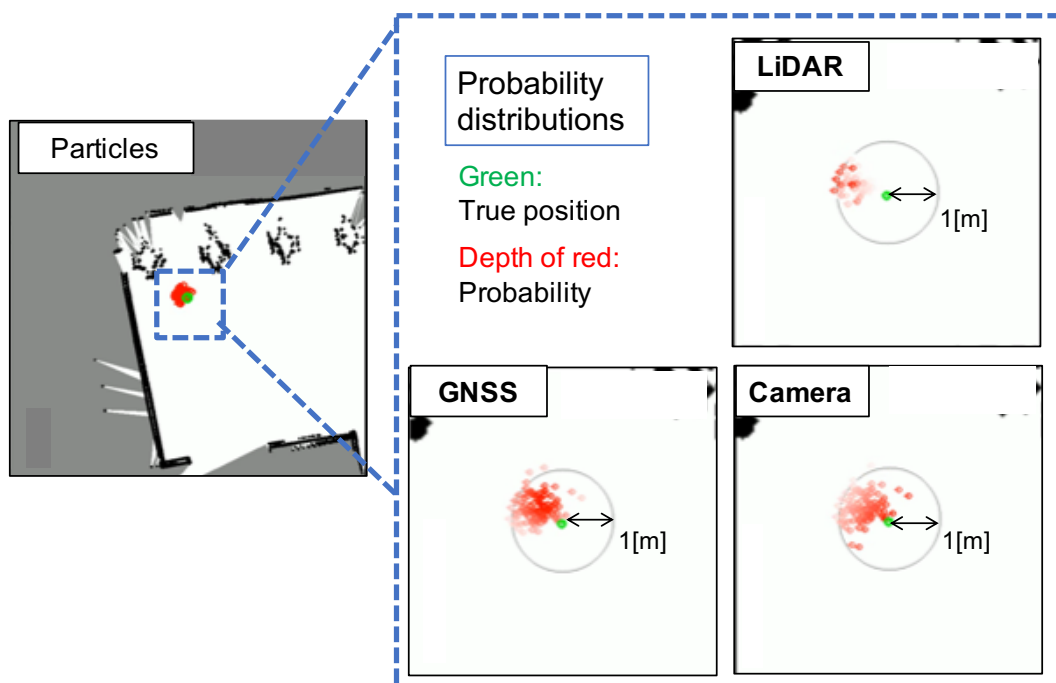


図 5.7. 図 5.5 の 152 秒で得た存在確率分布

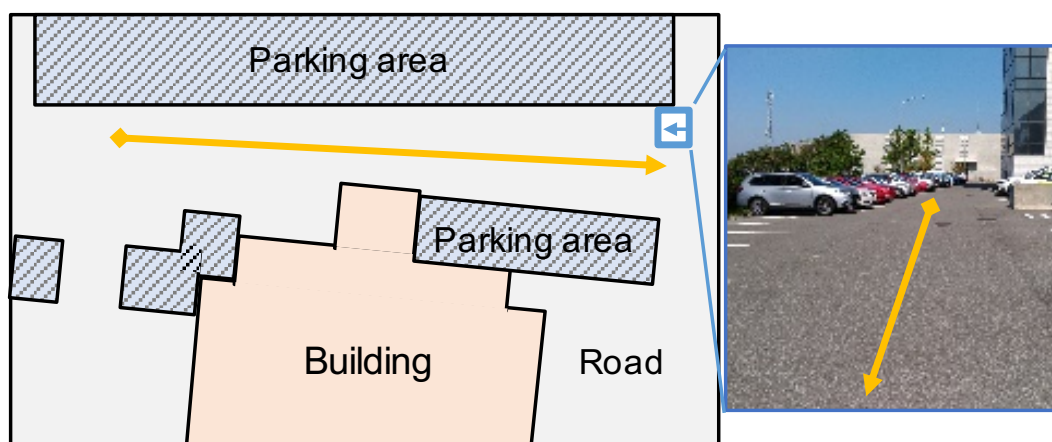


図 5.8. 実験環境 (駐車場)

表 5.3. 図 5.8 の 254 秒で得た存在確率分布間の相関係数

	GNSS	Camera	LiDAR	L_m	Selection
GNSS	1	0	0.286	2	Use
Camera	0	1	0	1	
LiDAR	0.286	0	1	2	Use

(threshold value $\rho_{th} = 0$)

5.3.4 駐車場における実験

三つ目の実験を図 5.8 に示す駐車場で行い、黄色線上を移動体で走行した。結果を図 5.9 に示す。図 5.9 より、全てを融合した場合、および、提案法において全ての区間で誤差 1m 以内の位置推定ができていることが確認できる。254 秒においてセンサから得た確率分布を図 5.10 に、相関係数の値を表 5.3 に示す。図 5.10 より、真の位値から 1m 以内の全てのパーティクルにおいて高い存在確率を有していることが確認できる。カメラのパーティクルについてみると、全てのパーティクルが同じ存在確率を有し、カメラから得る存在確率分布が一様分布であることが確認できた。一様分布は積による融合に悪影響を及ぼさないものの、一様分布単体では、位置を一意に特定できず破綻してしまう。つまり、提案法において、一様分布以外の分布も適切に選択しなければ、位置推定が破綻してしまう恐れがある。表 5.3 より、カメラ以外の分布を適切に選択することができ、融合する存在確率分布に一様分布が含まれていても提案法は有効に機能することが確認できた。




図 5.9. 図 5.8 における位置推定誤差




図 5.10. 図 5.8 の 254 秒で得た存在確率分布

5.3.5 考察

一つの位置情報が壊滅的な誤差を含んだ環境では、提案システムの位置推定誤差は、全てを融合した場合に比べ小さくなった。提案システムは、最大で6mの誤差を3mまで減少させることができた。さらに、いずれの位置推定法も壊滅的な誤差を含んだ位置情報を算出していない場合、提案システムの位置推定誤差は全てを融合した場合と同等になっている。提案システムは、壊滅的な位置推定誤差を含んだ位置情報を排除して融合することで、全てを融合した場合と同等、もしくは、それ以上の性能があることがわかった。以上より、「同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定のもと、提案システムのロバスト性向上を確認できた。

5.4 本章のまとめ

本章では、パーティクルフィルタによる時系列遷移を含めた複数環境における位置推定実験を行なった。提案システムは、「偶然誤差」を減少させるパーティクルフィルタによる時系列処理に、「系統誤差」を減少させる存在確率分布間の相対評価による外れ値処理機能を付加した。実機実験では、「同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定が成り立てば、提案手法による位置推定誤差は、全てを融合した場合の誤差に対して小さい、または、同等なった。本実験により、上記仮定のもとで、提案融合システムの有効性を確認した。次章では、本システムを応用した、位置推定法の信頼性マップ構築法について言及する。

第6章

位置推定法の信頼性マップ構築に向けた相対評価法の応用

6.1 はじめに

第4章では、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定のもと、真の位置における存在確率が著しく低い分布（バイアス分布）を外れ値として排除する手法を提案した。第5章では、パーティクルフィルタの理論に基づき、各位置推定法から得る位置情報を位置の存在確率分布で表現、相対比較による外れ値処理に基づき融合した分布を生成、生成された分布をもとに次時刻のセンサの観測を処理する方法を提案した。

本章では、存在確率分布の相対比較による外れ値処理法の応用として、位置推定法の信頼性マップ構築法について述べる。位置推定法の信頼性マップは、相対比較の結果を可視化することで、位置推定法の信頼性が低い領域を位置推定法ごとに教示するものである。複数の位置推定法で信頼性が低いと判定された領域は、「同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定を満たさず、外れ値処理に基づく融合システムにおいて誤差を適切に排除できない可能性が高い領域である。複数の位置推定法の信頼性が低い領域を信頼性マップから読み取り、その領域で機能する位置推定法を移動体に増設するか、環境に位置推定を補助するセンサを設置することで、その領域における位置推定の信頼性を向上させることができる。そこで、位置推定法の信頼性マップの構築法と信頼性マップの妥当性について、実環境におけるデータ解析を通して言及する。

6.2 信頼性マップ構築の手順

文献 [82] におけるセンサ信頼性マップを利用した。本論文で意味する位置推定法の信頼性マップとは、移動体が活動する領域ごとに、その手法の位置推定の信頼性

を示す指標である。信頼性マップの構築では、位置推定法ごとに信頼性マップを用意する。信頼性マップは、移動体が移動する環境全体を量子化した地図である。量子化された環境地図の各セルごとにその位置推定法の信頼度が割り当てられている。初期のマップは、全てのセルで一定の値が割り当てられている。移動体が走行する環境においてセンサの観測を手動走行で取得し、位置推定法ごとに推定位置を算出する。算出された推定位置を相対評価に基づく選択的融合法で融合し、時刻 t における融合後の推定位置 $\hat{\mathbf{x}}_t$ を算出する。融合位置周辺における各位置推定法の信頼性を、相対評価における選択結果に基づいて、決定する。具体的には、相対比較で選択されなかった位置推定法の信頼性マップにおいて、融合位置周辺におけるセルの信頼度を、以下に示す更新式を用いて更新する。

$$\text{Rel}_{i,j}^k = \begin{cases} \text{Rel}_{i,j}^k - 1 & (|\hat{\mathbf{x}}_t - r_{i,j}| < r_{th}) \\ \text{Rel}_{i,j}^k & (\text{otherwise}) \end{cases} \quad (6.1)$$

ここで、 $\text{Rel}_{i,j}^k$ は、位置推定法 k の信頼性マップ上の i, j 番目のセルに対する信頼度を表し、 $r_{i,j}$ は、 i, j 番目のセルの位置を表す。融合後の推定位置 $\hat{\mathbf{x}}_t$ と i, j 番目のセルの位置 $r_{i,j}$ の距離が閾値 r_{th} 未満のセルの信頼度 $\text{Rel}_{i,j}^k$ のみを下げる。閾値 r_{th} は環境マップ中のある位置において相対比較で得た選択結果と同様の結果が得られると考えられる範囲を表す。この更新式は、推定された位置で選択されなかった位置推定法はその周辺でも選択されない可能性が高い、という仮定の下で設計した。選択的融合法での位置推定結果とその際の位置推定法の選択結果が得られる毎に上記の更新を行うことで移動経路上周辺すなわち既知環境における信頼性マップを生成する。

6.3 実環境における検証

図 6.1 に示す名古屋大学 IB 館周辺の黄色の線上を LiDAR (Velodyne VLP-16)、ステレオカメラ (ZED2)、車輪オドメトリを搭載した移動体 (図 6.2) が走行し、位置推定法ごとに信頼性マップ作成を行った。ロボットは、(a) から東側に (b) へ向かい、(c)-(d)-(e) の順に巡回し、(a) に戻る。本環境は周辺に建物があり特徴的な物体が多い環境であるので、ステレオカメラや LiDAR の信頼性が高いと思われる。一方、歩道は凹凸が激しく、車輪オドメトリの誤差が生じやすい。さらに、(b)、(c) の位置を通過するには、図 6.1 にあるような柵を通過しなければならない、移動体が旋回するとき車輪オドメトリで大きな誤差が出ることが予想される。

本環境で検証する手法は、検証する手法は、LiDAR による NDT Mapping とステレオカメラによる ORB SLAM、車輪オドメトリによるデッドレコニングである。




図 6.1. 走行環境（名古屋大学 IB 館周辺）




図 6.2. 使用した移動体

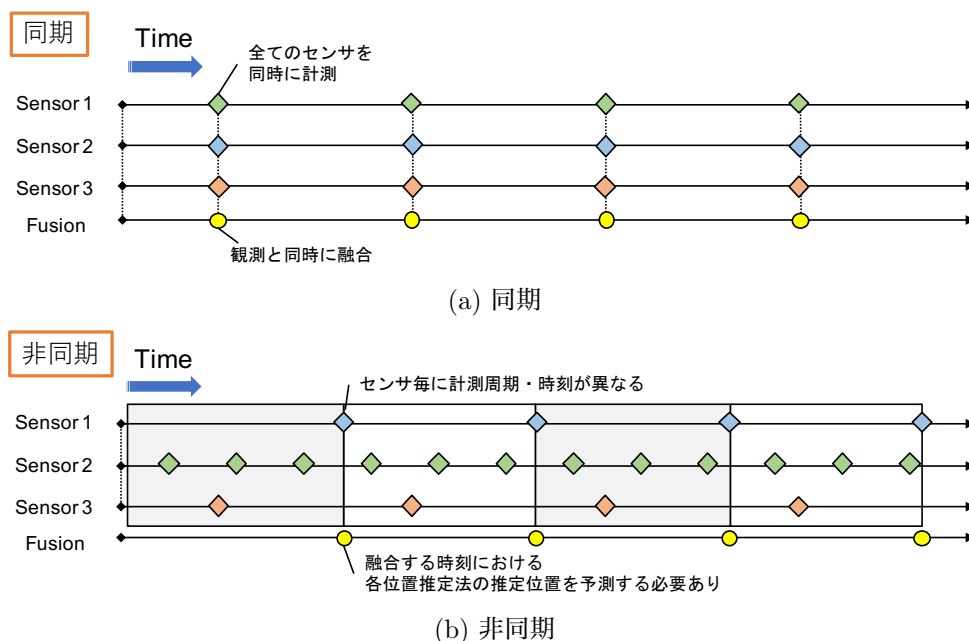


図 6.3. センサの観測の同期と非同期

LiDAR と車輪オドメトリは 10Hz で、ステレオカメラは 30Hz でセンサの観測を非同期で取得し、位置推定を行い、推定位置 \hat{x} を算出する。各位置推定法から得る位置情報の融合は、LiDAR と車輪オドメトリの計測周期である 10Hz に合わせた。手法ごとに位置の存在確率分布を正規分布（平均 \hat{x} と共分散 \mathbf{R} ）で算出する。NDT Mapping や ORB SLAM の推定位置の共分散行列の算出には、文献 [54] を参考に、最適化アプローチを利用した位置推定において、評価関数のヘッセ行列を利用して方法により設計した。

