

TUMSAT-OACIS Repository - Tokyo

University of Marine Science and Technology

(東京海洋大学)

カメラ画像と汎用センサの統合による自動車位置推定の研究

メタデータ	言語: jpn 出版者: 公開日: 2018-06-20 キーワード (Ja): キーワード (En): 作成者: 武山, 洪二郎 メールアドレス: 所属:
URL	https://oacis.repo.nii.ac.jp/records/1571

博士学位論文

カメラ画像と汎用センサの統合による
自動車位置推定の研究

平成 29 年度

(2018 年 3 月)

東京海洋大学大学院

海洋科学技術研究科

応用環境システム学専攻

武山 洪二郎

目次

1 章	序論	1
1. 1	自動車の智能化と意義	1
1. 2	車両位置情報を利用した運転支援システム	3
1. 3	車両位置の要求仕様	6
1. 4	本研究の目的	7
2 章	世の中の測位技術と本研究の位置付け	9
2. 1	絶対測位と推測航法	9
2. 2	世の中の測位技術	11
2. 2. 1	絶対測位	11
2. 2. 1. 1	衛星利用型	11
2. 2. 1. 2	地図利用型	18
2. 2. 2	推測航法	23
2. 2. 2. 1	内界センサ利用型	23
2. 2. 2. 2	外界センサ利用型	24
2. 2. 2. 3	衛星利用型	26
3 章	推測航法の性能向上	31
3. 1	カメラ画像を用いた推測航法	31
3. 1. 1	基本原理	33
3. 1. 1. 1	特徴点の抽出および追跡方法	33
3. 1. 1. 2	走行軌跡推定	35
3. 1. 2	課題	40
3. 1. 3	従来研究	42
3. 1. 4	本研究のアプローチ	44

4. 4	本章のまとめ	105
5 章	結論	107
5. 1	本研究のまとめ	107
5. 2	今後の課題と展望	109

謝辞

参考文献

1 章 序論

本論文は自動車の運転支援のための高精度車両位置技術に関する研究成果をまとめたものである。本章ではまず、自動車の知能化とも言える運転支援システムの意義とその開発の歴史について述べる。次に、運転支援システムにおける車両位置情報の重要性について述べたあと、運転支援システム成立のため車両位置情報に求められる要件について言及する。そして本研究の目的、および本論文の構成について述べる。

1. 1 自動車の知能化と意義

自動車は18世紀に発明されて以降、産業用途から日常生活を支える乗り物へと変遷し、現在では人間が社会生活を行う上で欠かせない道具として普及している。優れた自動車に求められる条件は、安全性・快適性・利便性・環境性をより高いレベルで成立することであり、時代変化と共に自動車には多くの改良が積み重ねられ進化を遂げてきた。黎明期から長らくは車体やエンジンなどハードウェアの改良が主であったのに対し、20世紀末期からはIT(Information Technology)の爆発的な進歩に伴って自動車のソフトウェアの改良が加速度的に進み、言わば自動車の知能化の時代を迎えた。

図1に20世紀後期以降の日本における自動車の変遷を示す。1990年代にカーナビゲーションが普及して以降、急速な知能化が始まった。道路インフラと協調したシステムでは、渋滞などの道路情報を提供するVICS、非接触型の自動道路課金を行うETCが標準化されることで渋滞が大幅に緩和されるなど、世の中の交通システムに大きな変革をもたらした。また車両側のシステムでは、エコ運転支援[1](環境性向上)、衝突予防のための警報・ブレーキアシスト[2]、レーンキープアシスト[3](安全性向上)、また前車を自動追従するアダプティブクルーズコントロール(ACC)[7]や、自動操舵による駐車支援[4](利便性・快適性向上)など、個々のニーズに合わせた多様な形の運転支援システムが開発されるようになった。また2010年以降では、運転支援システムのさらなる高度化が進み、車両周辺監視の下で操舵・車速調整を自動で行う、半自動運転型の運転支援システムが一部のフラグシップモデルにて実用化が始まっている[5]。

このような運転支援システムの発展によって、予防安全の確保や運転者の負担大幅軽減など、従来のハードウェア改良だけでは成し得なかった恩恵を得られるようになった。そして現在では運転支援システムの終着点とも言える完全自動運転の実現へ向けた動きが全世界で広がっている。一方、完全自動運転などの、高度な運転支援システム実現のためには様々な要素技術のさらなる進化が求められる。各種運転支援システムにおいて必要となる要素技術は多岐に渡るが、走行環境において『車両位置』を正確に推定する技術は近年の運転支援システムでは特に重要な位置付けとなっている。次節では車両位置情報を利用した運転支援システム例とその重要性を示す。

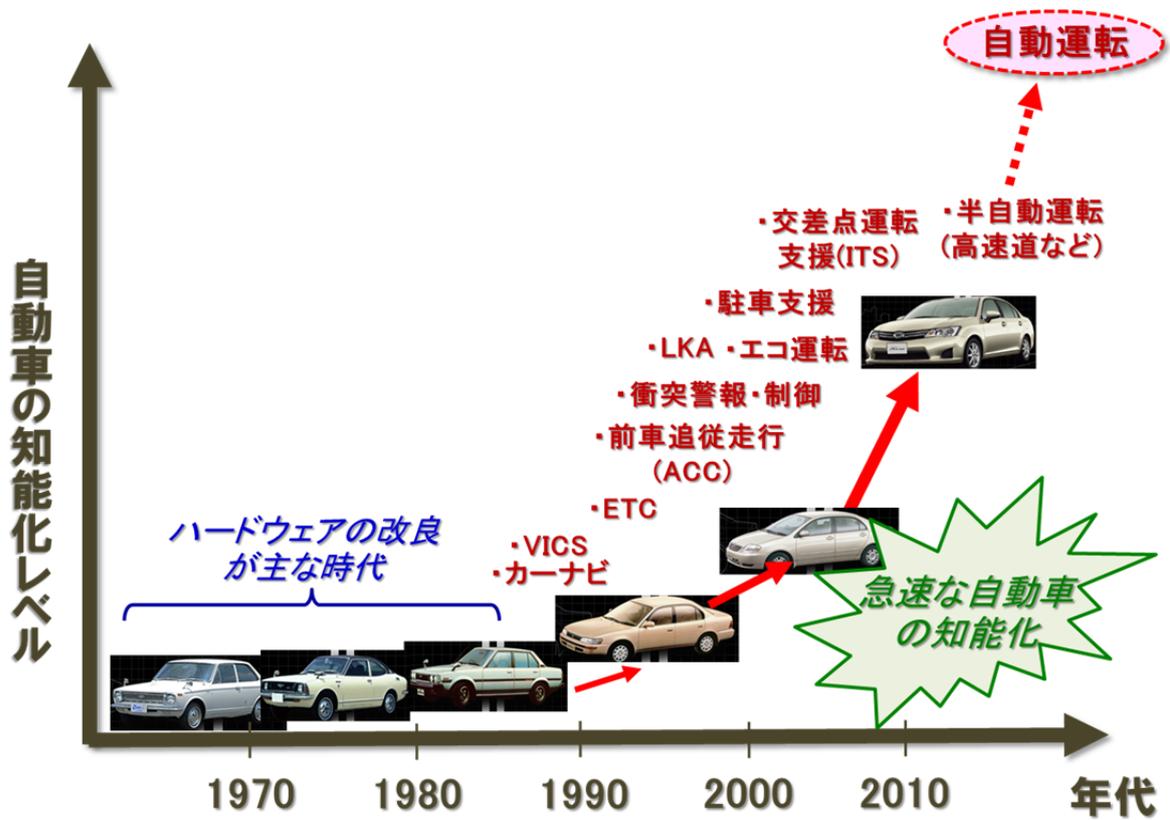


図1：時代の変遷に伴う自動車の知能化
 (車写真はトヨタ自動車 HP, COROLLA 歴代モデル[6]より引用)

1. 2 車両位置情報を利用した運転支援システム

近年では車両位置情報および地図情報を活用した運転支援システムが注目されている。ここで言う地図情報とは、道路の形状・曲率・勾配のみならず、道路周辺の建物の形状、信号や標識、路面マークなど様々な物標を対象とした空間情報データベースのことであり、古くから使われてきた道路地図よりも広義の地図である。(本論文において特に断りない限り、地図情報とは上記の広義の地図を示す)

車両位置情報と地図情報を合わせて利用することで多様な形の運転支援システムを実現することができる。これまでの代表的な例ではカーナビゲーションシステム(以下、カーナビ)が挙げられる(図 2)。カーナビでは車両位置情報に基づき地図上において走行中の道路を特定し、さらにそこから目的地への最適ルートを誘導するシステムである。このシステムの普及によりユーザは旅行先など初走行の地域であっても短時間・かつ安全に目的地に到着できるようになった。また、これら車両位置情報と地図情報の利用による先進的な運転支援システムの開発も行われている。図 3 は自車位置情報を利用した急カーブ手前の減速支援(a)、一時停止交差点前の停止支援(b)の例を示す。これらシステムでは車両位置情報と地図情報から、急カーブあるいは一時停止標識と自車との距離を算出し、距離が近づいているにも関わらず車速が速いと判断した場合にはユーザへの警告あるいは車速の減速制御を行うことで衝突の危険を低減する。また、図 4 はエコ運転システムの例を示す。ハイブリッドシステムではモーターとエンジンの切り替え制御方法が燃費向上の鍵となるが、車両前方の地形を考慮することで制御効率の向上が可能となる。例えば、通常下り坂を走行中は回生ブレーキによりバッテリーが充電されるが、バッテリー容量の上限を超えた分は余剰エネルギーとして廃棄される。これに対し、車両位置情報と地図情報の利用により前方に長い下り坂があると分かった場合、下り坂に到達前に積極的にモーターを動かしバッテリー残量を減らすことで、下り坂でより多くのエネルギーを回収することができる。また、図 5 に自動駐車の実例を示す。自動駐車では自宅車庫など事前に登録された特定の駐車スペースにおいて、周辺の物体に対する相対的な車両位置情報に基づき自動で車庫入れを行う。そして図 6 に自動運転の実例を示す。自動運転では他車や周辺物との衝突を回避するため車両位置情報が重要となる。自車および他車の位置情報、および周囲の道路や構造物の地図情報をサーバを介して共有し、死角を含め全ての車両・構造物の位置関係を把握することによって衝突が起こらない安全な自動運転システムを実現することができる。

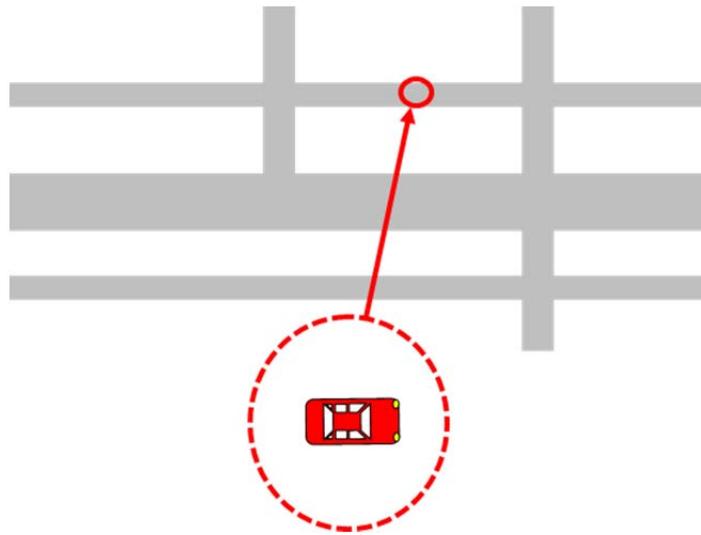
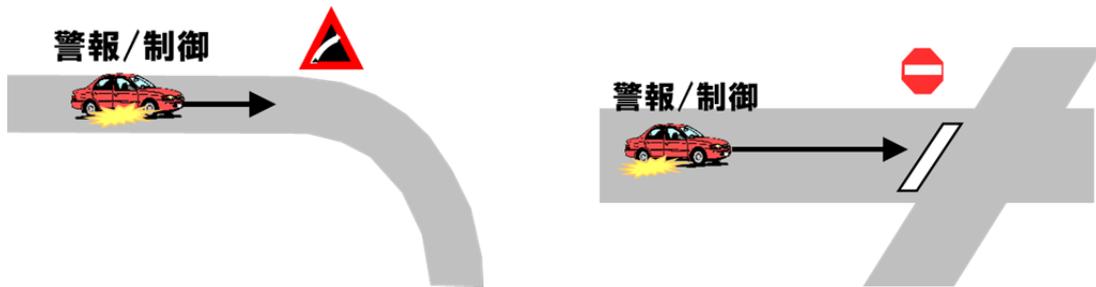


図 2：車両位置情報を用いたカーナビゲーションシステム



(a) 急カーブ減速支援

(b) 一時停止支援

図 3：車両位置情報を用いた減速・停止支援



図 4：車両位置情報を用いたエコ運転支援

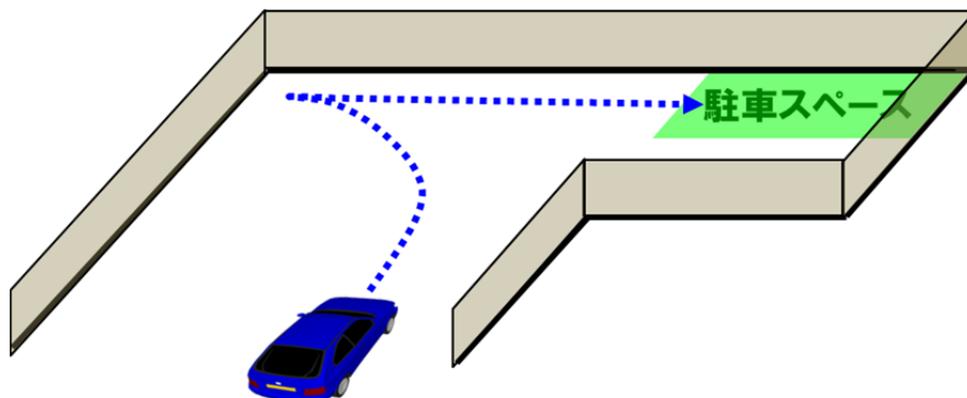


図 5：車両位置情報を用いた自動駐車

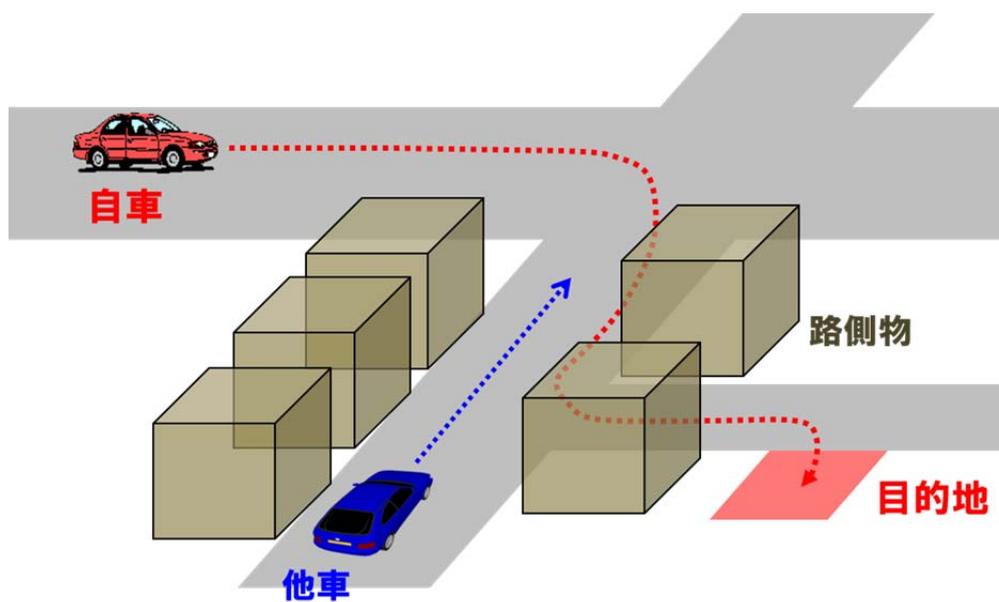


図 6：車両位置情報を用いた自動運転

1. 3 車両位置の要求仕様

以上では車両位置情報および地図情報を活用した運転支援システムにより、様々な恩恵が得られることを示した。これらシステムを正しく動作するためには、地図上において車両位置を正しく把握することが重要となるが、車両位置情報への要求はシステム毎に異なる。表1に各種運転支援システムにおける車両位置情報の要求仕様を示す。カーナビは公道全域で動作する必要があるが、走行中の道路を判別できれば良いため要求される位置精度は10~20m程度、また一時的な誤差増大によるシステム動作停止（瞬断）が許容される。同様に、エコ運転、カーブ減速支援、一時停止支援では要求される位置精度が比較的低く、瞬断が許容され、動作環境は主に屋外であるため、GPSなどの簡易センサで比較的容易に対応できる。また、自動駐車システムでは0.1m以下の精度が求められ、連続的に動作する必要があるため瞬断も許容されないが、自宅車庫など事前に登録された特定の場所を動作対象とすることが多いため、事前に駐車スペース周辺のデータベースを作るなどして対応可能である。一方、自動運転システムでは自動車が走行する全ての環境を対象とし、要求される位置精度は0.3m以下、かつ瞬断が許されないため、現状では高価なセンサを用いて高精度高信頼な測位システムを組む必要がある。

表1：各運転支援システムにおける車両位置情報の要求仕様

	位置精度	瞬断	動作環境
カーナビ	~20m	可	公道全域
エコ運転	~20m	可	郊外
カーブ減速支援	~10m	可	郊外
一時停止支援	~5m	可	公道全域
自動駐車	~0.1m	不可	駐車スペース
自動運転	~0.3m	不可	全走行環境

1. 4 本研究の目的

前節では運転支援システムにおける車両位置情報の重要性と各種システム成立のために必要な要件を示した。本研究はもっとも高度な運転支援アプリケーションである自動運転に適用可能な車両位置情報をターゲットとし、地図上において、低コストかつあらゆる環境でシームレスに 0.3m 以下の位置精度を提供するための測位手法実現を目的とする。

2章 世の中の測位技術と本研究の位置付け

前章では研究の背景と目的を示した。本章では世の中における自動車の測位技術をまとめ、本研究の位置付けを示す。

測位技術は、古くは天体の位置・方向から自己位置を推定する天文航法から始まり長らく運用されてきたが、20世紀後半にはGPS(Global Positioning System)[8][9]の登場により、測位の精度・可用性が飛躍的に向上した。それ以降、IT化の時代の流れと共に測位技術は急速に発展し、現在では用途に合わせて多様なアプローチの測位手法が実用化されている[10]。測位技術は大きく分けて2つの種類に分類することができる。一つは『絶対測位』、もう一つは『推測航法』である。本章では、まず絶対測位と推測航法の定義を確認し、両者の関係性について説明する。次に、世の中における既存の測位手法を絶対測位と推測航法に分類した上で、それぞれの特徴について述べる。そして、最後にこれら測位手法に対する本研究の位置付けを示す。

2.1 絶対測位と推測航法

本節では絶対測位と推測航法を定義し、その違いについて述べる。本研究では「絶対測位」を、地図上における車両位置を直接的に決定する方法と定義する。例えばGPSによって地図上の位置を算出する方法は絶対測位に分類される。これに対し、本研究では「推測航法」を過去のある時点における自車位置からの相対的な位置推定と定義する。例えば、自動車が進行方向と車速を基に、10秒前の車両位置からどちらの方向に何メートル移動したか推定した場合、これは推測航法を行ったことになる。

表2に絶対測位と推測航法の一般的な性質の違いを示す。絶対測位は車両の外部から得た観測情報に基づいた測位を行うため、周辺環境の影響により瞬間的に位置誤差の増大が生じたり測位自体が出来なくなることがあるが、地図上の位置を直接的に決定する方法であるため位置誤差は各時刻において独立であり時刻と共に蓄積することはない。一方、推測航法は各時刻における自車の移動量を逐次的に積算していく方法であるため測位は連続的であり精度も安定するが、時刻と共に位置誤差が蓄積する性質がある。このように、絶対測位と推測航法はそれぞれ異なる長所・短所を有するため、高精度かつシームレスな測位実現のためには、両者の統合が必須である。例えば、GPSによる絶対測位では、衛星信号の遮蔽や反射により、測位精度が劣化したり測位ができない区間が生じることがあるが、このような区間では一時的に推測航法により位置を繋げることで測位精度の安定性・連続性を保つことができる(図7)。このため、絶対測位と推測航法、両方の精度が重要となる。次節では世の中における多様な測位手法について、絶対測位と推測航法分類を行っ

た上で、各手法の特徴について述べる。

表 2：絶対測位と推測航法の一般的な性質の違い

	絶対測位	推測航法
可用性	途切れあり	途切れなし
誤差急変動	あり	なし
誤差蓄積	なし	あり

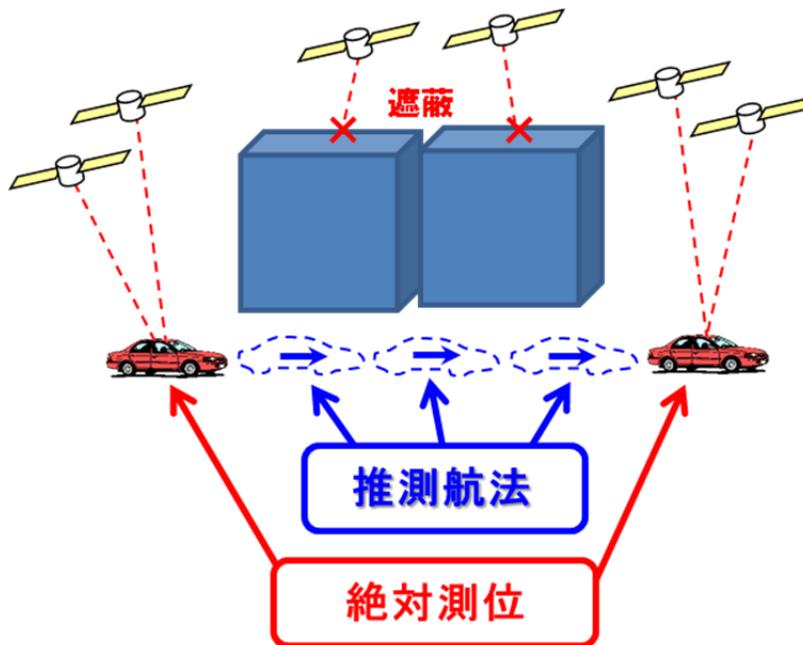


図 7：絶対測位と推測航法の関係

2. 2 世の中の測位技術

以上では自動車のように周辺環境が多様に変化する乗り物においては、絶対測位と推測航法の両方が非常に重要な役割を果たすことを示した。本節では、世の中における自動車のための測位手法を絶対測位と推測航法に分類した上で、各手法の詳細を記す。

2. 2. 1 絶対測位

自動車で用いられる絶対測位手法は大きく分けて、衛星利用型の測位と、地図利用型の測位に分類される。ここではそれぞれの詳細を説明する。

2. 2. 1. 1 衛星利用型

【概要】

衛星利用型の測位手法(以下、衛星測位)は、地球を周回する複数の人工衛星から送信された電波(衛星信号)を用いることで地球上における自己位置を特定する手法であり、地球座標(緯度経度など)を持った地図情報と合わせることで地図上における位置を算出することができる。

衛星測位は時間・場所を問わず実用精度の測位が可能であるため、現在では自動車を始め、航空機、船舶、測量など広い分野で利用されており、衛星測位の登場により近代における産業分野に大きな影響を与えたと言える。

衛星測位の歴史は米海軍の NNSS(Navy navigation satellite system)から始まり、1978年には現在の GPS 衛星のプロトタイプが打ち上げられ、システムの運用が開始された。GPS は当初、軍事用途が主であったため、長らくは暗号化ノイズ(SA: Selective availability)により米軍以外が利用する場合には位置精度が意図的に低下した状態(位置誤差 100m 程度)で運用されたが、Differential GPS[11]など SA の影響を排除できる技術が確立されたのに伴い 2000 年には SA が解除された[12]。一方、民生利用では SA 解除に伴い衛星測位を用いた製品の普及が加速していき、これに伴い衛星測位の精度・場所率のさらなる向上が求められるようになった。衛星測位の精度や場所率向上のためには少しでも多くの衛星信号を受信することが重要となるため、米国の GPS に加え、各国の衛星測位システムを合わせて利用するマルチ GNSS 技術の実用化が進展した。各国の衛星測位システムはそれぞれ独自に研究開発が進められてきたが、2010 年頃を境にマルチ GNSS 実用化のトレンドが押し寄せ、ロシアの GLONASS を始め、中国の BeiDou, EU の Galileo, そして日本の QZSS など各国の衛星測位システムを利用した製品が次々と登場した。そして現在ではカーナビゲーションシステム始め、スマートフォンなどあらゆる小型デバイスでマルチ GNSS が利用されている。

【原理】

以下では、衛星測位システムの基本原理について簡単に説明する。衛星測位システムは、ユーザセグメント、スペースセグメント、コントロールセグメントの3つのセグメントから構成される。ユーザセグメントは衛星信号の受信機を持ったユーザ、スペースセグメントは地球を周回する衛星、コントロールセグメントは衛星の制御や情報提供などを行う地球上の基地局を指す。

衛星は自身の軌道などの情報を、直進性が強い高周波数帯の電波（GPSの場合1.6GHz付近）に乗せて地上に向けて放送する。これを受けたユーザは衛星信号の送信時刻（衛星信号内に含まれる）と受信時刻との差分（信号伝搬時間）を光速で除することで衛星-ユーザ間の距離に相当する疑似距離を観測する。また、衛星信号に含まれる衛星軌道情報から衛星位置を取得することができる。ユーザは基本的に、衛星位置と疑似距離の情報に基づき測位演算を行う。

図8に衛星測位原理の模式図を示す。実世界ではユーザの3次元を求める問題であるが、ここでは模式的に2次元測位として図を示す。ユーザが観測できる情報は、宇宙空間における衛星位置、および衛星からユーザまでの距離に相当する疑似距離である。もしユーザがある一つの衛星信号を受信して、衛星位置と疑似距離が得られた時、ユーザ位置の候補は衛星位置を中心とし疑似距離を半径とする円周上にあるとすることができる（3次元測位では球面上）。同様に、複数の衛星信号を受信した時、全ての円周上がユーザ位置の候補となり、円が最も密に交わる点が最も確からしいユーザ位置であると考えることができる。一般的には空が開けた環境であれば1m~5m程度の精度の測位結果が得られる。

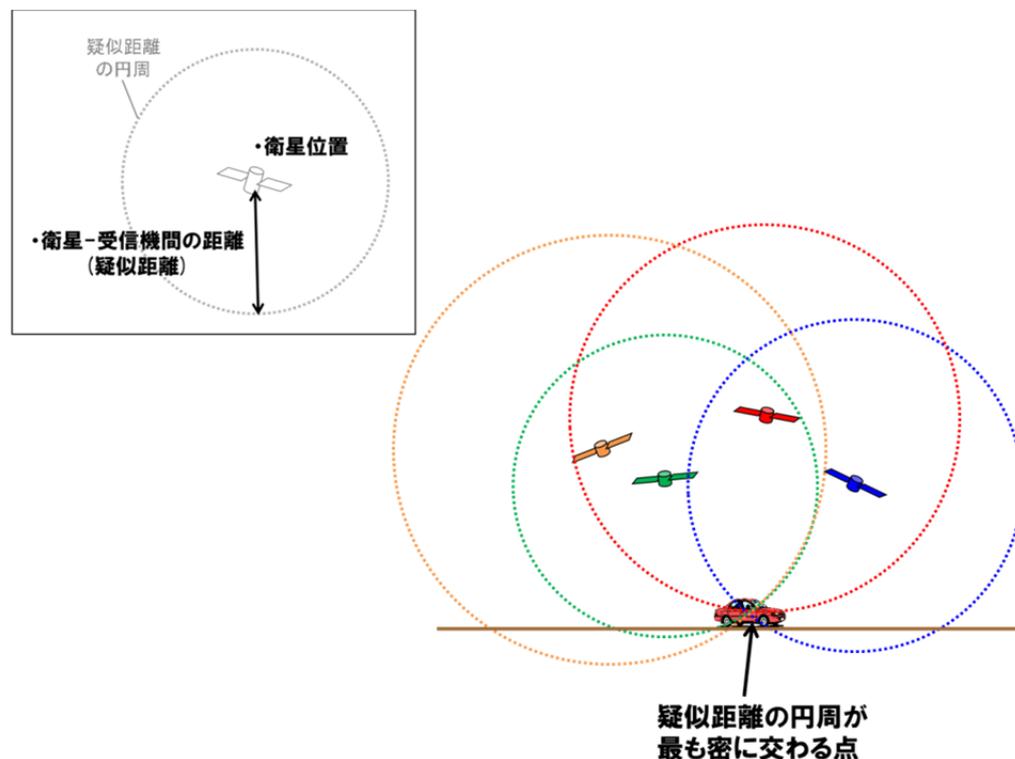


図8：衛星測位のイメージ

【衛星測位の種類】

衛星測位はこれまで測位精度向上のため、様々な手法が提案されてきた。以下に、代表的な手法を示す。

・D-GPS (Differential GPS)

衛星測位原理説明では、衛星-ユーザ間の距離に相当する疑似距離、および衛星位置を用いてユーザ位置を算出できることを示した。一方、これら観測値に誤差が生じた場合には測位誤差が発生する。衛星測位の主な誤差要因を以下に示す。

・衛星位置誤差

衛星位置は衛星軌道情報に基づいた予測値であるため、実際の衛星位置に対し通常数 m 程度の誤差が発生する。通常の衛星軌道情報とは別に作成された精密軌道情報を用いた場合には衛星位置誤差を 5cm 程度まで低減できるが、衛星から送信される情報は通常の衛星軌道情報のみである。

・衛星時計誤差

衛星内の時刻管理は非常に正確なセシウム原子時計によって行われているが、1日あたり 10^{-8} 秒程度のオーダーの時刻誤差を生じる。衛星信号の中に含まれた補正情報を用いて衛星時計誤差を補正できるが、それでも疑似距離換算で数 m 程度の誤差が残存する。

・電離層/対流圏による誤差

電離層や対流圏における大気の屈折率変化の影響により衛星信号速度にわずかな遅延が生じ、これにより疑似距離換算で数 m～十数 m の誤差が生じる。

・受信機時計誤差

通常、ユーザが持つ受信機には比較的安価な時計が用いられるため、衛星の時計誤差を大幅に上回る時計誤差を有することが前提となる。例えば、受信機の時計が 10^{-3} 秒の誤差を持つ場合、疑似距離換算で約 300km の誤差となる。一般的には、受信機時計誤差はユーザ位置と共に未知パラメータとして扱うことで吸収することができる。

・反射波/回折波による誤差

衛星測位では衛星-ユーザ間において信号が最短距離で到達することを前提とするが、地上付近では建物による衛星信号の反射(マルチパス)や回折に伴い、信号伝搬経路の変化が生じることがある(図 9)。この場合、疑似距離には数 m～数十 m 程度の誤差が発生する。

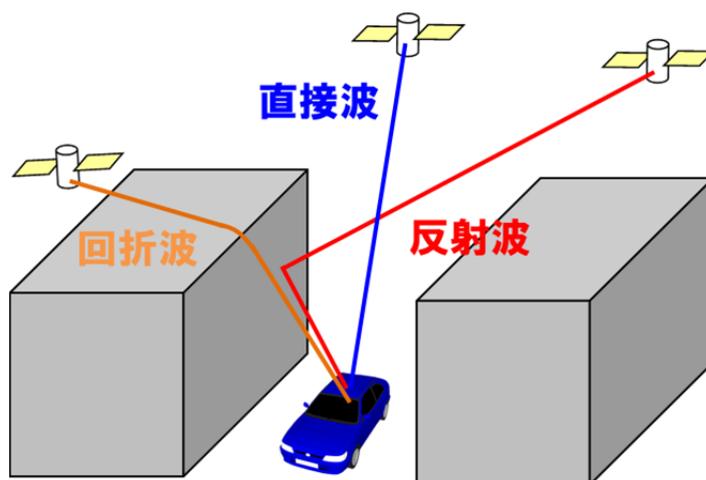


図 9：反射波/回折波イメージ

測位精度向上のためには、このような観測値の誤差要因を極力排除することが望ましい。誤差要因のうち衛星位置誤差，衛星時計誤差，電離層/対流圏誤差については，一定範囲内にいる全ユーザに共通した値の誤差となるため，D-GPS(Differential GPS)を用いることでその影響を補正することができる。

図 10 に D-GPS の概要を示す。D-GPS では基準局で観測した衛星情報を利用して誤差の補正を行う。基準局は上空が開けた場所にあるためマルチパスなどの影響を受けず，また常時正確な時刻情報を取得できるため時計誤差も無視することができる。さらに，精密軌道情報から正確な衛星位置を取得でき，基準局自身の位置情報も静止測量により正確に計測されているため，衛星-基準局間の実際の距離を知ることができる。すなわち，基準局で計測した疑似距離から衛星-基準局間の実際の距離を引くことで，衛星位置，衛星時計，電離層/対流圏に起因する疑似距離誤差を算出することができる。これら誤差は基準局から数百 km 圏内にいるユーザに共通の値となるため，基準局から放送された補正值を用いることで衛星位置，衛星時計，電離層/対流圏に起因する疑似距離誤差を補正することができる。補正後は，疑似距離と実際の衛星-ユーザ間距離との差異は受信機の時計誤差と反射波/回折波による誤差となる。受信機の時計誤差については，ユーザ位置と共に未知パラメータとして扱うことで誤差の影響を吸収できるため，マルチパスなどが生じない環境であれば誤差 1m 程度の測位結果を得ることができる。

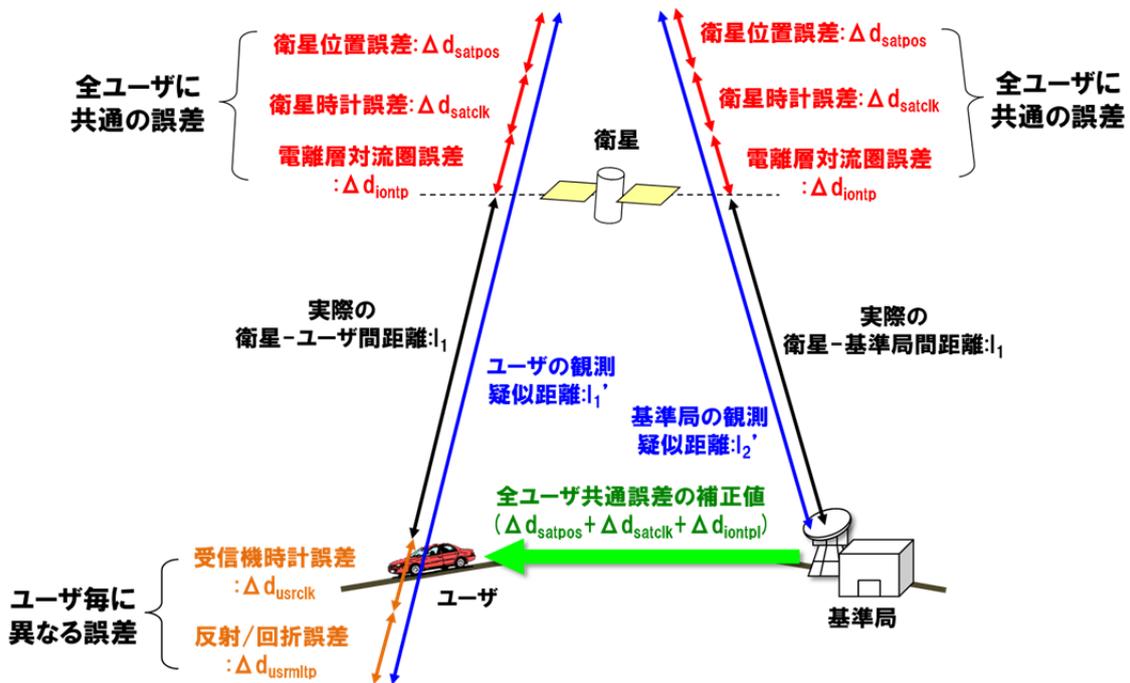


図 10 : D-GPS 概要

・ RTK-GPS (Real time kinematic GPS)

RTK-GPS[13][14]は衛星信号の搬送波位相を利用した測位手法であり、上空が開けた環境であれば誤差数 cm～数十 cm 程度の測位結果を得ることができる。現在、衛星測位手法の中で最も高精度な手法として知られており、測量をはじめ様々な分野で利用されている。

これまで述べた基本的な衛星測位や D-GPS では、衛星信号に含まれる PN(Pseudo Noise)コードと言われる雑音符号を受信することで疑似距離算出を行うが、その波長は約 300m と長いので距離分解能が低く、測位誤差のばらつきが大きくなりやすい。

これに対し、PN コードのキャリアである搬送波は直進性を保つため波長が短く(約 0.2m)、その位相を見ることで波長の 1/10～1/100 程度の距離分解能を得ることができる(図 11)。このため、D-GPS などに比べて高精度な測位が可能となる。一方、PN コードでは信号の発信時刻の情報が含まれているため、衛星-ユーザ間の距離を直接的に算出できるのに対し、搬送波では位相以外の情報を持たないため、衛星-ユーザ間の距離は波長×N と波長×位相(1 周期の中のどこの位相か)の和で表され、この中で N はアンビギュイティと呼ばれる不定の整数となる(図 12)。このため、RTK-GPS ではユーザ位置とアンビギュイティを同時に解くことで測位演算を行う。なお、RTK-GPS は非常に精密な測位精度を扱うため、観測値の誤差要因を極力除くことが重要である。このため、D-GPS と同様に基準局観測値に基づき全ユーザに共通する誤差を事前に除去する方法が一般的に用いられる。一方、RTK マルチパスなどユーザ側に起因した誤差が生じた場合には正しい測位が困難となるため、都心部のような環境では正しい位置が得られる場所は減少する傾向にある。

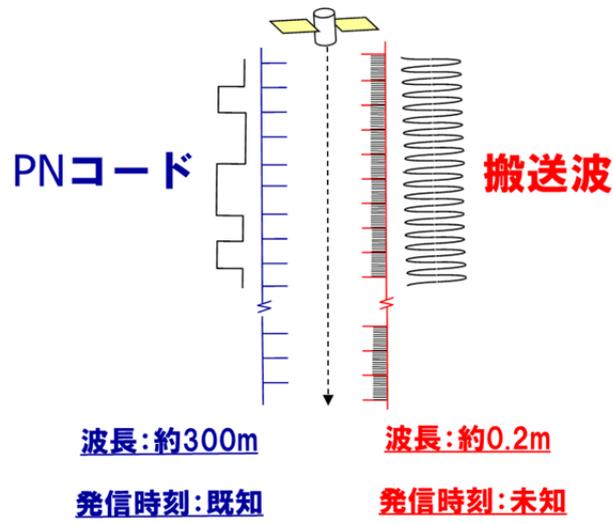


図 11 : PN コードと搬送波の違い

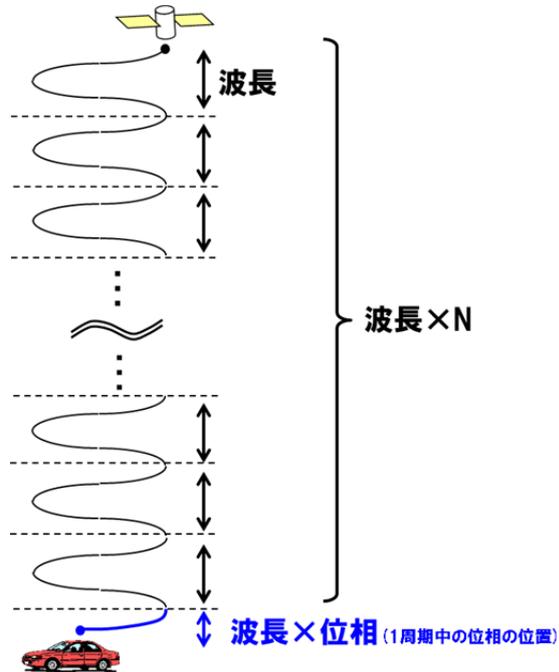


図 12 : 搬送波位相による衛星-ユーザ間の距離表現

【衛星測位まとめ】

衛星測位は上空が開けた環境であれば、世界中のどこでも昼夜・天候を問わず利用できることが最大の利点である。さらに近年では受信機の小型化・低コスト化が進んでいるため、手軽に利用できる点も価値が高いと言える。一方、建物により衛星信号の遮蔽・反射・回折が起こりやすい都心部のような環境では、高精度な測位が可能な場所は限定され、さらに屋内駐車場やトンネルのような衛星信号が完全に遮蔽された環境では測位そのものが不能となるなどの点が課題となる。

2. 2. 1. 2 地図利用型

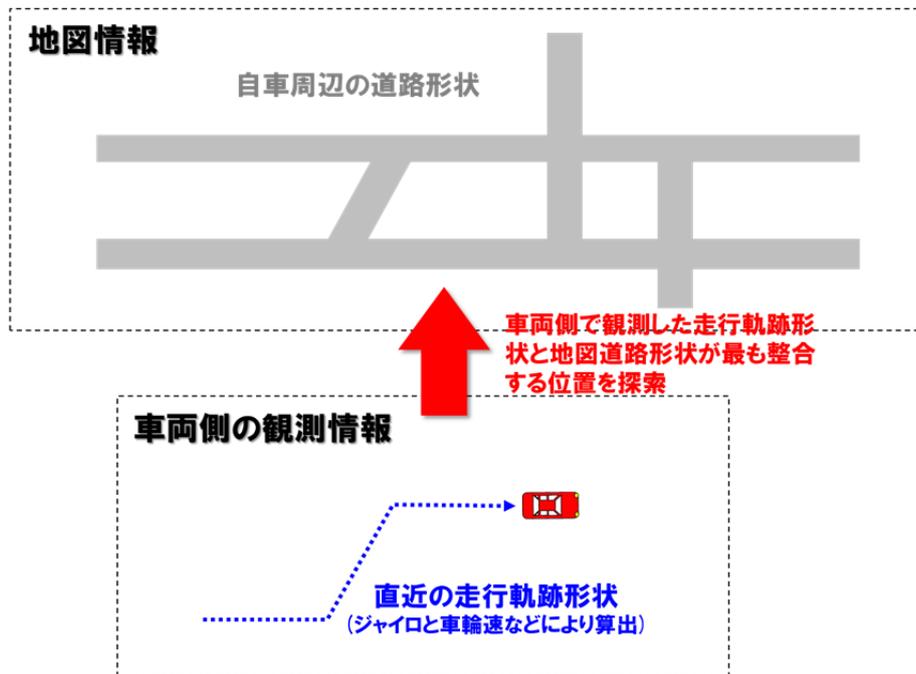
【概要】

衛星を用いた絶対測位では衛星信号から推定した地球座標系の位置に基づき地図上の位置を決定する手法であるのに対し、地図利用型の測位ではユーザ周辺の観測情報と地図情報との照合を行うことで、地図上における位置を決定する手法である。ここで言う地図情報とは、1章でも述べた通り、道路形状の情報、道路周辺の立体物の形状情報、信号/標識/路面マークといった物標情報など、道路周辺のあらゆる空間情報を対象としたデータベース(DB)である。地図利用型の測位では、車載センサで観測した自車周辺における何らかの特徴物の情報と地図情報中の特徴物とのマッチングを行い、整合性が最大となる位置を探索することで地図上における自車位置を特定する。なお、本研究では便宜上、地図利用型の測位を『ローカライズ』と呼ぶことにする。以下では、代表的なローカライズ手法をいくつか示す。

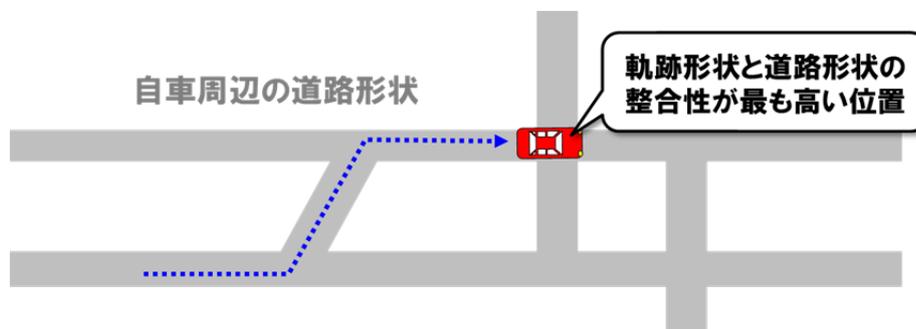
【ローカライズ手法】

・ナビ地図を利用したローカライズ

カーナビゲーション用の道路地図(ナビ地図)を手掛かりに自車位置を決定する手法は、いわゆるカーナビで用いられるマップマッチング[15][16]と呼ばれる技術であり、現在もっとも広く知られたローカライズ手法であると言える。この手法では、自車の走行軌跡の形状と、地図に記録された自車周辺の道路形状とのマッチングを行い、両者の形状がもっとも整合する位置を探索することで地図上における自車の位置を決定する。図13に道路形状を利用したローカライズのイメージを示す。地図情報には道路形状が記録されており、通常これらはリンクとノードにより構成される。また、車両側の観測値として用いられる走行軌跡の形状は、車輪速から算出した進行距離とジャイロのヨーレートから算出した進行方位に基づき与えられる。ローカライズの際には地図上のあらゆる位置に走行軌跡の当てはめを行い、最終的に道路形状と走行軌跡形状の整合性が最も高くなる位置を自車位置とする。この方法はナビゲーション用途の地図情報をそのまま利用することができ、さらに使用するセンサも車載標準装備の汎用センサのみであるため、コストが非常に安い。また、車輪速とジャイロは内界センサであるため、周辺環境に対するロバスト性も高い。一方、この手法では主にナビゲーション用途で使用され、走行中の道路が大まかに分かれば良いため、自動運転に求められるような精密な位置情報を得ることは難しい。例えば、道路形状の特徴がない直線路では進行方向の位置がずれやすく(位置誤差:数m~数十m程度)、また、道路内における横位置(走行レーンなど)を特定することは難しい。



(a) ローカライズの入力情報



(b) ローカライズ結果

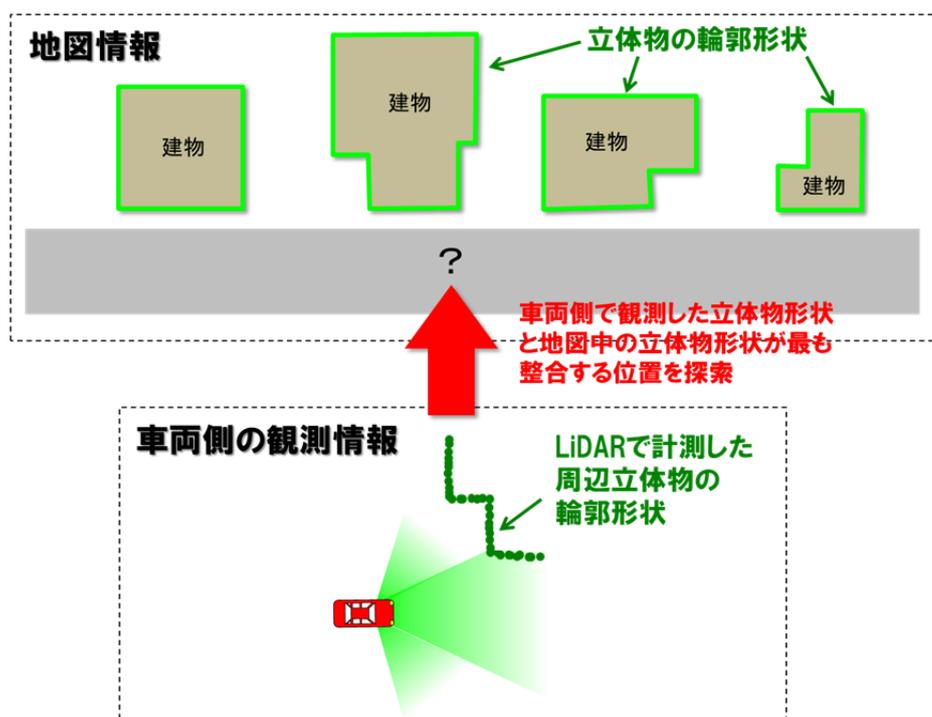
図 13 : 道路形状を利用したローカライズ手法イメージ

・LiDAR を利用したローカライズ

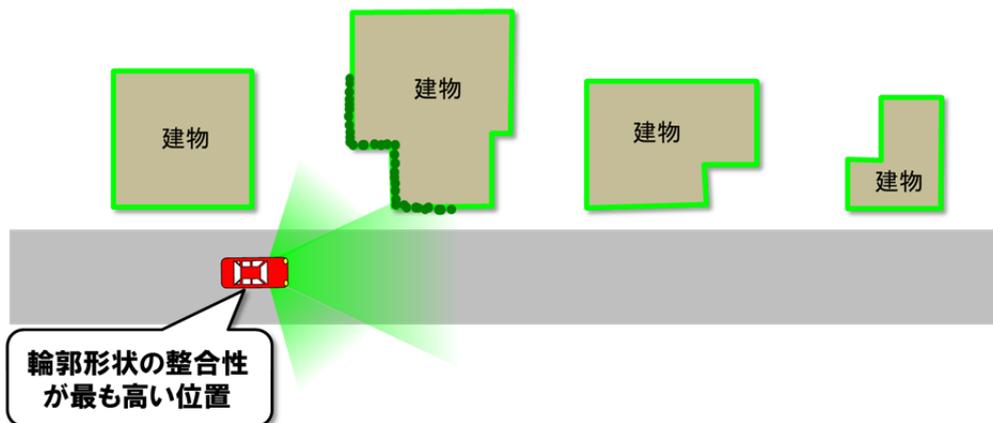
LiDAR(Laser Imaging Detection and Ranging)はレーザ光により立体物との距離を測ることができるセンサであり、その精度・ロバスト性からあらゆる分野で活用されている。LiDAR を用いたローカライズ手法では、走行道路周辺に存在する建物、電柱、ガードレール、縁石など様々な立体物の形状を LiDAR で取得し、これら立体物の輪郭形状を手がかりとしたマッチングを行うことで地図上の自車位置を特定する[17][18]。図 14 に LiDAR を利用したローカライズ手法のイメージを示す。地図情報には LiDAR などを用いて事前

に計測された道路周辺の立体物の輪郭形状が記録されている。一方、車両側では LiDAR により現在車両周辺に存在する立体物の輪郭形状を取得できるため、地図中の立体物輪郭形状と車両で観測された立体物輪郭形状の整合性が最大となる位置を探索することでローカライズを行う。

LiDAR は天候や昼夜などの影響を受けず、常に高精度かつ安定的に周辺の立体物形状を取得することができるため、ローカライズの安定性・精度も非常に高い(位置誤差：～0.3m 程度)。このため、現状、実証実験が行われている自動運転システムではそのほぼ全てが LiDAR を用いたローカライズを採用している。一方、現状では自動運転に適用可能な性能を持つ LiDAR は非常に高コストであるため、一般の市販車両への普及は難しい。



(a) ローカライズの入力情報



(b) ローカライズ結果

図 14：立体物形状を利用したローカライズ手法イメージ

・カメラ画像を利用したローカライズ

カメラ画像を利用したローカライズでは、カメラ画像中に写る周辺の特徴物と、地図中の特徴物とのマッチングを行うことで、自車位置を決定する。道路環境において特徴物として利用できるものは多様であるが、路面マークを利用したローカライズ[19]の例を図 15 に示す。地図側では路面マークの形状・位置などの情報を事前に生成・保持し[100]、これに対し車両側では車載カメラで撮影した前方の路面マークの情報をマッチングの手がかりとして用いる。ローカライズの際には、車載カメラ画像中の路面マークを上空からの視点（鳥瞰図）に変換した上で地図中の路面マークとマッチングを行い、路面マークが最も一致する自車位置を探索・決定する。

カメラ画像を用いたローカライズは近年標準装備化が進んでいる車載カメラをそのまま利用できるためコストが安く、また周辺に特徴物が多く存在する環境であれば高精度かつ高頻度な位置推定も期待できる。一方、周辺環境に特徴物が少ない場合は精度や頻度の劣化の可能性がある。また、特徴物がある場合でも天候や季節などの変化や、一時的な照明の変化などに伴い画像中の物体の見え方が変わった場合、特徴のマッチングが困難になり、やはり精度・頻度が劣化することが課題となる。

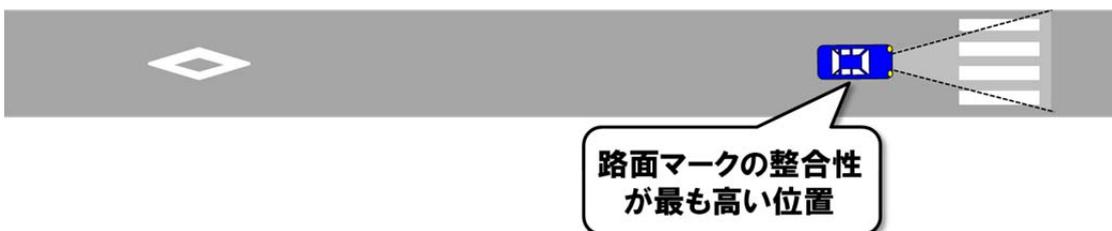
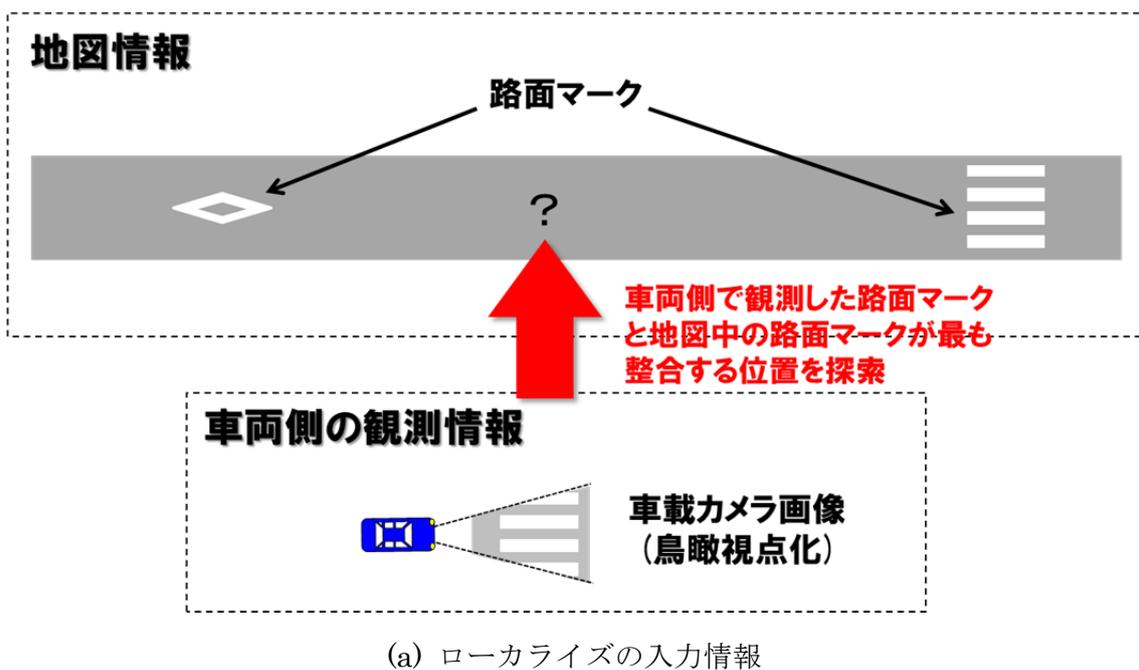


図 15 : カメラ画像を用いたローカライズ手法イメージ

【絶対測位まとめ】

以上では絶対測位のアプローチを衛星利用型と地図利用型に大別して記した。

衛星利用型の測位は上空が開けた環境であれば、世界中のどこでも昼夜・天候を問わず利用できることが最大の利点である。さらに近年では受信機の小型化・低コスト化が進んでいるため、手軽に利用できる点も価値が高いと言える。一方、建物により衛星信号の遮蔽・反射・回折が起りやすい都心部のような環境では、高精度な測位が可能な場所は限定され、さらに屋内駐車場やトンネルのような衛星信号が完全に遮蔽された環境では測位そのものが不能となるなどの問題がある。

これに対し地図利用型の測位（ローカライズ）では、上空が遮蔽された都心部や屋内環境においても安定的に測位を行うことができる。ナビ地図を用いたローカライズでは、安定的に走行中の道路を特定することが可能でありコストも安いですが、詳細な位置情報を得ることはできない。また、LiDARを用いたローカライズでは、高精度な位置情報をロボストに得ることができるが、現状ではコストが高いことが問題となる。カメラ画像を用いたローカライズでは特徴物を多く照合できれば高精度な自車位置が得られるが、ロボスト性に課題がある。

表3に絶対測位の各アプローチの特徴をまとめた表を示す。各手法では長所・短所があり、現状では精度・ロボスト性・コストの全てを高いレベルで成立させることは困難であることが分かる。

表3：絶対測位の代表的アプローチの特徴

	位置精度	ロボスト性	車載コスト
RTK-GPS	◎ (~0.3 [m])	× (信号の遮蔽/反射などに弱い)	○ (千~数千 [円])
マップマッチング	× (~10 [m])	○	○ (千~数千 [円])
カメラ	○ (~1 [m])	△ (照明変化、季節変化などに弱い)	○ (千~数千 [円])
LiDAR	◎ (~0.3 [m])	○	× (数万~数十万 [円])

2. 2. 2 推測航法

推測航法は、自車の移動量に基づき、過去の自車位置からの相対的な位置を算出する手法である。以下に推測航法の代表的な手法を挙げる。

2. 2. 2. 1 内界センサ利用型

・INSを利用した推測航法

INS(Inertial Navigation System)は推測航法に利用する慣性センサの総称であり、主にジャイロと車輪速を指す。ジャイロではヨーレイトなど車両の角速度を計測することができ、車輪速では車輪の回転数の計測に基づき車速を算出することができる。図 16 に INS を利用した推測航法のイメージを示す。各時刻では、ジャイロのヨーレイトから算出した自車の進行方位と車輪速から算出した車速を基に速度ベクトルを算出し、各時刻の速度ベクトルを逐次的に積算していくことで走行軌跡を算出する。INS は内界センサであるため、周辺環境によらず安定的な精度が得られる。一方、一般的にジャイロや車輪速にはバイアス性の誤差があるため、進行方位や自車位置の誤差が蓄積していく。特に進行方位の誤差は推測航法の精度を大きく劣化させるため、その精度向上が課題となる。

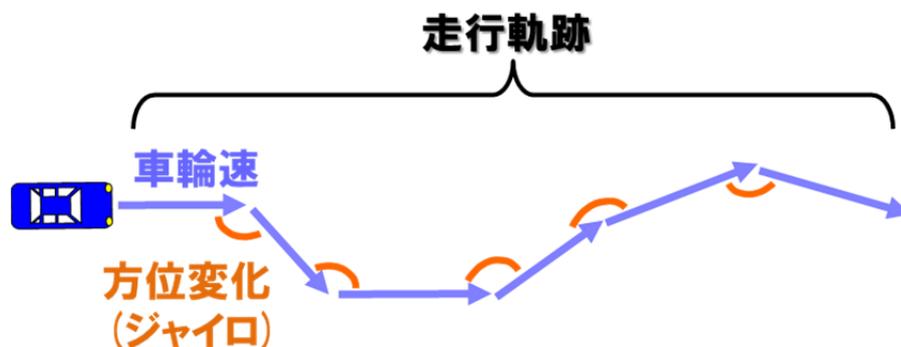


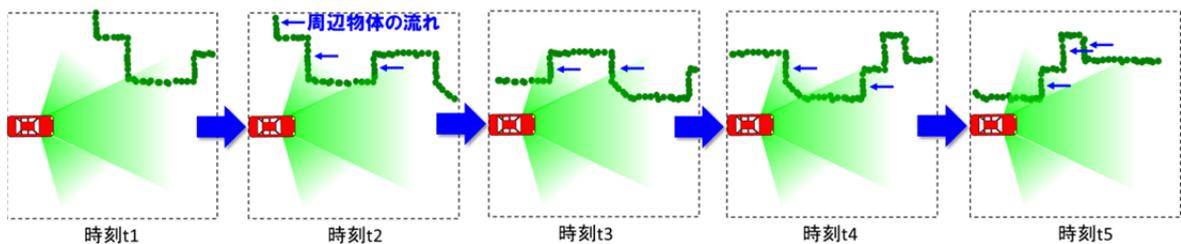
図 16 : INS による推測航法イメージ

2. 2. 2. 2 外界センサ利用型

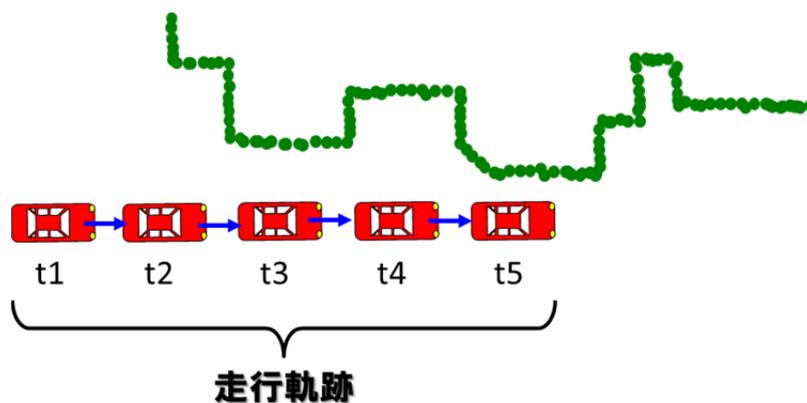
・LiDAR を利用した推測航法

LiDAR を用いたローカライズについて前項で示したが、立体物の輪郭形状の地図情報がないエリアを走行する場合にはローカライズを行うことができないため、推測航法が必要となる。LiDAR では周辺の立体物と自車との相対的な位置関係を測ることができるため、時間的に連続した観測値から得られる立体物の動きに基づき、相対的に自車がどのように動いたかを知ることができる[20][21][22]。図 17 に LiDAR を用いた推測航法のイメージを示す。時刻 $t_1 \sim t_5$ は時間的に連続した LiDAR の観測情報であり、その中では周囲の立体物が自車の前方から後方へ流れていく様子が分かる。立体物は建物などの静止物体であると仮定すると、立体物の動きは全て自車の動きに起因するものであるため、そこから自車の走行軌跡を算出することができる。

LiDAR を用いた推測航法は、INS に比べて高精度であり十分なロバスト性も有する一方、やはり実用化を考えた場合においてコストの高さが課題となる。



(a) 推測航法の入力情報



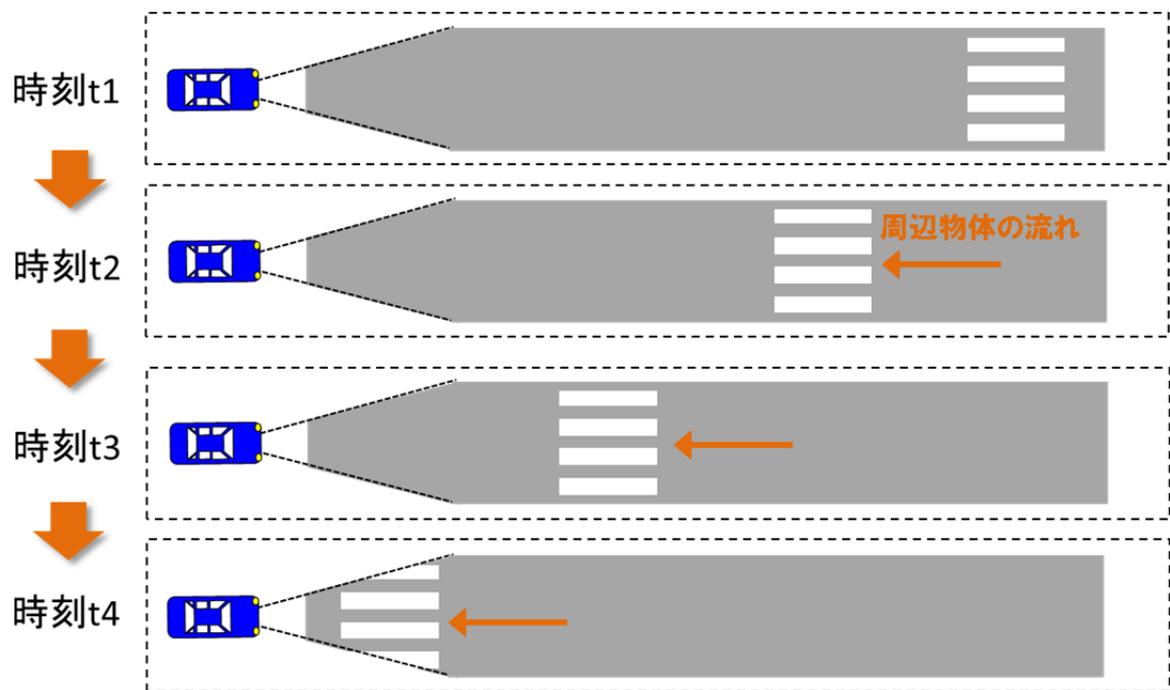
(b) 軌跡推定結果

図 17 : LiDAR を用いた推測航法イメージ

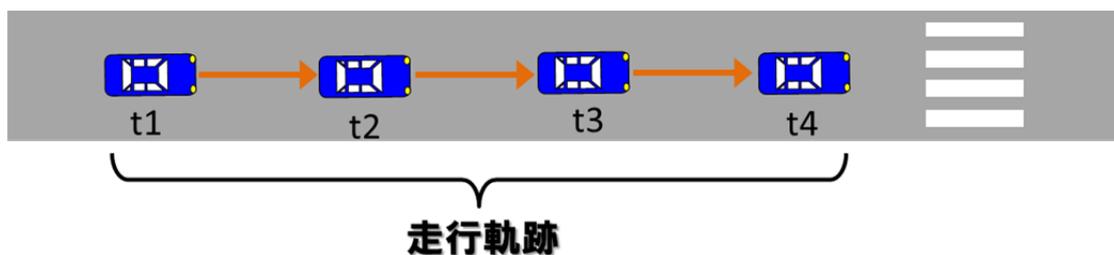
・カメラ画像を利用した推測航法

カメラ画像を利用した推測航法では、カメラ画像中の周辺物体の動きから自車の動きを推定する。図 18 にカメラ画像を用いた推測航法のイメージを示す。カメラ画像を利用する場合、周辺物体の動きを把握する方法は多様であるが、ここでは簡単な例として、画像中の路面マーク位置の推移から自車の動きを推定する方法を挙げる[23]。時刻 $t_1 \sim t_4$ における画像中の路面マークの見え方から、路面マークが自車に対しどのように動いているかが分かるため、そこから相対的に自車の動きを算出することができる。

カメラ画像は比較的成本が安く、ジャイロに比べて誤差が蓄積しにくい利点がある。一方、照明変化が生じた場合や、周囲に移動物体がある場合には精度劣化の恐れがある。また、



(a) 推測航法の入力情報



(b) 軌跡推定結果

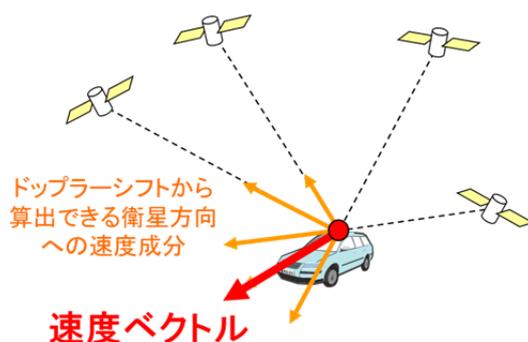
図 18 : カメラ画像を用いた推測航法イメージ

2. 2. 2. 3 衛星利用型

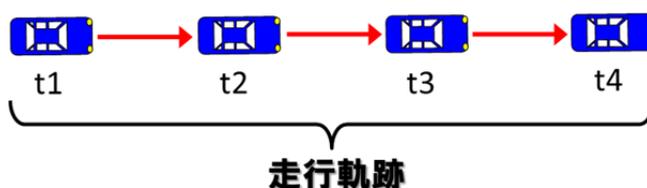
・衛星信号のドップラーシフトを利用した推測航法

衛星信号の搬送波では、衛星-車両間の相対速度の影響によってドップラー効果が発生し、周波数の変化(ドップラーシフト)が生じる。逆説的に考えた場合、衛星信号のドップラーシフトの観測値からは衛星-車両間の相対速度を算出することができ、そこから衛星の速度成分を引くことで車両の速度ベクトルを算出することができる[24][25]。図 19 にドップラーシフトを用いた推測航法のイメージを示す。衛星信号の受信機ではドップラーシフトを観測できるため、まずそこから衛星-車両間の相対速度を得る。この相対速度は衛星の速度成分と自車の速度成分の合計であるため、そこから衛星速度成分(衛星軌道情報より算出可)を差し引くことで、衛星方向への自車の速度成分を算出することができる。そして最後に衛星4つ分以上の速度成分を合わせることで自車の速度ベクトルを算出することができる。速度ベクトルに時間をかけることで移動量ベクトルが得られるので、これを積算することで走行軌跡が得られる。

この方法が他の推測航法と違う点は、東西南北などのように地球座標系の中での進行方位(絶対方位)が得られることである。絶対方位が得られない他の推測航法では、方位の変化量を逐次的に積分する形で方位を算出するため、時刻に伴い方位誤差が蓄積するのに対し、絶対方位が得られる場合には逐次的な積分計算を必要としないため、方位誤差の蓄積が生じない。これがドップラーシフトを用いた推測航法の最大の利点である。一方で、測位を行う場合と同様に衛星信号の遮蔽/反射などの影響を受けるため、他の推測航法に比べて上空遮蔽に対するロバスト性が低い点が問題となる。



(a) ドップラーシフトからの速度ベクトル算出イメージ



(b) 軌跡推定結果

図 19 : 衛星信号のドップラーシフトを利用した推測航法イメージ

【推測航法まとめ】

以上では代表的な推測航法のアプローチを、内界センサ利用型 (INS)、外界センサ利用型 (LiDAR, カメラ画像), 衛星利用型 (衛星のドップラーシフト) に大別し, 各手法について述べた。INS はもともと簡便に利用できる手法であり, 低コストかつロバスト性が高いが, 方位誤差が増加しやすいため軌跡精度に問題がある。LiDAR は精度とロバスト性を両立できるがコストがネックとなる。カメラ画像では INS より精度が良くコストも比較的安価であるが, 周辺環境の変化の影響を受けやすい。また, 衛星のドップラーシフトを用いた場合では方位誤差の蓄積がないため, 上空が開けた環境では軌跡推定が非常に高いが, 信号の遮蔽/反射の発生により可用性と精度が容易に劣化する。

以上に述べた各手法の特性を表 4 に示す。各手法にはそれぞれ長所・短所があり, 軌跡精度, ロバスト性, コストを同時に満足することは困難であることが分かる。

表 4 : 推測航法の代表的アプローチの特徴

	軌跡精度 (100m走行あたり)	ロバスト性	車載コスト
INS	× (~3 [m])	◎	◎ (数百~千 [円])
LiDAR	◎ (~0.1 [m])	○	× (数万~数十万 [円])
カメラ	○ (~1 [m])	△ (照明変化、移動物などに弱い)	○ (千~数千 [円])
衛星ドップラーシフト	◎ (~0.1 [m])	× (信号の遮蔽/反射などに弱い)	◎ (数百~千 [円])

2. 3 本研究の位置付けとアプローチ

自動運転システムでは高精度かつシームレスな測位が必要であり、市販車への搭載を考えた場合にはコストの安さも重要な要素となる。一方、現状においては、絶対測位、推測航法ともに精度・ロバスト性・コストの全てを満たす方法は確立されていない。

そこで、本研究では複数の低コスト車載センサを統合することにより、精度・ロバスト性・コスト全てを満足する推測航法手法および絶対測位手法をそれぞれ提案する。表 5、表 6 に従来の推測航法手法と絶対測位手法に対する本研究の狙い所をそれぞれ示す。安価な INS, GPS, カメラの統合を基本とすることで低コストを実現し、さらにセンサ統合により、個々のセンサの短所を補い長所を活かした構成とすることで、LiDAR と同等の精度・ロバスト性を目指す。

表 5：代表的な絶対測位手法と本研究の狙い所

	位置精度	ロバスト性	車載コスト
RTK-GPS	◎ (~0.3 [m])	× (信号の遮蔽/反射などに弱い)	○ (千~数千 [円])
マップマッチング	× (~10 [m])	○	○ (千~数千 [円])
カメラ	○ (~1 [m])	△ (照明変化、季節変化などに弱い)	○ (千~数千 [円])
LiDAR	◎ (~0.3 [m])	○	× (数万~数十万 [円])
本研究	◎ (~0.3 [m])	○	○ (千~数千 [円])

表 6：代表的な推測航法手法と本研究の狙い所

	軌跡精度 (100m走行あたり)	ロバスト性	車載コスト
INS	× (~3 [m])	◎	◎ (数百~千 [円])
LiDAR	◎ (~0.1 [m])	○	× (数万~数十万 [円])
カメラ	○ (~1 [m])	△ (照明変化、移動物などに弱い)	○ (千~数千 [円])
衛星ドップラースhift	◎ (~0.1 [m])	× (信号の遮蔽/反射などに弱い)	◎ (数百~千 [円])
本研究	◎ (~0.3 [m])	○	○ (千~数千 [円])

カメラ画像を利用した推測航法，絶対測位は共に，高精度かつ屋内外で利用可能であるため，本研究ではカメラ画像をベースとし，その短所を他センサで補う形で統合を行った。以下に，提案手法における推測航法および絶対測位の構成と訴求点について述べる。

・本研究における推測航法の構成と訴求点

カメラ画像を用いた推測航法は，INS に比べて高い精度で自車の走行軌跡推定を行うことができるが，方位蓄積誤差および周囲の移動物などが課題となる。そこで，本研究では他センサとの統合によりカメラ画像を用いた推測航法の改善手法を提案した。図 20 に提案手法の構成と訴求点を示す。

①GPS/INS の統合による方位補正

本研究では GPS のドップラーシフトと INS の時系列データを密に統合することで，都市部のような衛星信号受信状況が悪い環境における絶対方位推定の精度・頻度を向上した。この絶対方位を用いて推測航法(カメラ画像ベース)の方位補正を行うことで，軌跡精度を向上した。

②カメラ画像/INS の統合による移動物除去

カメラ画像中に含まれる他車両などの移動物体は推測航法の精度劣化要因となるため除去することが望まれる。本研究では INS(ジャイロ，車輪速)の観測情報と画像情報を統合することで精度良く移動物除去を行った。これにより移動物が多い環境においてカメラ画像を用いた推測航法の精度が向上した。

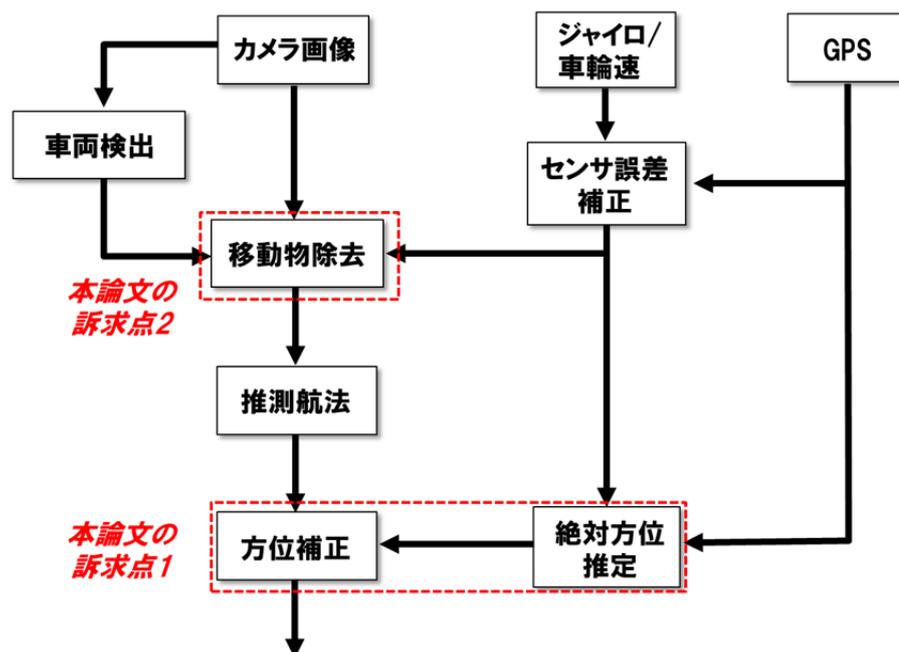


図 20：センサ統合による推測航法の構成

・本研究における絶対測位の構成と訴求点

カメラ画像を用いた絶対測位は、周辺に特徴となる物体が多い場所では高精度な測位が可能であるが、周囲にマッチングを行う手掛かりとなる特徴が少ない場合に精度が劣化する可能性がある。本研究では、他センサとの統合によりカメラ画像を用いた絶対測位の改善手法を提案した。図 21 に提案手法の構成と訴求点を示す。