6.3.1 確率的な位置情報の融合法

各位置推定法から得る位置情報の選択法と融合法について述べる。本章における実験条件では、前章における条件と相違点が二つある。一つ目は、センサの観測が同期されていない点である。第 5 章の実験では、センサの観測は同期されていた。図 6.3(a) に示すように全てのセンサの観測は同時刻に取得されるため、各時刻で得たセンサの観測から位置情報を算出し、同時に相対比較を行うことができる。しかし、今回の移動体の構成では、センサの観測が同期されていない (図 6.3(b))。センサの観測が同期されていない場合、センサごとに観測を得る時刻が異なるため、それを利用して算出される位置情報も同期されていない。各位置推定法から得る位置情報のある時刻で融合する場合、その時刻における各位置推定法の推定位置を予測しな

ければならない。二つ目は、位置推定法としてSLAMを利用している点である。前章における位置推定では、事前に計測しセンサ間で地図の歪みに対する校正を行った地図を利用した。そのため、過去の位置推定誤差が影響することはなく、各位置推定法から算出される推定位置をそのまま融合すればよかった。しかし、本章ではSLAMによる検証を行う。SLAMでは、誤差が蓄積してしまうため、そのまま比較すると、過去の誤差の影響を大きく受けてしまう懸念がある。以上を受け、本章における実機実験では、非同期のセンサの観測を融合する方法と、蓄積誤差の影響を受けない移動体の相対位置を比較する方法について述べる。

6.3.1.1 アンセンテッドカルマンフィルタによる速度・角速度推定

各位置推定法から得る位置情報がある時刻で融合する場合、その時刻における各位置推定法の推定位置を予測しなければならない。本節では、各位置推定法から算出される推定位置から移動体の速度と角速度を算出する方法について述べる。これにより、融合する時刻における移動体の位置を速度と角速度を利用して予測することができる。移動体の速度と角速度の算出には、アンセンテッドカルマンフィルタ (Unscented Kalman Filter, UKF) を利用する。UKFは、非線形カルマンフィルタの一種であり、遷移や観測における関数をアンセンテッド変換を利用して非線形化している。UKFにより推定する状態を $\chi = (x, y, \theta, v, \omega)^T$ 、その共分散を \mathbf{P} として定義する。ここで、 x, y は移動体の位置、 θ は移動体の進行方向、 v は移動体の速さ、 ω は進行方向 θ の角速度である。時刻 t^k において、位置推定法 k から得る移動体の推定位置 $\hat{\mathbf{x}}_{t^k}^k = (\hat{x}_{t^k}^k, \hat{y}_{t^k}^k, \hat{\theta}_{t^k}^k)^T$ とその共分散行列 $\mathbf{R}_{t^k}^k$ を利用して、時刻 t^k における移動体の状態 $\chi_{t^k|t^k}^k$ と共分散 $\mathbf{P}_{t^k|t^k}^k$ を推定する。

遷移

時刻 $t^k - 1$ における移動体の状態 $\chi_{t^k-1|t^k-1}^k$ と共分散行列 $\mathbf{P}_{t^k-1|t^k-1}^k$ を、遷移関数 $f(\cdot)$ を利用して遷移させ、時刻 t^k における移動体の状態 $\chi_{t^k|t^k-1}^k$ とその共分散行列 $\mathbf{P}_{t^k|t^k-1}^k$ を予測する。

まず、時刻 $t^k - 1$ における移動体の状態 $\chi_{t^k-1|t^k-1}^k$ と共分散行列 $\mathbf{P}_{t^k-1|t^k-1}^k$ から、次式により、シグマ点 $\pi_{t^k-1|t^k-1}^{k,i}$ を算出する。

$$\begin{cases} \pi_{t^k-1|t^k-1}^{k,0} = \chi_{t^k-1|t^k-1}^k \\ \pi_{t^k-1|t^k-1}^{k,i} = \chi_{t^k-1|t^k-1}^k + \left(\sqrt{(L + \lambda)\mathbf{P}_{t^k-1|t^k-1}^k} \right)_i, (i = 1, \dots, L) \\ \pi_{t^k-1|t^k-1}^{k,i} = \chi_{t^k-1|t^k-1}^k - \left(\sqrt{(L + \lambda)\mathbf{P}_{t^k-1|t^k-1}^k} \right)_i, (i = L + 1, \dots, 2L) \end{cases} \quad (6.2)$$

ここで, L は, 状態 χ_t の次元数 ($L = 5$), $\left(\sqrt{(L + \lambda)\mathbf{P}_{t^k-1|t^k-1}^k}\right)_i$ は $(L + \lambda)\mathbf{P}_{t^k-1|t^k-1}^k$ の平方根の i 列目の要素である.

時刻 t^k で予測されるシグマ点 $\pi_{t|t-1}^{k,i}$ は, 遷移関数 $f'(\cdot)$ とシグマ点 $\pi_{t-1|t-1}^{k,i}$ を利用して算出される.

$$\pi_{t^k|t^k-1}^{k,i} = f' \left(\pi_{t^k-1|t^k-1}^{k,i} \right) \quad i = 0, \dots, 2L \quad (6.3)$$

ここで, 時刻 $t-1$ における状態 $\chi_{t-1|t-1}$ から時刻 t における状態 $\chi_{t|t-1}$ を予測する遷移関数 $f'(\cdot)$ を以下の式により定義する.

$$\chi_{t|t-1} = f' \left(\chi_{t-1|t-1} \right) = \begin{cases} x_{t-1|t-1} + v_{t-1|t-1} \cdot \Delta_{t|t-1} \cdot \cos \theta_{t-1|t-1} \\ y_{t-1|t-1} + v_{t-1|t-1} \cdot \Delta_{t|t-1} \cdot \sin \theta_{t-1|t-1} \\ v_{t-1|t-1} \\ \theta_{t-1|t-1} + \Delta_{t|t-1} \cdot \omega_{t-1|t-1} \\ \omega_{t-1|t-1} \end{cases} \quad (6.4)$$

ここで, $\Delta_{t^k|t^k-1}$ は, t^k と t^k-1 の時間差である.

時刻 t^k で予測される状態 $\chi_{t^k|t^k-1}^k$ とその共分散行列 $\mathbf{P}_{t^k|t^k-1}^k$ は次式により算出される.

$$\chi_{t^k|t^k-1}^k = \sum_{i=0}^{2L} W_S^i \pi_{t^k|t^k-1}^{k,i} \quad (6.5)$$

$$\mathbf{P}_{t^k|t^k-1}^k = \sum_{i=0}^{2L} W_c^i \left[\pi_{t^k|t^k-1}^{k,i} - \chi_{t^k|t^k-1}^k \right] \left[\pi_{t^k|t^k-1}^{k,i} - \chi_{t^k|t^k-1}^k \right]^T + \mathbf{Q}_{t^k} \quad (6.6)$$

ここで, 状態に対する重みと共分散行列に対する重み W_s^i, W_c^i は, 次式により算出される

$$\begin{aligned} W_s^0 &= \frac{\lambda}{L + \lambda} \\ W_c^0 &= \frac{\lambda}{L + \lambda} + (1 - \alpha^2 + \beta) \\ W_s^i &= W_c^i = \frac{1}{2(L + \lambda)} \end{aligned} \quad (6.7)$$

$$\lambda = \alpha^2(L + \kappa) - L$$

ここで, α と κ は, それぞれ, シグマ点の拡散性をコントロールする値であり, β は, 位置 $\hat{\mathbf{x}}_t$ に関する分布である.

更新

時刻 t^k に位置推定法 k から得る推定位置 $\hat{\mathbf{x}}_{t^k}$ とその共分散行列 \mathbf{R} を利用して、時刻 t^k における移動体の状態 $\chi_{t^k|t^k}^k$ とその共分散行列 $\mathbf{P}_{t^k|t^k}^k$ を算出する。

まず、時刻 t^k で予測される状態 $\chi_{t^k|t^{k-1}}^k$ とその共分散行列 $\mathbf{P}_{t^k|t^{k-1}}^k$ を利用して、シグマ点 $\pi_{t^k|t^{k-1}}^{k,i}$ を算出する。

$$\begin{cases} \pi_{t^k|t^{k-1}}^{k,0} = \chi_{t^k|t^{k-1}}^k \\ \pi_{t^k|t^{k-1}}^{k,i} = \chi_{t^k|t^{k-1}}^k + \left(\sqrt{(L+\lambda)\mathbf{P}_{t^k|t^{k-1}}^k} \right)_i, (i = 1, \dots, L) \\ \pi_{t^k|t^{k-1}}^{k,i} = \chi_{t^k|t^{k-1}}^k - \left(\sqrt{(L+\lambda)\mathbf{P}_{t^k|t^{k-1}}^k} \right)_i, (i = L+1, \dots, 2L) \end{cases} \quad (6.8)$$

推定位置に関するシグマ点を算出する。

$$\mathbf{X}_{t^k|t^{k-1}}^{k,i} = \left(x_{t^k|t^{k-1}}^i, y_{t^k|t^{k-1}}^i, \theta_{t^k|t^{k-1}}^i \right)^T \quad (6.9)$$

これは、シグマ点 $\pi_{t^k|t^{k-1}}^{k,i}$ の位置 x, y と角度 θ の要素を抽出した値である。

時刻 t^k で予測される位置 $x_{t^k|t^{k-1}}^k$ とその共分散 $\mathbf{S}_{t^k|t^{k-1}}^k$ を次式により算出する。

$$\mathbf{x}_{t^k|t^{k-1}}^k = \sum_{i=0}^{2L} W_S^i \mathbf{X}_{t^k|t^{k-1}}^{k,i} \quad (6.10)$$

$$\mathbf{S}_{t^k|t^{k-1}}^k = \sum_{i=0}^{2L} W_c^i \left[\mathbf{X}_{t^k|t^{k-1}}^{k,i} - \mathbf{x}_{t^k|t^{k-1}}^k \right] \left[\mathbf{X}_{t^k|t^{k-1}}^{k,i} - \mathbf{x}_{t^k|t^{k-1}}^k \right]^T + \mathbf{R}_{t^k}^k \quad (6.11)$$

状態 χ と位置 \mathbf{x} の相互共分散は次式となる。

$$\mathbf{C}_{t^k|t^{k-1}}^{\chi, \mathbf{x}} = \sum_{i=0}^{2L} W_c^i \left[\pi_{t^k|t^{k-1}}^{k,i} - \chi_{t^k|t^{k-1}}^k \right] \left[\mathbf{X}_{t^k|t^{k-1}}^{k,i} - \mathbf{x}_{t^k|t^{k-1}}^k \right]^T \quad (6.12)$$

カルマンゲイン $\mathbf{Kg}_{t^k|t^{k-1}}$ は、次式により算出される。

$$\mathbf{Kg}_{t^k|t^{k-1}} = \mathbf{C}_{t^k|t^{k-1}}^{\chi, \mathbf{x}} \left(\mathbf{S}_{t^k|t^{k-1}}^k \right)^{-1} \quad (6.13)$$

時刻 t^k における移動体の状態 $\chi_{t^k|t^k}^k$ とその共分散行列 $\mathbf{P}_{t^k|t^k}^k$ は、次式により算出される。

$$\chi_{t^k|t^k}^k = \chi_{t^k|t^{k-1}}^k + \mathbf{Kg}_{t^k|t^{k-1}} \left(\hat{x}_t^k - x_{t^k|t^{k-1}}^k \right) \quad (6.14)$$

$$\mathbf{P}_{t^k|t^k}^k = \mathbf{P}_{t^k|t^{k-1}}^k - \mathbf{Kg}_{t^k|t^{k-1}} \chi_{t^k|t^k}^k \left(\mathbf{Kg}_{t^k|t^{k-1}} \right)^T \quad (6.15)$$

以上の式により、時刻 t^k において、位置推定法 k から得る移動体の状態 $\chi_{t^k|t^k}^k$ を推定し、速度 $v_{t^k|t^k}^k$ と角速度 $\theta_{t^k|t^k}^k$ を算出する。

6.3.1.2 相対移動量比較による融合

時刻 t^f において、各位置推定法から得る状態の類似性を比較する。各位置推定法から状態 $\chi_{t^k|t^k}^k$ と共分散 $\mathbf{P}_{t^k|t^k}^k$ を得る。まず、同期ずれを解消するために、式(6.2)-(6.6)を利用して、融合する時刻 t^f における $\chi_{t^f}^k$ と $\mathbf{P}_{t^f}^k$ を得る。 $\chi_{t^f}^k$ と $\mathbf{P}_{t^f}^k$ を比較するが、そのまま比較してしまうと、各位置推定法から得る推定位置の誤差がそのまま累積してしまい、互いに離れてしまい、類似性が出ない可能性がある。そこで、 $t^f - 1$ からの相対位置 $d_{t^f|t^f-1}^k$ を利用する。相対移動量であれば、SLAM による累積誤差を無視した融合を行える。各位置推定法から得る相対位置の類似性を次式により算出する。

$$\text{Mh}_{k-l} = \left(d_{t^f|t^f-1}^k - d_{t^f|t^f-1}^l \right) \left(\mathbf{P}_{t^f}^k \right)^{-1} \left(d_{t^f|t^f-1}^k - d_{t^f|t^f-1}^l \right)^T \quad (6.16)$$

式(6.16)は、マハラノビス距離と呼ばれ、正規分布間の相関性を評価するために利用される値である。式(6.16)は、マハラノビス距離は、 k と l のどちらを起点とするかによって値が変わってしまう。起点によって値が変わらないように、以下の値を利用する。

$$\text{Mh}_{k,l} = \frac{\text{Mh}_{k-l} + \text{Mh}_{l-k}}{2} \quad (6.17)$$

前章で提案した相対比較により、融合する分布を選択する。選択された分布は、正規分布間の積により融合される。

$$\mathbf{P}_{t^f} = \left(\sum_{k=1}^K \left(\mathbf{P}_{t^f}^k \right)^{-1} \right)^{-1} \quad (6.18)$$

$$\chi_{t^f} = \mathbf{P}_{t^f} \cdot \sum_{k=1}^K \left(\mathbf{P}_{t^f}^k \right)^{-1} \chi_{t^f}^k \quad (6.19)$$

各位置推定器は、統合した値を利用して位置推定を続ける。選択結果をマップに反映させる。

6.3.2 結果と考察

結果を図6.4-6.6に示す。白がロボットの走行経路、赤の濃さが位置情報の信頼性の低さ、灰が実領域を表している。図6.5,6.6より、ステレオカメラやLiDARの信頼性は高い。これは、本環境は周辺に建物があり特徴的な物体が多い環境であり、ステレオカメラやLiDARの位置推定の信頼性が高い知見と一致する。一方、図6.4より、全経路においてオドメトリの位置推定の信頼性が低いことが確認できる。歩道は凹凸が激しく、車輪オドメトリの誤差が生じやすい。特にオドメトリの信頼性




図 6.4. 車輪オドメトリのデッドレコニングによる信頼性マップ

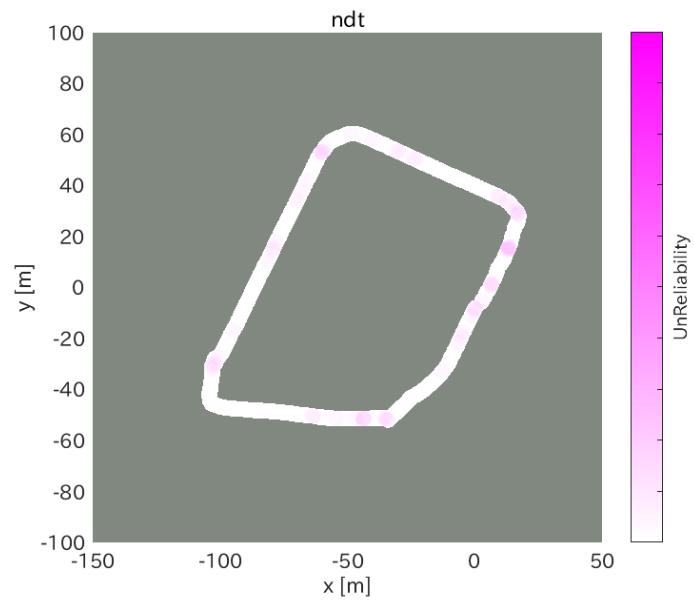


図 6.5. NDT による信頼性マップ




図 6.6. ORB による信頼性マップ

が低くなった区間が二箇所ある。ここは、通路を通過するために柵を通る必要があり、移動体を旋回させながら柵を通過するため、オドメトリの回転方向に非常に誤差のりやすい。この区間では特にオドメトリが排除される結果が得られたことから、適切な信頼性マップを構築できたと考える。以上より、相対評価の結果を可視化により、走行環境に対する位置推定法の特徴を解析できる。さらに、黄色の区間では、全ての位置推定法で誤差が信頼性が低い場合が存在する。この区間は、全ての位置推定法で信頼性が低いことを示し、位置推定の破綻が起きる可能性がある領域と言える。この区間には、環境中に移動体の位置を教示するシステムを設置すれば、安定した自律移動を行える可能性がある。位置推定法の信頼性マップを利用することで、位置推定のロバスト性向上のために対策する必要がある領域を可視化することができた。

6.4 本章のまとめ

本章では、相対比較による外れ値処理法の応用として、選択結果を移動環境の領域ごとに可視化する位置推定法の信頼性マップを構築法を提案した。移動体が移動する空間に対して、選択結果に基づいて信頼値を更新し、外れ値として検出・排除された回数が多い位置推定法をその領域で位置推定の信頼性が低い手法として教示する。複数の位置推定法で信頼性が低いと判定された領域は、位置推定が破綻する

可能性が高い領域である。実環境における検証では、信頼性マップを利用して環境ごとに位置推定法の精度の信頼性を解析できることを確認した。車輪オドメトリによる位置推定の信頼性が環境で全体的に低くなった。これは、走行経路は凹凸が激しく、車輪オドメトリによる位置推定に誤差がのりやすいという事前知識と一致した。さらに、環境中に柵がある領域では、信頼性が特に低くなった。以上より、環境の事前知識から想定されるセンサの信頼性に合致した信頼性マップが構築されていることが確認できた。

第7章

実世界データ循環学との関係

7.1 はじめに

実世界データ循環とは、実世界に存在するデータを活用してシステムの性能を向上させる概念である [83]。ここでいうデータとは、サービスにおける顧客の情報や、センサにより得る環境情報などが該当する。実世界におけるデータを有効に利用することで、サービスや商品の質を再帰的に向上させていく。本コンセプトでは、実世界で得るデータの取得・解析・実装の循環によりシステムの質の向上させていく。データの取得では、実世界のあらゆる情報をデータとして取得する。インターネットの普及、小型・高性能なセンシングデバイスの発展を背景に実世界から膨大な量のデータを取得できるようになっている。データの解析では、取得したデータを処理して、新たな知見を得る。データ処理における情報技術には、統計解析や機械学習などが利用される。データの実装では、解析結果に基づいて、新たなサービスや商品を作る。新規サービスや商品を介して新たなデータを取得し、データを解析、解析結果に基づいてサービスや商品の質を再帰的に向上させていくコンセプトが実世界データ循環である。

本章では、実世界データ循環のコンセプトに基づいて、位置推定のロバスト性を向上させる概念を提案する。7.2節では、本論文における、データの取得・解析・実装に相当する箇所について述べる。7.3節では、データ循環に基づく位置推定のロバスト性向上について述べる。

7.2 本論文におけるデータの取得・解析・実装

本節では、本論文で述べた項目と実世界データの取得・解析・実装の関係について述べる (図 7.1)。本論文におけるデータとは、位置推定法を通して得る位置情報が相当する。第3章の内容は、位置推定法の多重化の有効性と外れ値処理による位

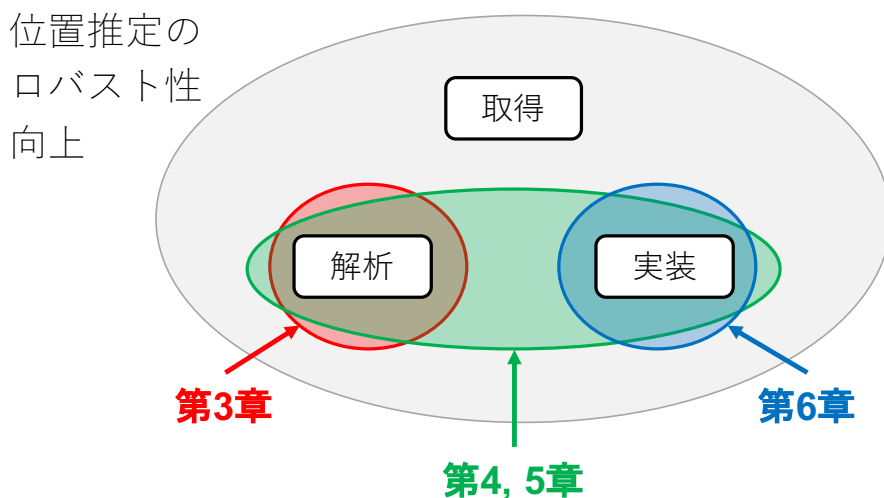


図 7.1. 実世界データの取得・解析・実装と本論文の関係

置情報の解析であった。位置推定を破綻させる影響を持つ壊滅的な「系統誤差」の低減を目的とし、位置推定法の多重化とそれに適した統計的融合法について検証した。センサの観測を複数の位置推定法で多角的に解析し、外れ値処理に基づいて融合することで、位置推定のロバスト性が向上することが確認できた。これは、実世界データ循環におけるデータの取得と解析に相当する。第4章と第5章の内容は、確率的に表現された複数の位置情報を相対的に評価して外れ値を検出する手法の提案と、それを利用した時系列処理による確率的な位置推定法を提案した。第4章では、位置情報を相関を利用して評価することの有効性を示すことができた。第5章では、相対評価法を確率的な位置推定法に実装することで、位置推定のロバスト性が向上することを確認できた。これは、実世界データ循環におけるデータの解析と実装に該当する。第6章では、相対比較の結果を可視化する位置推定法の信頼性マップを提案した。これは、複数の手法で位置推定の信頼性が低い領域を可視化することで、位置推定が破綻する可能性が高い領域を視覚化し、追加の位置推定法増設を提示するものであった。これは、解析結果の実装の一つである。以上、本論文では、データ取得に関する内容を第3章で、データ解析に関する内容を第3, 4章で、解析結果の実装事例を第5章、第6章で述べた。

7.3 データ循環による位置推定のロバスト性向上

先の章で述べたデータの取得・解析・実装の循環により、位置推定のロバスト性を向上させる方法について述べる (図 7.2)。

まず移動体に多種多様なセンサを搭載し、多角的に環境を観測する。取得したセンサデータを多種多様な位置推定法で処理し、複数の位置情報を算出する（データの取得）。算出された位置情報を相対比較して、その領域における位置推定法の信頼性を評価する（データの解析）。相対評価の結果を可視化することで、位置推定が破綻する可能性がある領域を教示する位置推定法の信頼性マップを構築する（データの実装）。複数の位置推定法の信頼性が低い領域を信頼性マップから読み取り、その領域で機能するセンサを移動体に増設するか、環境に位置推定を補助するセンサを設置することで、その領域における位置推定の信頼性を向上させる。新たな位置推定系で環境のセンサデータを再度取得し、相対評価により解析、解析結果に基づいて位置推定法の信頼性マップを更新する。上記を繰り返すことで、移動体が走行する環境全体において安定して動作する位置推定系を構築することができる。

センサデータが集まれば集まるほど、多種多様な環境の変化が反映された位置推定法の信頼性マップを構築できる。時間帯、季節ごとにいろいろな環境条件で得たセンサデータにより位置情報を算出し、相対評価の結果をもとに信頼性マップを更新することで、多種多様な環境条件の変化が反映された信頼性マップを構築できる。また、環境中を複数の移動体が走行している場合、各移動体から得るセンサデータを集約し解析することで、より効率的な位置推定法の信頼性マップ構築ができる。その信頼性マップに従って、位置推定法が苦手な領域を明確にし補償することで、移動体が活動する全領域に対して安定した動作が可能な位置推定系を構築することができる。センサデータの循環により、センサデータが集まれば集まるほど、位置推定のロバスト性を向上させることができる。

7.4 本章のまとめ

本章では、実世界データ循環と本研究との関係性について述べた。実世界データ循環とは、実世界に存在するデータを活用してシステムの性能を向上させるコンセプトである。本章では、データ循環のコンセプトを活用した位置推定のロバスト性向上に向けたアプローチについて述べた。センサデータの取得、複数の位置推定法により複数の位置情報を算出、位置情報間の相対評価によりその領域で信頼性が低い位置情報を検出、位置推定法の信頼性マップの構築による信頼性の可視化を行う。複数の位置推定法で信頼性が低い領域を補償する新たな位置推定法を増設し、再度センサデータの取得、解析、実装することで、位置推定のロバスト性を再帰的に向上させるコンセプトについて述べた。