③カメラ画像/INS の統合によるローカライズ

一般的なローカライズでは現在の観測値に基づき位置推定を行う。これに対し、本研究では INS の走行軌跡を拘束条件としたカメラ画像の時系列データを利用することで、地図情報とマッチングするための手がかりを増加することができる。これによりローカライズの精度・ロバスト性が向上した。なお、GPS 情報はドップラーシフトのみを用い、INS のセンサ誤差補正に利用した。

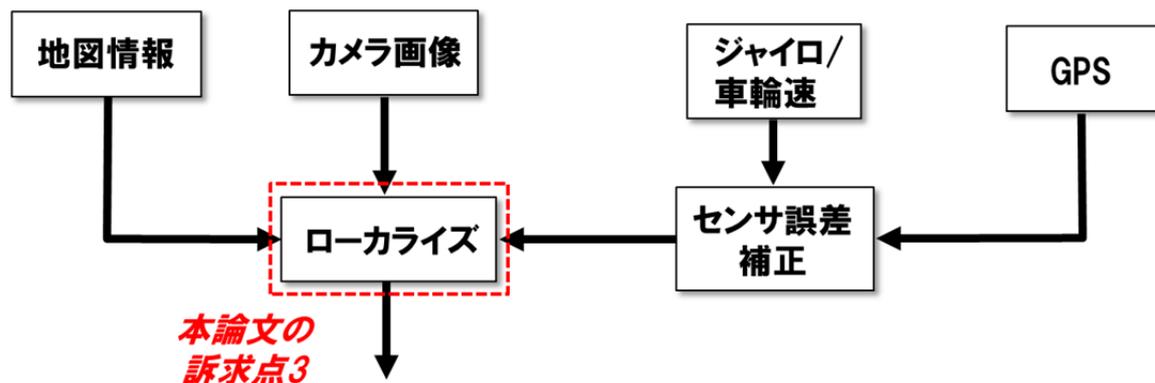


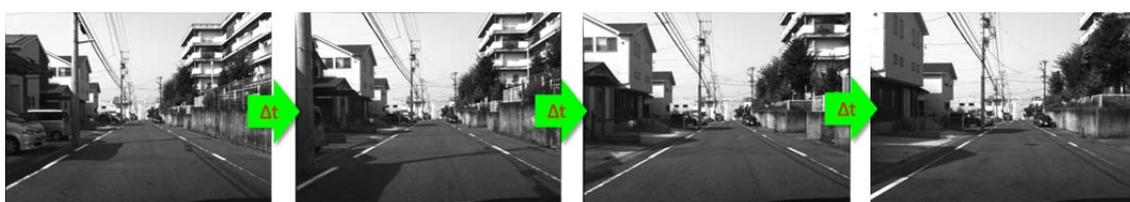
図 21 : センサ統合による絶対測位の構成

3 章 推測航法の性能向上

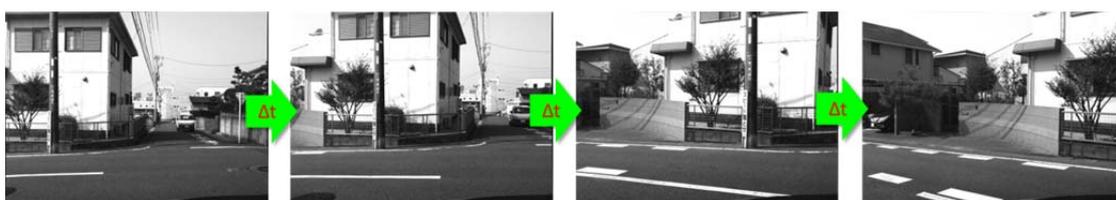
推測航法は精度良い絶対位置が得られない場所における測位手段であり、高精度な測位を持続的に行うために必要不可欠である。自動運転への適用のため、推測航法に求められる条件は、長距離を走行した場合においても誤差の蓄積が小さいこと、どのような環境においても安定的な精度を保てること、そして低コストであることが挙げられる。既存の推測航法のアプローチではこれらの条件を満たすことは難しいが、本研究ではカメラ画像による推測航法をベースとし複数センサを相補的に統合することで高精度、高ロバスト性、そして低コストな推測航法の実現を目指す。本章ではまず、カメラ画像を用いた推測航法の基本原理と課題について述べた後、これら課題に対する従来のアプローチと本研究における提案手法について述べる。

3. 1 カメラ画像を用いた推測航法

カメラ画像を用いた推測航法は、一般的には Visual odometry (以下、VO) と呼ばれ、時間的に連続する画像中の物体の動きから相対的に自車の動きを算出する手法である。図 22 に直進時と左折時におけるカメラ画像の変化を表す。直進時は周囲の物体が自車に接近するように一様に流れており、左折時は周囲の物体が画像左側から右側に流れている様子が分かる。人間はこのように視覚的に捉えた周辺物体の動きから相対的に自己の動きを知覚することができるのと同様に、VO でも同様の原理で画像中における周辺物体の動きから自己の動きの推定が可能である。



(a) 直進時の周囲の物体の動き



(b) 左折時の周囲の物体の動き

図 22 : 自車の動きと周囲の物体の動きの関係

VO で精度良い推定を行うためには、画像中の周辺物体の動きをできるだけ多く正確に追跡することが重要であるが、そのためには画像中において追跡対象の選定方法がポイントであり、様々な手法が提案されている。路面マーク、標識、看板などの物標を追跡するオブジェクトベースの手法[26][27]、建物や看板の角などの目印となる点を追跡する点ベースの手法[28][29][30]、そして近年では画像中の全ての物体を画素単位で追跡する画素ベースの手法[31][32]などが挙げられる(図 23)。オブジェクトベースの手法は誤追跡が少ないが、追跡対象となるオブジェクトが周囲に存在しない場所では利用できない問題がある。また、画素ベースの手法では基本的にどこでも利用可能であるが、実用的な精度を得るためには非常に高度なノウハウが必要であり、かつ計算コストも高いため車載 CPU レベルではリアルタイム動作は難しい。一方、点ベースの手法は、利用可能なシーンは画素ベースの手法とほぼ変わらず、実装が比較的容易であり計算コストも現実的であるため、最も汎用的に利用されている。そこで本研究では点ベースの VO を利用する。以下では、点ベースの VO の基本原理について説明する。



(a) オブジェクトベース



(b) 点ベース



(c) 画素ベース

図 23 : 画像中の物体追跡手法

3. 1. 1 基本原理

図 24 に VO の基本的な処理の流れを示す。本研究ではまず、カメラ画像内において追跡の目印となる特徴点と呼ばれる点を抽出し、さらに時間的に連続な画像において特徴点を追跡することで物体の動きを把握する。そして最後に特徴点の動きに基づき、自転車の動きを推定し走行軌跡を得る。以下では、特徴点の抽出および追跡方法、および走行軌跡の推定方法について説明を行う。

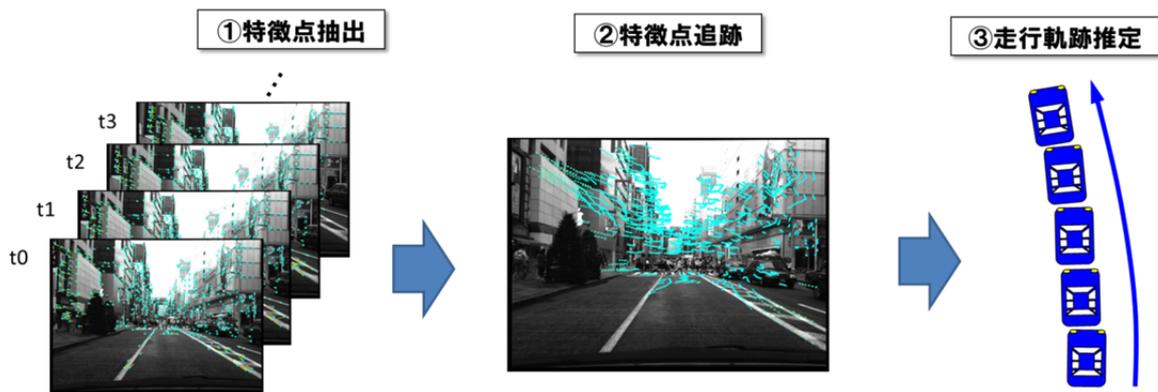


図 24 : VO の基本的な処理の流れ

3. 1. 1. 1 特徴点の抽出および追跡方法

以下ではまず特徴点について説明を行う。特徴点は画像中の目印となる点を意味し、異なる画像間において同一の箇所を対応付けるために利用される。図 25 に特徴点のイメージを示す。画像 1 と画像 2 の同一箇所を対応付けることを目的とした時、画像 1 の建物の角のような尖った場所は、画像 2 でそれがどこに移動したかを正確に特定できるため、特徴点と呼ばれる。特徴点は具体的には画像の輝度パターンにより定義される。図 26 に最も簡単に特徴点を表したイメージ図を示す。画像は画素の集合により表現され、各画素は一般的に 0~255 の輝度を持つ。図 26 中右上の四角形の領域は輝度が低く、それ以外は輝度が高いことを示している。輝度が高い箇所と低い箇所との境目となる画素では画像輝度勾配を定義することができ、四角形の辺の画素では X 方向か Y 方向どちらかの勾配のみが生じるが、四角形の角の画素では XY 両方向の勾配が生じていることが分かる。このように XY 両方向の勾配がある点は他の点と区別しやすいため特徴点として定義される。以上では最も基本的な特徴点の例を述べたが、特徴点の記述方法は様々な方法 (SURF[33], ORB[34], SIFT[35], AKAZE[36]など) が提案されており、特徴の選択によって特徴点の抽出できる頻度や追跡精度、計算負荷などに違いが現れる。どの特徴を用いた場合でも建物の角などの尖った箇所 (画素の輝度勾配が大きい箇所) に特徴点が見られる傾向は共通する。本研究では回転やスケール変化に対しロバスト性が高い AKAZE を用いて特徴点抽出を行った。

そして特徴点の追跡処理では、各時間の画像から独立に抽出した特徴点同士を比較し、互いに類似度が高いペアを同一特徴点と見なすことで特徴点追跡処理を行った。このようにして得られた特徴点の時系列の画像中位置情報はオプティカルフローと呼ばれる。

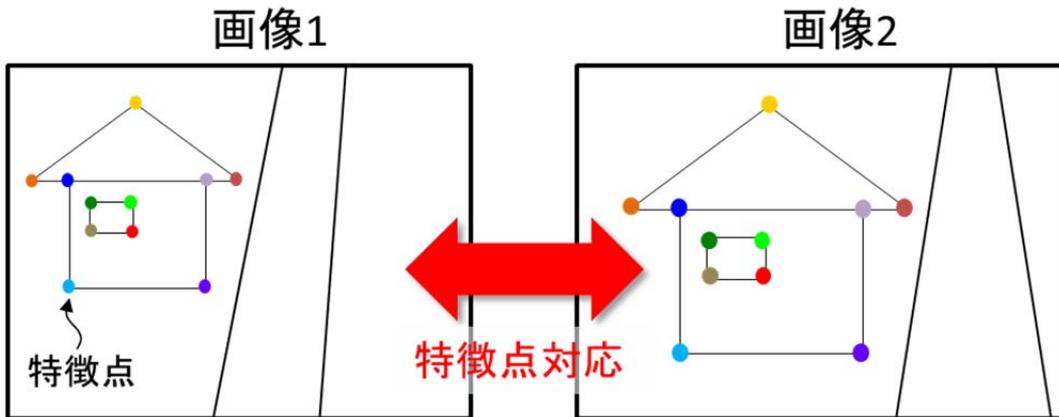


図 25：特徴点の利用イメージ

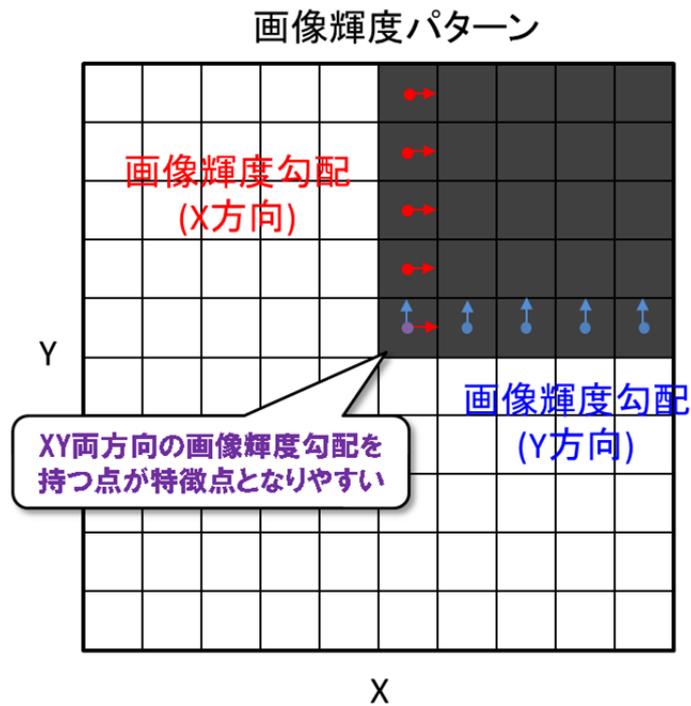


図 26：画像輝度パターンによる特徴点の表現

3. 1. 1. 2 走行軌跡推定

ここでは、オプティカルフロー（カメラ画像中の特徴点の時系列の位置）を用いて自転車の走行軌跡を推定する方法を説明する。まず、手法の基本的な考え方について説明した後、具体的計算方法について述べる。

【手法の基本的な考え方】

図 27 にカメラ画像中の特徴点の位置，実世界中の特徴点の位置，自転車位置・姿勢との関係を模式的に示す。図中のカメラ撮像面とカメラ中心は両者ともカメラ構造の一部であるため実際には同一位置にあると見なして良い。また，以下ではカメラ画像中の特徴点の位置を特徴点 2 次元位置，実世界中の特徴点の位置を特徴点 3 次元位置と表現する。

特徴点 2 次元位置は，特徴点 3 次元位置がカメラの撮像面に投影された像であるため，特徴点 3 次元位置と自転車位置(カメラ中心)を結ぶ線(以下，視線)とカメラ撮像面との交点が特徴点 2 次元位置となる。すなわち，特徴点 2 次元位置は，特徴点 3 次元位置と自転車の位置・姿勢によって決定される。また，特徴点 3 次元位置は，自転車位置から特徴点 2 次元位置の奥行方向へ延ばした視線上に存在する。

次に，車載カメラ画像から特徴点を時系列で観測した時の，特徴点 2 次元位置，3 次元位置および自転車位置・姿勢の関係を示す(図 28)。特徴点は静止物体上にあることを前提とするため，特徴点 3 次元位置は時間変化しない。一方，車両は時刻と共に移動するため，各時刻において異なる視線が特徴点方向へ延びている。VO では，「同一の特徴点を見ている各時刻の視線は一点で交わるはず」という前提を手がかりに各時刻の自転車位置・姿勢(= 走行軌跡)を推定する。

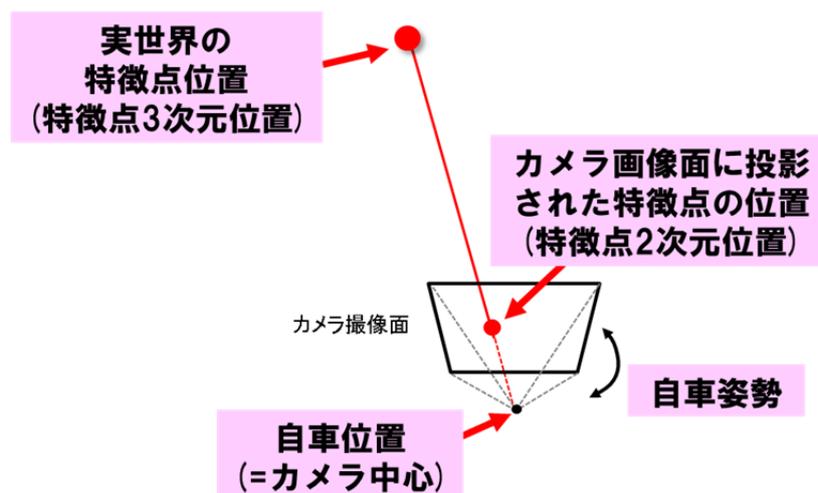


図 27：特徴点 2 次元位置，特徴点 3 次元位置，自転車位置・姿勢との関係

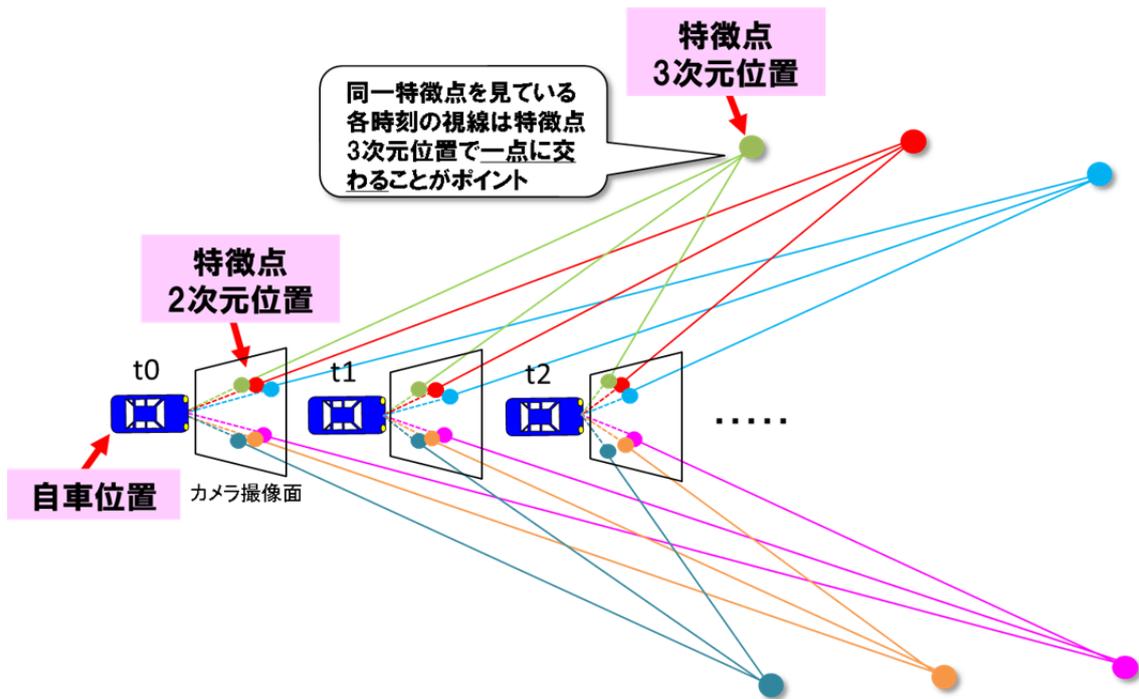


図 28：特徴点 2 次元位置，特徴点 3 次元位置，自車位置・姿勢の関係（時系列）

以上では，車両が移動時における，特徴点 2 次元位置，特徴点 3 次元位置，自車位置・姿勢(走行軌跡)の関係を示した。以下では，実際に走行軌跡推定を行う際の問題設定とその解法について述べる。図 29 に走行軌跡推定の問題設定を示す。VO を用いて走行軌跡を行う際，カメラ画像で観測できる情報は特徴点 2 次元位置のみであり，その他の情報は未知である。このため，VO では特徴点 2 次元位置を入力情報として，自車の走行軌跡を推定することが命題となる。ここでは各時刻における同一特徴点への視線は一点で交わる，という拘束条件を満たすような走行軌跡を探索する。初期条件として適当な走行軌跡を与えた場合(図 29)では，各時刻において車両から特徴点へ向けて延びる視線は一点で交わらないが，そこから各時刻の自車位置・姿勢を少しずつ動かしていき，各時刻の視線が一点で交わるような走行軌跡を探索することで，最適な走行軌跡が得られる。図 30 に走行軌跡の最適化後のイメージを示す。各時刻の特徴点への視線が一点で交わっており，その結果，最適な走行軌跡が得られていることが分かる。

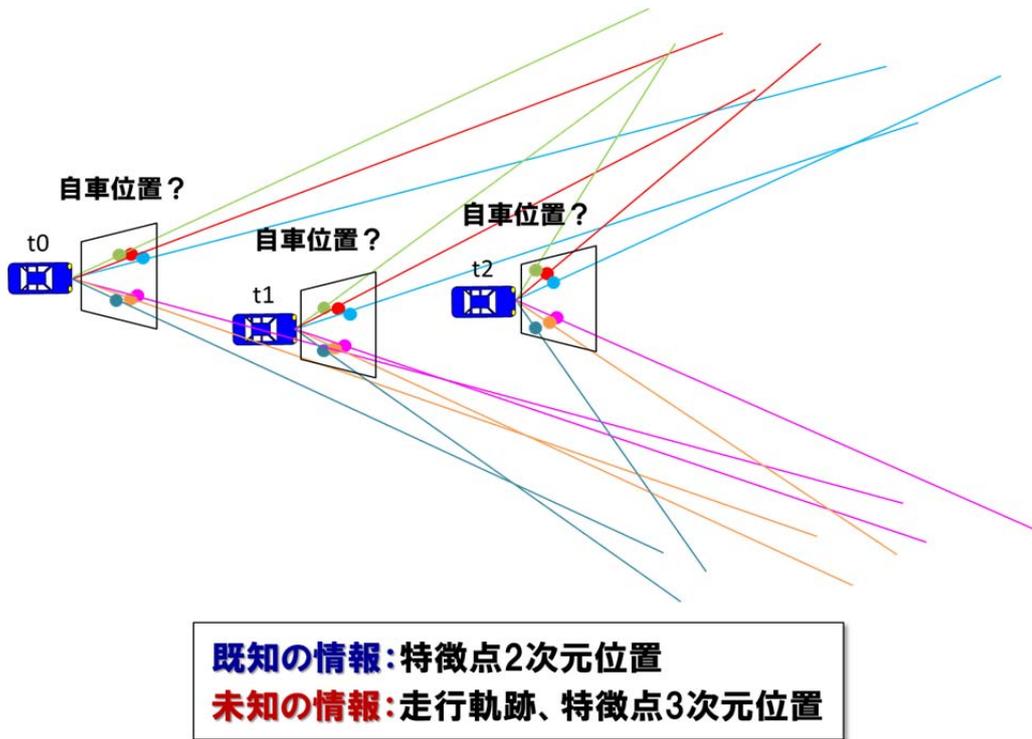


図 29 : 走行軌跡推定の問題設定

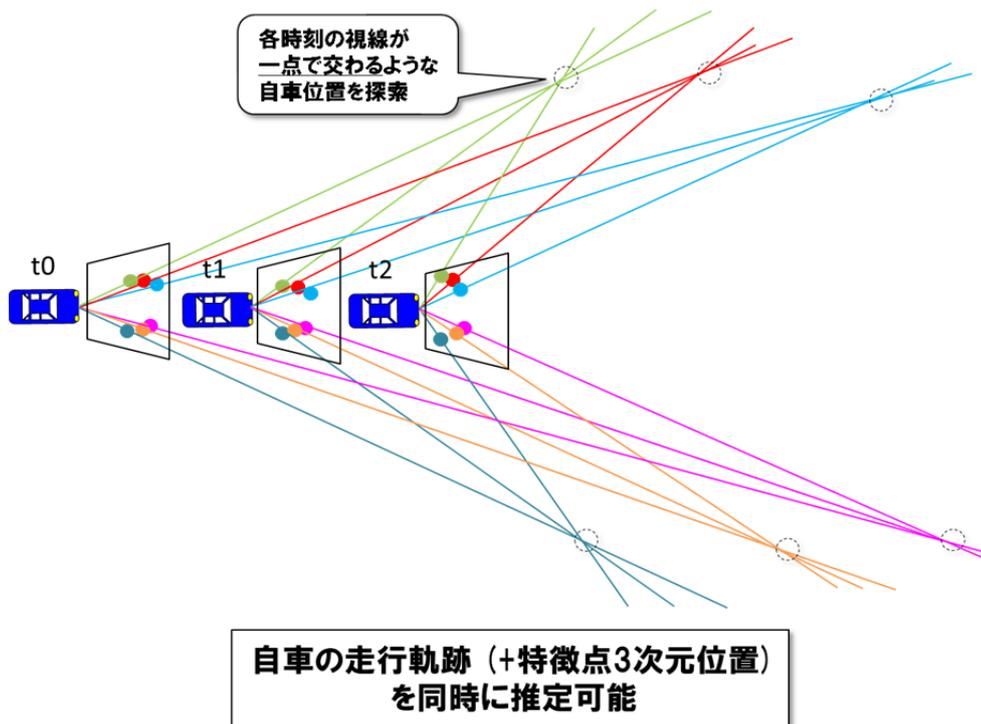


図 30 : 走行軌跡推定のイメージ

【計算方法の詳細】

一般的に各時刻の画像内における特徴点 2 次元位置，実世界中の特徴点 3 次元位置，および各時刻の自車の位置・姿勢の関係式（観測方程式）は式(1)のように表される。

$$\mathbf{X}'_{t,m} = \mathbf{K}\mathbf{R}_t[I | -\mathbf{x}_t]\mathbf{X}_m \quad (1)$$

ここで， $\mathbf{x}'_{t,m}$ は画像中の特徴点位置（観測値）， \mathbf{K} はカメラのキャリブレーション行列（既知）， \mathbf{x}_t は 3 次元自車位置（未知数）， \mathbf{R}_t は自車の姿勢（ピッチ，ヨー，ロール）を要素とした 3 次元回転行列（未知数）， \mathbf{X}_m は実空間中の特徴点の 3 次元位置（未知数）， I は単位行列を示す。 t, m はそれぞれ時刻インデックス，特徴点インデックスを示す。各変数の定義を図 31 に示す。

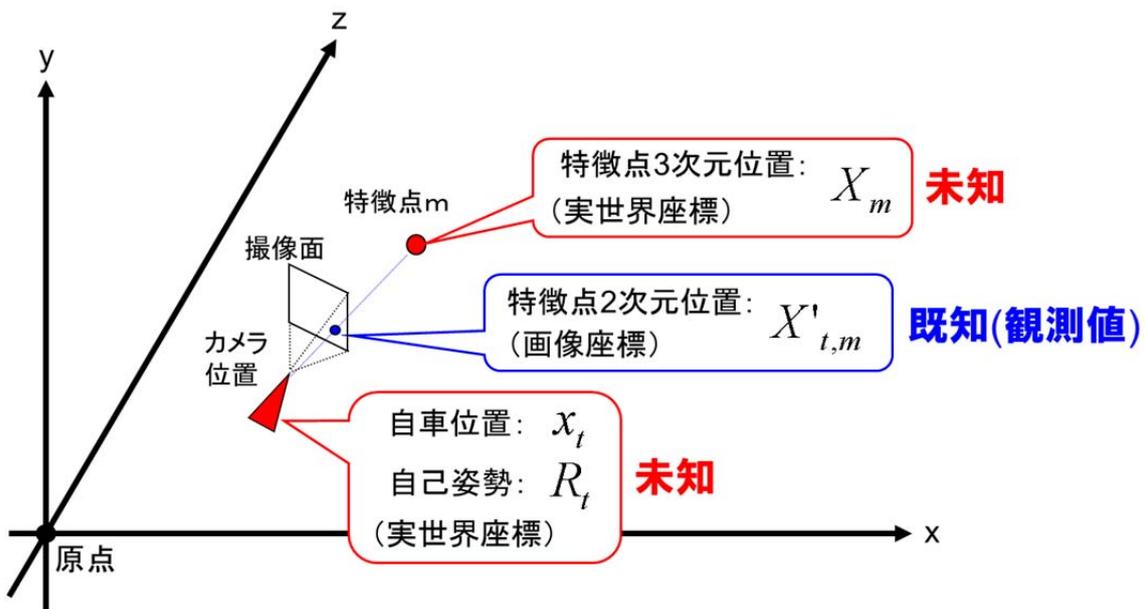


図 31 : 各変数の定義

キャリブレーション行列 \mathbf{K} は式(2)で表される。

$$\mathbf{K} = \begin{bmatrix} f_x & 0 & p_x \\ 0 & f_y & p_y \\ 0 & 0 & 1 \end{bmatrix} \quad (2)$$

ここで， f_x, f_y はそれぞれカメラ画像縦方向横方向の焦点距離， p_x, p_y はそれぞれカメラ画像中におけるカメラ中心位置(縦方向，横方向)を示す。各パラメータはキャリブレーション

ションボードなどを用いて事前に計測されており，既知のパラメータとして扱う。

また，3次元回転行列 \mathbf{R}_t は式(3)で表される。

$$\mathbf{R} = \mathbf{R}(Z, \phi)\mathbf{R}(Y, \theta)\mathbf{R}(X, \psi) \quad (3)$$

$$= \begin{bmatrix} \cos \phi & -\sin \phi & 0 \\ \sin \phi & \cos \phi & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos \theta & 0 & \sin \theta \\ 0 & 1 & 0 \\ -\sin \theta & 0 & \cos \theta \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \psi & -\sin \psi \\ 0 & \sin \psi & \cos \psi \end{bmatrix}$$

$$= \begin{bmatrix} \cos \phi \cos \theta & \cos \phi \sin \theta \sin \psi - \sin \phi \cos \psi & \cos \phi \sin \theta \cos \psi + \sin \phi \sin \psi \\ \sin \phi \cos \theta & \sin \phi \sin \theta \sin \psi + \cos \phi \cos \psi & \sin \phi \sin \theta \cos \psi - \cos \phi \sin \psi \\ -\sin \theta & \cos \theta \sin \psi & \cos \theta \cos \psi \end{bmatrix}$$

ここで ϕ ， θ ， ψ はそれぞれ，実世界座標の x, y, z 軸周りの回転角であり，ピッチ角，ヨー角，ロール角に相当する。

式(1)の観測方程式において未知数は x_t ， \mathbf{R}_t ， \mathbf{X}_m であり，観測値 $\mathbf{X}'_{t,m}$ 1 つにつき，1 つの観測方程式を得ることができる。この観測方程式において最適化問題を解く方法は大きく分けて二つある。一つは逐次推定型の EKF (Extended Kalman Filter) [37]，もう一つは一括推定型の BA (Bundle Adjustment) [38] である。EKF では各時刻の観測値の誤差を考慮して時刻が進むごとに推定値を少しずつ最適解に近づけていく手法であり，比較的低い計算量で最適化問題を解くことができる。一方，BA は時系列の観測データを連立し，最小二乗法で解くことにより，過去一定範囲内の推定値を一括して得る手法である。この方法は時系列データに含まれる全ての未知数を同時に解くため，計算量は EKF より大きくなる傾向にあるが，誤差の蓄積が増加しにくい利点がある。本研究ではより高い精度を目指すため BA を用いた最適化問題の解法を採用した。

式(4)に最小二乗法のコスト関数を示す。ここでは，コスト関数 E_{cam} が最小となる x_t ， \mathbf{R}_t ， \mathbf{X}_m を探索することで最適化問題を解く。式(2)は非線形であるため，コスト関数の勾配情報に基づき最適な解を探索する Levenberg-Marquardt 法 [39] を用いることにより x_t ， \mathbf{R}_t ， \mathbf{X}_m の最適化を行った。

$$E_{cam}(\mathbf{R}_t, x_t, \mathbf{X}_m) = \sum_{t=0}^M \sum_{m=0}^N (\mathbf{X}'_{t,m} - \mathbf{K}\mathbf{R}_t [I | -\mathbf{x}_t] \mathbf{X}_m)^2 \quad (4)$$

(M, N はそれぞれ推定に用いる時系列データ数, 特徴点数)

3. 1. 2 課題

VO は周囲に動きを追跡できる物体がある環境であれば屋内外問わず、良好な精度の走行軌跡推定を可能とする一方、精度劣化要因となる課題もある。以下に、大きく分けて 3 つの課題を示す。

① 方位の蓄積誤差

VO では各時刻間における自車の相対的な方位変化を精度良く推定できるが、方位変化を逐次的に積分して車両方位を算出する際には、各時刻で推定した方位変化の誤差が蓄積していく。一般的に VO で推定した方位変化はバイアス性誤差を持たないが、ノイズ誤差を有するため、方位算出の際にはノイズ誤差が蓄積することでランダムウォークに類するバイアス性の誤差となる。また、特徴点の追跡失敗など外的要因による方位変化誤差が生じた場合には、これがそのまま方位のバイアス性誤差として蓄積される。このように方位のバイアス性誤差が増加した場合には進む方向がずれることで、大幅な走行軌跡誤差を引き起こす(図 32)。走行軌跡推定誤差を低減するためには、長時間走行した場合でも方位誤差が蓄積しないための工夫が必要となる。

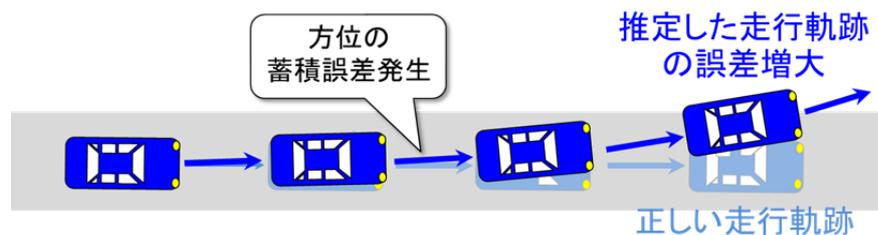


図 32 : 方位の蓄積誤差に伴う走行軌跡誤差拡大

② 車両周辺の移動物

VO は周囲の静止物を動きから相対的に自車運動の推定を行うため、周囲に車両などの移動物が多く存在する場合には走行軌跡の精度劣化が生じる恐れがある。画像中における静止物の動き方は自車の動きのみによって決まるため、そこから自車の動きを逆算することができるが、画像中における移動物の動きは、自車と移動物の相対的な動きによって決まるため、移動物の動きが既知でない限り自車の動きを逆算することはできない。図 33 に例を示す。自車が直進中の場合、周囲の静止物は自車に接近するように画像の手前端側に流れていく。一方、画像中における移動物体の動きは、自車と移動物体の相対的な動きによって決まるため、前方の移動物が自車より速い場合は、画像中の移動物は自車から遠ざかるように画像上方へ動き、移動物の車速が自車より遅い場合にはその逆となる。また、自車と移動物が同速度で動いている場合には画像中の移動物は静止状態となる。以上の理由により、画像中の移動物は自車の動きを推定するための手がかりにならないばかりか、逆に精度劣化要因となるため、推定精度向上のためには移動物上のオプティカルフローを

検出し、VO の入力から除外する処理が必要となる。

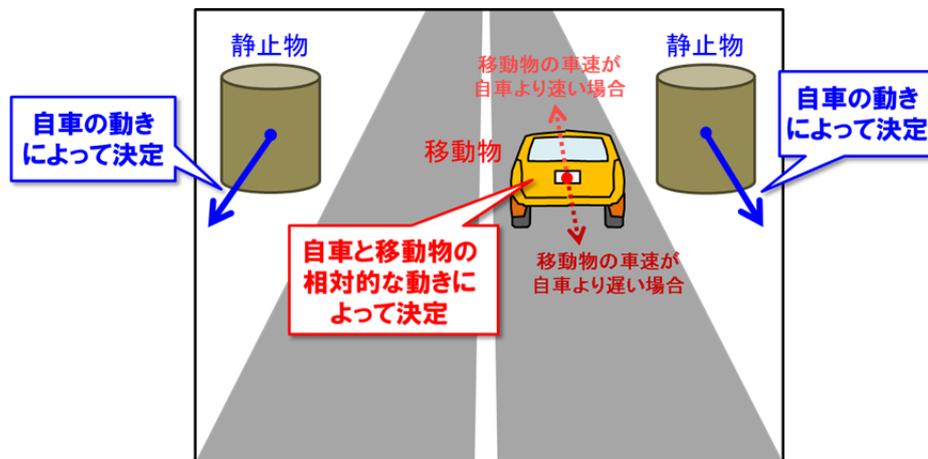


図 33：画像中の静止物体と移動物体の動きの違い

③ 照明条件の急激な変化

照明条件の変化などによって視界に急激な変化が生じた場合、画像内の物体追跡が困難になり誤差が増大する恐れがある。図 34 に精度劣化シーンの例を示す。直射日光がカメラに入ってきた場合(a)、画像の一部分の明度が急激に上がるため、物体の追跡が困難となる。また、屋内から屋外に出る場合(b)、照明の明度が急激に大きくなるため、カメラの絞りの調整が困難となり、画像全体の明度が大きく変化する。この場合にも画像中の物体の追跡は困難となる。



(a) 直射日光が射すシーン



(b) 屋内から屋外に出るシーン

図 34：照明条件の変化に伴う画像輝度変化

3. 1. 3 従来研究

以上で挙げた VO の各課題についてはこれまで様々な研究が行われている。従来研究のアプローチを以下に示す。

【方位蓄積誤差に対する従来研究のアプローチ】

方位蓄積誤差は VO のように相対的な方位推定である限り発生を避けることが出来ないため、絶対方位推定による方位誤差の補正が有効な解決策となる。これまで様々な方法の絶対方位推定手法が提案されている。