データ循環による位置推定のロバスト性向上

- ① センサデータを複数の位置推定法で処理し、複数の位置情報を算出（取得）。
- ② 位置情報を相対比較して、その領域における位置推定法の信頼性を評価（解析）。
- ③ 評価結果を可視化する信頼性マップを位置推定法ごとに構築（実装）。
- ④ 複数の位置推定法の信頼性が低い領域を信頼性マップから読み取り、その領域で動作する位置推定法を増設し、再度位置情報を取得（取得）。
- ⑤ 上記を繰り返す、走行環境全体でロバストに動作可能な位置推定法を構築する。

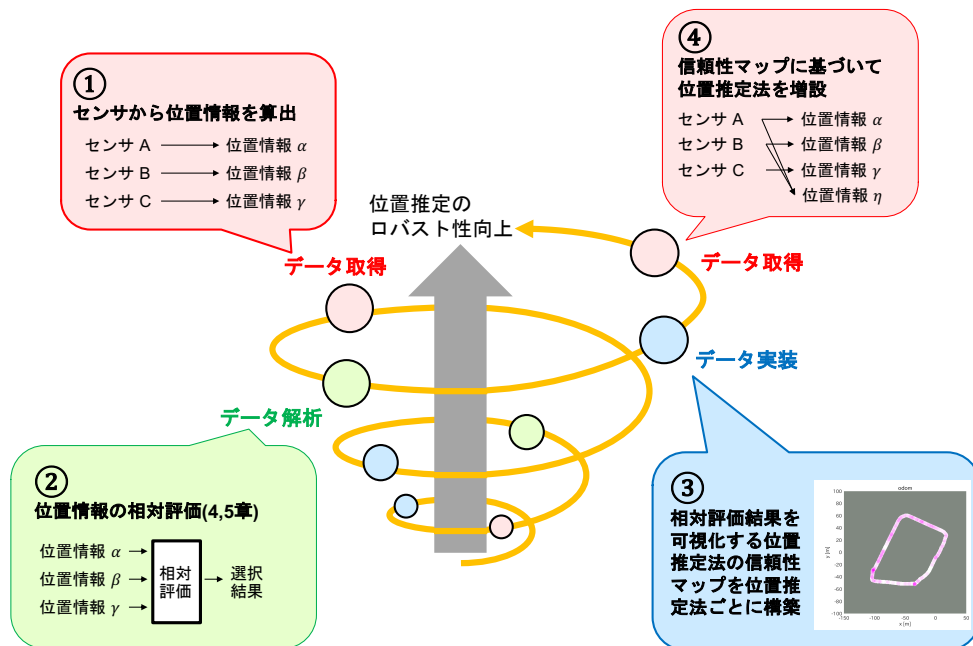


図 7.2. データ循環による位置推定のロバスト性向上

第8章

結言

本論文では、自律移動体の位置推定のロバスト性向上を目指したセンサ融合に関する研究の成果をまとめた。本章では、本研究全体を総括し、今後の展望について述べる。

8.1 本研究のまとめ

本論文では、移動体の自律移動の要素技術の一つである位置推定において、センサ融合によりロバスト性を向上させるために取り組んだ一連の研究をまとめた。

第1,2章では、本研究の背景と従来研究について述べた。自律移動体の活用範囲は、自律移動のために整備されていない環境に拡大している。安全・確実に動作する自律移動体を実現するには、位置推定のロバスト性向上が求められる。位置推定における誤差は、「偶然誤差」と「系統誤差」に分類される。一般的な位置推定系の開発では、センサの観測の時系列処理により偶然誤差に対処し、環境要因のモデル化により系統誤差に対処してきた。しかし、移動体が活動する実環境は、非常に多くの環境要因が予測不能に変化してしまうため、モデル化されていない環境要因の変化により壊滅的な位置推定誤差が生じてしまう場合がある。モデル化されていない環境要因の変化により壊滅的な推定誤差が生じた場合、自律移動系全体の動作が破綻し、重大事故につながる危険性がある。位置推定の破綻を防ぐためには、環境要因のモデル化に加え、それとは異なるアプローチにより系統誤差に対処する必要がある。

本研究では、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定のもと、センサと位置推定法の多重化により得る複数の位置情報を外れ値処理を施して融合する手法を提案することを述べた。これにより、モデル化されていない環境要因の変化により壊滅的な系統誤差が生じた場合でも、提案する外れ値処理で対処することで、ロバスト性が高い位置推

定を行えるシステムの実現を目指している。本論文では、先の仮定のもと、「系統誤差」と「偶然誤差」に対処できる位置推定法の実現を目指し、1. 「系統誤差」に対する外れ値処理の有効性の検証、2. 「系統誤差」と「偶然誤差」への対処を目指した、外れ値処理法を利用したベイズフィルタによる位置推定法の提案に取り組むことを述べた。さらに、3. 位置推定のロバスト性向上を目指した2. の応用として、位置推定法の信頼性マップ構築法の提案を行うことを述べた。

1. モデル化されていない環境要因の変化により生じる「系統誤差」に対する外れ値処理の有効性の検証

先の仮定のもとでは、壊滅的な推定誤差を含む位置情報は、他の推定位置に対して著しく離れた外れ値になる。複数の位置推定法から得る推定位置の集合からその代表値を得る方法の一つであるメディアンは、外れ値の影響を受けにくい融合法とされる。第3章では、KITTI Odometry Benchmark が提供するカメラとLiDARから得る観測データを、LiDARによる位置推定法、カメラによる位置推定法、LiDARとカメラによる位置推定法を通して複数の推定位置を算出、メディアンにより融合することの有効性を検証した。検証実験では、モデル化されていない環境要因の変化により系統誤差が生じることで位置推定が破綻してしまう場合があることが確認できた。その誤差が生じてしまった環境において、先の仮定を満たしていれば、外れ値の影響を受けにくいメディアンにより推定位置を融合することで、個々の位置推定法や平均よりもロバスト性が高い位置推定を行うことができた。一方、この仮定を満たすことができない環境があることも確認され、個々の位置情報が持つ壊滅的な推定誤差をメディアンにより排除できないことがわかった。先の仮定を満たすためには、この環境下で精度よく位置推定ができる手法を増設する必要があると考えられる。以上より、先の仮定を満たしていれば、外れ値処理により、位置推定を破綻させる影響を持つ壊滅的な「系統誤差」を低減できることがわかった。

2. 「系統誤差」と「偶然誤差」への対処を目指した外れ値処理法を利用したベイズフィルタによる位置推定法の提案

ベイズフィルタに代表される確率的位置推定法は、「偶然誤差」に対処できることから、位置推定の分野で広く活用されている。確率的位置推定法では、各位置推定法から得る位置情報を位置の存在確率分布として表現することで、位置の不確実性を表現する。センサ融合では、各位置推定法から確率分布を積により融合することで、位置の不確実性を考慮して融合できる。しかし、積により融合される分布の中に、真の位置における存在確率が著しく低い分布（バイアス分布）が含まれると、位置推定が破綻する例が報告されている [19]。バイアス分布は、モデル化されていない環境要因の変化により生じる「系統誤差」

が反映された分布であり、確率的位置推定法では対処できない。第3章における実験にて、「系統誤差」に対して外れ値処理が有効であることを確認した。そこで、第4,5章では、ベイズフィルタを利用したセンサの観測の時系列処理による「偶然誤差」への対処と、外れ値除去による「系統誤差」への対処を複合した手法を提案した。

第4章では、確率的位置情報における外れ値除去法を提案した。自律移動移動体の自己位置推定におけるロバスト性向上のために、特性が異なる複数のセンサから得る存在確率分布の相対比較による外れ値処理に基づく融合法を提案した。先行研究では、存在確率分布の類似性に基づいて外れ値を検出・排除し残りを融合するシステムが提案されたが、類似性評価指標と選択法に問題があり、外れ値を適切に排除できない場合があった。そこで、新たな融合システムとして確率分布の1対比較による選択、および、新たな類似性評価指標として相関に基づく手法を提案した。シミュレーションおよび実環境における検証において、先行研究における融合システムに対する提案融合システムの有効性を確認した。これにより、確率的位置情報における外れ値除去法を構築することができた。

第5章では、第4章で提案した「系統誤差」に対処できる外れ値除去法を、「偶然誤差」を減少させるパーティクルフィルタによる時系列処理に適用した位置推定法を提案した。これにより、「系統誤差」と「偶然誤差」に対処可能な手法の枠組みを提案した。実機実験では、センサの数を外れ値処理が機能する最低限の数である三つとして検証を行った。提案手法による位置推定誤差は、全てを融合した場合の誤差に対して小さい、または、同等となった。「系統誤差」と「偶然誤差」への対処を目指した、外れ値処理法を利用したベイズフィルタによる位置推定法が有効に機能することを確認できた。

3. 位置推定法の信頼性マップ構築に向けた相対評価法の応用

第5章で提案した相対比較による外れ値処理法の応用として、位置推定法の信頼性マップ構築法について第6章で述べた。位置推定法の信頼性マップは、相対比較の結果を可視化することで、位置推定法の信頼性が低い領域を位置推定法ごとに教示するものである。位置推定法の信頼性マップの構築法と信頼性マップの妥当性について、実環境におけるデータ解析を通して言及した。実環境における実験により、環境の事前知識から想定されるセンサの信頼性に合致した信頼性マップが構築されていることが確認できた。

本論文で提案した手法を実世界データ循環の枠組みにあてはめ、第7章では、本論文の各章で提案した方法を利用した位置推定のロバスト性向上の方法について言及した。本研究で提案する位置推定のロバスト性向上の方法は以下の通りである。ま

ず移動体に多種多様なセンサを搭載し、多角的に環境を観測する。取得したセンサデータを複数の位置推定法で処理し、複数の位置情報を算出する（取得）。算出した位置情報を相対比較して、その領域における位置推定法の信頼性を評価する（解析）。評価結果が反映された位置推定法の信頼性マップを構築する（実装）。複数の位置推定法の信頼性が低い領域を信頼性マップから読み取り、その領域で動作する位置推定法を増設し、再度位置情報を取得する（取得）。上記を繰り返す、走行環境全体でロバストに動作可能な位置推定法を構築する。センサデータが集まれば集まるほど、多種多様な環境の変化が反映された位置推定法の信頼性マップを構築できる。その信頼性マップに従って、位置推定法が苦手な領域を明確にし補償することで、移動体が活動する全領域に対して、多様な環境条件で安定した動作が可能な位置推定系を構築することができる。これは、実世界データ循環のコンセプトに基づいて構築している点について、第7章で述べた。

本論文全体を通して、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定が成り立つ場合に、以下の二点を達成した。

- 「系統誤差」と「偶然誤差」への対処を目指した、外れ値処理法を利用したベイズフィルタによる位置推定法を提案した。第3章では、位置推定法ごとでモデル化されていない環境要因の変化による系統誤差が生じてしまう場合があることを実データにより確認し、壊滅的な系統誤差が生じている位置情報を外れ値として検出・排除可能なことを確認した。第4章では、確率的な位置情報において外れ値処理を行う手法を提案し、先の仮定のもとで壊滅的な誤差を含むバイアス分布を適切に排除できることを確認した。第5章では、確率的な位置情報を利用した時系列処理による位置推定法を提案した。実環境における検証では、複数の環境下で、提案手法による位置推定誤差が、全てを融合した場合の誤差に対して小さくなったことから、位置推定のロバスト性が向上していることを確認した。
- 実世界データ循環の枠組みに基づき、センサデータの取得と位置情報の算出、位置情報の相対評価、信頼性マップによる位置推定法の可視化を行うことで、位置推定のロバスト性を再帰的に向上させるコンセプトを第7章で述べた。本論文では、位置情報の相対評価に基づく位置推定法の提案（第5章）と、信頼性マップ構築法の提案（第6章）を行った。先の仮定を満たす場合、信頼性マップにより、位置推定法の信頼性を解析できることを確認した。

8.2 今後の展望

本研究の今後の展望として、以下の点がある。

一つ目に、利用する位置情報を増設したときの、位置推定のロバスト性向上可能性を検証する。本論文では、センサの観測から得る位置情報が三つの場合のみを検証した。これは、外れ値処理が機能する最低限の数である。より多くの手法を搭載した場合に、本論文で仮定した、「複数の位置推定法で同時に同様の壊滅的な推定誤差を含む位置情報が算出されることは稀である」という仮定が成り立つか否かを検証する必要がある。オープンソースで利用可能な位置推定手法が複数提案されている。Robot Operating Systemなどの共通プラットフォームの発展により様々な手法を搭載できるようになった。四つ以上の特性が異なる位置推定法を実装し、それらから得る位置情報を解析することで、仮定の妥当性を検証し、外れ値処理を行うことで、位置推定法のロバスト性が向上するか否かを検証することが求められる。

二つ目に、単一のセンサによる位置推定法の有効性について検証することがある。第3章では、二つのセンサに対して三つの位置推定法を利用して、位置推定法ごとに環境に対する特性が異なることを検証した。一方で、一つのセンサを利用して二種類の位置推定法を検証した場合に、位置推定法ごとに環境に対する特性が異なるかどうかは検証していない。同一の種類 of センサの観測でも、位置推定法が異なれば、環境に対する特性が異なる可能性がある。これが成り立つならば、同一のセンサ構成でも種類が異なる位置推定法を多数増設することで、位置推定のロバスト性が向上する可能性がある。単一のセンサから得るセンサ情報で、位置推定手法のみを変えることで、環境に対する位置推定誤差の変化を見る必要がある。

本論文では、センサ融合による移動体の位置推定のロバスト性向上のみに着目して実験を行った。一方、移動体における物体認識など他のセンシング技術における情報源増設の有効性や、他の協調デバイスとの通信による情報源の増設については検証していない。例えば、IoTの発展により、色々な通信デバイスが持つセンサ情報は互いに共有されるようになる。交通インフラでは、Cooperative Intelligent Transportation System (C-ITS)の研究が盛んに行われている。道路上にある、インフラ、自動車といったデバイスが互いに通信を行うことで、おのおののデバイスが持つセンサの観測が互いに共有される。この中には、他のインフラ・自動車から見た自身の位置情報も含まれる。協調デバイスのセンサの観測を融合することで位置推定のロバスト性向上の可能性について検証する必要がある。

付録 A

異種デバイス間の情報共有によるセンシング情報の増加

本章では、本研究において課題を検討・解決策を提案したものの、学術論文としてまとめるには至らなかった内容について述べる。本論文では、センサフュージョンによる移動体の位置推定のロバスト性向上のみに着目して実験を行った。一方、移動体における物体認識など他のセンシング技術における情報源増設の有効性や、他の協調デバイスとの通信による情報源の増設については検証していない。例えば、IoTの発展により、色々な通信デバイスが持つセンサ情報は互いに共有されるようになる。交通インフラでは、Cooperative Intelligent Transportation System (C-ITS)の研究が盛んに行われている。道路上にある、インフラ、自動車といったデバイスが互いに通信を行うことで、おのおののデバイスが持つセンサの観測が互いに共有される。この中には、他のインフラ・自動車から見た自身の位置情報も含まれる。協調デバイスのセンサの観測を融合することで、物体認識におけるトラッキングのロバスト性向上の可能性について検証する。

A.1 はじめに

センサの観測により歩行者の位置、速度などの状態を推定する歩行者トラッキングは、自律移動体が安全に移動するために重要である。歩行者トラッキングにおけるタスクは、未だ以下の課題が残っている。1) トラッキング対象の歩行者の数を数えること。これは、新しい歩行者の出現、既存の歩行者の消失、およびご検出により変動する。2) 他の物体によってオクルージョンとなった歩行者をトラッキングする。3) 急加速、減速、一時停止などの非常に動的な歩行動作をトラッキングする。本章では、オクルージョンとなる歩行者を正確にトラッキングすることは、特に都市環境における移動体の自律移動において、潜在的な衝突を検出するのに役立つため、

2 番目の課題に対処する。第 2 の課題を克服するために、一般的に、オクルージョンとなる歩行者の位置を予測するための運動学モデルが状態遷移モデルとして利用される。よく知られている単純な線形の運動学モデルは、Constant Velocity Model (CVM), Constant Turn Rate Model (CTRM), および、Constant Acceleration Model (CAM) である。しかし、これらモデルでは、速度と加速度が一定という仮定をおいているため、長期的な歩行運動を予測することができない。

本問題を解決するために、本章では、Cooperative Intelligent Transportation System (C-ITS) に着目している。これは、交通網上にある移動体やインフラ、歩行者の通信デバイスが、vehicle to vehicle (V2V), vehicle to infrastructure (V2I), vehicle to pedestrian (V2P) などの通信により互いに情報を共有する仕組みである。特に、V2P 通信は、歩行者のオクルージョン問題を解決できる可能性が高い。歩行者の状態を通信デバイスの情報から受け取ることで、移動体は、歩行者の動作を推定しながら、安全に自律移動できる。しかし、既存の V2P 通信に関する研究は、通信デバイスの GNSS による位置情報のみしか利用していない。GNSS により得る位置情報の精度は、一般的に、3-10m 程度の誤差を含んでおり、移動体の安全性を確保するために十分ではない。歩行者の通信デバイスは、歩行動作（速度、進行方向）に関する情報も所持しているが、それらを利用したオクルージョンとなる歩行者のトラッキングに関する研究例はない。

本章では、V2P 通信による新しい協調歩行者トラッキングシステムを提案する。歩行者がオクルージョンとなる時は、提案システムは、歩行者の通信デバイスの情報を利用して歩行者の動作を予測する。歩行者が自律移動体から見える時は、移動体による歩行者の検出情報と歩行者の通信デバイスの情報を融合する。本章では、上記二つの機能を Unscented Kalman Filter (UKF) による統一的な枠組みで達成する手法を提案する。

A.2 協調歩行者トラッキングのフレームワーク

歩行者の協調トラッキングのフレームワークを図 A.1 に示す。トラッキングする歩行者の状態は、 $\chi = (x, y, v, \theta, \omega)$ である。ここで、 x, y は、歩行者の位置、 v は、歩行者の速度、 θ は、歩行者の進行方向、 ω は、歩行者の進行方向の角速度である。Prediction のブロックでは、歩行者の状態を遷移モデルに従って予測する。その後、Observation のブロックにてセンサの観測に従って歩行者の状態を予測する。本節では、遷移関数 $f'(\cdot)$ について A.2.1 節で、各センサの観測による観測関数を A.2.2-A.2.4 節で述べる。

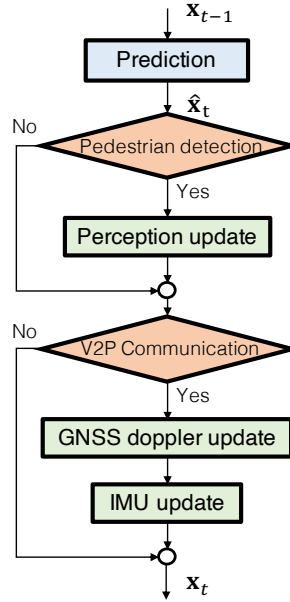


図 A.1. V2P による協調歩行者トラッキングフレームワーク

A.2.1 Prediction ブロック

Prediction のブロックでは、歩行者の予測状態 $\hat{\chi} = (\hat{x}, \hat{y}, \hat{v}, \hat{\theta}, \hat{\omega})$ を以下の遷移関数に従って算出する。

$$\hat{\chi}_t = f(\chi_{t-1}) = \begin{pmatrix} x_{t-1} + v_{t-1} \cdot \Delta t \cdot \cos \theta_{t-1} \\ y_{t-1} + v_{t-1} \cdot \Delta t \cdot \sin \theta_{t-1} \\ v_{t-1} \\ \theta_{t-1} + \Delta t \cdot \omega_{t-1} \\ \omega_{t-1} \end{pmatrix} \quad (\text{A.1})$$

ここで、 Δt は、時刻 $t-1$ と t の時間差である。予測位置 \hat{x}_t, \hat{y}_t は、時刻 $t-1$ における位置 x_{t-1}, y_{t-1} と速度 v_{t-1} と進行方向 θ_{t-1} により算出される。次節以降で示すセンサの観測により速度、進行方向、角速度を更新することで、歩行者がオクルージョンとなっている時でも歩行者の位置を予測できるようにする。

A.2.2 通信デバイスの GNSS ドップラーによる速度推定

GNSS 信号のドップラー効果を利用した速度推定は、歩行者の絶対速度と絶対進行方向を推定できる。GNSS ドップラーは、GNSS による位置推定における誤差要

因である電離層遅延や大気圏遅延の影響を受けにくいことから、高精度な速度推定が期待される。

i 番目の衛星信号を利用した歩行者の三次元空間における速度推定の式を次式に示す。

$$V_{rs}^i = G_x^i Vx + G_y^i Vy + G_z^i Vz - C_{vs} \quad (\text{A.2})$$

ここで、 V_{rs}^i は、 i 番目の衛星と歩行者の相対速度、 $[G_x^i, G_y^i, G_z^i]$ は、 i 番目の衛星と歩行者間の単位ベクトル、 $[Vx, Vy, Vz]$ は、歩行者の三次元空間における速度、 C_{vs} は、GNSS 受信器のクロックドリフトである。相対速度 V_{rs}^i と単位ベクトル $[G_x^i, G_y^i, G_z^i]$ は、次式により算出される。

$$V_{rs}^i = \frac{D^i}{f^i} c - (G_x^i Vx_s^i + G_y^i Vy_s^i + G_z^i Vz_s^i) \quad (\text{A.3})$$

$$\begin{bmatrix} G_x^i & G_y^i & G_z^i \end{bmatrix} = \frac{-1}{r^i} \begin{bmatrix} X_s^i - X_p & Y_s^i - Y_p & Z_s^i - Z_p \end{bmatrix} \quad (\text{A.4})$$

ここで、 D^i は、衛星 i からのドップラーシフト、 c は、光の速度、 f^i は、GNSS 信号のキャリア周波数、 $[Vx_s^i, Vy_s^i, Vz_s^i]$ は、衛星 i の速度、 $[X_s^i, Y_s^i, Z_s^i]$ は、衛星 i の位置、 $[X_p, Y_p, Z_p]$ は、歩行者の位置、 r^i は、衛星 i と歩行者の相対距離である。

式 (A.2) は、観測衛星の数だけ得ることができる。上記の速度やクロックドリフトに関する式を最小二乗法を利用して解くことで、歩行者に関する速度 Vx, Vy を得ることができる。GNSS ドップラーによる観測 \mathbf{z}_t^{GNSS} とその共分散行列 \mathbf{R}_t^{GNSS} は、次式により定義される。

$$\mathbf{z}_t^{GNSS} = \begin{pmatrix} V_t^{GNSS} \\ \Theta_t^{GNSS} \end{pmatrix} = \begin{pmatrix} \sqrt{(Vx^2 + Vy^2)} \\ \arctan \frac{Vy}{Vx} \end{pmatrix} \quad (\text{A.5})$$

$$\mathbf{R}_t^{GNSS} = \begin{pmatrix} \sigma_{V,t} & 0 \\ 0 & \sigma_{\Theta,t} \end{pmatrix}, \quad (\text{A.6})$$

ここで、 $V_t^{GNSS} \Theta_t^{GNSS}$ は、GNSS ドップラーにより観測される歩行者の速度と進行方向であり、 $\sigma_{V,t}, \sigma_{\Theta,t}$ は速度と進行方向に関する分散である。式 (A.7) は、観測関数 $h'(\cdot)$ を表す。

$$\hat{\mathbf{z}}_t = h'^{GNSS}(\chi_t) = \begin{pmatrix} v_t \\ \theta_t \end{pmatrix} \quad (\text{A.7})$$

A.2.3 移動体による歩行者の認識

機械学習といった技術の発展により、歩行者検出の精度が向上している。特に、LiDARを利用した検出では、センサから歩行者までの相対位置 \mathbf{o}_t を正確に推定できる。歩行者の絶対位置は、移動体の位置と進行方向に関する情報 $\mathbf{x}_{t,\text{veh}} = (x_{t,\text{veh}}, y_{t,\text{veh}}, \theta_{t,\text{veh}})$ をもとに次式により算出される。

$$\begin{aligned} \mathbf{z}_t^{\text{prcp}} &= g(\mathbf{x}_{t,\text{veh}}, \mathbf{o}_t) \\ &= \begin{pmatrix} \cos \theta_{t,\text{veh}} & -\sin \theta_{t,\text{veh}} \\ \sin \theta_{t,\text{veh}} & \cos \theta_{t,\text{veh}} \end{pmatrix} \mathbf{o}_t + \begin{pmatrix} x_{t,\text{veh}} \\ y_{t,\text{veh}} \end{pmatrix} \end{aligned} \quad (\text{A.8})$$

歩行者の認識に関する共分散 $\mathbf{R}_t^{\text{prcp}}$ は、次式のヤコビ行列により算出される。

$$\mathbf{R}_t^{\text{prcp}} = \frac{\partial g}{\partial (\mathbf{x}_t, \mathbf{o}_t)} \begin{pmatrix} \Sigma_{\mathbf{x},t} & 0 \\ 0 & \Sigma_{\mathbf{o},t} \end{pmatrix} \left(\frac{\partial g}{\partial (\mathbf{x}_t, \mathbf{o}_t)} \right)^{\text{T}}, \quad (\text{A.9})$$

ここで、 $\Sigma_{\mathbf{x},t}, \Sigma_{\mathbf{o},t}$ は移動体の自己位置に関する共分散と歩行者相対位置に関する共分散を表す。観測関数 $h(\cdot)$ は、次式により定義される。

$$\hat{\mathbf{z}}_t = h^{\text{prcp}}(\chi_t) = \begin{pmatrix} x_t \\ y_t \end{pmatrix} \quad (\text{A.10})$$