最も原始的な絶対方位推定手法としては、地球の磁気方向から南北を感知する磁気方位計[40]が挙げられる。[41][42]は磁気方位計から得られる絶対方位を用いて VO の方位蓄積誤差の補正を行い、一定の効果を確認した。しかしながら、地磁気にはむらがあるため磁気方位計で得られる絶対方位は一般的に数 deg 程度の方位誤差があり、また、地磁気は周囲に金属製の構造物の影響を受けやすいため、高架や電柱などの金属製構造物が多い都心部においては方位誤差が劣化しやすい問題がある。

また、GPS 信号のドップラーシフトを用いた絶対方位推定により、VO の方位補正を行う方法[43][44]が提案されている。この方法では、GPS 信号のドップラーシフトから算出できる車両の速度ベクトルから絶対方位を取得する。類似の方法では、GPS で得た位置情報を利用した方法[45]もある。この方法では時系列の位置情報と VO の軌跡が一致するように VO の方位を補正する。これら GPS を利用した方法は GPS 受信環境が良好な場所では良好な精度で方位補正を行うことができるが、都心部では衛星受信状態の劣化により正しい方位補正ができる場所が限られることが問題となる。

また、道路地図情報を用いた方位補正手法[46][47][48]も提案されている。この方法ではカーナビで用いられるマップマッチングを行う際に、走行中の道路の向きを用いて進行方位の補正を行う。道路地図上を走行中であればどこでも方位を補正できる利点がある一方、道路地図から知ることができる情報は大局的な方位のみであるため、車線変更などで局所的な方位変化が生じた場合には方位誤差が生じ、また駐車場のような広域な走行エリアでは方位補正を行うことができないなどの問題がある。

【移動物に対する従来研究のアプローチ】

画像中の移動物による VO の精度劣化を避けるためには、移動物上のオプティカルフローの検出・排除を行うことが解決策となる。これまで移動物上のオプティカルフローを検出するための研究は多数行われている。

移動物上のオプティカルフローの検出手法として、一般的に RANSAC[49]が用いられる。RANSAC は多数決投票による外れ値検出手法であり、画像中のオプティカルフロー全体に対し、移動物上のオプティカルフローの割合が少ない場合には有効に働く[50][51]。しかしながら、移動物上のオプティカルフローの割合が大きい場合には、外れ値として除去すべき対象が少数派ではなくなるため、正しい判別ができなくなる。

また、画像以外の情報をリファレンスとした移動物検出方法もある。[52][53][54]では

INS で計測した自車の動きから画像中の正しいオプティカルフローの動きを予測し、そこから外れた動きのオプティカルフローを移動物と判定する方法を提案している。この方法は移動物が多いシーンでもその影響を受けず動作できる利点があるが、カメラと INS に僅かにでも同期ずれがある場合には、特に車両がピッチ変動などにより急激な動きをした瞬間に移動物の誤検出が多く発生する恐れがある。また INS 以外にもステレオカメラ画像 [55][56]や、LiDAR[57][58][59]を用いた移動物検出手法もある。これらは精度良くロバストに移動物検出を行うことができるが、コストの高さが問題となる。

画像のパターン認識を用いた移動物検出手法[60][61]も提案されている。パターン認識は画像中に含まれる特定の物体を検出する技術であり、SVM[62]、CNN[63][64]などを用いた機械学習をベースとした手法が一般的に用いられる。パターン認識技術を用いることで画像中に含まれる（一般的に移動物と見なされる）車両や歩行者などの領域を検出し、その領域内のオプティカルフローを除去することができる。パターン認識の性能が良好であれば安定的な移動物検出を行うことができるが、シーンによってはパターン認識に誤りが生じ、対象となる移動物を検出しない場合や、逆に以外の物を検出する場合もある。また、パターン認識では走行車両と停車中の車両の区別ができないため、車両を移動物と見なした場合には静止車両上のオプティカルフローも除去され VO の精度劣化要因となる恐れがある。

【照明条件の変化に対する従来研究のアプローチ】

照明条件の変化が生じた場合には、画像中に正しいオプティカルフローがほぼ得られなくなるため、自車運動を正しく推定することは困難となる。このため、その影響を避けるためには、VO の精度劣化状態を判別し、その瞬間を VO の代わりに INS で算出した軌跡で繋ぐなどの対策が必要となる。これを行うためには、VO の精度が劣化したか否かの判別方法がキーであり、いくつかの方法が提案されている。

[65]では INS で計測した自車の動きと VO で算出した自車の動きを比較し、両者に一定以上の差異がある場合には、VO の精度劣化が生じていると判断する方法を提案している。INS の精度は常に安定であるため、この方法を用いることで VO のある程度大きい誤差を排除することができる。また、[66]では VO を行う際に、画像中のオプティカルフローを無作為に選択した複数の組み合わせを作り、それぞれの組み合わせから運動を算出した後、その分散値に基づき VO の精度を判断する方法を提案しており、一定以上の誤差を高い精度で除去できることが確認されている。以上の方法を用いることで VO の精度劣化状態の判別については実用的に問題がないレベルの効果が得られると考えられるため、本研究では照明条件の変化についての対策は改めて提案しないものとする。

3. 1. 4 本研究のアプローチ

以上では VO の 3 つの課題に対する従来研究のアプローチについて述べた。本研究ではこれら課題のうち、方位蓄積誤差と移動物に対する新たな対策を提案する。

方位の蓄積誤差については、GPS のドップラーシフトと INS の時系列データをタイトカップリング方式で統合することにより、衛星数が少ない都心部において方位補正頻度を増加する手法を提案する。また、移動物については、INS とパターン認識を相補的に統合することにより移動物が多い環境においても正確に移動物検出・除去を行う手法を提案する。以下ではこれら提案手法についての説明を行う。

3. 2 提案手法1：ドップラーシフトとINSの

時系列データ統合による方位補正

本研究ではカメラ画像を用いた推測航法をベースに、課題対策として方位補正の高頻度化および移動物除去の高精度化を行った。本節では、方位補正の頻度向上方法、およびその前段処理にあたるセンサ誤差補正方法について説明を行う。(図 35 赤字箇所)

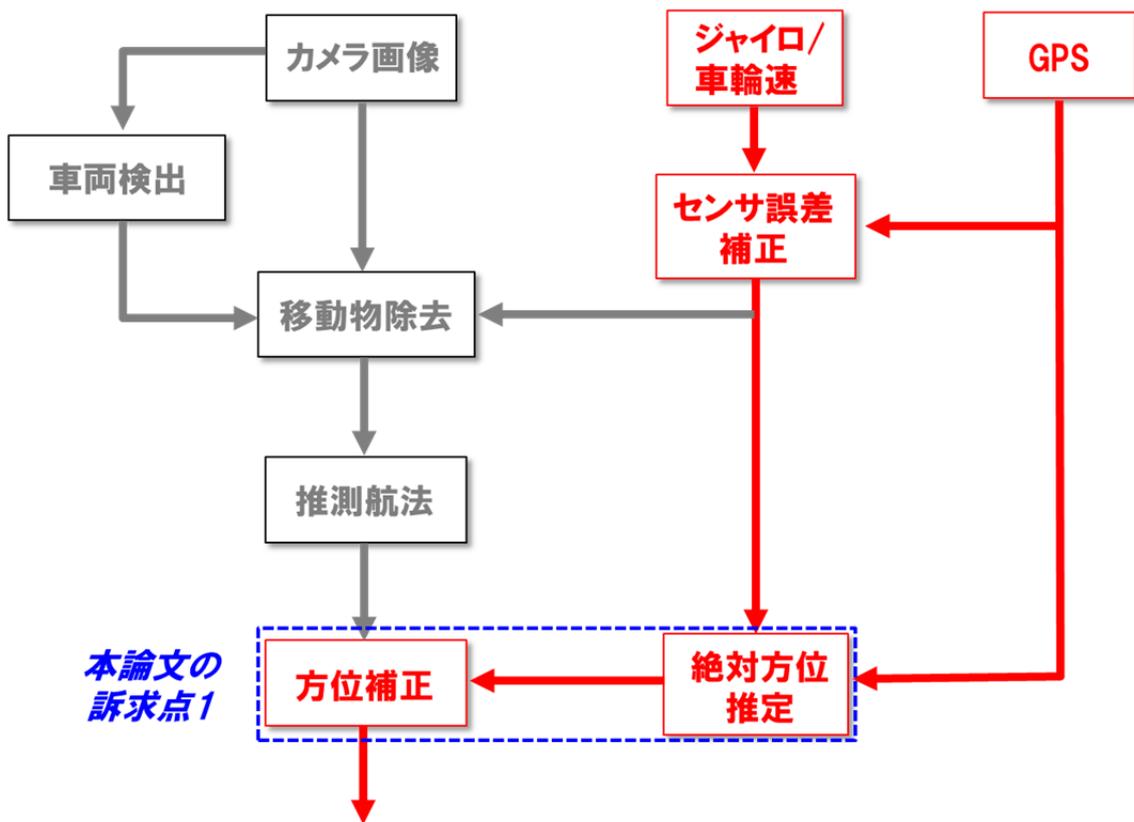


図 35：本研究が提案する推測航法概要と本節における説明箇所

3. 2. 1 絶対方位推定手法の概要

本研究では衛星信号のドップラーシフトを用いて VO の方位補正を行うが、衛星数が減少する都心部のような環境では絶対方位を推定できる場所が限られるため、十分な頻度で方位補正を行えない恐れがある。そこで、衛星信号のドップラーシフトと INS の時系列情報を統合することによって衛星環境が劣悪な場所における絶対方位推定の頻度を改善した。図 36 に提案手法における絶対方位推定手法の構成を示す。提案手法の入力は GPS と INS の情報であるが、INS を構成するジャイロと車輪速にはそれぞれバイアス誤差、スケール誤差が乗っているため、本研究ではドップラーシフトから推定した車両の速度を用い

てこれらの誤差の補正を行った。ここではまずその補正方法について説明を行う。そして次にドップラーシフトと INS の統合による絶対方位推定の頻度向上の手法(提案手法)について説明する。

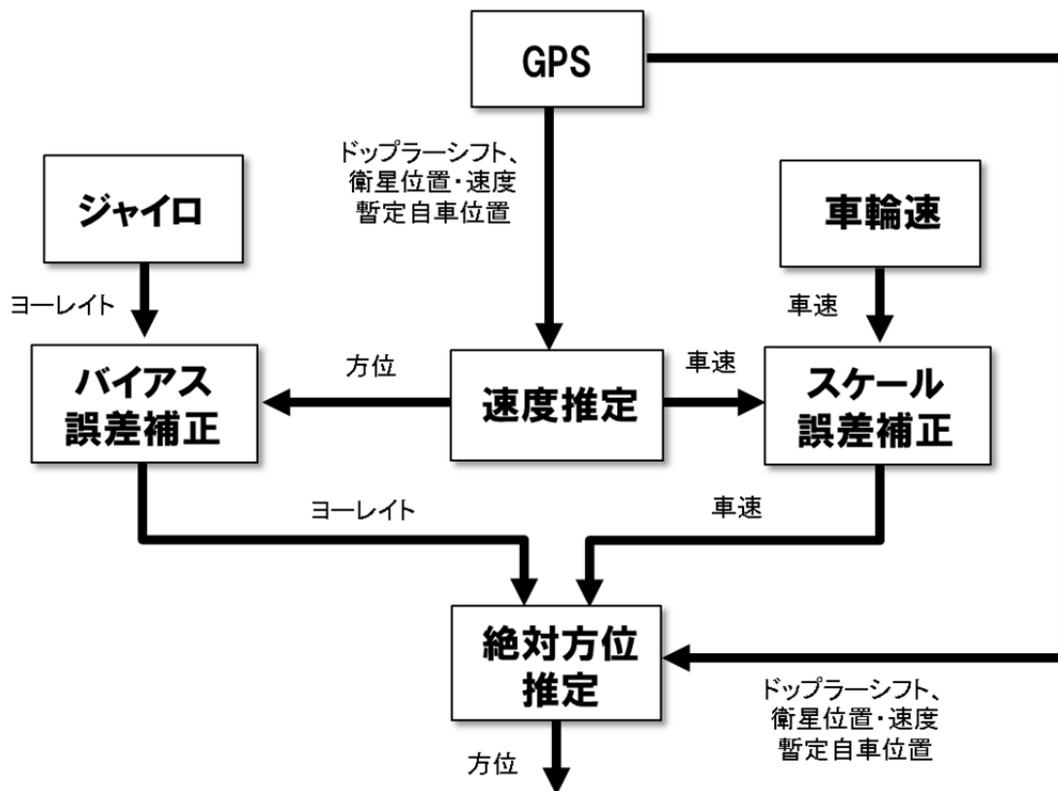


図 36 : 衛星信号のドップラーシフトと INS の統合による絶対方位推定の概要

3. 2. 2 ドップラーシフトを用いた自車速度推定 (従来手法)

衛星-自車間の相対速度によってドップラー効果が生じることで、衛星信号の周波数が変化する。この周波数の変化量がドップラーシフトである。以下では、ドップラーシフトから自車の 3 次元速度ベクトルを算出する方法について述べる。

式(5)に衛星のドップラーシフトと自車の 3 次元速度ベクトルの関係式を示す。

$$Vs_i = \mathbf{G}_i \cdot \mathbf{v} - c\tau \quad (5)$$

$$\mathbf{G}_i = \frac{\mathbf{x}'_i - \mathbf{x}}{|\mathbf{x}'_i - \mathbf{x}|}, \quad Vs_i = \frac{D_i}{f_1} c - \mathbf{G}_i \cdot \mathbf{v}'_i$$

(i=1,...,N)

i は衛星のインデックス, N は 1 時刻あたりに観測可能な衛星数, v_s は自車と衛星の相対速さ(m/s), \mathbf{G}_i は自車-衛星間の視線方向単位ベクトル(無次元), \mathbf{v} は自車の 3 次元速度

ベクトル(m/s), τ はクロックドリフトと呼ばれる衛星受信機の時計誤差変化率(無次元), c は光速(m/s)を示す (図 37)。ここで, \mathbf{G}_i は衛星位置 \mathbf{x}'_i と暫定自車位置 \mathbf{x} を用いて算出でき, V_{s_i} は衛星のドップラーシフト D_i (Hz), 光速 c , 衛星信号の搬送波周波数 f_1 (Hz), 単位ベクトル \mathbf{G}_i , 衛星の 3 次元速度ベクトル \mathbf{v}'_i (m/s) を用いて表すことができる。衛星の位置

位置 \mathbf{x}'_i と 3 次元速度ベクトル \mathbf{v}'_i はそれぞれ衛星の軌道情報から算出することができ, 暫定自車位置 \mathbf{x} は疑似距離を用いた測位などによって算出することができる。暫定自車位置は自車-衛星間の視線方向単位ベクトル \mathbf{G}_i の計算に用いるが, 自車-衛星間の距離は通常 2 万 km 以上であるため暫定自車位置に数百 m 程度の誤差があったとしても速度推定精度への影響は無視できる。

式(5)中, 未知数は 3 次元自車速度ベクトル \mathbf{v} と クロックドリフト τ の 4 つであり, 他の変数は全て既知である。式(5)は観測可能な衛星と同数だけ連立できるため, 最低 4 つの衛星があれば未知数を解き, 自車の 3 次元速度ベクトルを得ることができる。

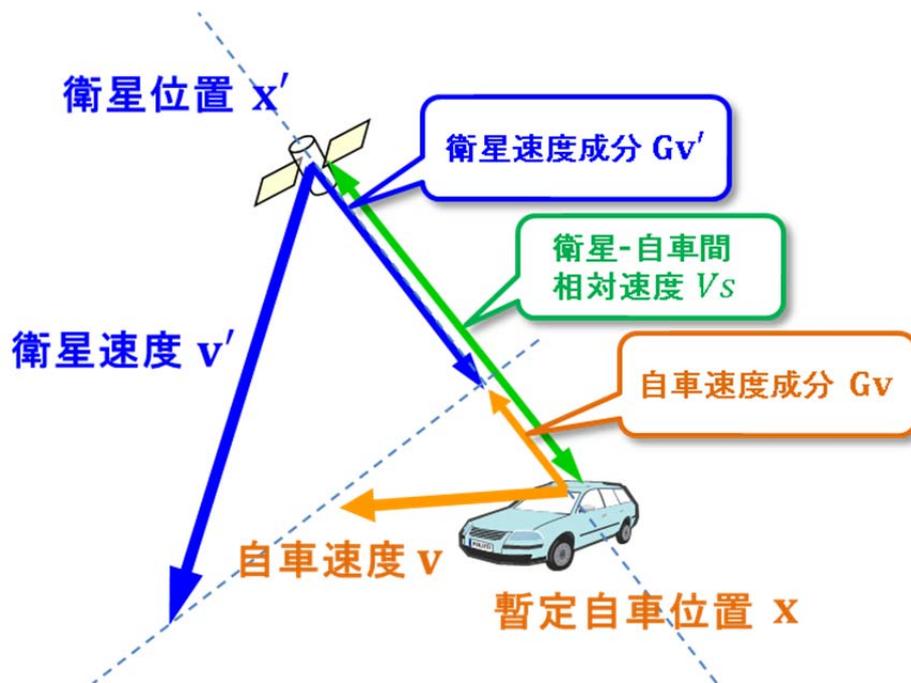
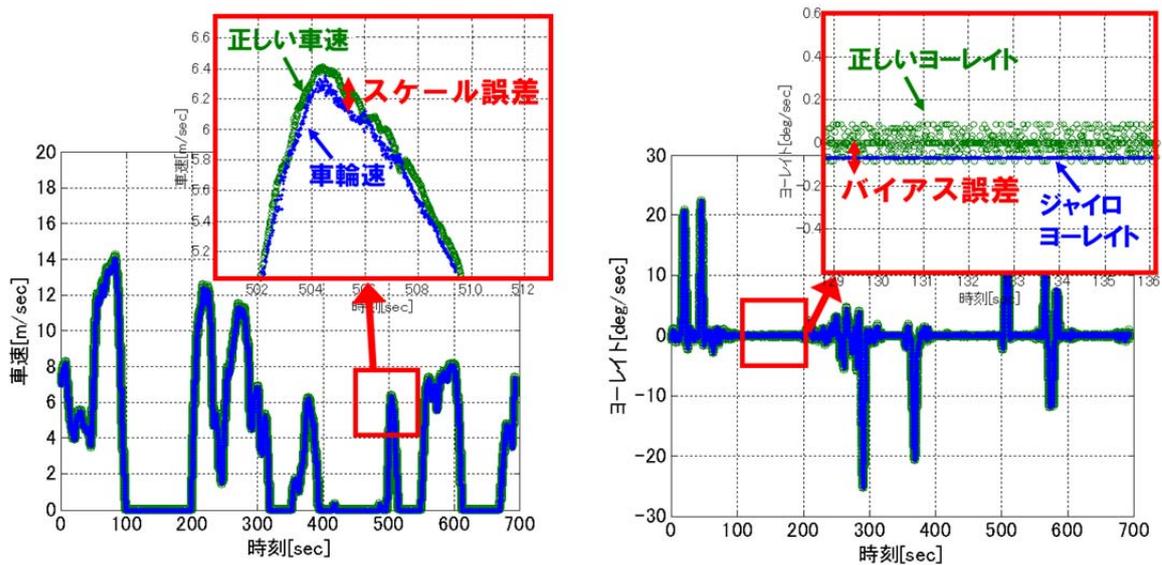


図 37 : 各変数の関係図

3. 2. 3 ドップラー速度を用いた INS センサ誤差補正

車輪速は車輪が回転を検出し、車輪の回転数にタイヤ径を乗じることで車両の進行距離を算出する装置である。通常、タイヤ径はほぼ変動しないため、その値として一律に決められた固定値が用いられる。しかしながら、厳密には空気圧変化などにより僅かにタイヤ径が変化しスケール誤差が生じるため(図 38(a))、その影響により進行距離の誤差が増加する。また、ジャイロは車両の角速度を計測できるが、一般的に、機材の温度変化などの影響によって生じるバイアス性の誤差を有する(図 38(b))。角速度にバイアス誤差が生じた場合、角速度から車両姿勢を算出する際に時間と共にバイアス誤差が蓄積していくため、姿勢誤差が増大する。

そこで本研究ではドップラーシフトを用いて算出した自車速度ベクトルを利用し、車輪速のスケール誤差とジャイロのバイアス誤差の補正を行った。ジャイロについては、軌跡算出の際に重要となる進行方位に関するヨーレイトのみを補正した。この方法では、ドップラーシフトの速度ベクトルから得られる「自車速度の大きさ(車速)」と「進行方位」を利用し、車輪速スケール誤差補正とヨーレイトバイアス誤差をそれぞれ補正した(図 39)[67]。次にその詳細な方法について述べる。



(a) 車輪速スケール誤差

(b) ヨーレイトバイアス誤差

図 38 : INS センサ誤差

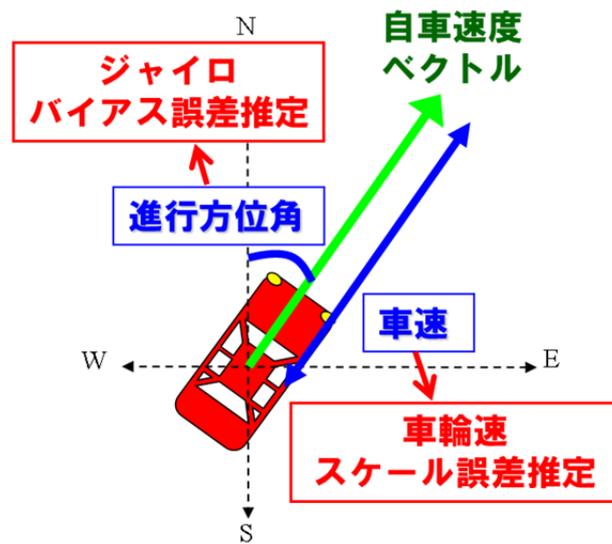


図 39：ドップラー自車速度の利用方法

3. 2. 3. 1 車輪速スケール誤差補正

車輪速は真の車速に対しスケール誤差を有するが、連続かつ安定した精度で車速の推定を行うことができる。一方、ドップラーシフトから算出した車速（以下、ドップラー車速）は、スケール誤差を持たないが、衛星信号の遮蔽・反射により、車速が得られなかったり、ばらつきが生じることがある(図 40)。このため、まずドップラー車速のばらついた箇所を排除した上で、残った精度の良いドップラー車速のみを用いて車輪速スケール誤差の補正を行う。

図 41 に車輪速スケール誤差補正の概要を示す。まず始めに、ドップラー車速の時系列の分散値を算出し、その値が大きい箇所のドップラー車速は除外する。次に、残ったドップラー車速に最もフィットする最適なスケール補正値を最小二乗法により算出する。式(6)に最小二乗法のコスト関数 E_{scale} を示す。

$$E_{scale}(\alpha) = \sum_{t=0}^M (\alpha Vw_t - V'_t)^2 \quad (6)$$

α は最適化するスケール補正値、 Vw_t は車輪速、 V'_t はドップラー車速、 t は時刻インデックスを示す。式(6)のコストを最小化する α を解くことで、車輪速のスケール誤差の補正値を得ることができる。

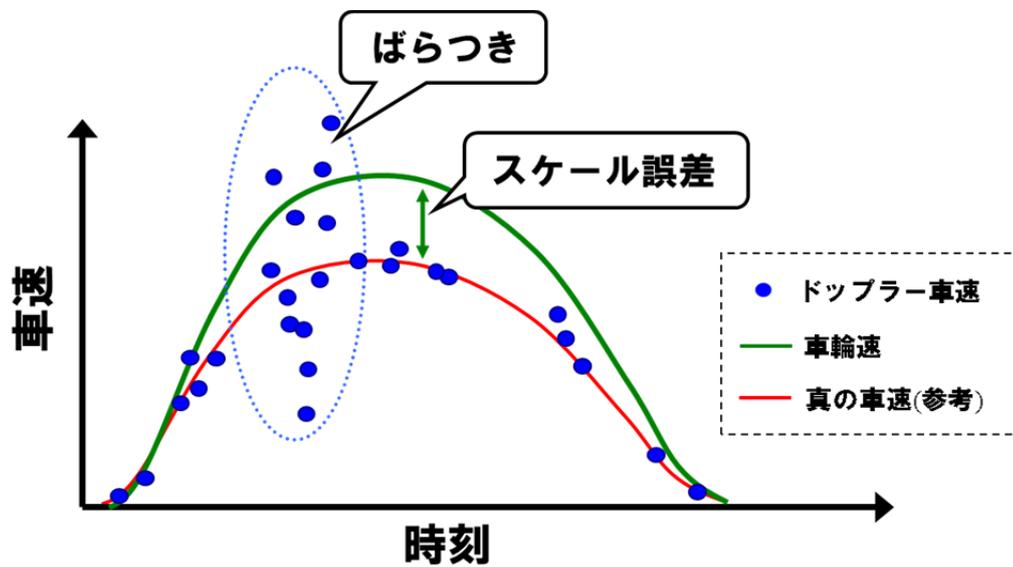


図 40 : 車輪速とドップラー車速の特性の違い

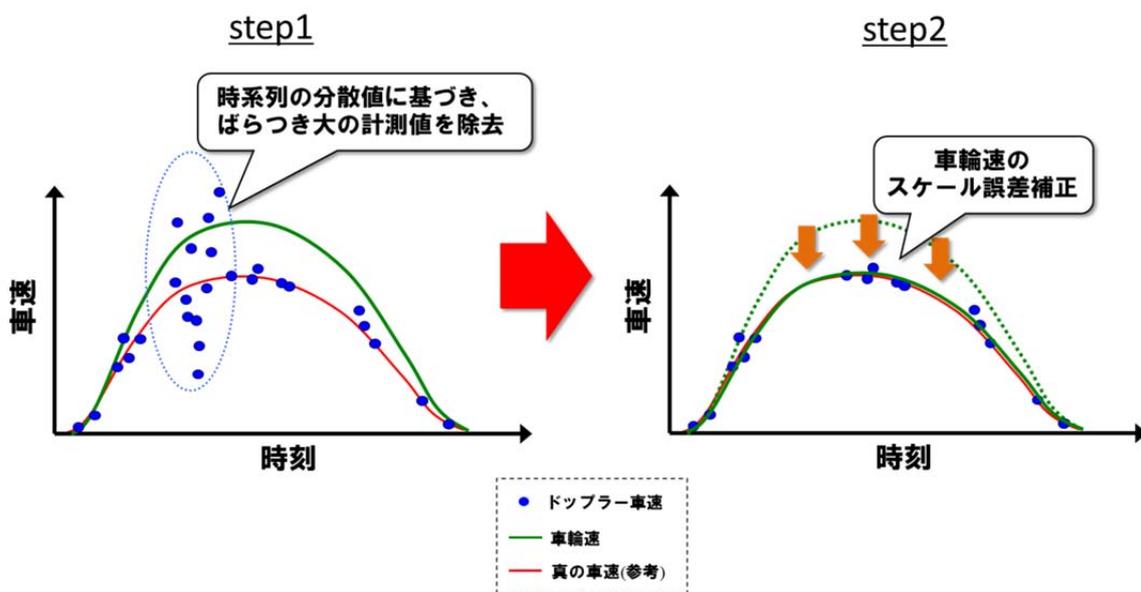


図 41 : 車輪速スケール誤差補正の概要

図 42 に車輪速スケール誤差の補正前後の比較を示す。スケール誤差補正前は正しい車輪速との間にスケール誤差があったのに対し、補正後ではスケール誤差がなくなっていることが分かる。また、図 43 にスケール補正に伴う進行距離誤差の低減効果の例を示す。補正前は実際の進行距離に対し 2%程度の誤差があったのに対し、補正後では 0.1%程度に誤差が低減されていることが分かる。なお、このシーンは都心部における走行データであり衛星受信状態は比較的悪い環境であるが、過去 600 秒程の蓄積データを使用して最小二乗法を解くため、十分な数の精度良いドップラー車速を集めることができる。これは車輪速スケールは短時間において変化しないという仮定の下に成り立つ。

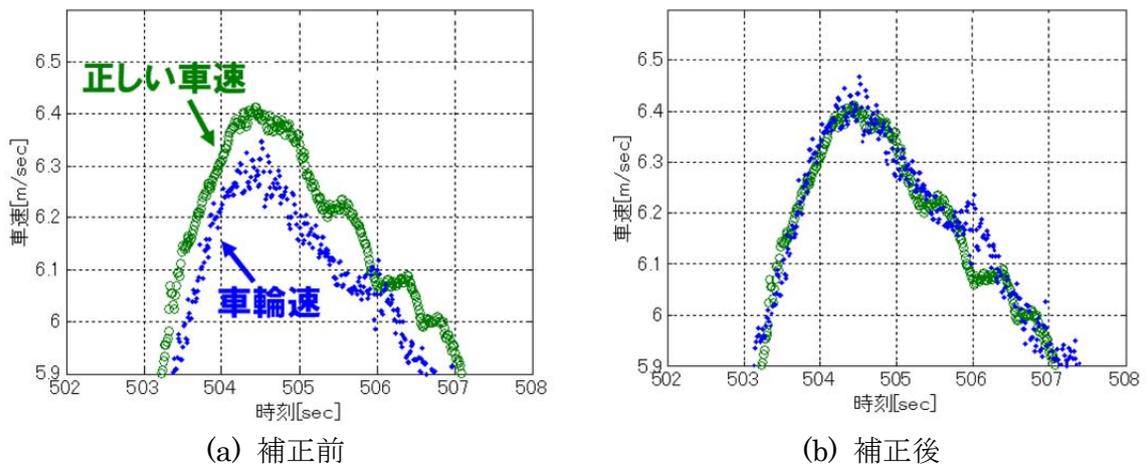


図 42：車輪速スケール誤差の補正前後の比較

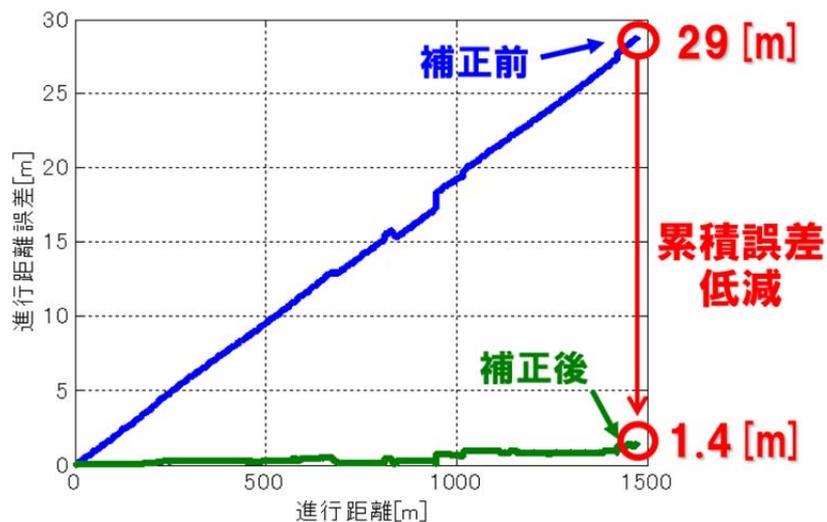


図 43：車輪速スケール誤差補正による進行距離誤差の低減効果

3. 2. 3. 2 ジャイロヨーレイトバイアス誤差補正

ここでは、ヨーレイトを積算した「方位」の形とした上で、ドップラー方位との比較を行う。ヨーレイトは周囲の環境によらず精度が安定であるが、一定のバイアス誤差が乗っているため、その積算値である方位(以下、ヨーレイト積算方位)では時刻と共にほぼ線形に誤差が増加する。一方、ドップラーシフトから算出した方位(以下、ドップラー方位)はバイアス誤差を持たないが、衛星信号の遮蔽・反射などにより、方位が得られなくなったり、ばらつきが生じることがある(図 44)。このため、車輪速スケール補正と同様に、まずドップラー方位のばらつきが大きい箇所を排除した上で、残った精度の良いドップラー方位のみを用いてバイアス誤差の補正を行う。

図 45 にヨーレイトバイアス誤差補正の概要を示す。まず始めに、ドップラー方位の時系列の分散値を算出し、この値が大きいドップラー方位は信頼度が低いものとして排除する。次に、残ったドップラー方位に対し、ヨーレイト積算方位が最もフィットするようなバイアス誤差補正値を最小二乗法により算出する。式(7)に最小二乗法のコスト関数 E_{bias} を示す。

$$E_{bias}(\beta) = \sum_{T=0}^M \left\{ \sum_{t=0}^T (\omega_t + \beta) - \theta_T \right\}^2 \quad (7)$$

β は最適化するバイアス誤差補正値、 ω_t は車輪速、 θ_T はドップラー車速、 t , T はそれぞれ時刻インデックスを示す。式(7)のコストを最小化する β を解くことで、ヨーレイトのバイアス誤差補正値を得ることができる。

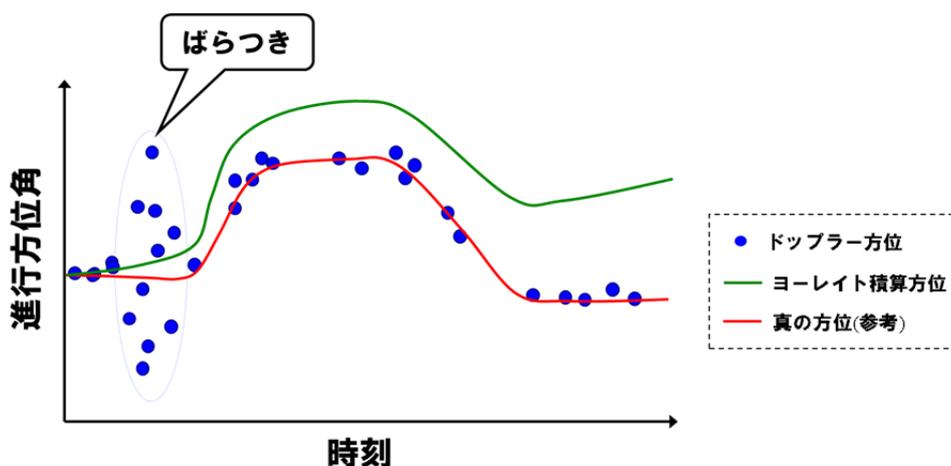


図 44：ジャイロヨーレイト積算方位とドップラー方位の特性の違い

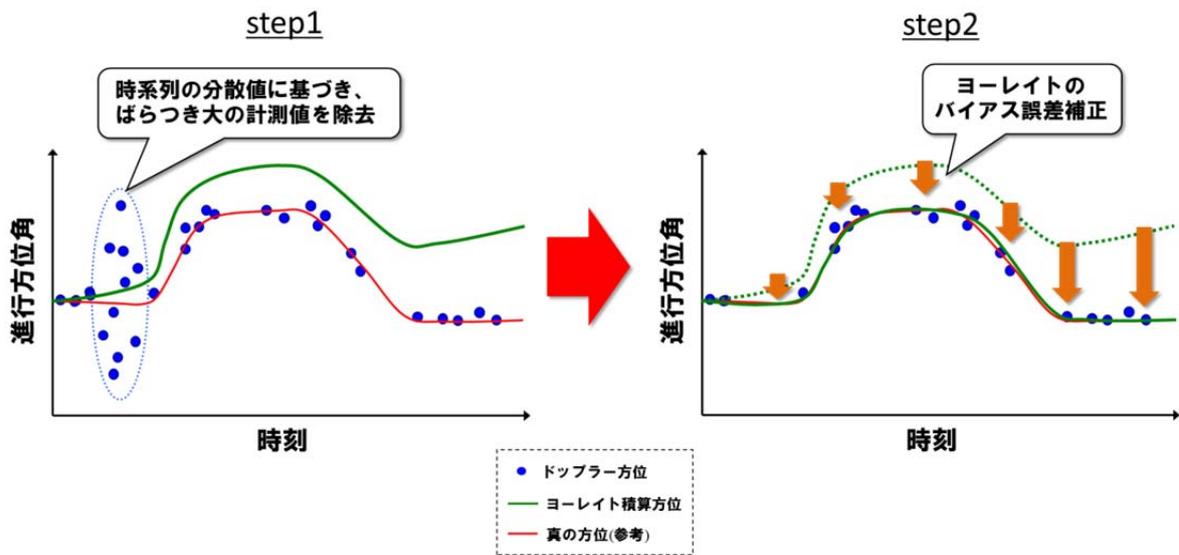


図 45 : ヨーレイトバイアス誤差補正の概要

図 46 にヨーレイトバイアス誤差の補正前後の比較を示す。バイアス誤差補正前は正しいヨーレイトとの間にバイアス誤差があるのに対し、補正後ではバイアス誤差がなくなっていることが分かる。また、図 47 にヨーレイトバイアス誤差補正に伴う方位誤差改善の例を示す。補正前は走行距離 100m あたりに蓄積する方位誤差が 2deg 程度であったのに対し、補正後では 0.16deg 程度に改善されていることが分かる。なお、走行データは衛星環境が劣悪な都心部であるが、過去 60 秒程の蓄積データを用いて最小二乗法を解くことで、十分な数の精度良いドップラー方位を集めることができる。これは 60 秒間におけるヨーレイトバイアス誤差の変動は無視できる程小さいという仮定の下に成り立つ。