A.2.4 通信デバイスのIMUによる角速度推定

スマートフォンなどの通信デバイスは、デバイスの傾きを取得するためにIMUセンサが搭載されている。これらIMUを利用した手法では、加速度・角速度を積分することで、歩行者の位置や速度を推定できる。しかし、加速度を利用した歩行者の速度や位置の推定は、歩行の上下運動に起因する問題により、正確に推定できないことが知られている。よって、提案手法では、IMUから得る水平面上の回転角速度 Ω_t のみを利用して、歩行者の角速度を推定する。

$$\mathbf{z}_t^{\text{IMU}} = \Omega_t \quad (\text{A.11})$$

$$\mathbf{R}_t^{\text{IMU}} = \sigma_{\omega,t} \quad (\text{A.12})$$

$$\hat{\mathbf{z}}_t = h^{\text{IMU}}(\chi_t) = \omega_t \quad (\text{A.13})$$

ここで、 $\sigma_{\omega,t}$ は、推定した角速度の分散を表す。

A.3 実機実験

LiDAR を搭載した移動体により、通信デバイスを保持した歩行者をトラッキングする実験を行った。

A.3.1 実験条件

実験環境を図 A.2 に示す。実験は次の二つのシチュエーションで行った。1) 歩行者が (a)-(b)-(c) の順に歩行速度を変えながら歩行し、移動体は (f) の位置に停車して歩行者をトラッキング。2) 移動体は (d)-(e)-(f) の順に手動で移動し、(a)-(b)-(c) を移動する歩行者をトラッキング。移動体には、LiDAR (Velodyne H64e)、GNSS (Novatel) と IMU を搭載している。移動体は、Convolutional Neural Network (CNN) を利用して、LiDAR から得る点群の中から歩行者を検出する。歩行者の絶対位置は、GNSS と IMU を利用して推定された移動体の絶対位置と LiDAR により算出される歩行者の相対位置を利用して算出される。LiDAR、GNSS、IMU の計測周期は、それぞれ、10Hz、10Hz、100Hz である。歩行者は、通信デバイスとして、Galaxy S9 を保持している。この通信デバイスは、GNSS と IMU を搭載しており、それぞれ 1Hz と 100Hz で観測を取得する。歩行者は、通信デバイスを前方で保持した状態で歩行する。実験では、センサの観測を記録し、オフラインで処理する。歩行者の真の位置は、別の場所に設置した 3D LiDAR を利用して取得した。3D Lidar は、図 A.2 中の (g) の位置に設置されており、歩行者の歩行を全て観測することができる。

A.3.2 シチュエーション 1：歩行者のみ歩行

シチュエーション 1 にて実験を行った。歩行者は、次の三つケースで走行する。1) 歩行者は、1m/s で (a)-(b)-(c) を歩行する。2) 歩行者は、(a)-(b)-(g) まで歩行し、(g) で 10 秒間停止、その後 (c) まで歩行する。3) 歩行者は、1m/s で (a)-(b) まで歩き、(b)-(c) は 0.5m/s でゆっくりと歩行する。実験を通して、歩行速度がオクルージョンの歩行者の位置の推定に及ぼす影響を調べる。

ケース 1：歩行者が 1m/s の一定速度の場合

実験結果を図 A.3 に示す。図 A.3 (a) の上下の図は、通信デバイスの GNSS の位置 (赤)、移動体の認識 (黄色)、提案システム (青)、および真の経路 (緑) による歩行者の歩行の経路と位置推定誤差を示している。図 A.4 (a) は、時間軸上の歩行速度と進行方向の推定結果も示している。通信デバイスの GNSS による推定位置は、真の経路から大きくズレており、推定誤差は、平均、3.54m であった。移動体による認識の結果は、(a)-(b) の区間では、真の経路とほぼ同じであるのに対し、

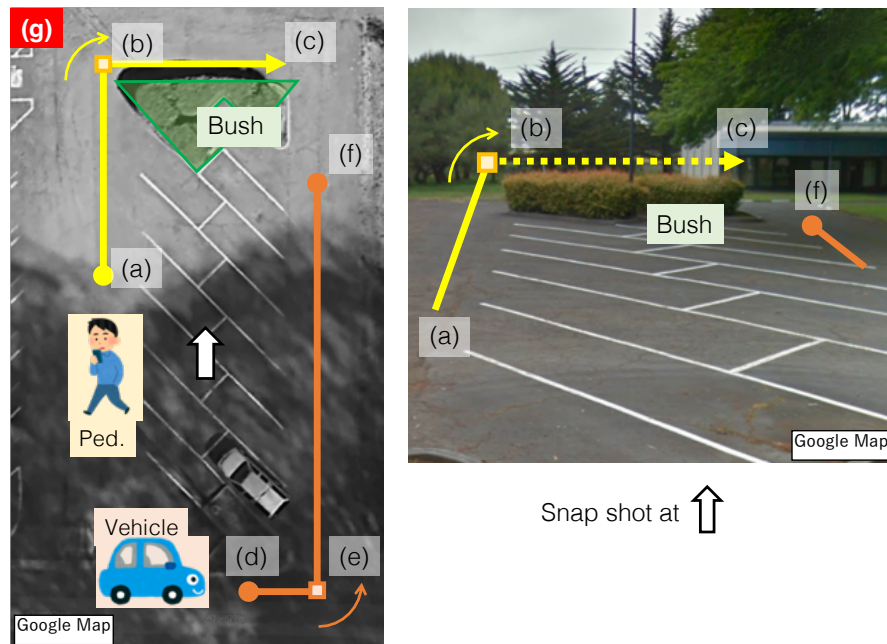


図 A.2. 実験環境

(b)-(c) の区間では、オクルージョンにより検出できていない。一方、提案システムでは、(a)-(b)-(c) の全ての区間において歩行者の経路を推定できている。提案システムの平均推定誤差は、(a)-(b) で 0.280m, (b)-(c) で 0.668m であった。(b)-(c) 区間における提案システムの歩行者の位置は、通信デバイスの GNSS による推定位置より誤差が小さい。これは、図 A.4(a) より、通信デバイスの GNSS ドップラーにより、歩行者の速度と進行方向を正確に推定できたためと思われる。

ケース 2：(b)-(c) 区間の中央で停止する場合

実験結果を図 A.3(b) に示す。ケース 1 と同様に、通信デバイスの GNSS による推定位置は大きな誤差を持っており、移動体の認識による推定位置は、(b)-(c) 区間で歩行者の位置を推定できていない。一方、提案システムでは、(a)-(b)-(c) の全ての区間において歩行者の経路を推定できた。提案システムの平均推定誤差は、(a)-(b) 区間で 0.303m, (b)-(c) 区間で 0.441m であった。

図 A.4(b) の歩行者の進行方向についてみると、提案法における GNSS ドップラーによる推定が 22s から 30s で誤差を持っている。(b)-(c) の間では、歩行者は停止しているため、GNSS ドップラーによる V_x, V_y の推定は、非常に小さい誤差のみ含む。ノイズの影響が式 (A.5) の \arctan の算出で顕著に現れ、進行方向 θ_t の誤差に繋がったと思われる。しかし、この区間における速度は 0 であったため、進行方向の誤差は推定位置に影響を及ぼさなかった。

ケース 3：(b)-(c) 区間をゆっくり歩く場合

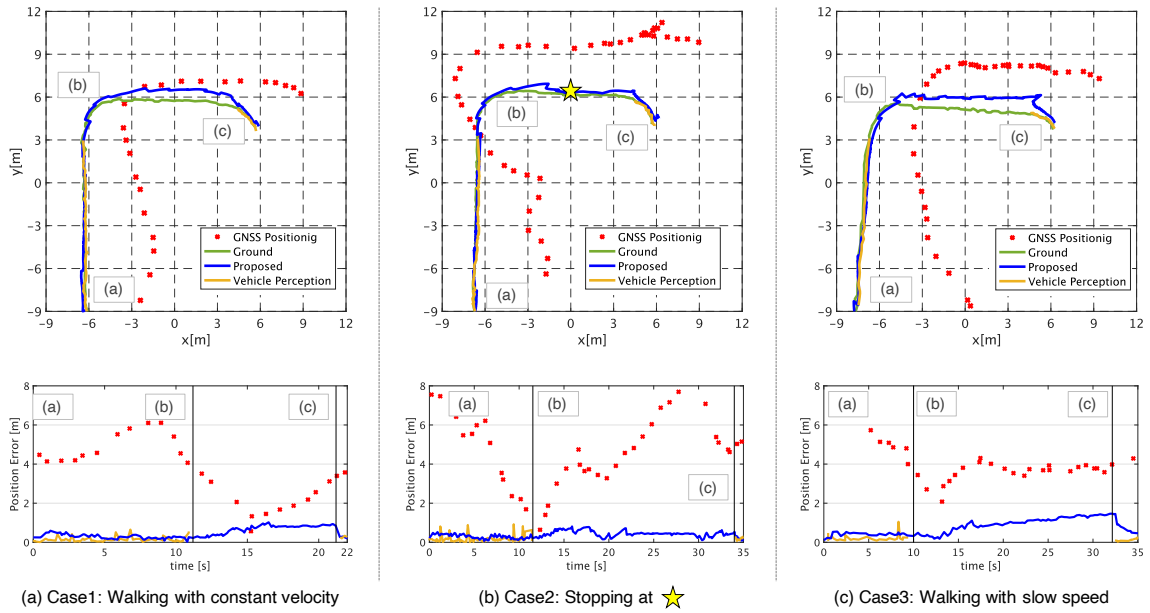


図 A.3. シチュエーション 1 における推定結果. 上から順に, 歩行経路と推定誤差を表す.

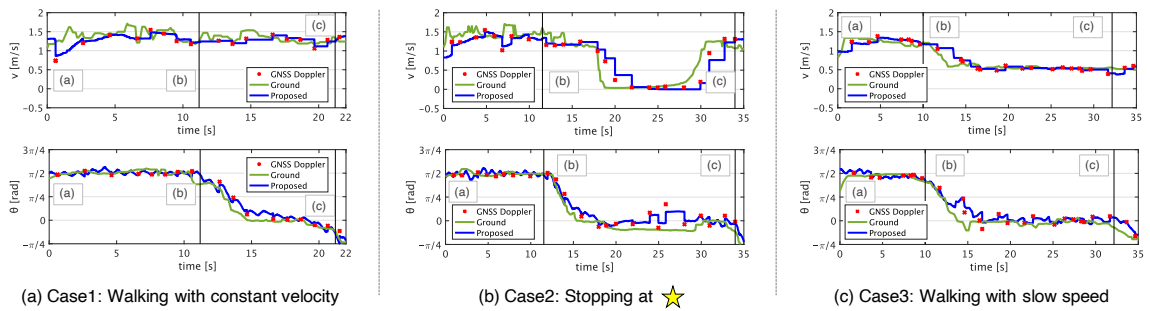


図 A.4. シチュエーション 1 における推定結果. 上から順に, 推定速度と推定進行方向を表す.

実験結果を図 A.3(c) に示す。他の結果と同じように、通信デバイスの GNSS による推定位置は大きな誤差を持っており、移動体の認識による推定位置は、(b)-(c) 区間で歩行者の位置を推定できていないが、提案システムでは、(a)-(b)-(c) の全ての区間において歩行者の経路を推定できた。提案システムの平均推定誤差は、(a)-(b) 区間で 0.402m、(b)-(c) 区間で 0.975m であった。ケース 1 における (b)-(c) 区間の推定誤差と比べると、ケース 3 における (b)-(c) 区間の推定誤差は大きくなっている。これは、歩行者がターンする時の速度の変化が 15s あたりで生じ、進行方向に誤差を含んでしまったためと考えられる。この誤差が (b)-(c) 区間の誤差を引き起こした。(b)-(c) 区間の最大誤差が 1.6m あたりまで上昇してしまったものの、それは GNSS による位置推定の誤差よりも小さく、提案システムの有効性を確認できたものと考ええる。

A.3.3 シチュエーション 2：移動体が動く場合

移動体が (d)-(e)-(f) の区間をマニュアルで走行し、歩行者が (a)-(b)-(c) の区間を一定速度で歩くシチュエーション 2 の実験を行った。実験結果を図 A.5 に示す。GNSS による推定位置は、真の経路から大きく外れており、推定誤差は、平均、5.38m であった。移動体による認識では、(b)-(c) 区間で歩行者の経路を推定できていないのみならず、(a)-(b) の区間でも誤差が生じてしまっている。これは、移動体が走行することで、自己位置推定誤差が生じてしまったがために、歩行者の位置もズレてしまったものと考えられる。一方、提案システムの平均誤差は、(a)-(b) 区間で 0.402m、(b)-(c) 区間で 0.972m であった。提案システムは、移動体による歩行者の認識情報と通信デバイスの GNSS ドップラー、および、IMU の情報を融合することで、誤差を低減することができた。

A.4 本章のまとめ

本章では、V2P 通信による歩行者の位置情報の増加による協調歩行者トラッキングのロバスト性向上を確認した。一般的な V2P 通信では、通信デバイスの位置情報を利用するのに対し、本研究では、通信デバイスによる歩行者の動作情報を利用して協調歩行者トラッキングを行った。実験では、異なる二つのケースで実験を行い、有効性を確認した。実験による、提案手法では、オクルージョンとなる歩行者の位置を平均で 1m 以下で推定できることを確認した。

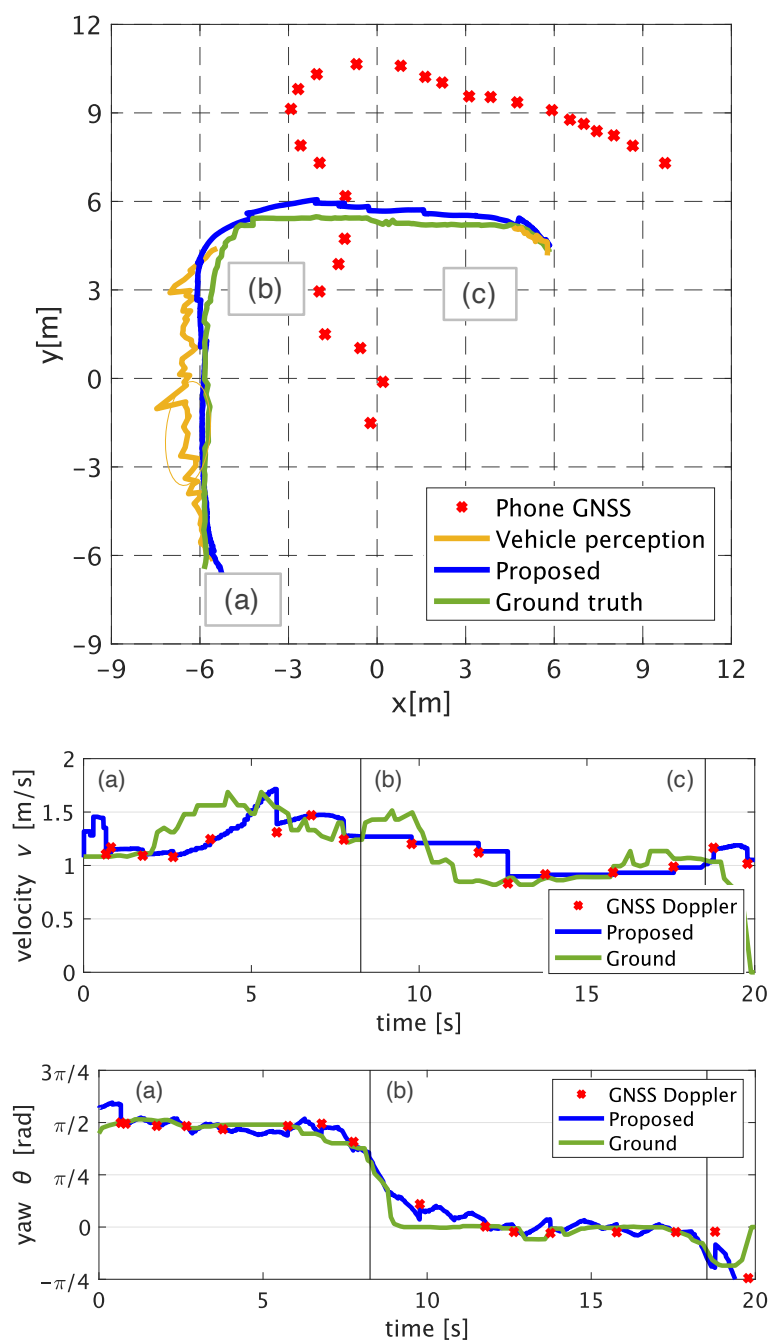


図 A.5. シチュエーション2における推定結果。上から順に、推定経路，推定速度，推定進行方向を表す。

参考文献

- [1] NEDO ロボット白書 2014, 2014.
- [2] 青木啓二, 自動運転技術の開発動向と実用化に向けた課題, 2013.
- [3] 照. 辻野 and 剛. 坪谷, “自動運転自動車の研究開発動向と実現への課題 1・2月号,” pp. 9–16, 2013.
- [4] 日立評論, “クルマが通じ合う-自動運転開発プロジェクト,” Tech. Rep., 2015.
- [5] 津村俊弘, “無人搬送車とその制御,” 計測と制御, vol. 26, no. 7, pp. 593–597, 1987.
- [6] トヨタ自動車 (株) , “愛・地球博で 21 世紀の未来型交通システムを体験.” [Online]. Available: <https://global.toyota.jp/detail/1614247>
- [7] 一般社団法人日本産業車両協会, “無人搬送車システムの納入実績 (統計資料) .” [Online]. Available: <http://www.jiva.or.jp/data.html>
- [8] “Stanley: The Robot that Won the DARPA Grand Challenge,” Tech. Rep. 9, 2006. [Online]. Available: <http://onlinelibrary.wiley.com/doi/10.1002/rob.21514/abstract>
- [9] “DARPA GRAND CHALLENGE 2004,” 2004. [Online]. Available: <https://archive.darpa.mil/grandchallenge04/index.htm>
- [10] “DARPA GRAND CHALLENGE 2005,” 2005. [Online]. Available: <https://archive.darpa.mil/grandchallenge05/index.html>
- [11] “DARPA URBAN CHALLENGE,” 2007. [Online]. Available: <https://archive.darpa.mil/grandchallenge/index.html>
- [12] つくばチャレンジ実行委員会, *TSUKUBA CHALLENGE 2016 参加レポート集*, 2016.

- [13] B. コルテ and J. フィーゲン, 組合せ最適化 第2版 (理論とアルゴリズム). シュプリンガー・ジャパン, 2009.
- [14] 神野郁夫, 小寺秀俊, 横小路泰義, 鈴木亮輔, 箕島弘二, 田中功, 富井洋一, and 中部主敬, 計測工学. 朝倉書店, 2014.
- [15] 友納正裕, *SLAM入門-ロボットの自己位置推定と地図構築の技術-*. オーム社, 2018.
- [16] 小島祥子, “自動車運転支援のための高精度自車位置推定に関する研究,” Ph.D. dissertation, 名古屋大学, 2015.
- [17] 名古屋大学低速自動運転車両事故 (令和元年 8 月 26 日) 検証委員会, “低速自動運転車両事故 報告書,” Tech. Rep.
- [18] “IEEE Catalog Number: CFP19IRO-ART,” in *2019 IEEE/RSJ Int. Conf. Intell. Robot. Syst.*, 2019.
- [19] 巢山慶太, 舟洞佑記, 道木慎二, and 道木加絵, “パーティクルフィルタを用いた自己位置推定のロバスト性向上を目指した確率分布の類似性に基づく動的なセンサ統合,” 計測自動制御学会論文集, vol. 53, no. 2, pp. 169–177, 2017.
- [20] 安田明生, “GPS の現状と展望,” 電子情報通信学会誌, vol. 82, no. 12, pp. 1207–1215, 2001.
- [21] 星野尾一明, “GPS の課題と展望,” *GPS (全地球的測位システム) と光学*, vol. 32, no. 11, pp. 654–661, 2003.
- [22] 内閣府宇宙開発戦略推進事務局, “みちびきとは.” [Online]. Available: https://qzss.go.jp/overview/services/sv01{_}what.html
- [23] “海上保安庁、ディファレンシャル GPS の運用を終了.” [Online]. Available: https://qzss.go.jp/news/archive/kaiho-dgps{_}190304.html
- [24] 内閣府宇宙開発戦略事務局, “サブメータ級測位補強サービス.” [Online]. Available: https://qzss.go.jp/overview/services/sv05{_}slas.html
- [25] 久保信明, “マルチ GNSS 時代の高精度測位,” システム/制御/情報, vol. 59, no. 4, pp. 120–125, 2015.
- [26] 内閣府宇宙開発戦略事務局, “センチメータ級測位補強サービス.” [Online]. Available: https://qzss.go.jp/overview/services/sv06{_}clas.html

- [27] 飯村太紀 and 山本健次郎, “搭乗型移動支援ロボット『ROPITS』の開発一類似画像検索による自己位置ロストからの回復一,” in 第27回ロボティクス・メカトロニクス講演会講演概要集, 2015.
- [28] 内山寛之, “市街地映像データベースを用いた 自車位置推定に関する研究,” Ph.D. dissertation, 名古屋大学, 2012.
- [29] Y. Taguchi, Y. D. Jian, S. Ramalingam, and C. Feng, “Point-plane SLAM for hand-held 3D sensors,” in *Proc. - IEEE Int. Conf. Robot. Autom.*, may 2013, pp. 5182–5189.
- [30] R. Mur-Artal, J. M. Montiel, and J. D. Tardos, “ORB-SLAM: A versatile and accurate monocular SLAM system,” *IEEE Trans. Robot.*, vol. 31, no. 5, pp. 1147–1163, 2015.
- [31] R. Mur-Artal and J. D. Tardos, “ORB-SLAM2: An Open-Source SLAM System for Monocular, Stereo, and RGB-D Cameras,” *IEEE Trans. Robot.*, vol. 33, no. 5, pp. 1255–1262, 2017.
- [32] R. Elvira, J. D. Tardós, and J. M. Montiel, “ORB-SLAM-Atlas: A robust and accurate multi-map system,” in *Proc. - 2019 IEEE/RSJ Int. Conf. Intell. Robot. Syst.*, Macau, China, 2019, pp. 6253–6259.
- [33] R. Wang, M. Schworer, and D. Cremers, “Stereo DSO: Large-Scale Direct Sparse Visual Odometry with Stereo Cameras,” in *Proc. 2017 IEEE Int. Conf. Comput. Vis.*, 2017, pp. 3923–3931.
- [34] S. Sumikura, M. Shibuya, and K. Sakurada, “OpenVSLAM: A versatile visual SLAM framework,” in *Proc. 27th ACM Int. Conf. Multimed.* Nice, France: ACM, 2019, pp. 2292–2295.
- [35] J. Engel, J. Sturm, and D. Cremers, “LSD-SLAM: Large-Scale Direct Monocular SLAM,” in *Proc. - Comput. Vis. - ECCV 2014.* Springer International Publishing, 2014, pp. 834–849.
- [36] S. Yang and S. Scherer, “CubeSLAM: Monocular 3D object SLAM,” *IEEE Trans. Robot.*, vol. 35, no. 4, pp. 925–938, 2019.
- [37] N. Yang, L. Von Stumberg, R. Wang, and D. Cremers, “D3VO: Deep Depth, Deep Pose and Deep Uncertainty for Monocular Visual Odometry,” in *Proc.*

- IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, 2020, pp. 1278–1289.
- [38] M. A. Fischler and R. C. Bolles, “Random sample consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography,” *Commun. ACM*, vol. 24, no. 6, pp. 381–395, 1981.
- [39] 徐剛 and 辻三郎, *3次元ビジョン*. 共立出版, 1998.
- [40] J. Kim and W. Chung, “Localization of a mobile robot using a laser range finder in a glass-walled environment,” *IEEE Trans. Ind. Electron.*, vol. 63, no. 6, pp. 3616–3627, 2016.
- [41] 山田大地 and 大矢晃久, “生活環境における移動ロボットの自己位置推定のためのレーザスキャナの統計的計測モデル,” *計測自動制御学会論文集*, vol. 52, no. 12, pp. 661–670, 2016.
- [42] 加藤正浩, 岩井智昭, 藤谷多史, 幸田健志, 水戸研司, and 村松英治, “ランドマーク情報を活用した LiDAR データ処理による自己位置推定技術の開発,” *自動車技術会論文集*, vol. 49, no. 1, pp. 112–117, 2018.
- [43] 植田宏寿, 山口一郎, 土谷千加夫, 佐野泰仁, and 古性裕之, “自車近傍の認識結果の蓄積に基づくロバストな自己位置推定技術の開発,” *自動車技術会論文集*, vol. 47, no. 3, pp. 815–819, 2016.
- [44] J. E. Deschaud, “IMLS-SLAM: Scan-to-Model Matching Based on 3D Data,” in *Proc. - 2018 IEEE Int. Conf. Robot. Autom.* Brisbane, Australia IMLS-SLAM:: IEEE, may 2018, pp. 2480–2485.
- [45] L. Sun, J. Zhao, X. He, and C. Ye, “DLO: Direct LiDAR Odometry for 2.5D Outdoor Environment,” in *Proc. - 2018 IEEE Intell. Veh. Symp.*, 2018, pp. 774–778.
- [46] X. Chen, A. Milioto, E. Palazzolo, P. Giguere, J. Behley, and C. Stachniss, “SuMa++: Efficient LiDAR-based Semantic SLAM,” in *Proc. - 2019 IEEE/RSJ Int. Conf. Intell. Robot. Syst.*, 2019, pp. 4530–4537.
- [47] S. Khan, D. Wollherr, and M. Buss, “Modeling laser intensities for simultaneous localization and mapping,” *IEEE Robot. Autom. Lett.*, vol. 1, no. 2, pp. 692–699, 2016.