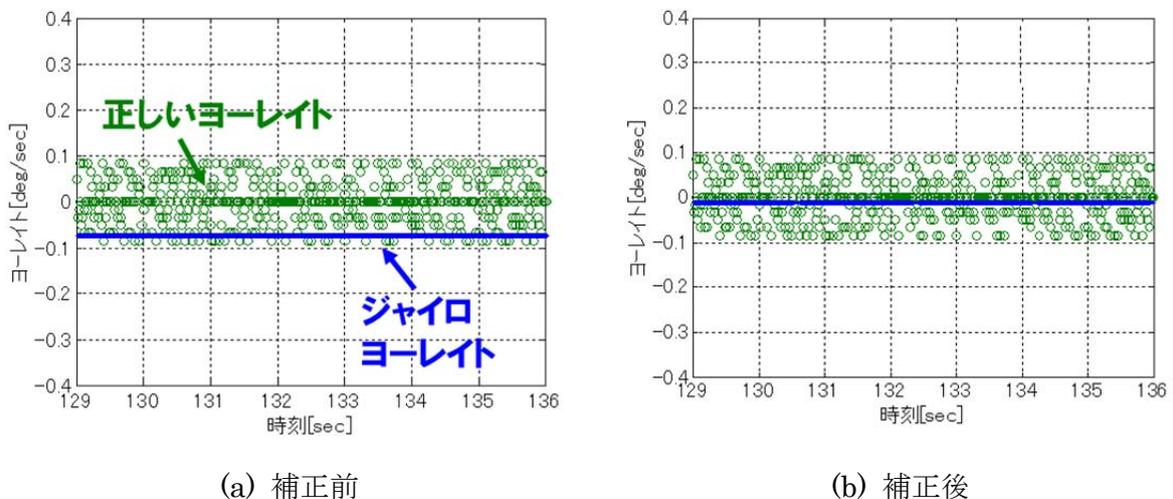


図 46 : ヨーレイトバイアス誤差の補正前後の比較

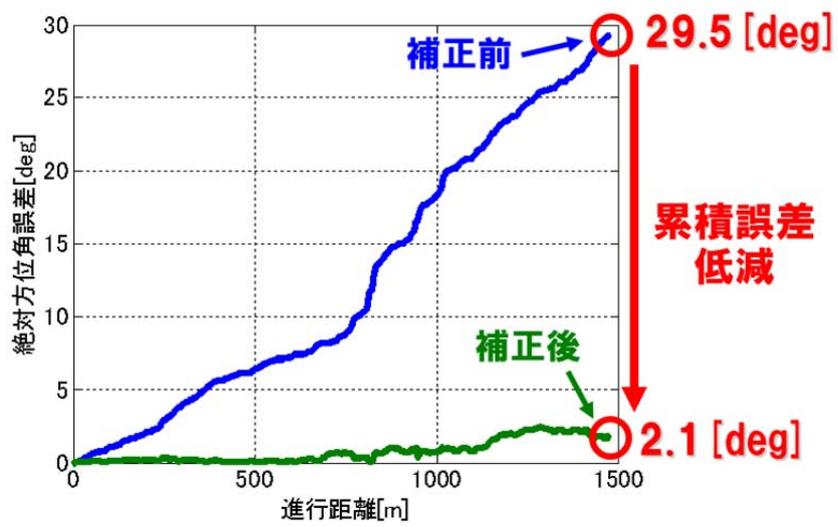


図 47：ヨーレイトバイアス誤差補正に伴う方位誤差の低減効果

3. 2. 4 ドップラーシフトと INS の時系列データ統合による絶対方位推定

図 48 に提案手法のコンセプトを示す。従来手法では、4 つの未知数(3 次元自車速度ベクトル、クロックドリフト)に対し、観測方程式の連立数は衛星数と同数であるため、衛星数が 4 以上の時のみ観測方程式を解き絶対方位を得ることができた(式(5))。これに対し提案手法では、時系列データを用いることで、見かけ上の衛星数を増加することを基本コンセプトとする[68][69][70]。観測方程式を単純に時系列方向に連立した場合、各時刻の車両速度が未知パラメータとして加わるため、これだけでは解の得られ易さは変化しない。このため、本研究では INS (ジャイロのヨーレートと車輪速) を用いて各時刻の車両速度の変化を拘束することで、時系列データ利用に伴う不定性の増加を抑えた。これにより時系列データ利用に伴う観測値増加の恩恵を受けられるようになるため、1 時刻あたりに観測できる衛星数が少ない場合でも観測方程式を解くことができるようになる。

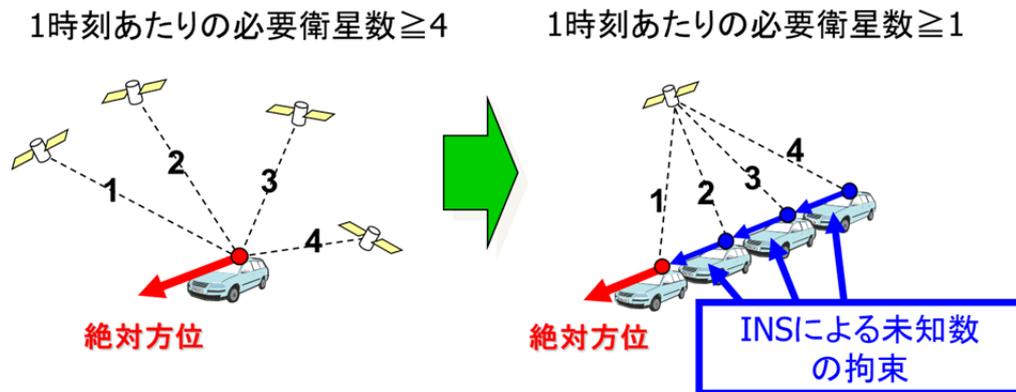


図 48：提案手法のコンセプト

以下に詳細な手法を示す。観測値として利用可能な衛星を増加するため、まず式(5)の観測方程式を時系列方向に拡張する(式(8))。

$$V_{S_{t,i}} = \mathbf{G}_{t,i} \cdot \mathbf{V}_t - c\tau_t \quad (8)$$

$$(t = 0, \dots, M; \quad i = 1, \dots, N_t)$$

t は時刻インデックス、 N_t は時刻 t における衛星数を示す。時系列データを用いることで、連立できる観測方程式の数は時系列方向のデータ長に比例して増加するが、時刻インデックスを持った未知数 \mathbf{V}_t 、 τ_t も同様に増加するため、式(8)の状態では解を得るために必要な衛星数は変わらない。そこで提案手法ではさらに INS を用いて時系列の未知数に対し拘束条件を加えることで時系列データ利用に伴う不定性増加を抑える。まず、式(9)中の 3 次元自車速度ベクトル \mathbf{V}_t を以下のように車速と方向に分解して表す。

$$\begin{aligned} \mathbf{V}_t &= [V_x \quad V_y \quad V_z] \\ &= |\mathbf{V}_t| [\cos\theta_t \quad \sin\theta_t \quad \sin\phi_t] \end{aligned} \quad (9)$$

$[V_x, V_y, V_z]$ は平面座標系における自車速度ベクトルの3成分, $|\mathbf{V}_t|$ は自車速度ベクトルの大きさ, θ_t, ϕ_t はそれぞれ自車速度ベクトルの向き(ヨー方向, ピッチ方向)を示す。次に, INS から得られる観測値を用いて以下の仮定を置く。

- ◇3次元自車速度ベクトルの大きさは車輪速と等しい
- ◇方位(ヨー角)変化量はジャイロのヨーレート積算値と等しい
- ◇ピッチ角は常に0で近似できる(都心部では平坦な道路が多いため上下方向の速度変化は無視できる)
- ◇クロックドリフトの時間変化は直線で近似できる(一般にクロックドリフトの時間変化は非常に緩やかであるため)

これらは拘束条件として式(10)-(13)のように表される。

$$|\mathbf{V}_t| = Vw_t \quad (10)$$

$$\theta_t = \theta_0 - \Delta t \sum_{i=0}^M \omega_i \quad (11)$$

$$\phi_t = 0 \quad (12)$$

$$\tau_t = \tau_0 - \mu \cdot t \quad (13)$$

Vw_t は車輪速(m/s), Δt は処理周期(s), θ_0 は現時刻におけるヨー角(rad), ω_i はジャイロのヨーレート(rad/s), τ_0 は現時刻におけるクロックドリフト, μ はクロックドリフト時間変化の傾きを示す。この中に含まれる未知数は θ_0, τ_0, μ の3つである。さらに, 式(9)と式(10)-(13)を式(8)に代入すると式(14)が得られる。

$$Vs_{t,i} = Vw_t \left\{ Gx_{t,i} \cos \left(\theta_0 - \Delta t \sum_{i=0}^M \omega_i \right) + Gy_{t,i} \sin \left(\theta_0 - \Delta t \sum_{i=0}^M \omega_i \right) \right\} - c(\rho_0 - \mu \cdot t) \quad (14)$$

式(8)では(4×時系列データ数 M)個の未知数が含まれていたのに対し, 時系列データに

対する拘束条件の式(10)-(13)を代入することにより、式(14)に含まれる未知数は 3 個 (θ_0, τ_0, μ)に削減された。一方、観測方程式の数は時系列データに比例して増加するため、1 時刻あたりの衛星数が少ない場合でも安定的に解を得ることができる。すなわち、従来手法では 1 時刻あたりの衛星数が 4 個以上必要であったのに対し、提案手法では 1 時刻あたりの衛星数は最小 1 個の場合でも解を得ることができる。

図 49 に衛星数と解の関係の例を示す。本図は実環境データの中で提案手法の効果を示す代表的なシーンを抽出したものであり、図の最上段に衛星数、その下に観測方程式の解いて得られた方位を示す。従来手法では衛星数が 4 以上の場合のみ方位が得られている。一方、提案手法では時系列データ数 M の増加に伴って方位が得られる場所が増加しており、 $M=10$ の場合は衛星数が最小 1 個の場合においても方位が得られていることが分かる。これは時系列データ全体に含まれる総衛星数が最低 10 個以上あるのに対し、未知数の数は 3 個であるため解が得られたことを示している。ただし、1 時刻あたりの衛星数が少ないほど観測誤差の影響が出やすい傾向にあるため、必ずしも精度良い方位が得られることを保証するものではないことに注意が必要である。なお、 M の設定による方位精度への影響については、 M が小さいほど方位誤差のばらつきが大きくなりやすく、 M が大きいほど INS の蓄積誤差やクロックドリフトの線形近似の影響により緩やかにバイアス性誤差が現れる傾向にあるため方位精度向上のためには適切な M の設定が必要である。最適な M の値は、INS の精度、衛星受信機のクロックドリフトの変化傾向、ドップラーシフトのばらつき量などに依存するため、取得データなどに基づいた M の設定が望ましい。

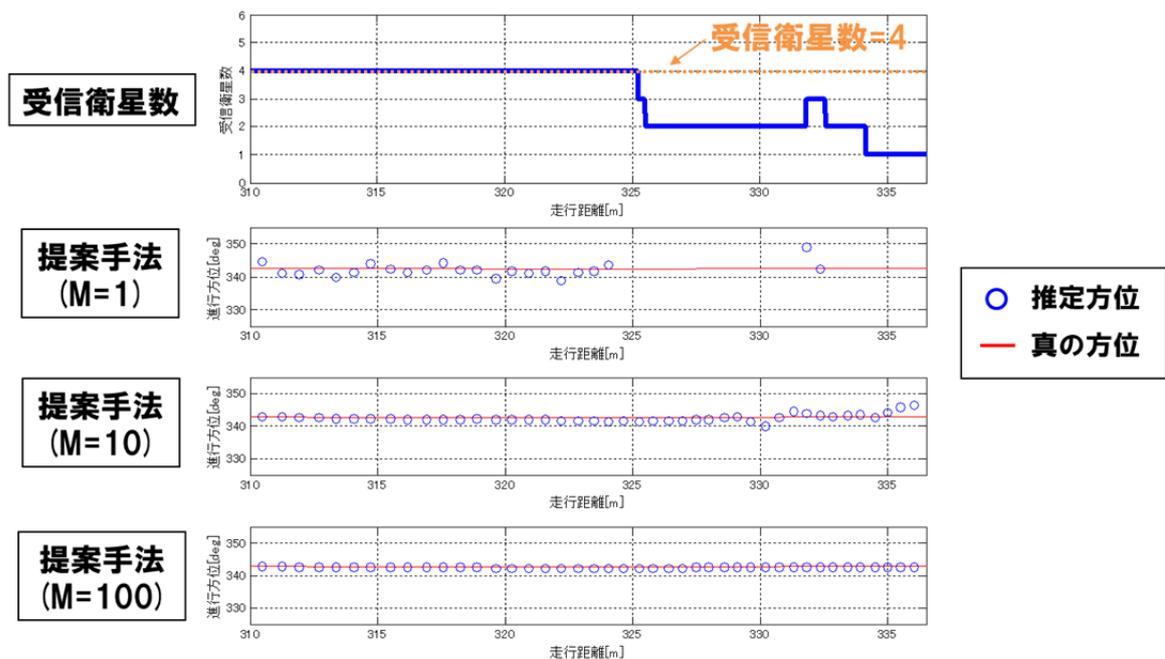


図 49：衛星数と解の関係

3. 2. 5 VO と絶対方位の統合

従来の VO では式(2)のコスト関数を最小化する自転車軌跡・姿勢を算出していた。これに対し、提案手法では新たに GPS による絶対方位、および車輪速による二つのコスト関数を拘束条件としてそれぞれ追加することで、VO の方位蓄積誤差低減、および距離スケールの決定を行う[71]。式(15)に提案手法で用いるコスト関数を示す。

$$E_{total} = E_{cam} + E_{heading} + E_{scale} \quad (15)$$

E_{total} は最終的に最小化の対象となるコスト関数、 E_{cam} はカメラ画像内の特徴点整合性に関する項(式(2))、 $E_{heading}$ は方位の整合性に関する項、 E_{scale} は進行距離の整合性に関する項であり、これら全体のコストを最小化することで拘束条件を考慮した最適な軌跡形状を推定する。以下にコスト関数、 $E_{heading}$ 、 E_{scale} について簡単に説明する。

$E_{heading}$ は GPS/INS の時系列統合により推定した方位と VO で推定する方位との乖離度合に比例して増加するコスト関数であり、このコスト関数を導入することで VO の推定方位が GPS/INS の方位と整合する値に収束する作用が働くため、VO のみの場合に生じていた方位の蓄積誤差を抑制することができる。具体的な算出方法を式(16)に示す。

$$E_{heading} = \sum_{t=0}^M \delta_t (\theta_t - \theta_t')^2 \quad (16)$$

θ_t は VO で推定する方位、 θ_t' は GPS から推定した方位、 δ_t は GPS の方位フラグをそれぞれ示す。方位フラグは GPS の方位推定の可否を示すフラグであり、方位推定結果が得られた場合は 1、得られなかった場合には 0 となる。

また、 E_{scale} は VO で推定する自転車位置の差分と車輪速で算出される進行距離との乖離度合に比例して増加するコスト関数である。このコスト関数を導入することで VO の軌跡長を車輪速の積算距離に近づける作用が働くため、進行距離を正しく保つことができる。算出方法を式(17)に示す。

$$E_{scale} = \sum_{t=1}^M (Vw_t \Delta t - |\mathbf{x}_t - \mathbf{x}_{t-1}|)^2 \quad (17)$$

Vw_t は車輪速(m/s)、 Δt は処理周期(s)、 \mathbf{x}_t は自転車位置を示す。

3. 2. 6 実験

3. 2. 6. 1 実験条件

図 50 に評価コースを示す。評価コースは新宿周辺の約 500m (走行時間：約 175 秒) の道路区間であり，周囲には高層ビルが立ち並ぶ。軌跡推定には単眼カメラ，INS(ジャイロのヨーレイト，車輪速)，GPS 受信機(出力 10Hz)を利用した。GPS 受信機は Trimble 社製の NetR9 であり，搬送波位相による RTK-GPS も可能であるが，本研究では GPS のドップラーシフトのみを用いた。

誤差評価用のリファレンスは Applanix 社の POSLV610[72]を用いた(表 7)。POSLV610 は RTK-GPS，高精度ジャイロ，高分解能車輪速から構成される測位装置であり，都心部でも～0.3m 程度の高精度測位，および～0.1deg 程度の高精度姿勢推定が可能である。

また，本評価では SXGA(1280×960)の画像情報を 15fps で取得し，特徴点追跡のための画像特徴量は AKAZE 特徴[36]と FAST 特徴[73]を併用した。各時刻において，方位推定では過去 20 時刻分(2 秒)の GPS/INS データを入力として演算を行い，VO では過去 50 時刻分(約 3.3 秒)の観測情報を入力とした最適化処理を行うことで軌跡推定を行った。また，本評価ではマルチパス対策として，外れ値除去に基づいた衛星選択アルゴリズム RAIM(Receiver Autonomous Integrity Monitoring)[74]を採用した。RAIM は最小二乗法を解いた後，その残差が一定値より大きい観測値を除外し，再度最小二乗法を解くことで外れ値の影響を低減するアルゴリズムである。

表 7：評価に使用した実験機器

センサ機器	製品	出力周期
ジャイロ	汎用車載品	12ms
車輪速	汎用車載品	12ms
GPS受信機	NetR9	100ms
カメラ	XCD-SX90 (SXGA)	66.7ms
リファレンス	POSLV610	5ms

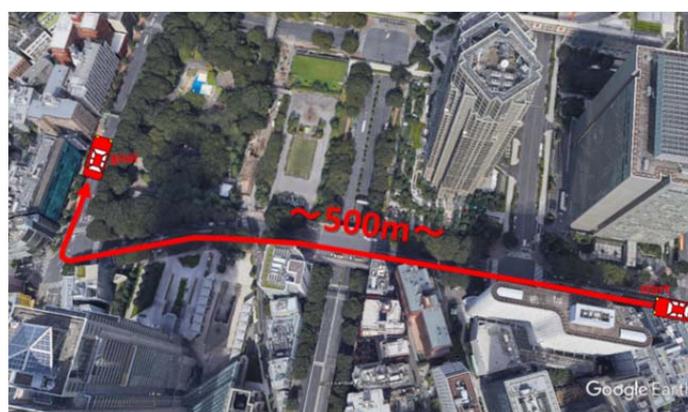


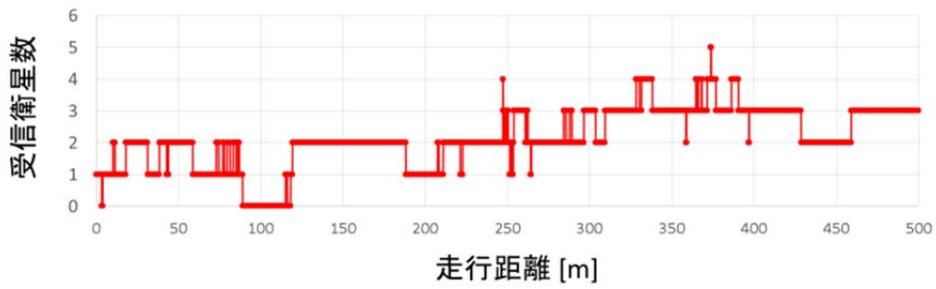
図 50：評価実験コース(新宿，Google Earth より引用)

3. 2. 6. 2 実験結果

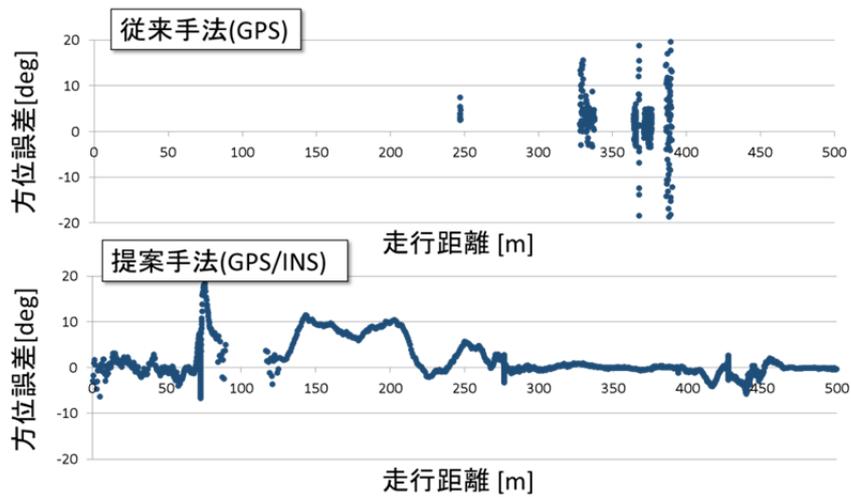
図 51(a)に受信衛星数を示す。評価コースでは周囲の高層ビルにより衛星信号が遮蔽されやすいため衛星数は概ね 4 未満であり、受信衛星数の中にはマルチパス信号も含まれている。図 51(b)に従来手法(GPS のみ)と提案手法(GPS/INS 統合)の方位推定誤差をそれぞれ示す。従来手法では衛星数が 4 以上の場合のみ方位推定結果が得られているのに対し、提案手法では衛星数が 4 未満の場所においても方位推定結果が得られていることが分かる。しかしながら、衛星数が少ないコース前半などにおいては大きな方位誤差の変動が見られるため、これをそのまま VO の方位補正に利用することは難しい。そこで本研究では信頼度に基づいた方位の使用可否判定を行い、精度の良い方位($\sim 0.5\text{deg}$ 程度)を選別した。

図 51(c)に従来手法と提案手法の信頼度指標および方位使用可否フラグをそれぞれ示す。信頼度評価では方位推定のばらつき度合に着目し、過去 20 時刻において得られた方位推定結果の分散値(以下、方位分散値)を信頼度指標として用いた。なお、方位分散値は誤差成分のばらつき以外にも車両の動き(進行方位の変化)の影響も受けるため、車両の動きによる方位変動分はジャイロヨーレイトを用いて補正した。これにより方位分散値は方位誤差の変動のみを反映した値となる。図 51(c)では方位分散値の閾値を 0.1deg として方位の使用可否判定を行った結果を示す。従来手法では方位のばらつきが全体に大きいため、信頼度が高い方位が得られない(フラグ=0)のに対し、提案手法では方位のばらつきが比較的小さいコース後半において信頼度が高い方位を得られている(フラグ=5)ことが分かる。

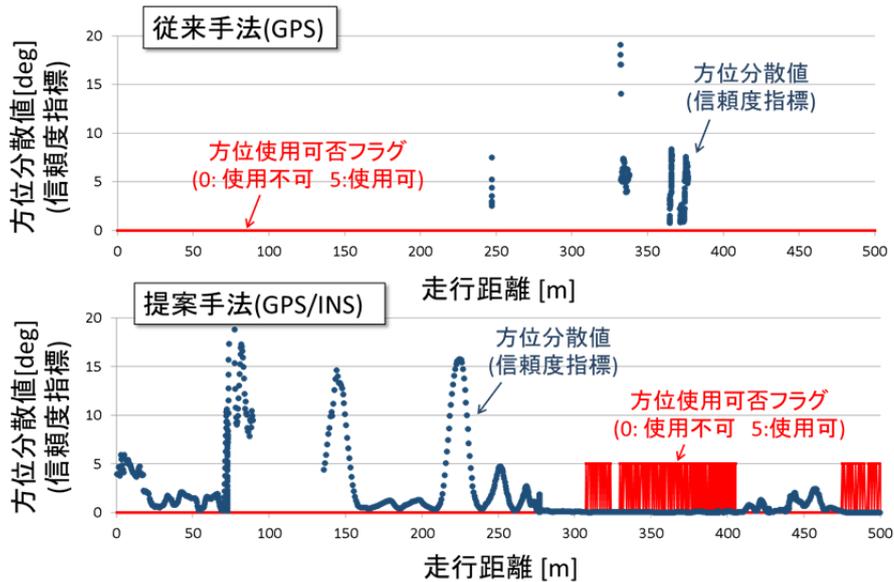
図 51 から読み取れる提案手法の効果を 2 点挙げる。1 点目は衛星数が 4 未満の場所でも精度良い方位の取得機会が得られたこと、2 点目は従来手法に比べ方位推定の誤差変動が低減していることが挙げられる。誤差変動低減の理由として、時系列データ利用に伴い衛星の観測値が増加することにより衛星毎の観測誤差を平均化する効果が生まれることに加え、観測情報の冗長性が増すほど RAIM の正確性が向上することなどが考えられる。一方、1 時刻あたりの衛星数が 1~2 の場合には上記効果の恩恵が減ることに加え、衛星配置の偏りによって誤差共分散が増大することで、高精度な方位を得られる可能性が低下する傾向にある。このようなシーンで方位精度の改善を行うためには、時系列データ数の最適化やマルチパス除去などの対策が必要であると考えられるが、図 51 の結果にも見られるように衛星数 1 の場合には衛星配置の偏りが誤差変動に及ぼす影響が大きいため、実用的な方位精度を得るためには最低でも衛星数 2 以上の環境が望ましいと考えられる。



(a) 衛星数



(b) 方位推定誤差



(c) 信頼度指標と方位使用可否フラグ

図 51 : 衛星数と方位結果

図 52 に軌跡推定結果を示す。4 つの軌跡はそれぞれ、VO の軌跡に GPS のみを用いた方位補正を行った従来手法の結果(VO+GPS 方位)、INS の軌跡に GPS/INS を用いた方位補正を行った従来手法の結果(INS+GPS/INS 統合方位)、VO の軌跡に GPS/INS を用いた方位補正を行った提案手法の結果(VO+GPS/INS 統合方位)、そしてリファレンスを示す。各軌跡は起点をリファレンスと合わせた上で描いている。軌跡推定結果の比較では、各従来手法は走行と共にリファレンスからのズレが拡大していくのに対し、提案手法ではリファレンスのズレはコース終盤においてもわずかである。最終地点においても提案手法の軌跡の到着点がリファレンスと最も近いことが分かる。

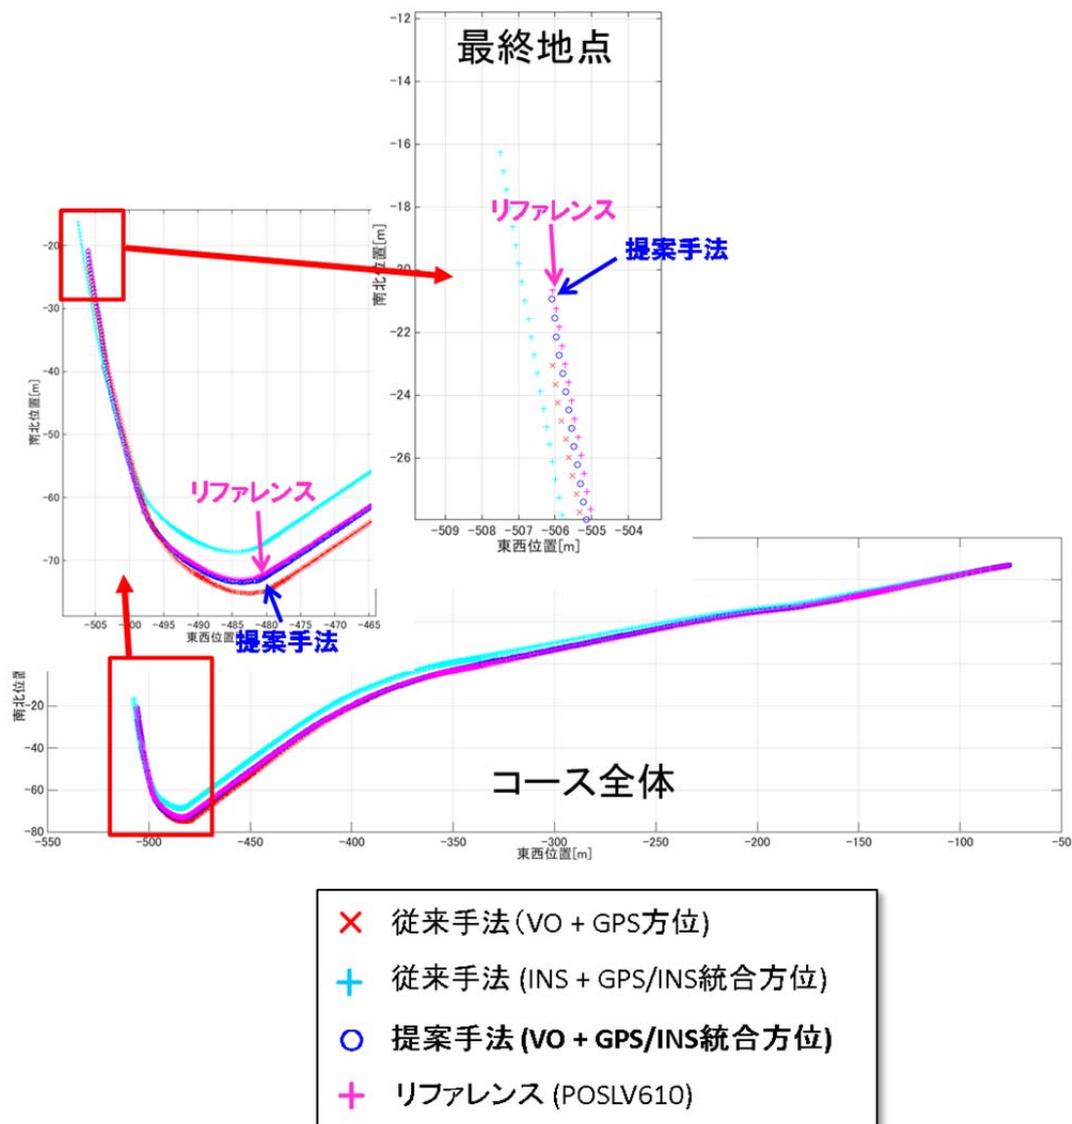


図 52 : 軌跡推定結果

図 53 に各手法の方位誤差をそれぞれ時系列で示す。VO+GPS 方位ではコース全般にわたり方位補正ができないため、画像中特徴点位置の誤差などによって僅かに生じる方位誤差が走行と共に蓄積している。一方、提案手法では GPS による方位補正が可能であるため、方位誤差の蓄積が随時リセットされていることが分かる。また、INS+GPS/INS 統合方位では後半において方位補正が行われるが、それまでの区間における方位の蓄積誤差が大きい。

また、図 54 に各手法の軌跡誤差をそれぞれ時系列で示す。各種従来手法では方位誤差が大きな区間においてそれぞれ軌跡誤差の増加が見られる。一方、提案手法ではコース全体を通して方位誤差が低減しているため、軌跡誤差の増加が抑えられていることがわかる。

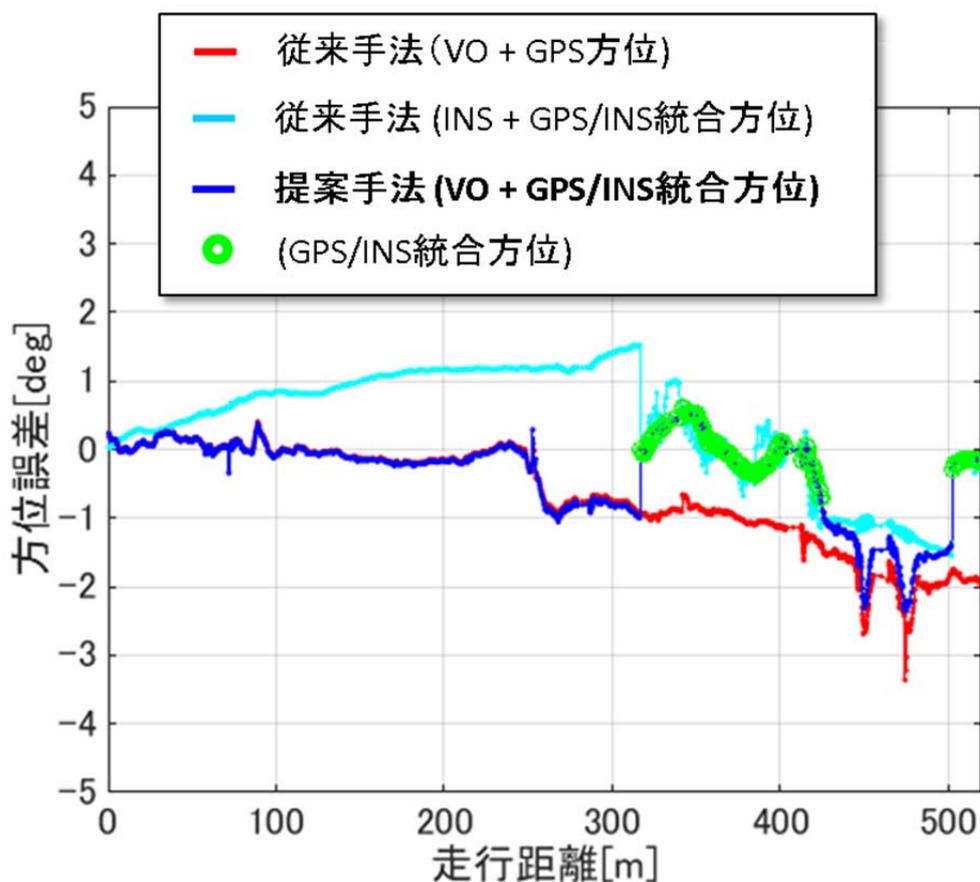


図 53 : 方位推定誤差

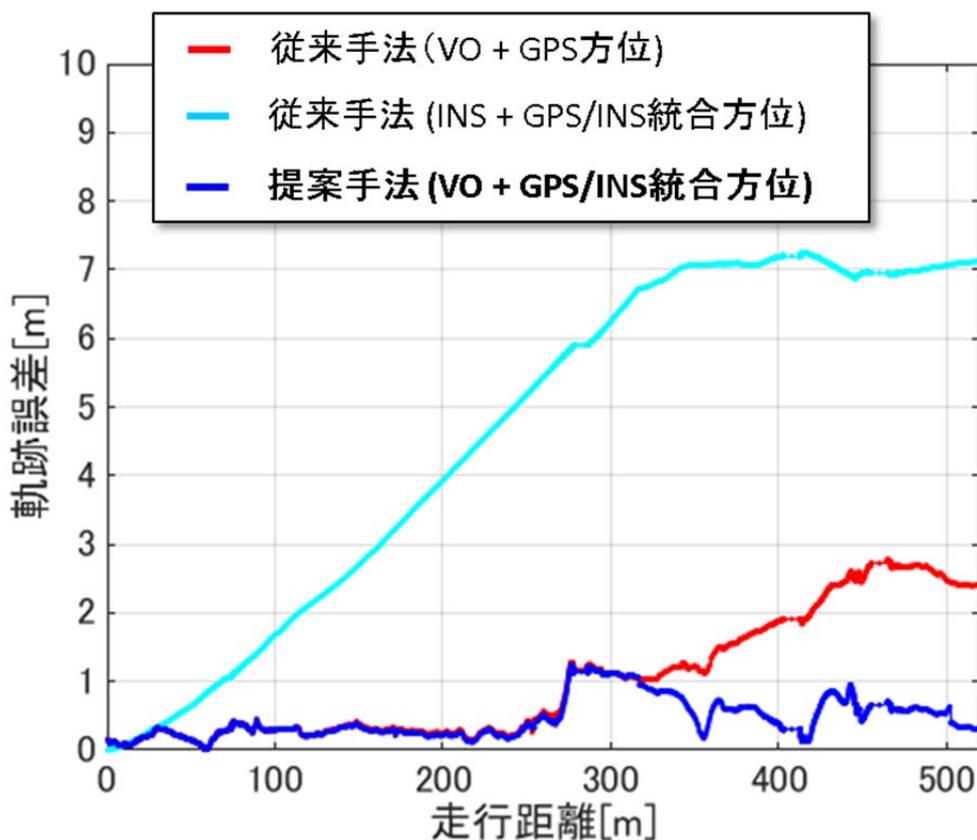


図 54 : 軌跡推定誤差

図 55, 図 56 に 100m 走行あたりに生じる方位誤差, 軌跡誤差の値をそれぞれ示す。100m 走行あたりに生じる軌跡誤差は, まず推定した軌跡を 100m 毎に区切り, 各 100m 区間の始点をリファレンスと合わせた上で終点におけるリファレンスからのズレをそれぞれ算出し, 最後に各 100m 区間で生じた全ての誤差の平均をとって算出した。100m 走行あたりに生じる方位誤差も同様の方法で算出した。

提案手法の方位誤差は, VO+GPS 方位に比べて約 3 割減, INS+GPS/INS 統合方位に比べて約 5 割減となっている。また, 提案手法の軌跡誤差は VO+GPS 方位に比べて約 3 割減, INS+GPS/INS 統合方位に比べて約 6 割減となっており, 提案手法では方位精度の改善により軌跡精度が向上したことがわかる。以上より, 都心部における提案手法の効果が示された。

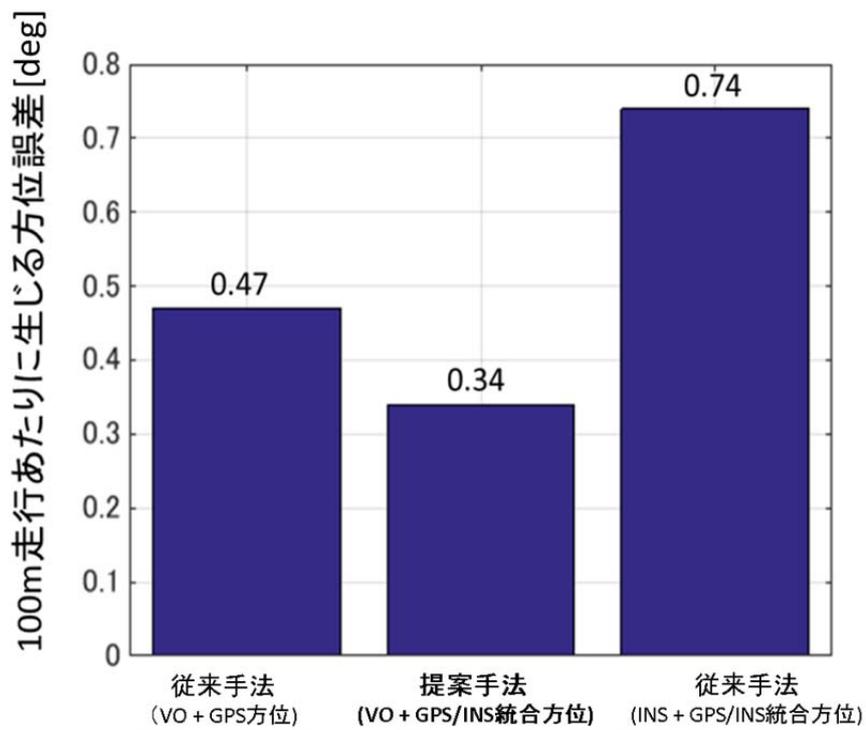


図 55 : 100m 走行あたりに生じる方位誤差

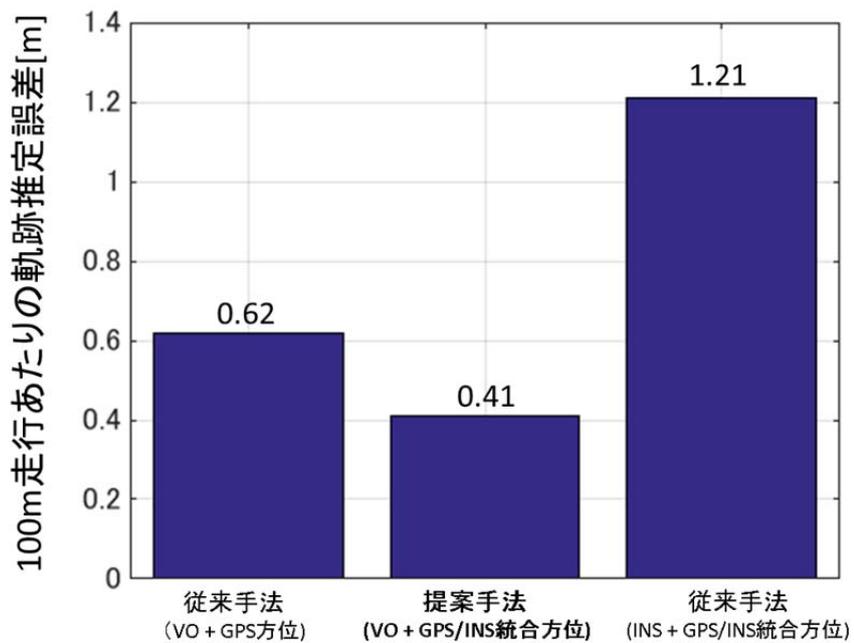


図 56 : 100m 走行あたりに生じる軌跡誤差

3.3 提案手法2：INS とパターン認識の統合による移動物判定

VO は画像中の静止物の動きから相対的に自車の動きを推定するため、画像中に移動物を含む場合、VO の精度劣化要因となっていた[75][76]。そこで本研究では INS の観測値と画像中のパターン認識結果との統合により、VO の入力となるオプティカルフローと呼ばれる、画像中における特徴点の時系列の位置が静止物上または移動物上かを判定し、移動物上である場合はオプティカルフローを除去する（図 57）。以下では静止物上、移動物上のオプティカルフローをそれぞれ静止物 OF、移動物 OF と呼ぶ。

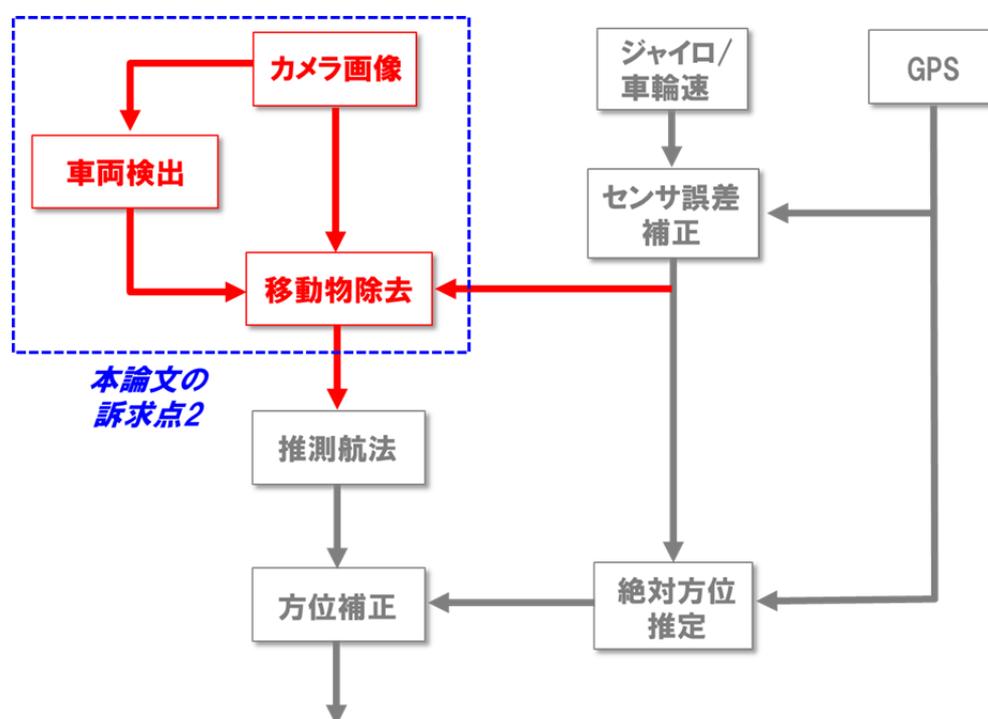


図 57：移動物による VO の軌跡精度劣化

図 58 に提案手法の処理イメージを示す。まず INS を用いてオプティカルフローの動きを予測した結果と実際のオプティカルフローとの比較に基づき、移動物 OF の候補を暫定的に決定する。次に、パターン認識を用いて画像中の車両領域を検出した結果と合わせることで、移動物 OF の判定結果の誤検出や未検出を低減する精緻化処理を行う。INS とパターン認識を統合した精緻化処理は本研究のポイントであり、これによりそれぞれを単独で用いた場合に比べて相乗的に移動物 OF の検出精度を向上することができる。

以下では INS を用いた移動物 OF の検出方法(3.3.1)と、パターン認識との統合による精緻化処理(3.3.2)について詳細を記す。

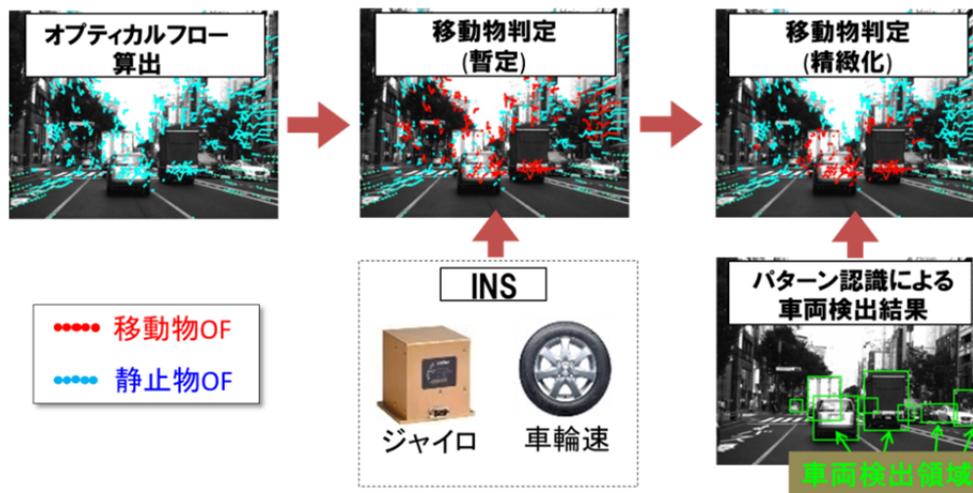


図 58：提案手法による移動物判定の流れ

3. 3. 1 INS を用いた移動物判定

画像中の静止物上のオプティカルフロー(特徴点の動き)は、自車の動きによって決まる。逆に言えば、自車の動きが分かれば、画像中の静止物上のオプティカルフローの動きを予測することができる。本研究では INS を用いて取得した自車の動きに基づき、画像中のオプティカルフローを算出する。以下では、INS を用いた静止物 OF の予測方法と、予測した静止物 OF に基づいた移動物判定方法について記す。

【INS を用いたオプティカルフロー予測方法】

図 59 に INS に基づいた静止物 OF の算出手順を示す。まず、各時刻の自車位置 (INS 計測) から画像中の特徴点の方向へ視線を引き (逆投影)、特徴点 3 次元位置の算出を行う。式(18)に特徴点 3 次元位置の算出式を示す。

$$X_m = (KR_t[I | -x_t])^{-1} X'_{t,m} \quad (18)$$

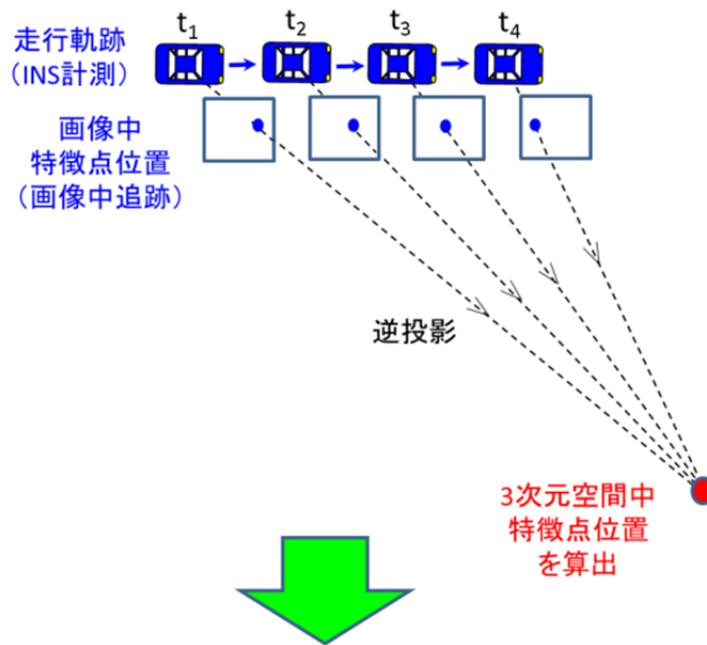
$X'_{t,m}$ は画像中の特徴点位置、 K はカメラのキャリブレーション行列、 x_t は 3 次元自車位置、 R_t は自車の姿勢(ピッチ, ヨー, ロール)を要素とした 3 次元回転行列、 X_m は実空間中の特徴点の 3 次元位置、 I は単位行列を示す。 t, m はそれぞれ時刻インデックス、特徴点インデックスを示す。ここで、 x_t, R_t は INS を用いて算出することができるので、未知数 X_m を解くことができる。

次に、算出した特徴点 3 次元位置を各時刻の画像上に再投影することで INS によるオプティカルフロー予測結果 $X''_{t,m}$ を算出することができる (式 19)。

$$X''_{t,m} = KR_t[I | -x_t]X_m \quad (19)$$

ここにおける処理は全て特徴点が静止物である前提の上で成り立つため、特徴点が静止物である場合には INS から予測されるオプティカルフローは画像中を追跡して得られるオプティカルフローと一致するが、特徴点が移動物である場合には前提が破綻し不整合が生じる。これにより移動物 OF を選別することができる。

①3次元空間中の特徴点位置を推定



②画像中の特徴点位置を推定

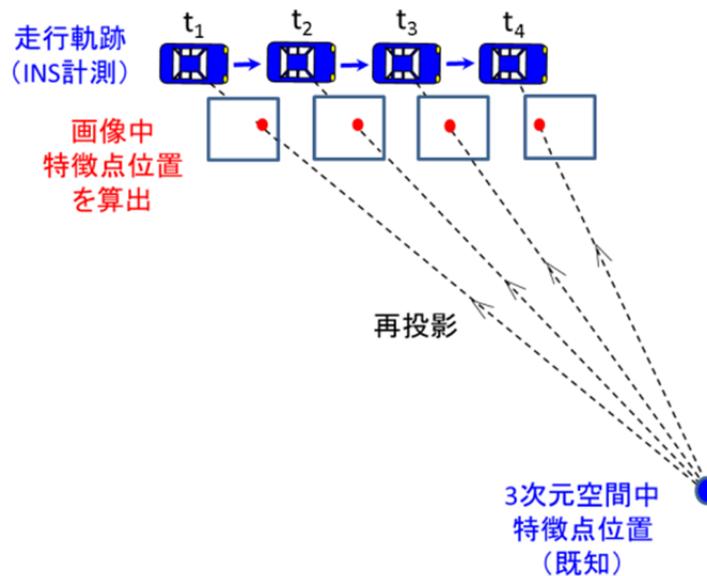


図 59 : INS に基づいたオプティカルフロー予測の手順

【オプティカルフロー予測値に基づいた移動物判定方法】

INS から予測した静止物 OF との比較に基づき、画像中の特徴点追跡で得られた OF の中から移動物 OF を検出する手順を図 60 に示す。まず始めに両オプティカルフローの差分を取り、対応する各特徴点間の距離（乖離距離）をそれぞれ算出する。図中のオプティカルフロー差分結果は、乖離距離が大きいほど赤く、小さいほど青く表示している。次に、乖離距離に基づき、画像中の特徴点追跡で得られた各オプティカルフローに対し移動物判定を行う。ここでは各オプティカルフローが有する時系列データ分の乖離距離の平均値を算出し、その値が閾値を超えた場合に移動物 OF（赤で表示）と判定する。式(20)に乖離距離の平均値 d_m の算出方法を示す。

$$d_m = \frac{1}{M} \sum_{t=0}^M |X'_{t,m} - X''_{t,m}| \quad (20)$$

$X'_{t,m}$ 、 $X''_{t,m}$ はそれぞれ画像中の特徴点追跡で得られたオプティカルフローと、INS で予測されたオプティカルフローを示す。 t,m はそれぞれ時刻インデックス、オプティカルフローのインデックスであり、 M はインデックス m のオプティカルフローの長さ(オプティカルフローが途切れるまでの時刻数)を示している。本研究では d_m の 10pixel を閾値として画像中の特徴点追跡によるオプティカルフローの移動物判定を行った。

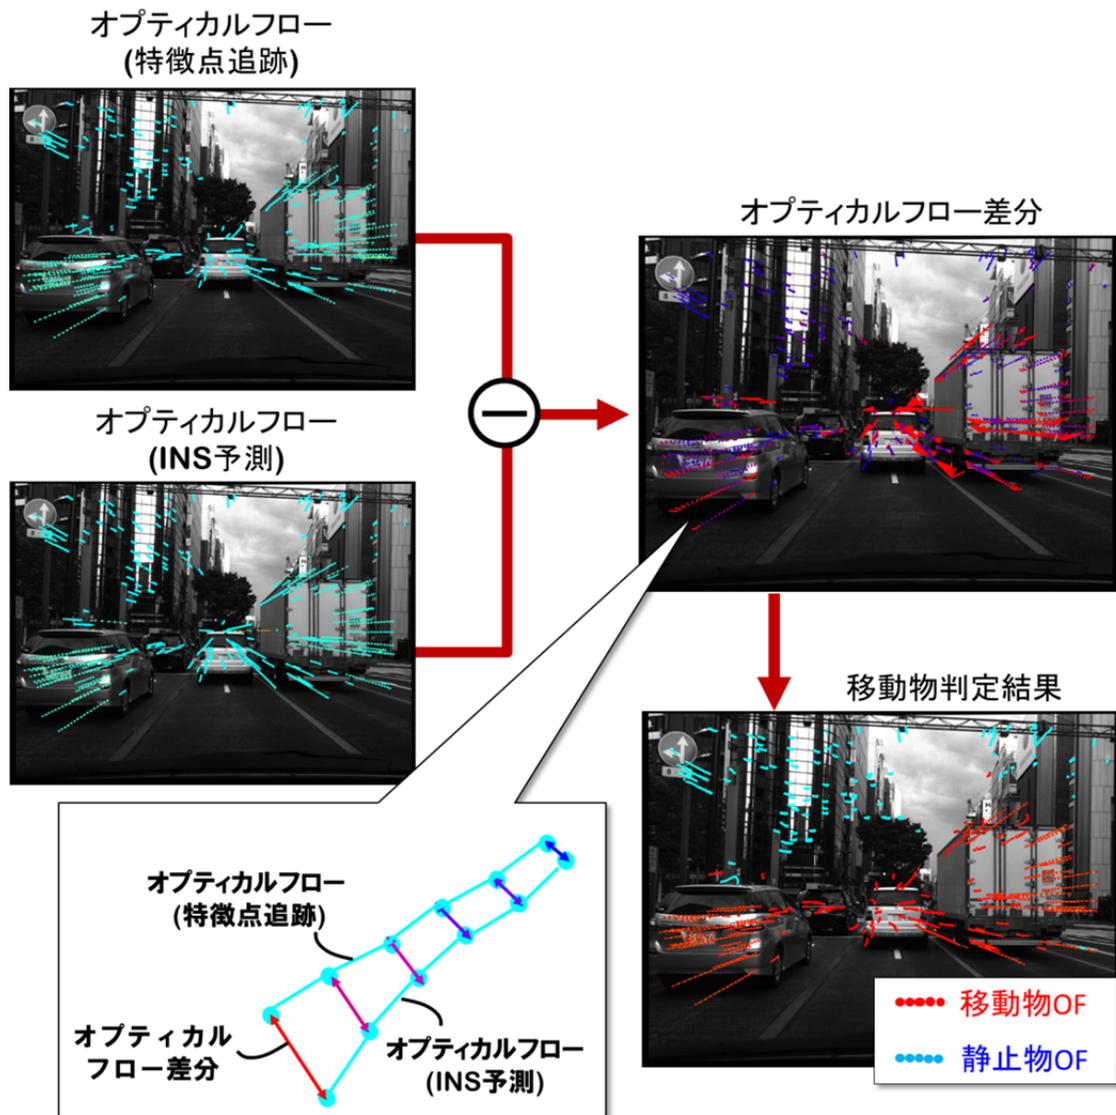
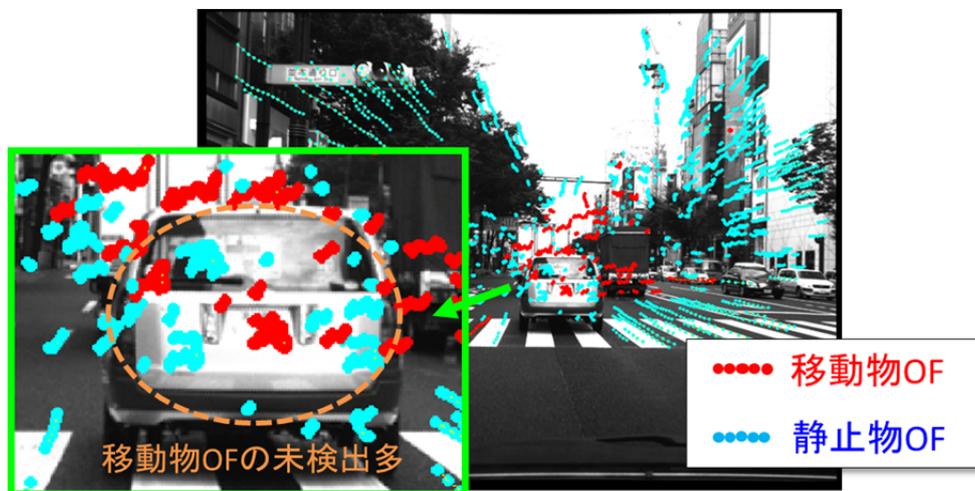


図 60 : オプティカルフロー比較による移動物判定

【INS を用いた移動物判定の問題】

INS を用いて検出した移動物 OF は画像中の移動物領域上に正しく現れることが多いが、いくつかの課題シーンも挙げられる(図 61)。移動物が正面遠方であり自車と同じ方向に動いている場合には、そのオプティカルフローの動きは小さく、正面遠方の静止物との区別が付きにくいいため、移動物 OF が静止物 OF と判定される（移動物 OF の未検出）要因となる。また、センサ間で僅かでも同期ずれがある場合、車両の細かいピッチ変動時などにおいて INS とカメラの計測値の不整合が生じるため、静止物 OF が移動物 OF と判定される（移動物 OF の誤検出）要因となる。そこで、本研究では画像中の車両検出結果との統合を行うことで、移動物 OF の未検出・誤検出の改善を行った。



(a) 移動物の未検出が多いシーン（移動物が正面かつ遠方）



(b) 移動物の誤検出が多いシーン

図 61 : INS を用いた移動物判定の課題

3. 3. 2 パターン認識による車両検出結果との統合

本研究ではパターン認識により画像中の移動物領域を検出した結果と、INS を用いた移動物 OF の検出結果と合わせることで、移動物 OF の検出精度を向上する。

パターン認識とは画像中の各画素が有する輝度のパターンに基づき画像中の物体を識別する技術であり、ここではパターン認識を用いて移動物領域の検出を行う。走行環境に存在する移動物は多様であるが、車載カメラに写る移動物の大半は走行車両であるため、本研究では車両のみを移動物と見なしてパターン認識の対象とした。画像には歩行者など車両以外の移動物が含まれる場合もあるが、これらはほとんどの場合は走行道路から撮影した画像内では無視できる程の小領域であるため、推定精度に及ぼす影響は小さいと考えられる。なお、本研究ではパターン認識手法としてニューラルネット型の手法である CNN (Convolutional Neural Network)[64]を車両検出に用いた。

以下に、本研究のポイントである、INS による移動物 OF 検出結果とパターン認識結果との統合方法を示す(図 62)。図右上は INS による移動物判定結果、図左上は CNN による車両検出結果を示す。車両検出結果には走行車両に加え、路上駐車や信号待ちの静止車両も含まれるため、まずこれら静止車両の除去処理を行う。具体的には、各車両検出領域内に含まれるオプティカルフローのうち移動物 OF の割合を算出し、その割合が閾値未満の場合には、その車両検出領域は静止車両と判断して削除する。これにより走行中の車両検出領域のみが残り、それらは全て移動物と判断できるため、車両検出領域内に存在するオプティカルフローを全て移動物 OF と判定する。これにより移動物 OF の未検出を減らすことができる。さらに、車両検出領域外は全て静止物であると考えられるため、車両検出領域外に存在するオプティカルフローを全て静止物 OF と判定する。これにより、移動物 OF の誤検出を減らすことができる。

一方、CNN による車両検出は基本的に安定であるが、一時的に車両領域の検出に失敗する場合もある。このような場合、その領域におけるオプティカルフローは全て静止物 OF と判定されるため、移動物 OF の未検出が生じることになる。そこで本研究では車両検出が一時的に失敗した場合の対策を行った。図 63 に対策の概要を示す。提案手法では、オプティカルフローが車両検出領域から外れた場合においても、もしそれらオプティカルフローが過去 3 時刻以上連続で車両検出領域内に存在していた場合には移動物判定状態を継続する処理を入れることで、車両検出失敗時における移動物 OF 検出の安定化を行った。

このように、INS による移動物 OF 検出結果と、パターン認識による車両検出結果とを相補的に統合する処理を行うことで、安定かつ精度良い移動物 OF 検出が可能となる。

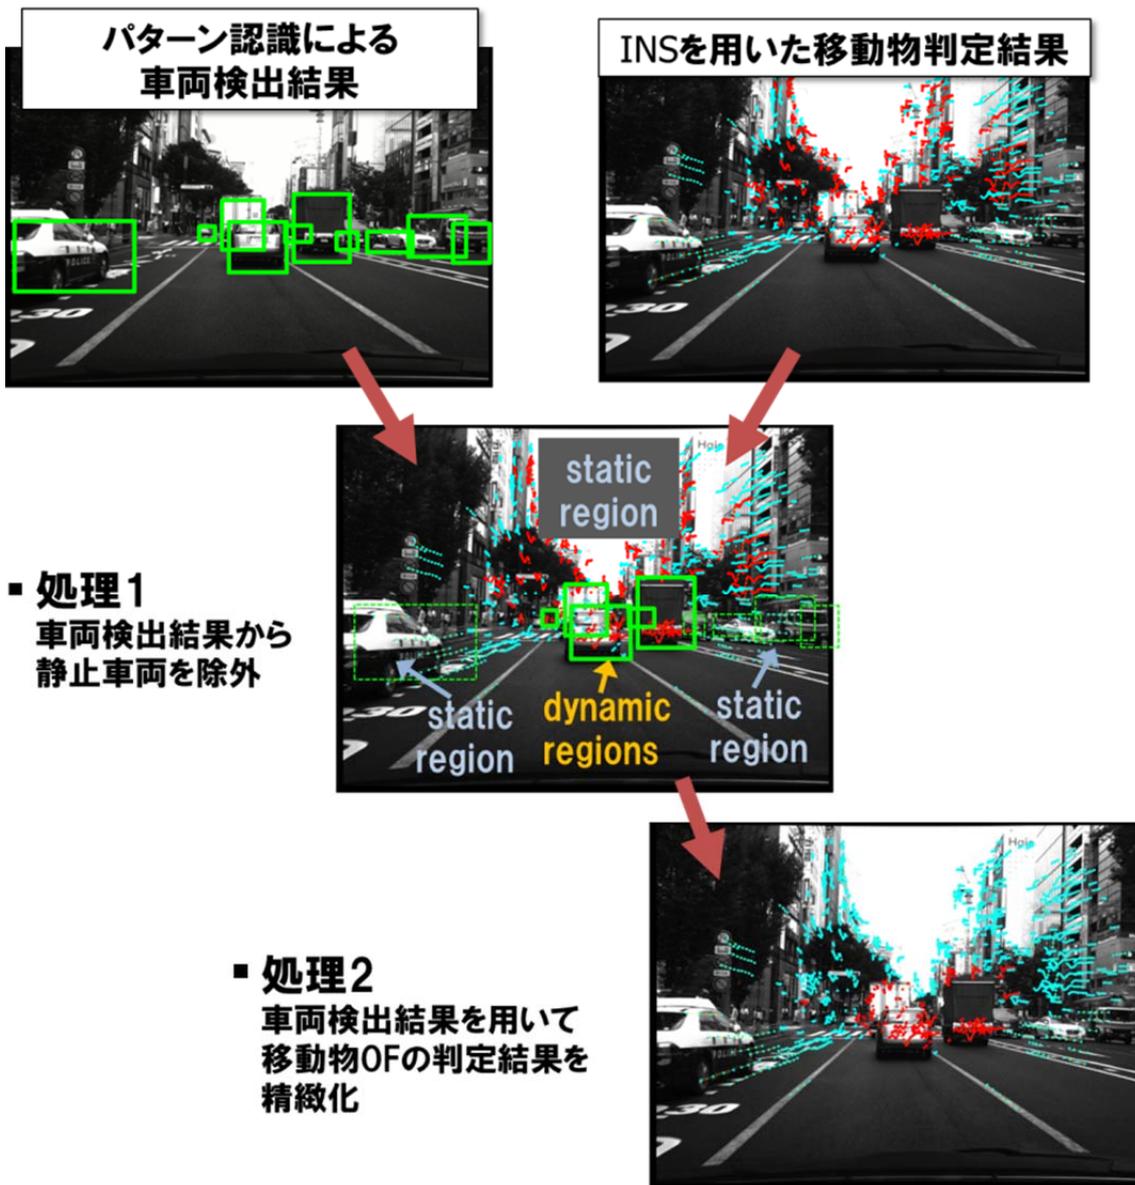


図 62 : パターン認識による車両検出結果と INS を用いた移動物判定結果の統合

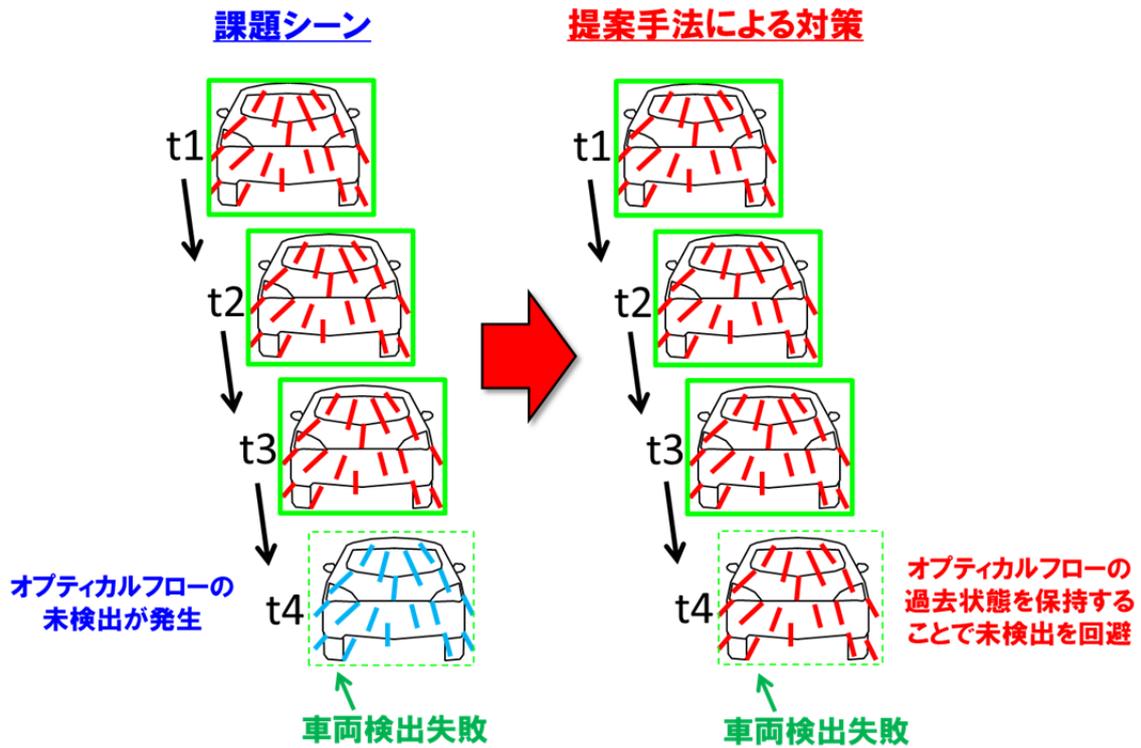


図 63 : 車両検出失敗時における対策

3. 3. 3 実験

3. 3. 3. 1 実験条件

図 64 に評価コースを示す。コースは車両などの移動物が多く存在する銀座駅周辺であり，移動物が多い約 500m（走行時間：約 97 秒）の走行区間を評価対象とした。前方カメラは XCD-SX90（モノクロ，SXGA）を単眼で用い，進行距離は車輪速から得た車速により算出した。また，移動物判定には汎用的な車載品相当のジャイロ(角速度)を用い，方位補正のための GPS のドップラースhiftは Trimble 社製の NetR9 から取得した。なお，軌跡精度評価のためのリファレンスとして POSLV610[72]を使用し，軌跡誤差は水平面内におけるリファレンスからのずれ（距離）として算出した。

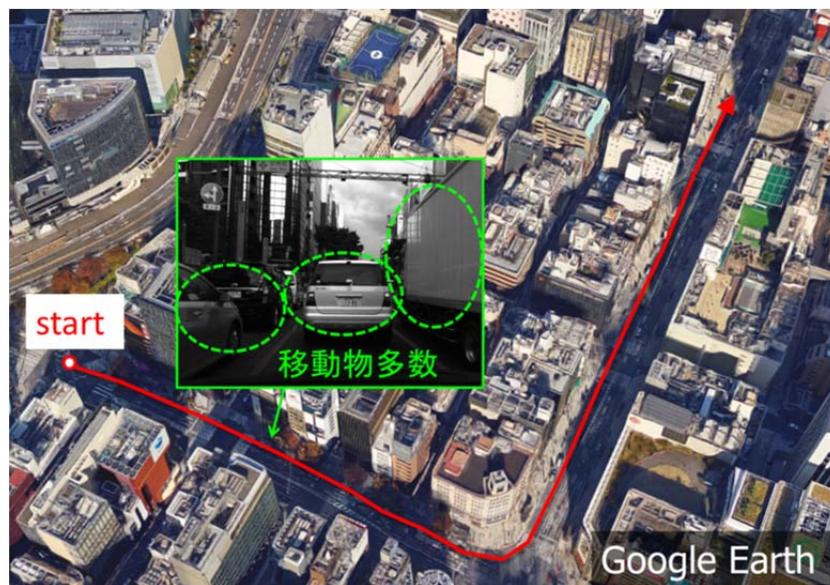


図 64：評価コース（銀座，Google Earth より引用）

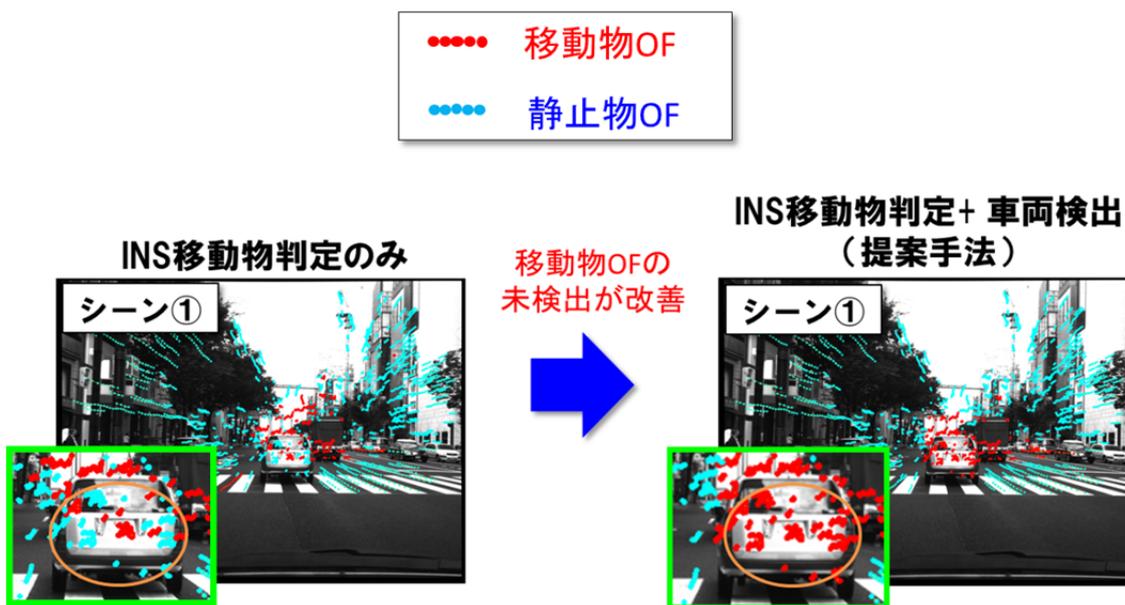
表 8：実験機器

センサ機器	製品	出力周期
ジャイロ	汎用車載品	12ms
車輪速	汎用車載品	12ms
GPS受信機	NetR9	100ms
カメラ	XCD-SX90 (SXGA)	66.7ms
リファレンス	POSLV610	5ms

3. 3. 3. 2 実験結果

【移動物判定結果】

図 65 に INS による移動物判定結果と提案手法による移動物判定結果との比較を示す。INS による移動物判定のみの場合には正面遠方の車両上の移動物 OF が未検出となっているのに対し、提案手法ではそれらが改善されていることが分かる(a)。また、INS による移動物判定を用いた場合に静止物上で移動物 OF の誤検出が生じていたのに対し、提案手法ではそれら誤検出が改善されていることが分かる(b)。これは車両検出結果との統合により移動物判定結果が精緻化された効果であると言える。



(a) 未検出低減シーン



(b) 誤検出低減シーン

図 65：提案手法による移動物 OF 判定の改善効果 (INS のみ利用時との比較)

図 67 に提案手法の移動物判定継続処理の有無の比較を示す。移動物継続処理を入れない場合では、パターン認識による車両検出が失敗した時に移動物 OF の未検出が発生している。これは INS による移動物判定結果と車両検出結果との統合による精緻化処理の中で、車両検出領域内のオプティカルフローを全て移動物 OF と判定するため、車両検出が失敗した場合には移動物 OF の判定が意図通りに行われなかったことが原因である。これに対し、移動物継続処理を入れた場合には、車両検出が一時的に失敗した時でも移動物 OF の状態を保持するため、移動物 OF が安定的に検出されていることが分かる。

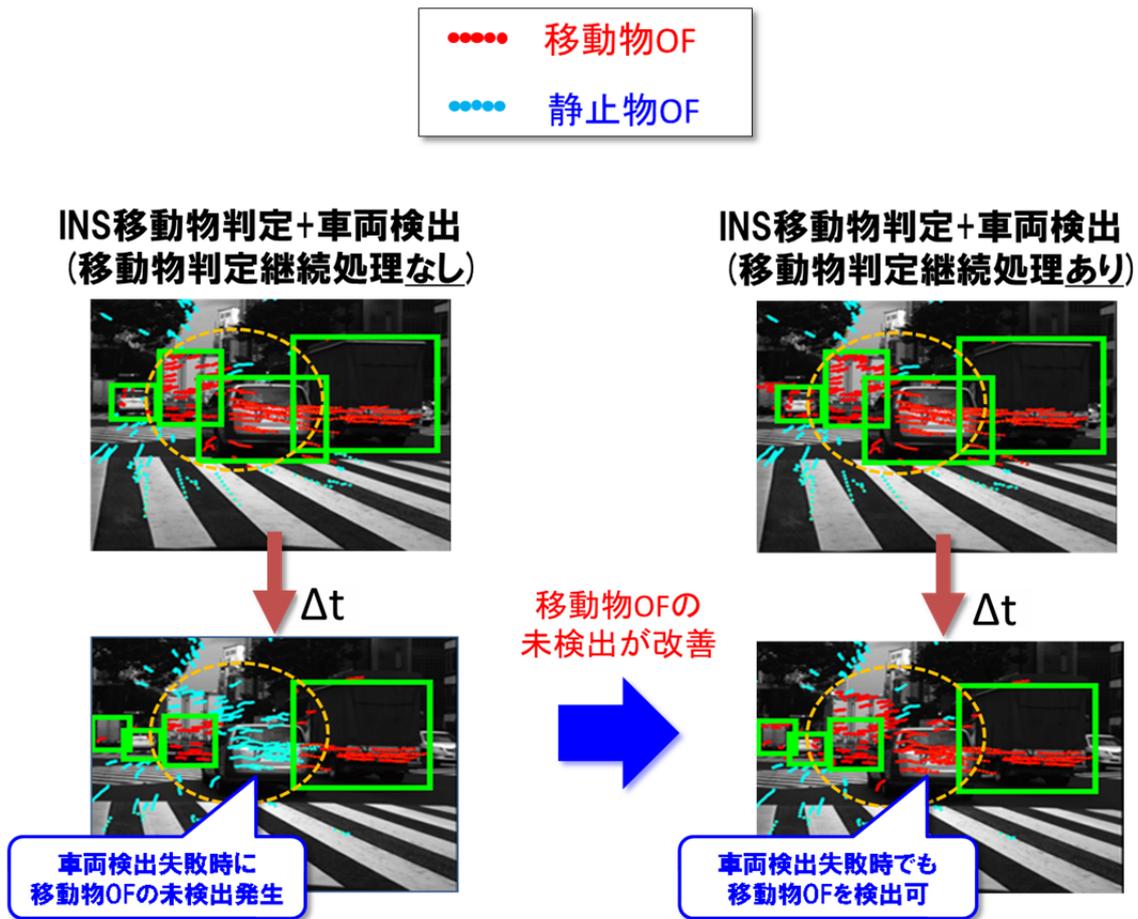


図 67：提案手法による移動物判定継続処理の効果

【軌跡推定結果】

図 68, 69 に VO の方位推定誤差と軌跡推定誤差を示す。ここで、『VO』は画像を用いた推測航法の結果を示し、『移動物判定』は INS を用いて移動物 OF を検出・除去した結果、パターン認識による車両検出を用いて移動物 OF を検出・除去した結果、または両者を統合した提案手法による移動物 OF 検出・除去結果を示す。また、『GPS 方位』は前節で説明した提案手法による方位推定結果を用いて VO の方位を補正した結果を示す。