- [48] E. Takeuchi and T. Tsubouchi, “A 3-D scan matching using improved 3-D normal distributions transform for mobile robotic mapping,” in *Proc. - IEEE/RSJ Int. Conf. Intell. Robot. Syst.* IEEE, 2006, pp. 3068–3073.
- [49] T. Shan and B. Englot, “LeGO-LOAM: Lightweight and ground-optimized lidar odometry and mapping on variable terrain,” in *Proc. - IEEE Int. Conf. Intell. Robot. Syst.*, 2018, pp. 4758–4765.
- [50] J. Du, R. Wang, and D. Cremers, “DH3D: Deep Hierarchical 3D Descriptors for Robust Large-Scale 6DoF Relocalization,” in *Eur. Conf. Comput. Vis.*, 2020.
- [51] M. Bijelic, T. Gruber, and W. Ritter, “A Benchmark for Lidar Sensors in Fog: Is Detection Breaking Down?” in *Proc. - 2018 IEEE Intell. Veh. Symp.* IEEE, 2018, pp. 760–767.
- [52] A. Carballo, J. Lambert, A. Monrroy, D. Wong, P. Narksri, Y. Kitsukawa, E. Takeuchi, S. Kato, and K. Takeda, “LIBRE: The multiple 3D LiDAR dataset,” in *Proc. - IEEE Intell. Veh. Symp.*, 2020.
- [53] 山田大地, “人の生活環境における自律ナビゲーションを目的とした移動ロボットの自己位置推定,” Ph.D. dissertation, 筑波大学, 2014.
- [54] 赤井直紀, 竹内栄二郎, 山口拓真, 吉原佑器, 奥田裕之, 鈴木達也, ル. 洋. モラレス, and 二宮芳樹, “INS と マルチレイヤー LiDAR を用いた自動運転車両のための高精度自己位置推定,” 自動車技術会論文集, vol. 49, no. 3, pp. 675–681, 2018.
- [55] S. Thrun, W. Burgard, and D. Fox, *Probabilistic Robotics*. MIT Press, 2005.
- [56] 増田良介, “センサ情報の統合への期待,” 日本ロボット学会誌, vol. 8, no. 6, pp. 724–727, 1990.
- [57] 鏡慎吾 and 石川正俊, “センサフュージョン: センサネットワークの情報処理構造 (<小特集>センサネットワーク論文),” 電子情報通信学会論文誌. a, 基礎・境界, vol. 88, no. 12, pp. 1404–1412, 2005.
- [58] 石川正俊, “センサフュージョンの課題,” 日本ロボット学会誌, vol. 8, no. 6, pp. 735–742, 1990.
- [59] 由井庸介, 小林泰生, 野沢拓史, 平谷拓也, and 内村裕, “ディープラーニングによる探索および信号認識機能を有する自律移動ロボットの開発,” in つくばチャレンジ 2016 参加レポート集, 2016, pp. 12–15.

- [60] 篠原正俊, S. A. Rahok, 井上一道, and 尾崎功一, “磁気センサとLIDARを用いた自己位置推定手法の開発,” 計測自動制御学会論文集, vol. 49, no. 8, pp. 795–801, 2013.
- [61] 機械システム振興協会, “移動体用高精度位置標定システムに関する調査研究報告書 (要旨),” Tech. Rep., 2005.
- [62] K. Takeyama, Y. Kojima, and E. Teramoto, “Trajectory estimation improvement based on time-series constraint of GPS Doppler and INS in urban areas,” in *Proc. 2012 IEEE/ION Position, Locat. Navig. Symp.* IEEE, 2012, pp. 700–705.
- [63] 小島祥子, 高橋新, and 二宮芳樹, “汎用GPSと車載レーザレーザを用いた高精度自動車位置推定,” 情報処理学会論文誌, vol. 50, no. 1, pp. 64–74, 2009.
- [64] Z. Tao and P. Bonnifait, “Sequential Data Fusion of GNSS Pseudoranges and Dopplers with Map-Based Vision Systems,” *IEEE Trans. Intell. Veh.*, vol. 1, no. 3, pp. 254–265, 2016.
- [65] G. Wan, X. Yang, R. Cai, H. Li, Y. Zhou, H. Wang, and S. Song, “Robust and Precise Vehicle Localization Based on Multi-Sensor Fusion in Diverse City Scenes,” in *Proc. - IEEE Int. Conf. Robot. Autom.* IEEE, 2018, pp. 4670–4677.
- [66] J. Zhang and S. Singh, “Visual-lidar odometry and mapping: Low-drift, robust, and fast,” in *Proc. - IEEE Int. Conf. Robot. Autom. (ICRA2015)*. IEEE, 2015, pp. 2174–2181.
- [67] J. Graeter, A. Wilczynski, and M. Lauer, “LIMO : Lidar-monocular visual odometry,” in *Proc. - IEEE/RSJ Int. Conf. Intell. Robot. Syst.*, 2018, pp. 7872–7879.
- [68] Z. Xiang, J. Yu, J. Li, and J. Su, “ViLiVO: Virtual LiDAR-visual odometry for an autonomous vehicle with a multi-camera system,” in *Proc. - 2019 IEEE/RSJ Int. Conf. Intell. Robot. Syst.*, Macau, China, 2019, pp. 2486–2492.
- [69] W. Shao, S. Vijayarangan, C. Li, and G. Kantor, “Stereo visual inertial LiDAR simultaneous localization and mapping,” in *Proc. - 2019 IEEE/RSJ Int. Conf. Intell. Robot. Syst.*, Macau, China, nov 2019, pp. 370–377.

- [70] X. Zuo, P. Geneva, W. Lee, Y. Liu, and G. Huang, “LIC-Fusion : LiDAR-Inertial-Camera Odometry,” in *Proc. - 2019 IEEE/RSJ Int. Conf. Intell. Robot. Syst.*, Macau, China, nov 2019, pp. 5848–5854.
- [71] J. A. Castellanos, J. Neira, and J. D. Tardos, “Multisensor fusion for simultaneous localization and map building,” *IEEE Trans. Robot. Autom.*, vol. 17, no. 6, pp. 908–914, 2001.
- [72] F. Caron, M. Davy, E. Duflos, and P. Vanheeghe, “Particle filtering for multisensor data fusion with switching observation models: Application to land vehicle positioning,” *IEEE Trans. Signal Process.*, vol. 55, no. 6, pp. 2703–2719, 2007.
- [73] T. N. Hossein, S. Mita, L. Han, and Q. H. Do, “Multi-sensor data fusion for autonomous vehicle navigation and localization through precise map,” *Int. J. Automot. Eng.*, vol. 3, no. 1, pp. 19–25, 2012.
- [74] L. Wei, C. Cappelle, and Y. Ruichek, “Camera/laser/GPS fusion method for vehicle positioning under extended NIS-based sensor validation,” *IEEE Trans. Instrum. Meas.*, vol. 62, no. 11, pp. 3110–3122, 2013.
- [75] J. Astola, P. Haavisto, and Y. Neuvo, “Vector Median Filters,” *Proc. IEEE*, vol. 78, no. 4, pp. 678–689, 1990.
- [76] “KITTI Odometry Benchmark – Visual Odometry / SLAM Evaluation 2012 –.” [Online]. Available: <http://www.cvlibs.net/datasets/kitti/eval{\-}odometry.php>
- [77] 山崎将史, 竹内栄二郎, 大野和則, and 田所諭, “三次元地形情報および GPS を用いたパーティクルフィルタによるマルチパスを考慮した自己位置推定,” *日本ロボット学会誌*, vol. 29, no. 8, pp. 702–709, 2011.
- [78] 花井稔典, “Plug-in hybrid vehicle の自動充電を目指した自律移動ロボットの動作計画に関する研究,” 修士学位論文, 愛知工業大学, 2013.
- [79] R. A. Fisher, *Statistical Methods for Research Workers*, 13th ed. Fisher1958: Hafner, 1958.
- [80] E. Pollard and D. Gingras, “Improved low cost GPS localization by using communicative vehicles,” in *Proc. - 2012 12th Int. Conf. Control. Autom. Robot. Vis.*, Guangzhou, China, dec 2012, pp. 317–322.

-
- [81] 柳原徳久 and 初本慎太郎, “特集 さまざまな次世代 GPS 測位方式,” 情報処理学会誌, vol. 43, no. 8, pp. 831–835, 2002.
- [82] 道木加絵, 新矢竜, 大橋臨, 舟洞佑記, 道木慎二, 鳥井昭宏, and 元谷卓, “センサ情報信頼度マップを用いた複数センサ情報統合による自律移動ロボットの自己位置推定,” 電気学会論文誌 *C* (電子・情報・システム部門誌), vol. 139, no. 12, pp. 1389–1399, 2019.
- [83] “実世界データ循環学.” [Online]. Available: <http://www.rwdc.is.nagoya-u.ac.jp/>

発表業績

学会誌等 (2件)

- 大橋臨, 舟洞佑記, 道木慎二, 道木加絵. 自律移動ロボットのロバストな位置推定のための相関係数による多数決的センサ選択と統合. 計測自動制御学会論文集, Vol. 55, No. 7, pp. 439-446, 2019.
- N. Ohashi, Y. Funabora, S. Doki and K. Doki. Multisensor Robust Localization in Various Environment with Correlation Checking Test. Robomech Journal, Vol. xx, No. x, pp. xx-xx, 20xx.

国際会議 (2件)

- N. Ohashi, Y. Funabora, S. Doki and K. Doki. Boosting SLAM: Combining SLAM Methodologies for Robust Localization. *019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS2019)*, (査読あり, 学会論文集にのみ寄稿), 2019.
- N. Ohashi, Y. Funabora, S. Doki and K. Doki. Majority Rule Sensor Fusion System with Particle Filter for Robust Robot Localization. *IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM 2018)*, 2018.

その他 (6件)

- 大橋臨, 舟洞佑記, 道木慎二, 道木加絵. 移動ロボットのロバストな位置推定のための複数センサ統合に適したパーティクルフィルタの検討. ロボティクス・メカトロニクス講演会 2018, 2P1-O03, 2018.

- 大橋臨, 舟洞佑記, 道木慎二, 道木加絵. 外れ値処理を用いた確率的位置情報の統合による移動ロボットのロバストな位置推定—統合処理における確率分布類似性評価法の検討—. ロボティクス・メカトロニクス講演会 2017, 2017.5.10-13
- 大橋臨, 舟洞佑記, 道木慎二, 道木加絵. 大橋臨, 舟洞佑記, 道木慎二, 道木加絵. センサ統合によるロバストな位置推定のための確率分布間の類似性評価指標の検討. 平成 29 年度 電気・電子・情報関係学会東海支部連合大会, 2017.9.7-8
- 大橋臨, 舟洞佑記, 道木慎二, 道木加絵. 移動ロボットのロバストな自己位置推定のための標本検定に基づく確率的位置情報の統合第 47 回東海ファジィ研究会 (蒲研 2019), 2017.8.28-29
- 大橋臨, 舟洞佑記, 道木慎二, 道木加絵. 異種センサを用いたロバストな自己位置推定のための確率分布の類似性評価法. 第 34 回日本ロボット学会学術講演会, 2016.9.7-9
- 大橋臨, 舟洞佑記, 道木慎二, 道木加絵. 大橋臨, 舟洞佑記, 道木慎二, 道木加絵. 複数の異種センサを用いたロバストな位置推定の実現を目指した確率分布の類似性評価法の検討第 17 回システムインテグレーション部門講演会 (SI2016), 2016.12.15-17

謝辞

本研究の遂行ならびに本論文の執筆にあたり、終始御指導を賜りました、名古屋大学大学院工学研究科情報・通信工学専攻 教授 博士（工学） 道木慎二先生に深く感謝いたします。

本論文をまとめるにあたり、貴重なご助言を賜りました、名古屋大学大学院工学研究科情報・通信工学専攻 教授 博士（工学） 佐藤理史先生、名古屋大学大学院工学研究科情報・通信工学専攻 教授 博士（工学） 河口信夫先生、愛知工業大学情報科学部情報科学科 教授 博士（工学） 中條直也先生に深く感謝の意を表します。

本研究に対し、貴重な御指導、御助言を賜りました、愛知工業大学工学部電気学科電子工学専攻 教授 博士（工学） 道木加絵先生に心より感謝いたします。

本研究を含め、ロボットの制御全般について、日頃から貴重かつ多大なる御指導を賜りました、名古屋大学大学院工学研究科情報・通信工学専攻 助教 博士（工学） 舟洞佑記先生に改めて感謝の意を表します。

本研究を含め、国内や海外へのインターンシップに対して多大なるご支援をいただいた博士課程教育リーディングプログラム 実世界データ循環学リーダー人材養成プログラム プログラムコーディネーター 武田一哉先生はじめ実世界データ循環学に関わられた先生方、企業メンタ、履修生の皆様に改めて感謝の意を表します。

本研究の遂行にあたり、日頃より有益な御助言、御協力を賜りました、名古屋大学大学院工学研究科情報・通信工学専攻博士後期課程3年 今井幸司氏、同2年 赤塚弘恭氏、王シン氏、キムジンス氏、博士前期課程2年 北村健太郎氏、木村圭佑氏、呉偉桐氏、中井喬太氏、堀翔太氏、山口紘生氏、同1年 小櫻崇雅氏、中川滉貴氏、正岡真一氏、森川祥平氏、鈴木明義氏、工学部電気電子・情報工学科4年 柴田泰雅氏、竹内琢真氏、羽根田雅也氏をはじめ、著者と同時代に名古屋大学道木研究室および愛知工業大学道木研究室に在籍したすべての方々に深く感謝申し上げます。

最後に、本研究を私生活の面から支え、私に多大な理解を示して頂きました家族に感謝を表し、謝辞の締めくくりとさせていただきます。