方位推定結果について移動物 OF の検出・除去の各手法を比較した場合、提案手法の誤差が最も小さく安定していることが分かる。これは提案手法による移動物 OF の未検出・誤検出の改善による効果であると考えられる。また、移動物 OF の検出・除去に INS のみを用いた場合と車両検出のみを用いた場合の比較では、車両検出の方が誤差が少ないことが分かる。車両検出のみを用いた場合では静止物 OF を移動物 OF と判定して除去してしまう移動物 OF の誤検出が起りやすいのに対し、INS のみを用いた場合では移動物 OF を静止物 OF と判定してしまう未検出が起りやすく、誤検出に比べて未検出の方が VO の精度に及ぼす影響が大きいと考えられる。また、GPS 方位による方位補正を行った場合には、各手法の方位誤差が改善される傾向にあるが、提案手法による移動物 OF の検出・除去を行った場合には GPS 方位を用いた場合との差は微小であった。提案手法による移動物 OF 検出・除去を行うことで方位誤差の蓄積を抑えることができるため、本評価の走行距離内では方位誤差蓄積はわずかである一方、走行距離がさらに伸びた場合には距離に比例して方位誤差が大きく蓄積する恐れがある。このため、GPS 方位による方位補正を用いた場合には走行距離に関わらず方位精度を担保できることが利点となる。なお、VO 単体(VO)については、方位誤差が 0 をまたいで大きく変動するため、方位補正を行った場合(VO+GPS 方位)、逆に方位誤差が増加するシーンも見られる(走行距離 300m~400m 付近)。

軌跡推定結果は、方位推定の精度の影響を大きく受けるため、方位推定結果と同様に提案手法による結果(VO+INS+車両検出+GPS 方位)が最小の誤差となっていることが分かる。図 70 に 100m 走行あたりに生じる軌跡誤差を示す。提案手法では軌跡誤差が 0.4m となっており、VO 単体の軌跡誤差約 1.6m に比べて 1/4 程度に低減しており、INS、車両検出を用いた場合に比べても、軌跡誤差はそれぞれ 5 割以上、2 割以上低減していることが分かる。

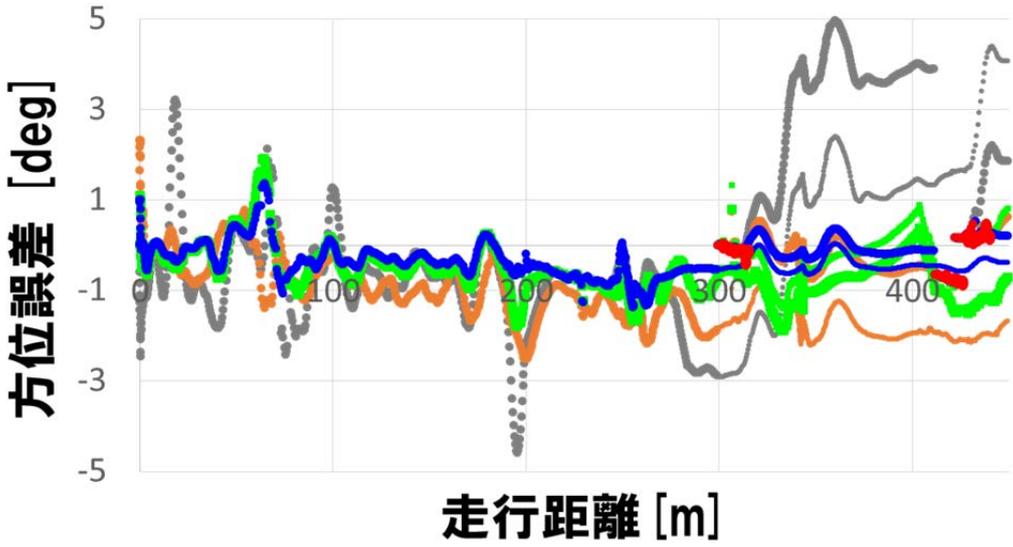


図 68 : 方位推定誤差

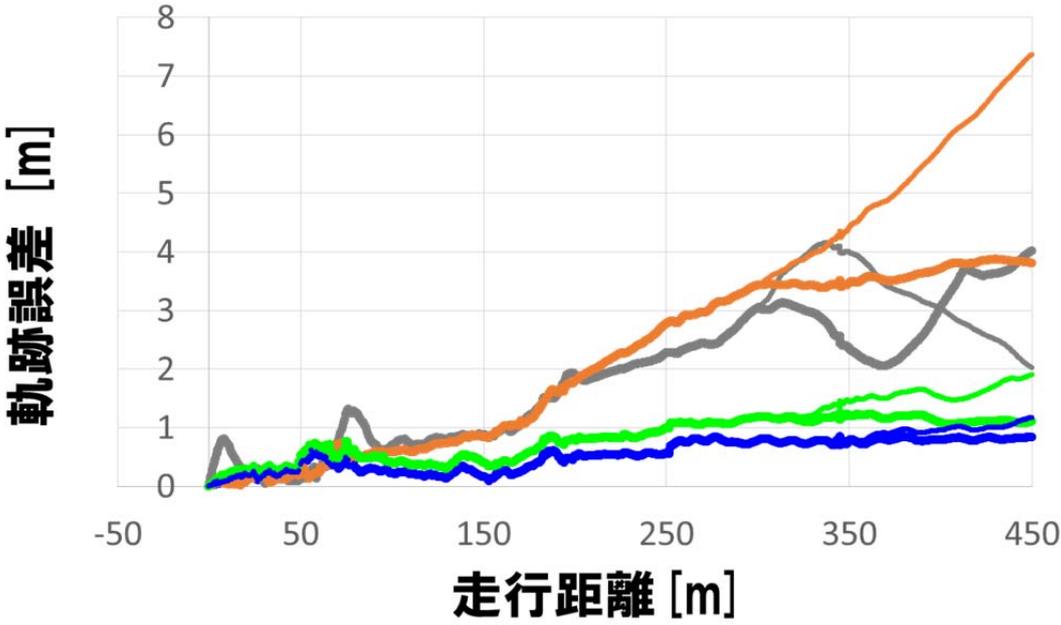


図 69 : 軌跡推定誤差

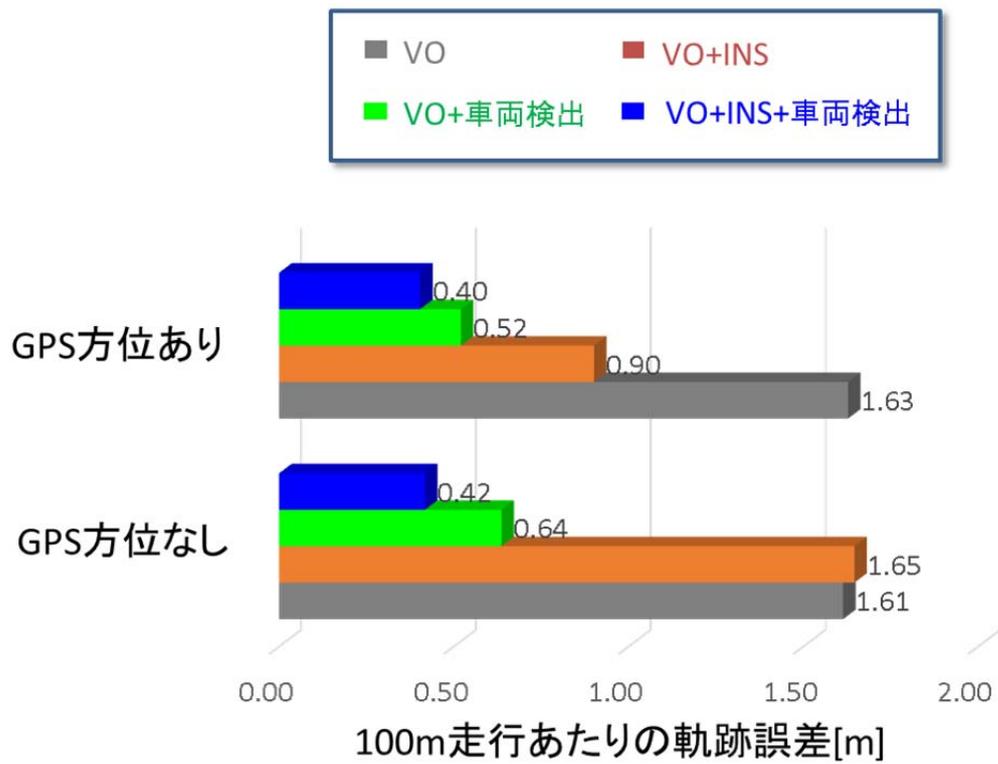


図 70 : 走行距離 100m あたりに生じる軌跡誤差

3. 4 本章のまとめ

本章では、推測航法の性能向上手法について述べた。本研究では、屋内外において高精度な推測航法が可能であり、かつ市販車に搭載可能なコスト性を合わせ持つカメラ画像を用いた推測航法 (VO: Visual Odometry) に着目し、精度向上のための課題解決を行った。VO はカメラ画像中の静止物体の動きから相対的に自車の動きを推定する手法であるため、画像中に移動物を含む場合、精度劣化要因となる。また、VO では絶対方位が得られないため方位誤差が蓄積し軌跡誤差が増大する恐れがある。本研究ではこれら二つの課題に対し、改善策の提案を行った。

まず、方位の蓄積誤差については、GPS のドップラーシフトと INS の時系列タイトカップリング型統合によって得た絶対方位推定結果を用いて VO の方位誤差を補正する手法を提案した。従来、GPS のドップラーシフトのみを用いた場合では可視衛星数が 4 以上ある場合しか絶対方位が得られなかったのに対し、提案手法では衛星数が 4 未満となる場合でも絶対方位推定が可能となり、これにより都心部のような環境においても VO の方位誤差を高頻度に補正できるようになった。都心部で評価を行った結果、従来手法に比べて、誤差が約 3 割低減することを確認した。

また、画像中の移動物の問題については、INS とパターン認識技術を用い、移動物上のオプティカルフローを検出・除去する手法を提案した。従来、INS やパターン認識を各々用いた移動物検出手法が提案されていたが、これらはそれぞれ精密さやロバスト性に課題があった。これに対し、提案手法ではまず、INS により大まかに移動物上のオプティカルフローを検出した後、パターン認識により得られた車両検出領域を用いて精緻化処理を行う統合型の移動物検出を行うことで、移動物上のオプティカルフローを正確に検出・除去できるようになった。都心部で評価を行った結果、従来手法に比べて軌跡誤差が 2 割以上低減することを確認した。次章では絶対測位の性能向上手法について述べる。

4 章 絶対測位の性能向上

前章では推測航法の性能向上について述べたが、推測航法は相対測位であるため走行と共に自車位置の誤差が僅かながらに蓄積していく。このため、自車位置を常に高い精度に保つためには絶対測位を高精度・高頻度に行い、推測航法で蓄積した位置誤差を随時補正することが重要となる。本研究では比較的成本が安く、高精度・高頻度な絶対測位の実現できる可能性を有する絶対測位手段として、カメラ画像を用いた位置推定技術（以下、ローカライズ）に着目し性能向上に取り組んだ。

ローカライズはカメラ画像中の特徴と地図 DB 中の特徴とのマッチングにより自車位置を推定する方法であり、精度向上のためには地図精度、およびマッチング方法が重要となる。本研究では特にマッチング方法の改善に焦点を当てローカライズ精度向上への取り組みを行った。本章ではまず始めに、ローカライズの従来手法と課題を示した後、本研究の提案手法について述べる。

4. 1 ローカライズの従来手法と課題

ローカライズは画像中に見える任意の特徴と、事前に生成した地図 DB の中に含まれる特徴とのマッチングを行い、地図中における自車位置・姿勢を推定する手法である。

一般的に、地図 DB 中に含まれる特徴の 3 次元位置や、画像中で検出した特徴の位置には若干の誤差が含まれるため、ローカライズ精度向上のためにはマッチングできる特徴の数をできるだけ増やし、誤差の平均化効果を得ることが重要となる。マッチングできる特徴の数を増やすためには、実際の道路環境における特徴の出現頻度、および、特徴が出現時において正しいマッチングできることが重要となるため、ローカライズのための特徴として様々な方法が提案されている。以下に各手法を示す。

【路面マークベース】

自動車のローカライズのための特徴として路面マークを利用した手法が多数提案されている[77][78][79][80]。これらの手法では白線、横断歩道、右左折サインなど様々な路面マーク情報を持った地図 DB を生成した後、現在車載カメラから見える路面マークと地図 DB 中の路面マークとのマッチングを行うことで自車位置・姿勢を決定する（図 71）。路面マークは季節を通して変化が少なく、天候や照明条件などの影響も受けにくいいため、マッチングのロバスト性が高い利点がある。一方、実際の道路環境においては路面マークが長く現れないシーンもあるため、そのようなシーンではローカライズ頻度が低下することが課題となる。



図 71：路面マークベースのローカライズ[77]

【点ベース】

画像中の特徴点をローカライズに利用する方法もこれまで多く研究されている[81][82][83][84][85] (図 72)。この方法では事前に生成した特徴点情報(画像特徴量+特徴点 3次元位置)を持つ地図 DB 中の特徴点と、カメラ画像中の特徴点とのマッチングを行うことで自車位置・姿勢推定を行う。周囲に何らかの立体物がある場所であれば特徴点を抽出することは可能であるため、大抵の場所においてローカライズを行う機会が得られることが利点となる。一方、天候変化や一時的な照明条件の変動などによって対象物の見え方が変化した場合には特徴点のマッチングが困難になり、ローカライズの精度が劣化したり推定自体が行えなくなる恐れがある。

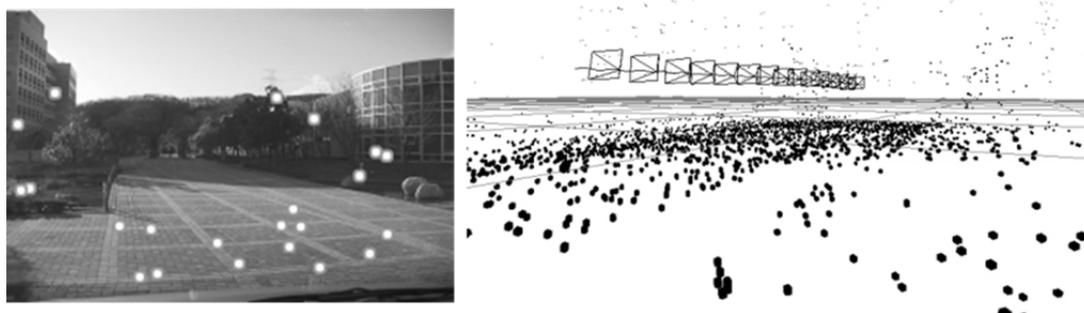


図 72：点ベースのローカライズ[85]

【線ベース】

特に都心部などの道路環境では、直線を含む構造物が周囲に多く存在するため、直線を特徴として利用したローカライズも提案されている[86][87][88] (図 73)。この方法では事前に生成した直線情報(直線の両端点の 3次元座標)を持つ地図 DB 中の直線と、車載カメラ画像中から抽出した直線とのマッチングを行うことで自車位置・姿勢を推定する。直線は照明条件の変化などに比較的強く、また周囲に建物などの構造物がある場所では出現頻度が高いという利点がある一方、直線同士の 1:1 の対応付けが困難であるため誤マッチングが起りやすいことと、山道のように周囲に構造物がない場所ではローカライズ頻度

が低下することが問題となる。

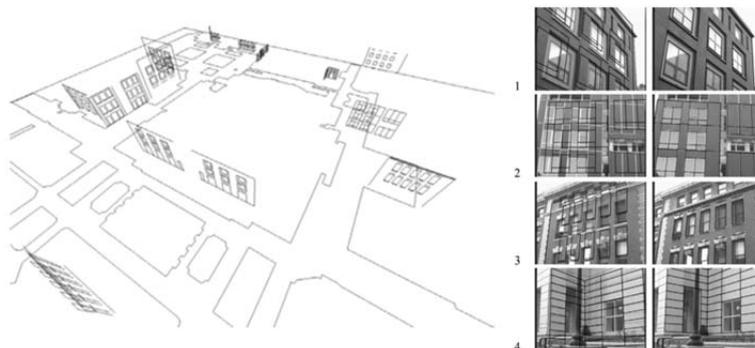


図 73 : 線ベースのローカライズ[86]

【オブジェクトベース】

オブジェクトベースのローカライズは、任意のオブジェクトを手がかりに地図 DB・カメラ画像間のマッチングを行う手法である[26][89] (図 74)。この方法では、まず任意に指定したオブジェクト(道路環境であれば信号、標識、看板など)の 3 次元位置を地図 DB に登録し、その後、カメラ画像内で認識したオブジェクトと地図 DB のオブジェクトとのマッチングを行うことで自車位置・姿勢の推定を行う。照明条件など環境変化に対するロバスト性が高い一方、オブジェクトの指定するものによっては十分な出現頻度が得られず、ローカライズの頻度が低下する恐れがある。

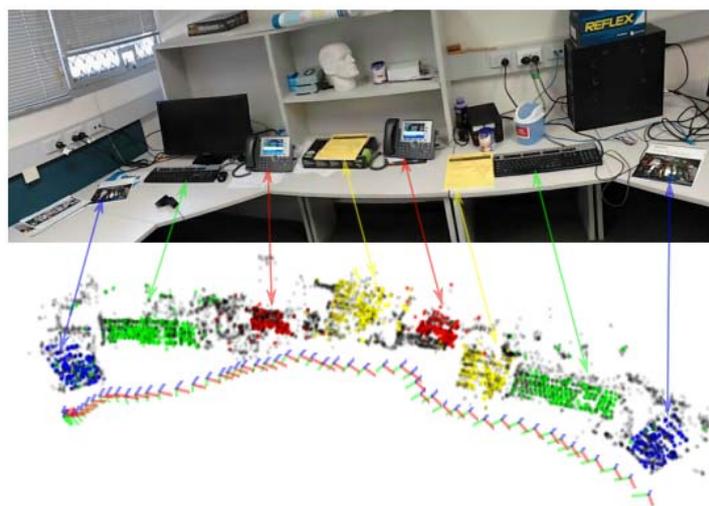


図 74 : オブジェクトベースのローカライズ[26]

【マーカベース】

マーカベースのローカライズでは、人工的に生成したデジタルパターンを有するマーカを手がかりとして位置推定を行う手法である[90][91][92](図 75)。この方法では、マーカの位置情報が記録されたデジタルパターンを有するマーカを作成し、事前にシーン設置する。その後、カメラ画像中にマーカをとらえた時にデジタルパターンを解析することでマーカの 3 次元位置を取得することができ、そこから自車位置・姿勢の推定が可能となる。周囲に十分な数のマーカがある場合にはロバストかつ正確な位置推定が可能となるが、事前のマーカ設置コストが課題となる。

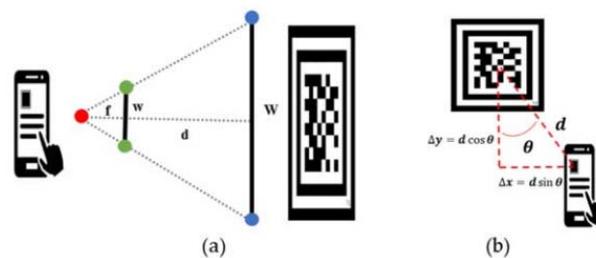


図 75 : マーカベースのローカライズ[92]

【3D モデルベース】

3D モデルベースのローカライズではあらかじめ生成した建物の 3D モデルの形状情報を手がかりとして自車位置推定を行う(図 76)。^{[93][94]}では建物の 3D モデルの輪郭線と、画像中の建物の輪郭線が最も整合するような位置を探索することで自車位置決定を行った。これらの方法では建物が多くあるシーンではロバストかつ精度良いローカライズが可能となるが、郊外など建物以外の自然物が多いシーンでは手がかりが得られず、ローカライズの精度が低下する恐れがある。

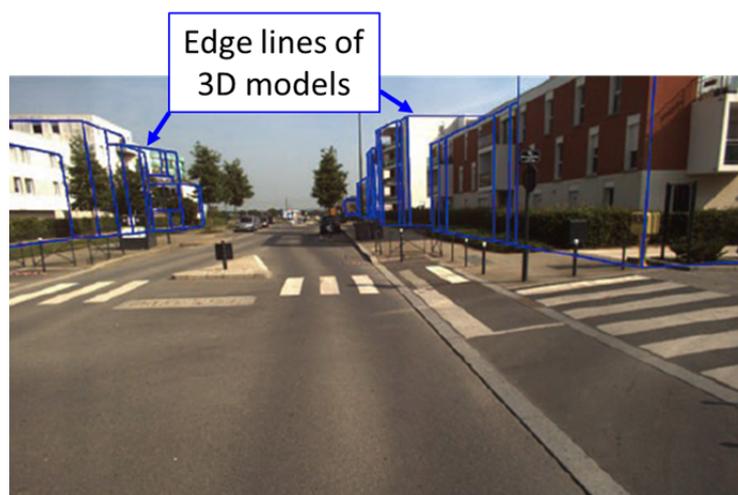


図 76 : 3D モデルベースのローカライズ[93]

【シーンベース】

シーンベースのローカライズでは、カメラ画像中に見えるシーン全体を手がかりとして位置推定を行う[95][96][97] (図 77)。地図 DB にはカメラ画像とそれを撮影した位置情報が登録されており、ローカライズの際には地図 DB 中の全画像の中から、車載カメラ画像と最も一致度が高い画像を選び、それを現在の自転車位置とする。この方法はこれまで述べたローカライズとは異なり、画像-画像のマッチングを行うため、地図 DB に登録された画像と全く同じ場所を通った場合は正確かつロバストな自転車位置推定が可能となるが、地図 DB に登録された画像とは異なるルートを行きつた場合には正確な位置推定が困難となる。例えば、鉄道のようにレール上で常に同じ位置を同じ向きで通る場合にはシーンベースのローカライズは非常に適しているが、自動車のように同じ道路内でも複数の車線があり、さらに道路内での位置や姿勢が走行毎にわずかに異なる場合には、そのズレを吸収することは困難である。

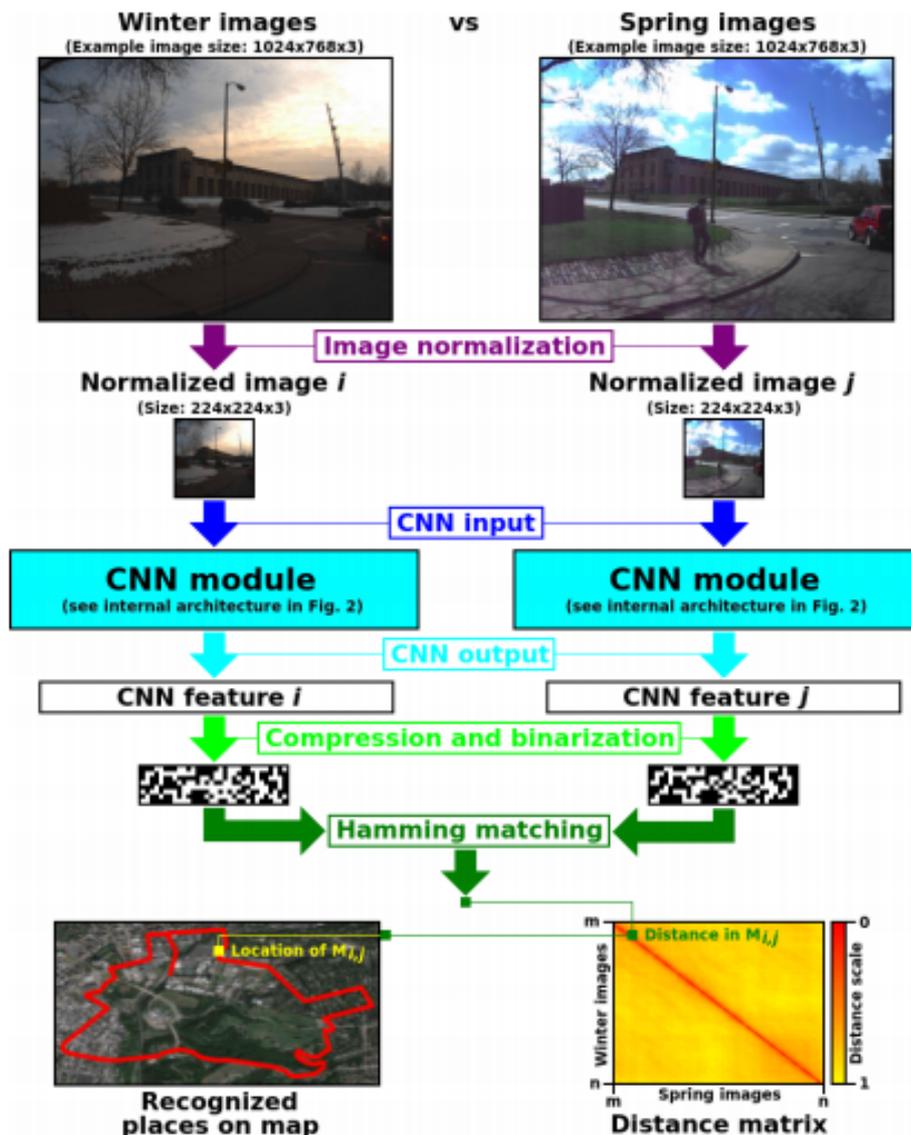


図 77 : シーンベースのローカライズ[96]

以上では様々な特徴量を利用したローカライズ手法について述べた。各手法とも長所・短所を有するが、本研究では、特徴の出現頻度が最も高く汎用性が高い手法として、特徴点を利用した(点ベース)ローカライズに着目する。特徴点を利用したローカライズは場所を問わず高精度な自車位置を得られる可能性を持つが、周辺物が少ないシーンや照明条件が変動するシーンではマッチングできる特徴点の数が減少し、ローカライズによる位置推定精度が劣化する可能性がある。そこで本研究では複数時刻の観測データを用いた上でINSとの統合を行うことで見かけ上マッチングできる特徴点数を増加し、周辺環境によらず高精度な位置推定の実現を目指す。

これまでローカライズ/INSの統合手法はいくつか提案されている。[92]では、ローカライズにより得た絶対測位結果と、INSによる推測航法結果とをEKF(Extended Kalman Filter)で統合することで測位誤差のばらつきを低減した。一方、この方法での統合はルーブリック方式(結果同士の統合)であるため、マッチングできる特徴点数の減少時にはローカライズの精度劣化が大きくなり統合後の精度に悪影響を及ぼす恐れがある。また、[91]ではINSで予測した画像中の特徴点位置に基づき、地図DB-画像間における特徴点の誤マッチングを低減した。この方法ではマッチングできた特徴点数が十分多い場合には、誤マッチング排除の効果を得ることができるが、マッチングできた特徴点数が減少時にはやはり精度劣化の恐れがある。これに対し、本研究ではローカライズ/INSをタイトカップリング方式(観測値同士の統合)で統合することで、マッチングできる特徴点数が減少した場合にも高精度なローカライズを可能とする方法を提案した。次節で提案手法の説明を行う。

4. 2 提案手法3：INS との時系列データ統合によるローカライズ

本節では、提案手法についての説明を行う。まず始めに、ベースとなる特徴点を用いたローカライズ手法(従来手法) について説明し、その後提案手法について述べる。また、本節ではローカライズに用いる地図 DB の構築方法についても述べる。

4. 2. 1 特徴点を用いたローカライズ手法

特徴点を用いたローカライズでは、車載カメラ画像中の特徴点と、特徴点地図 DB 中の特徴点とのマッチングを行うことで自車位置・姿勢を決定する。特徴点地図 DB については後で詳細を述べるが、各特徴点が 3 次元位置と画像特徴量の情報を有した地図 DB である。図 78 に特徴点を利用したローカライズ手法の概要を示す。まず、特徴点地図 DB では広域にわたり分布する特徴点群の中から自車位置周辺の特徴点を選択する。ここでは自車位置の範囲が大まかに分かれば良いため、前時刻におけるローカライズ位置や GPS の情報を利用する。次に、車載カメラ画像から抽出した特徴点と特徴点地図 DB 中の特徴点とのマッチングを行う。ここでは、AKAZE[36]などの画像特徴量に基づき画像-地図 DB 間で同一の特徴点を対応付ける。そして特徴点のマッチング後は、対応する特徴点同士の整合性が最も高くなる自車位置・姿勢を決定する。ここでは、「画像中の特徴点の奥行方向には実世界中の特徴点が存在する」、という仮定に基づき行う。具体的には、車載カメラ画像中の特徴点の奥行方向へ視線を引き、これらが対応する地図 DB 中の 3 次元特徴点となるべく正確に重なるような自車位置を探索する。

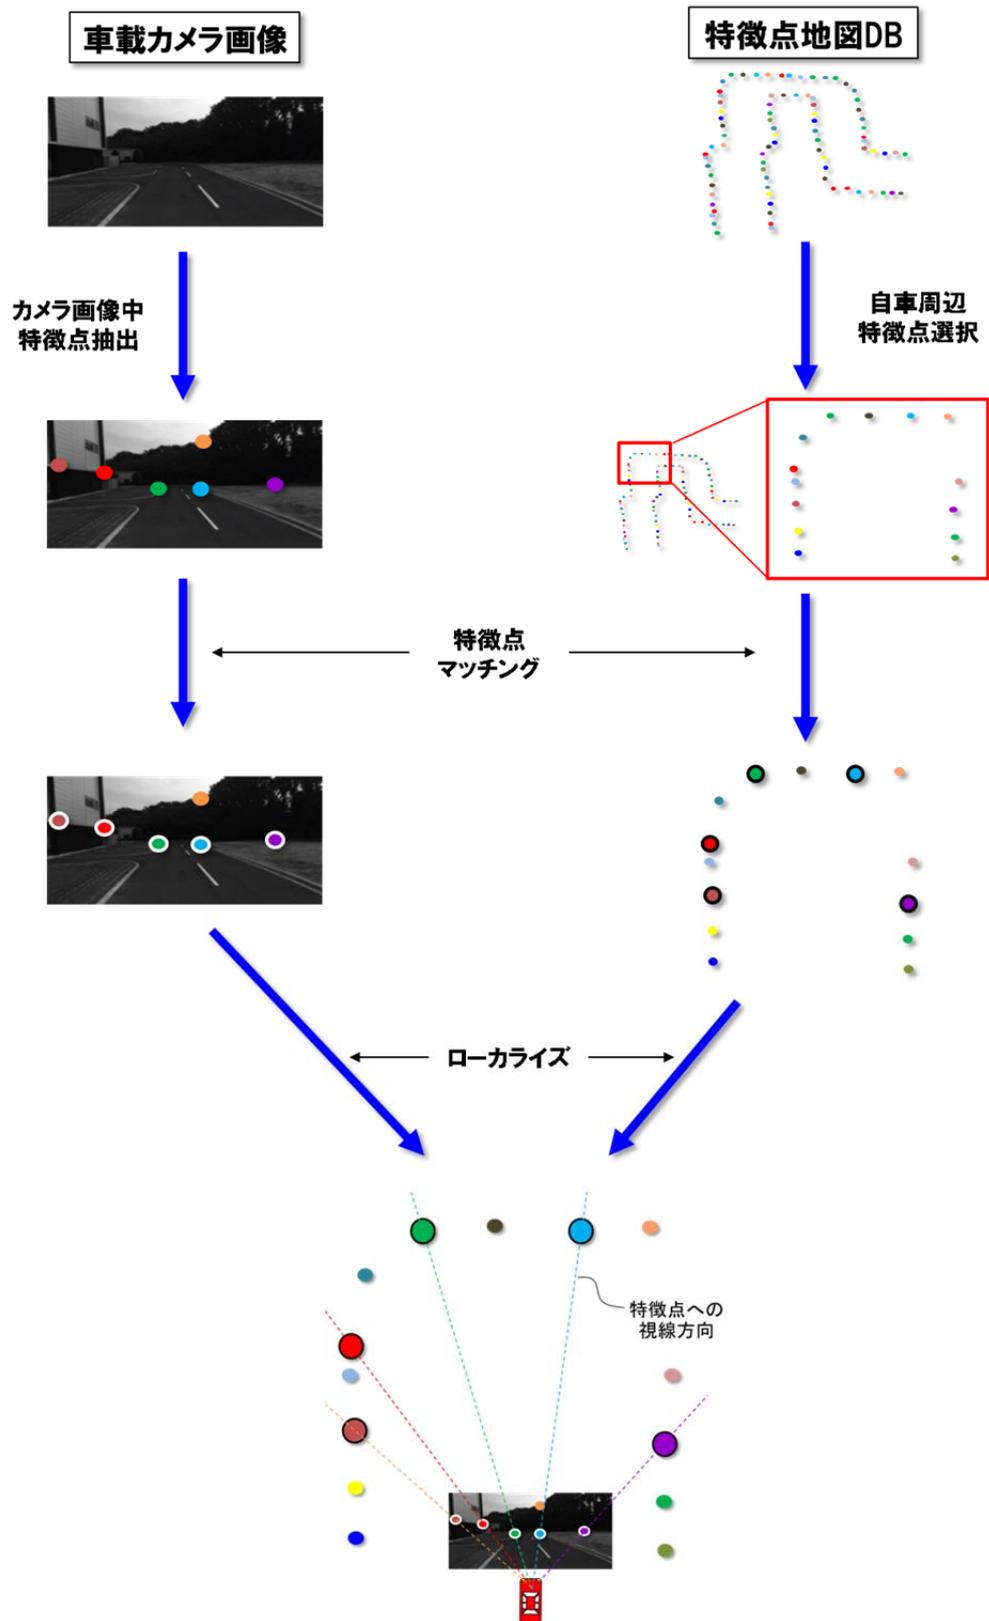


図 78：特徴点を利用した位置推定の概要

自車位置算出方法を以下に示す。特徴点を利用したローカライズでは、画像中における特徴点の 2 次元位置と、地図 DB 中における特徴点の 3 次元位置を観測値として、自車の位置/姿勢(共に 3 次元)の推定を行う。式(21)に特徴点の 2 次元位置, 3 次元位置, 自車位置, 自車姿勢の関係を示す。

$$\mathbf{X}'_m = \mathbf{KR}[\mathbf{I} | -\mathbf{x}]\mathbf{X}_m \quad (21)$$

ただし,

$$\mathbf{R} = \begin{bmatrix} \cos \phi & -\sin \phi & 0 \\ \sin \phi & \cos \phi & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos \theta & 0 & \sin \theta \\ 0 & 1 & 0 \\ -\sin \theta & 0 & \cos \theta \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \psi & -\sin \psi \\ 0 & \sin \psi & \cos \psi \end{bmatrix}$$

ここで, \mathbf{X}'_m は画像中の特徴点 2 次元位置 (観測値), \mathbf{K} はカメラのキャリブレーション行列(事前計測により既知), \mathbf{x} は自車の姿勢(ピッチ, ヨー, ロール)を要素とした 3 次元回転行列(未知数), \mathbf{R} は 3 次元自車位置(未知数), \mathbf{X}_m は地図 DB 中の特徴点 3 次元位置(観測値), \mathbf{I} は 3×3 の単位行列, m は特徴点インデックスを示す。

この観測方程式は画像・地図 DB 間でマッチングした特徴点の数だけ連立することができ, それら観測方程式を満足する \mathbf{x} , \mathbf{R} を推定する。観測方程式を解くためには, 式(22)に示すコスト関数を最小化する非線形最適化問題を解く必要があるため, Levenberg-Marquardt 法[39]などを用いた収束演算により解の探索を行う。

$$E = \sum_{m=0}^N (\mathbf{X}'_m - \mathbf{KR}[\mathbf{I} | -\mathbf{x}]\mathbf{X}_m)^2 \quad (22)$$

(N は推定に用いる特徴点数)

4. 2. 2 INS との時系列データ統合によるローカライズ

ローカライズでは、画像-地図 DB 間でマッチングした特徴点の数だけ観測方程式を連立することができるが、通常、観測方程式には特徴点位置などの誤差が含まれるため、より多くの観測方程式を連立することで精度の良い解を得ることができる。一方、実際の走行シーンでは周辺環境が常時移り変わりに応じて、周辺物が少ないシーンや照明条件の変動するシーンなど、地図 DB との特徴点マッチングが困難なシーン(図 79)に遭遇することがあり、このようなシーンではローカライズの位置推定精度が劣化する恐れがあった。

これに対し、提案手法では画像中特徴点の時系列データをマッチングに利用することで環境変化に対するロバスト性向上を行った。図 80 に従来手法と提案手法の比較イメージを示す。従来手法では現在観測した画像中の特徴点のみを地図 DB とのマッチングに利用するため、現時刻においてマッチングできる特徴点数が少なればローカライズ精度が劣化する恐れがある。これに対し提案手法では時系列画像中の特徴点をマッチングに利用することで、見かけ上マッチングできる特徴点の数を増加し、1 時刻あたりにマッチングできる特徴点が少ない場合でも自転車位置を精度良く推定することができる。なお、時系列データを利用する際には、ジャイロと車輪速で算出した走行軌跡を用いて各時刻間の相対的な自転車位置・姿勢を拘束し、時系列の車両全体を一つのかたまりとして扱い最適な位置を探索する。



(a) 周辺に特徴物が少ないシーン



(b) 照明条件変動シーン

図 79：特徴点のマッチングが困難なシーン

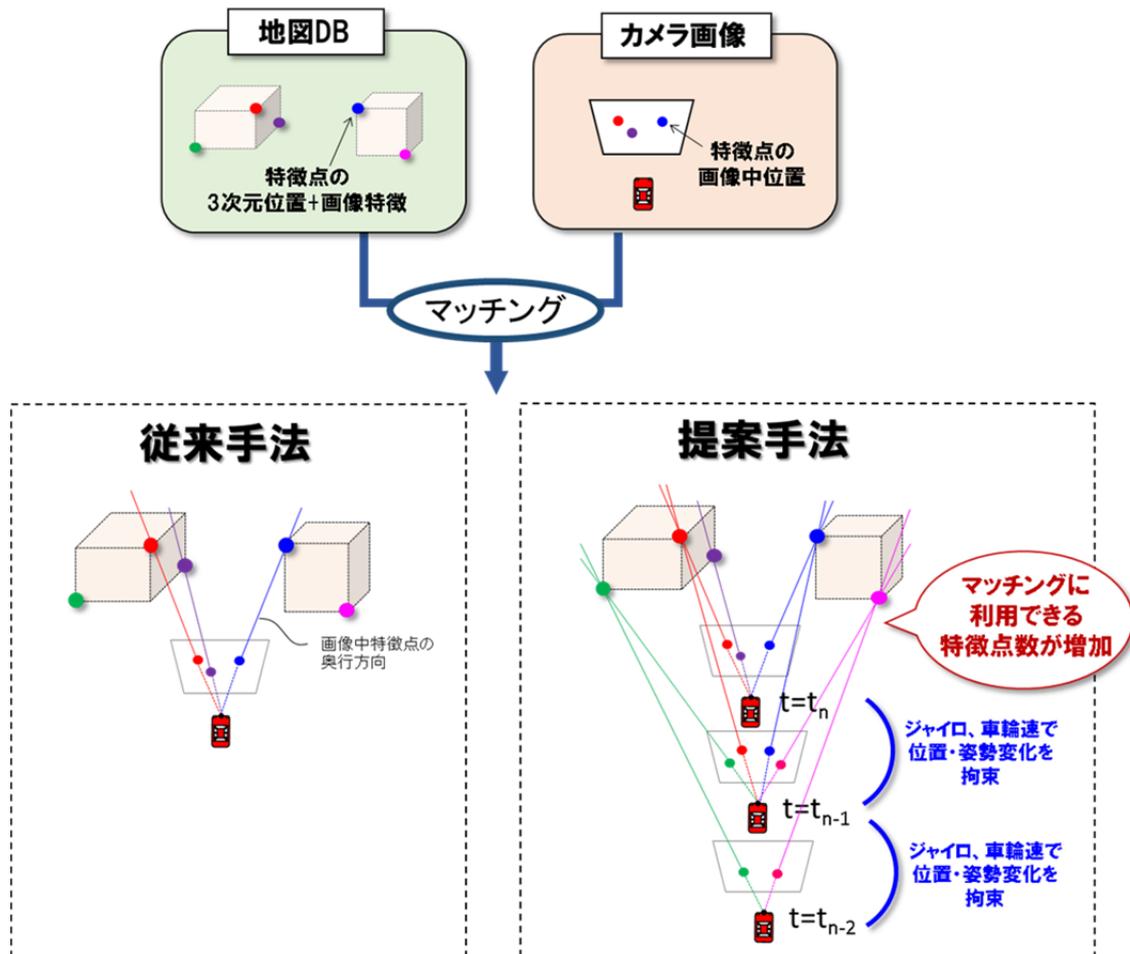


図 80 : 従来手法と提案手法の比較

自車位置算出方法を以下に示す。提案手法ではまず式(22)を時間方向に連立して式(23)を得る。

$$\mathbf{X}'_{t,m} = \mathbf{K}\mathbf{R}_t[\mathbf{I} \mid -\mathbf{x}_t]\mathbf{X}_m \quad (23)$$

ただし,

$$\mathbf{R}_t = \begin{bmatrix} \cos \phi_t & -\sin \phi_t & 0 \\ \sin \phi_t & \cos \phi_t & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos \theta_t & 0 & \sin \theta_t \\ 0 & 1 & 0 \\ -\sin \theta_t & 0 & \cos \theta_t \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \psi_t & -\sin \psi_t \\ 0 & \sin \psi_t & \cos \psi_t \end{bmatrix}$$

ここで、 $\mathbf{X}'_{t,m}$ は画像中の時系列の特徴点 2 次元位置、 \mathbf{K} はカメラのキャリブレーション行列、 \mathbf{R}_t は時系列の自車姿勢(ピッチ, ヨー, ロール)を要素とした 3 次元回転行列、 \mathbf{x}_t は時系列の 3 次元自車位置、 \mathbf{X}_m は地図 DB 中の特徴点 3 次元位置(観測値)、 \mathbf{I} は 3×3 の単位行列、 t, m はそれぞれ時刻インデックス, 特徴点インデックスを示す。式(23)中, 未知数は $\mathbf{x}_t, \mathbf{R}_t$ であり, このままでは時系列データ数に比例して未知数が増加するため, 時系列の未知数を削減するため以下の拘束条件(式(24), 式(25))を加える。

$$\mathbf{x}_t = \mathbf{x}_0 - \Delta \mathbf{x}_t \quad (24)$$

ただし,

$$\Delta \mathbf{x}_t = \begin{bmatrix} \sum_{t1=1}^t V_{t1} \cos(\theta_0' - \Delta t \sum_{t2=1}^{t1} \omega_{t2}) \\ \sum_{t1=1}^t V_{t1} \sin(\theta_0' - \Delta t \sum_{t2=1}^{t1} \omega_{t2}) \\ \sum_{t1=1}^t V_{t1} \sin(\phi_1') \end{bmatrix}, \quad \theta_0' = \theta_1' + \omega_1 \Delta t$$

$$\begin{bmatrix} \phi_t \\ \theta_t \\ \psi_t \end{bmatrix} = \begin{bmatrix} \phi_0 \\ \theta_0 - \Delta t \sum_{t1=1}^t \omega_{t1} \\ \psi_0 \end{bmatrix} \quad (25)$$

式(24)は時系列の自車位置についての拘束条件であり, ジャイロと車輪速から算出した走行軌跡 $\Delta \mathbf{x}_t$ によって各時刻間の自車位置変化を拘束している。式(24)中, \mathbf{x}_0 は現時刻における自車位置, V_t は車輪速, ω_t はジャイロのヨーレート, ϕ_1', θ_1' はそれぞれ前タイムステップにおける ϕ_0 (ピッチ), θ_0 (ヨー)の推定結果であり, θ_0' は θ_1' とヨーレートから算出した現時刻におけるヨー角の予測値を示す。なお, 式(4)中, 未知数は \mathbf{x}_0 のみであり, その他は全て既知の値である。

また, 式(25)は時系列の自車姿勢についての拘束条件であり, ジャイロのヨーレート ω_t によって各時刻間の自車方位(ヨー)の変化を用いて拘束し, ピッチ, ロールについては急激な変化をしないことを前提として一定値として拘束している。式(25)において, ϕ_0, θ_0, ψ_0

は現時刻における自車の姿勢(ピッチ, ヨー, ロール)を示す。式(25)中, 未知数は ϕ_0, θ_0, ψ_0 であり, その他は全て既知の値である。式(23)に式(24), 式(25)を代入することで, 時系列データ数と同数ある未知数 $\mathbf{x}_t, \phi_t, \theta_t, \psi_t$ をそ4つの未知数 $\mathbf{x}_0, \phi_0, \theta_0, \psi_0$ に置き換えることができる。これにより, 時系列データ利用に伴う未知数増加を抑えつつ, 観測方程式(式(23))の数を増加することができるため, 1時刻あたりにマッチングできる特徴点の数が少ない場合においても精度良い推定を行うことが可能となる。

式(26)に最小二乗法のコスト関数を示す。Levenberg-Marquardt 法による収束演算を用いて式(6)を最小化する $\mathbf{x}_0, \phi_0, \theta_0, \psi_0$ を探索することで最適な解を得ることができる。

$$E = \sum_{t=0}^{M-1} \sum_{m=0}^{N-1} (\mathbf{X}'_{m,t} - \mathbf{KR}_t [\mathbf{I} | -\mathbf{x}_t] \mathbf{X}_m)^2 \quad (26)$$

(M, N はそれぞれ時系列データ数, 推定に用いる特徴点数)

4. 2. 3 特徴点地図 DB 生成方法

特徴点地図 DB は特徴点の 3 次元座標(絶対座標)と画像特徴量を格納した地図 DB であり、特徴点を用いたローカライズを行う際に必要となる。特徴点地図 DB に含まれる特徴点の 3 次元位置はローカライズの精度に影響を与えるためその算出方法は重要となる。そこで本研究では画像情報、LiDAR、POSLV[72]を併用することにより高精度な特徴点 3 次元位置を取得した。

図 81 に特徴点 3 次元位置の算出手順を示す。まず AKAZE[36]を用いて画像中の特徴点の抽出を行う。画像中の特徴点位置からは自転車-特徴点の方向を知ることができるが、特徴点の奥行方向の位置は未知である。そこで、LiDAR を用いて特徴点の奥行方向の位置(自転車-特徴点間の距離)を取得する。これにより、自転車と特徴点の相対的な位置・姿勢を知ることができるが、この時点では地図 DB に必要な特徴点の絶対位置は得られない。そこで、POSLV を用いた絶対位置・姿勢を用いることで、自転車と共に特徴点の絶対位置(3次元)を算出する。この手順を広域の走行データで繰り返すことで、画像特徴(AKAZE)と 3 次元位置情報を持った特徴点地図 DB が生成される。

なお、本研究では POSLV、LiDAR など高価なセンサ構成で特徴点地図 DB 生成を行ったが、画像情報のみを用いた特徴点 3 次元位置算出方法[98][99]もこれまで多く研究されており、近年では飛躍的な性能向上が確認されている。このため、近い将来には画像情報のみで構築した高精度な特徴点地図 DB の実利用が可能となる見込みである。

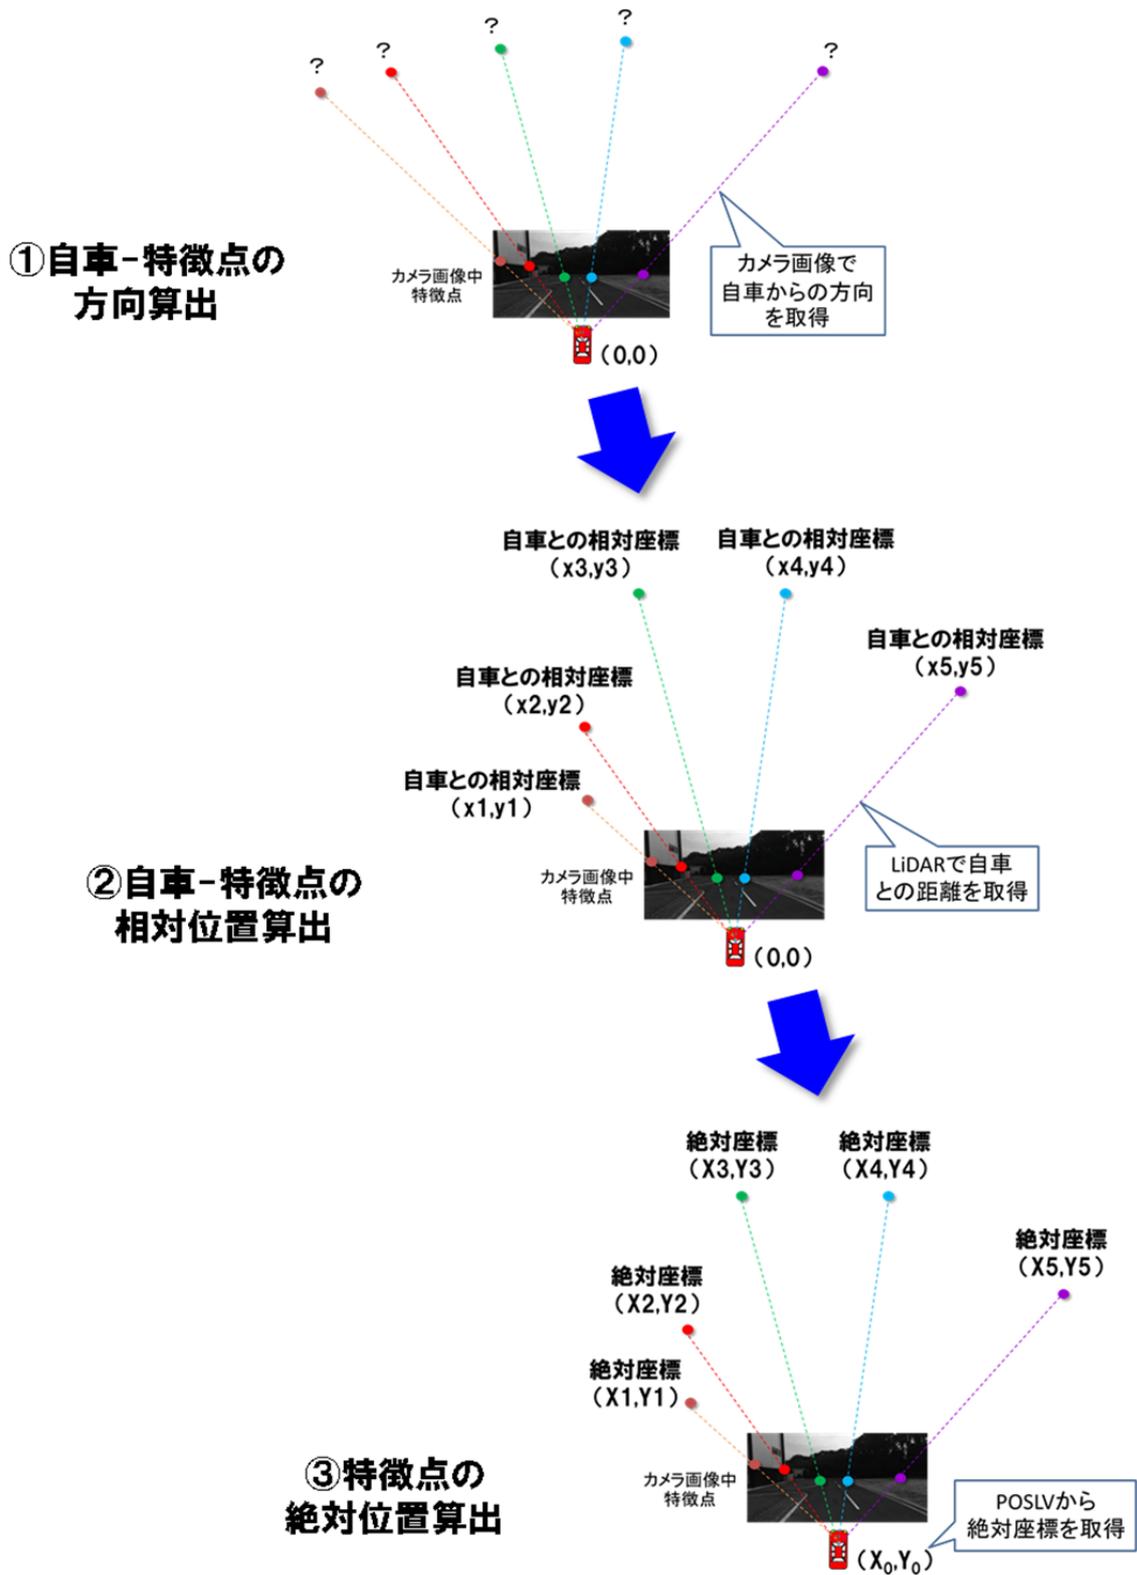


図 81 : 特徴点地図 DB 生成手順

4. 3 実験

4. 3. 1 実験条件

図 82 に評価コースを示す。評価コースは周辺に建物があり、マッチングに利用できる特徴点が比較的多い環境である(走行距離：約 60m, 走行時間：約 10 秒)。実験には画角 50 度相当の前向きカメラ画像, 汎用グレードの INS(市販車両内蔵), および事前に生成した特徴点地図 DB を用いた。誤差評価のためのリファレンスには POSLV を用いた。また, 提案手法では過去 10 時刻分の画像を用いて特徴点地図 DB とのマッチングを行った。なお, 位置誤差は水平面内におけるリファレンス位置からの距離とする。

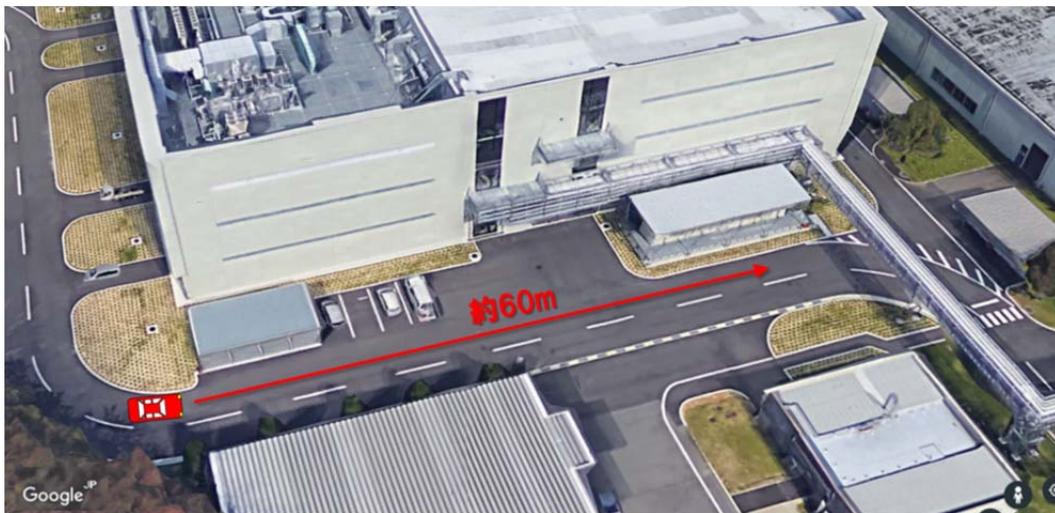


図 82 : 評価コース(長久手市, Google Earth より引用)

本評価コースでは特徴点を多くマッチングできる環境であるが, 多様な道路環境では周辺物の有無や照明条件などの影響でマッチングできる特徴点数が減少する場合がある。マッチングできる特徴点数が減少した場合, 観測誤差の影響が大きくなりローカライズ精度が劣化しやすくなる。本評価ではこのような場合を想定し, マッチングできた特徴点数の減少時における提案手法の効果を定量的に把握するため, マッチングできた特徴点数を意図的に間引いた場合の結果についての評価も行った。元データおよび間引き後におけるマッチングできた特徴点数 N を図 83 に示す。元データでは $N=150\sim 350$ 個程度であるのに対し, 間引き処理ではここからランダムに特徴点の削除を行い, それぞれ $N=100, 50, 20, 10$ 個まで減らした。図 84 に間引き後における特徴点マッチングの例を示す。図中の緑の点は特徴点地図 DB 内の特徴点を車載カメラ画像中に投影したもの, 赤の点はその中でカメラ画像中の特徴点とマッチングできたものを示す。元データではマッチングできた特徴点が比較的多く見られるのに対し, 間引き処理を行うことでそれらが減少していく様子が分かる。

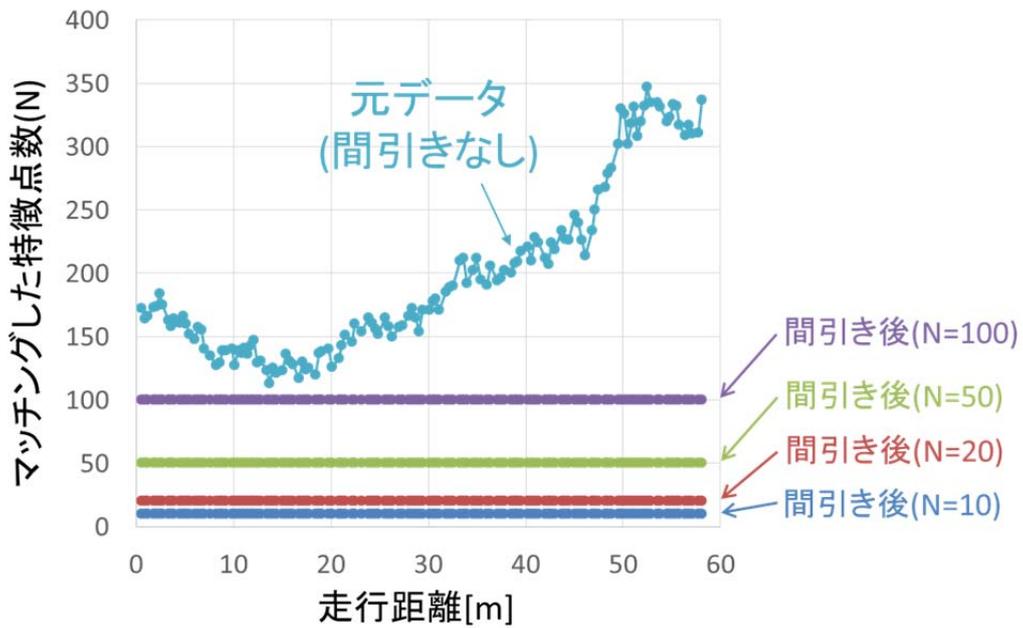


図 83 : 特徴点地図 DB-車載カメラ画像間でマッチングできた特徴点の数

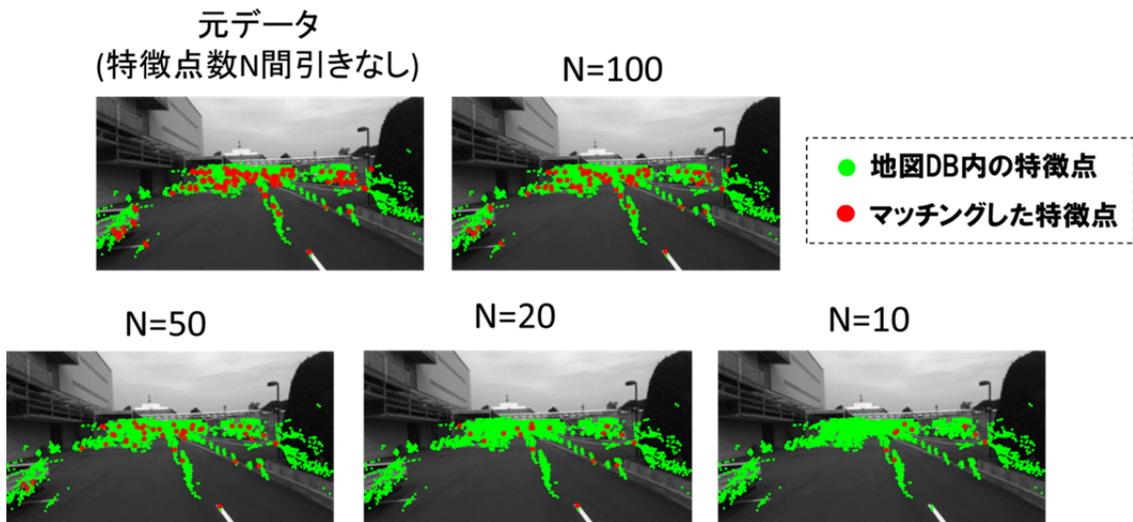


図 84 : マッチングできた特徴点の間引き処理の様子

4. 3. 2 実験結果

ここでは、ローカライズ結果として得られた自車の位置と方位について、従来手法（現時刻のみを用いたローカライズ）と提案手法（複数時刻を用いたローカライズ）の比較を行う。図 85 に従来手法と提案手法の位置誤差を示す。従来手法では N の減少に伴い誤差のばらつきが大きくなっているのに対し、提案手法では従来手法に比べ N の減少に伴う誤差のばらつきが低減されていることが分かる。提案手法では時系列データを利用することでマッチングできる特徴点の数が増加するため、このような誤差低減効果が得られる。また、図 86 に示す方位誤差についても同様の傾向が見られる。

図 87 に位置誤差と場所率の関係を示す、ここでは、評価コース全体のうち、位置誤差 0.1m 以下、0.2m 以下、0.3m 以下を満たす場所の割合を”場所率”として表している。従来手法、提案手法共に特徴点数 N の減少に伴い場所率が低下しているが、提案手法では従来手法よりも場所率が全体的に向上していることが分かる。

図 88 に方位誤差と場所率の関係を示す。ここでも従来手法に比べて提案手法では場所率が全体的に向上する傾向が見られる。ただし、方位は位置に比べて、 N の減少の影響を受けにくい結果となっており、これに伴い提案手法の効果も位置よりも小さくなっている。これは、ローカライズの原理的に、方位は位置よりも観測誤差の影響を受けにくいことに起因する。

図 87、図 88 の結果を表 9、10 に定量的に示す。表 9 の位置推定結果では従来手法に比べて全ての項目において場所率が向上していることが分かる。また、提案手法では位置誤差 0.3m 以下を満たす場所率が $N=20$ 以上では 100%で推移しており、 $N=10$ の場合においても 95%以上の場所率を確保できている。このことから、多様な道路環境においても位置精度 0.3m を実用的な頻度で達成できる見込みが得られたと言える。また、表 10 の方位推定結果では、全体として提案手法の場所率が従来手法を上回る傾向にあると言える。ただし、方位は位置に比べて観測誤差の影響を受けにくく N に伴う場所率の増減が小さいため、提案手法の効果は位置に比べて限定的となっている。

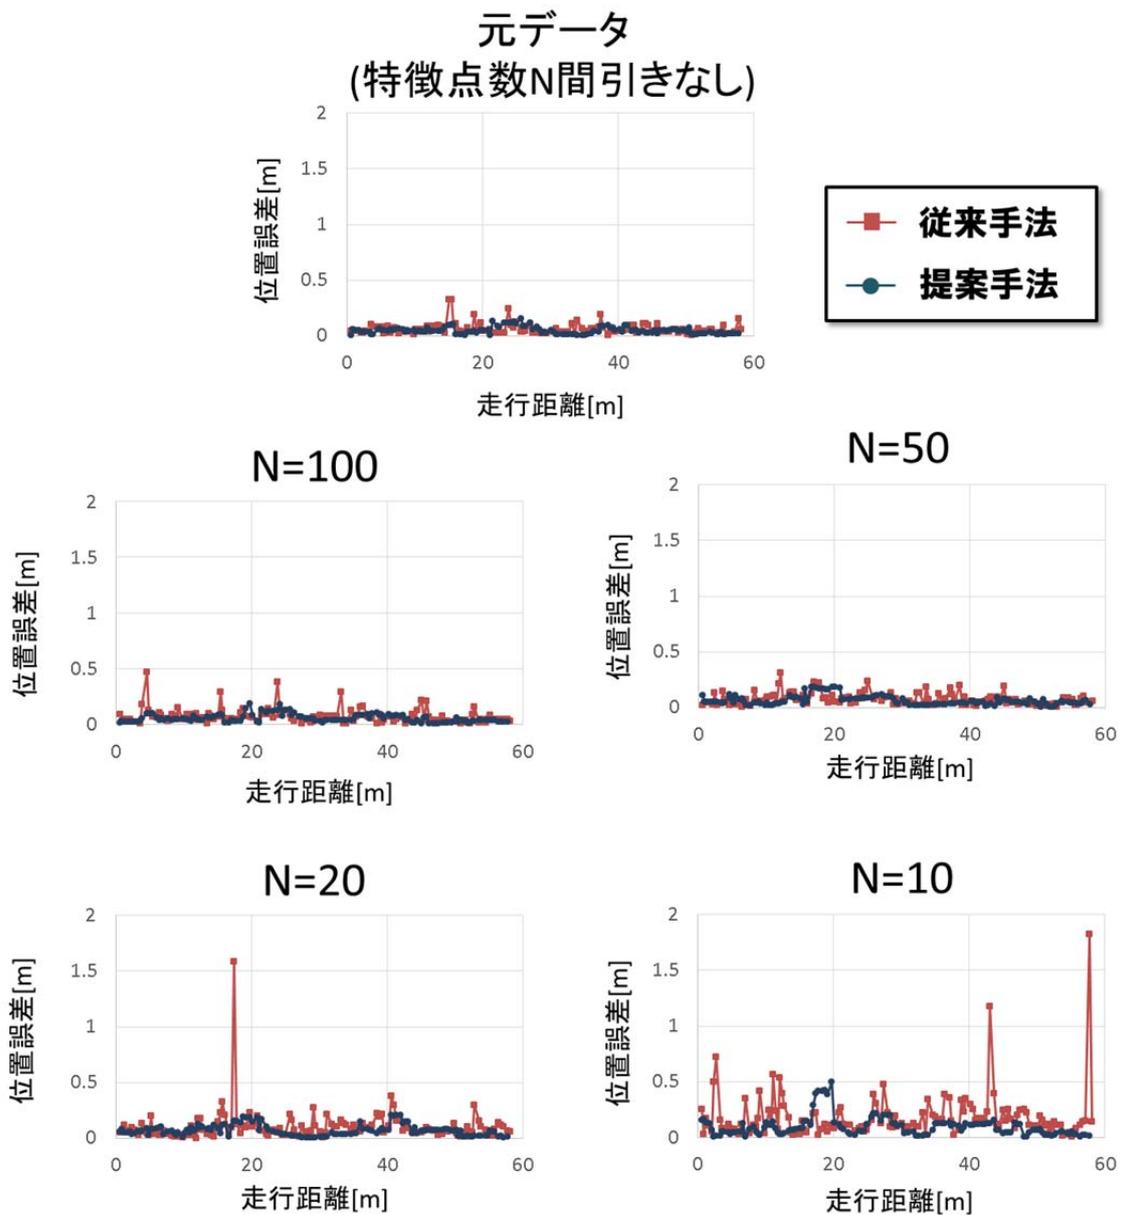
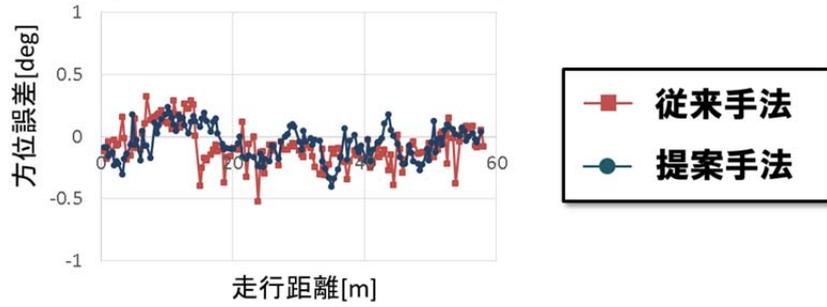
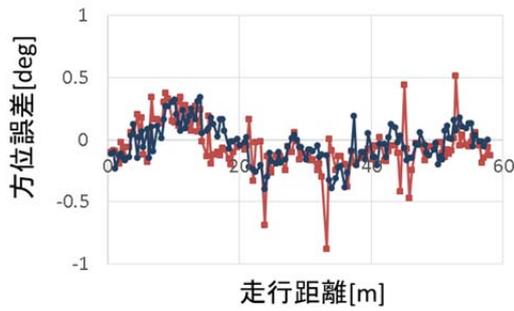


図 85 : 従来手法と提案手法の比較結果 (位置誤差)

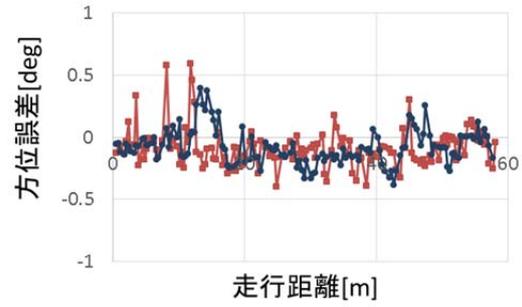
元データ
(特徴点数N間引きなし)



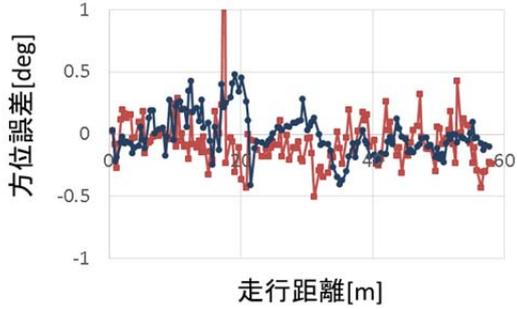
N=100



N=50



N=20



N=10

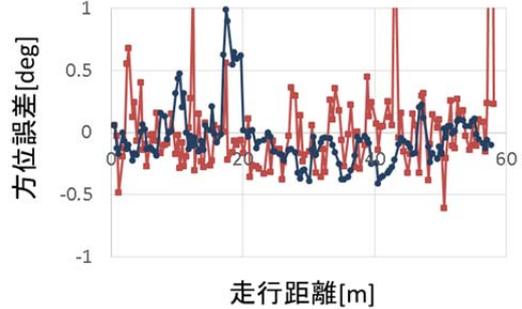


図 86 : 従来手法と提案手法の比較結果 (方位誤差)

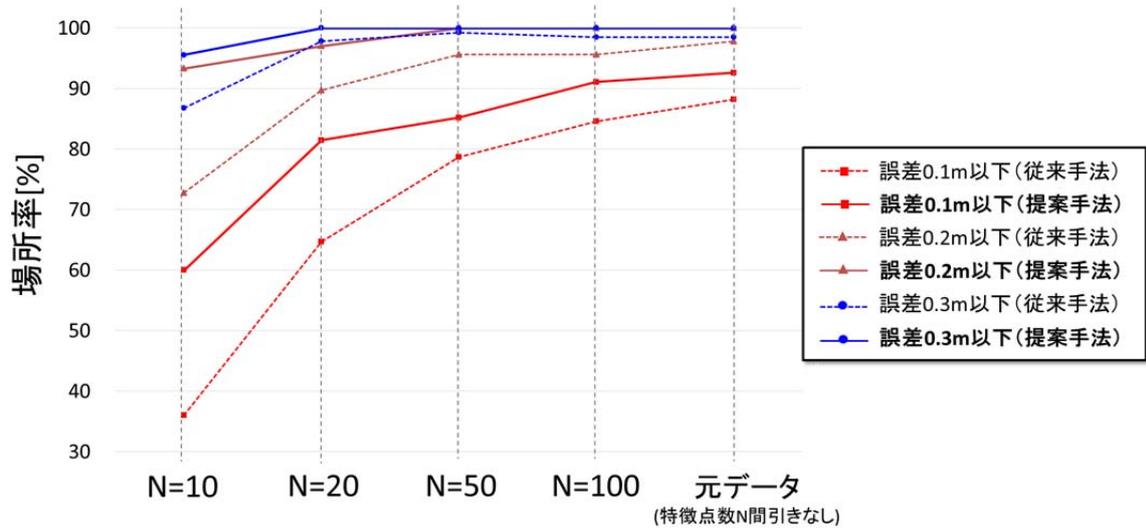


図 87 : 位置誤差と場所率の関係

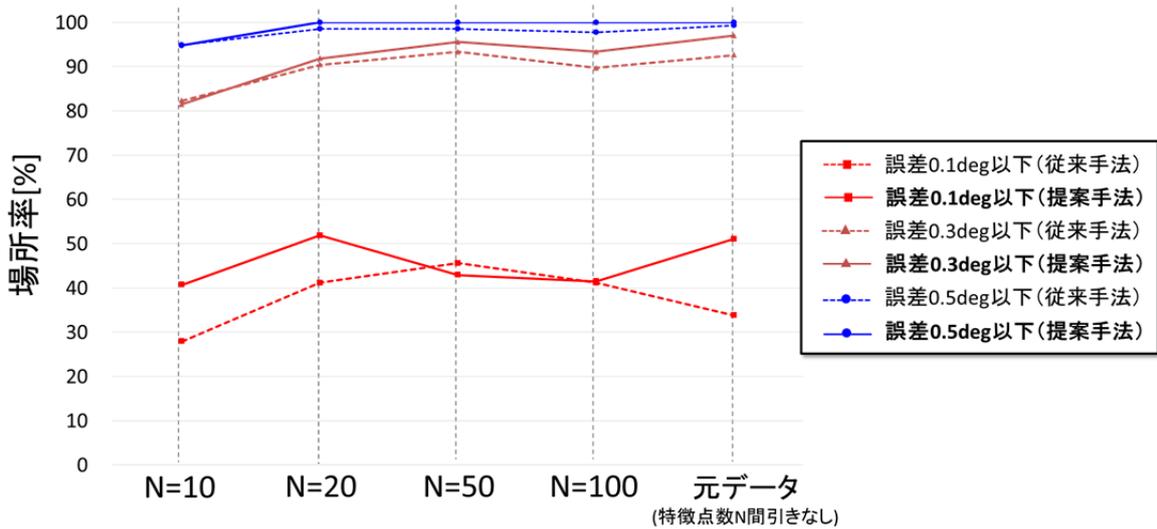


図 88 : 方位誤差と場所率の関係

表 9 : 位置誤差と場所率の関係

		N=10	N=20	N=50	N=100	元データ
位置誤差0.1m 以下の場所率[%]	従来手法	36.0	64.7	78.7	84.6	88.2
	提案手法	60.0	81.5	85.2	91.1	92.6
位置誤差0.2m 以下の場所率[%]	従来手法	72.8	89.7	95.6	95.6	97.8
	提案手法	93.3	97.0	100.0	100.0	100.0
位置誤差0.3m 以下の場所率[%]	従来手法	86.8	97.8	99.3	98.5	98.5
	提案手法	95.6	100.0	100.0	100.0	100.0

表 10 : 方位誤差と場所率の関係

		N=10	N=20	N=50	N=100	元データ
方位誤差0.1deg以 下の場所率[%]	従来手法	27.9	41.2	45.6	41.2	33.8
	提案手法	40.7	51.9	43.0	41.5	51.1
方位誤差0.3deg以 下の場所率[%]	従来手法	82.4	90.4	93.4	89.7	92.6
	提案手法	81.5	91.9	95.6	93.3	97.0
方位誤差0.5deg 以下の場所率[%]	従来手法	94.9	98.5	98.5	97.8	99.3
	提案手法	94.8	100.0	100.0	100.0	100.0

4. 4 本章のまとめ

本章では、絶対測位の性能向上について述べた。本研究では、屋内外において絶対測位が可能でありかつコスト的な課題が少ない絶対測位手法として、カメラ画像と地図 DB 中の特徴点マッチングによる位置推定（ローカライズ）の精度向上に取り組んだ。ローカライズの精度向上のためには、より多くの特徴点をマッチングすることが重要となるが、従来では周辺物が少ないシーンや照明変動が生じるシーンではマッチングできる特徴点数が減少しローカライズ精度が劣化する問題があった。これに対し、本研究では時系列画像の利用および INS を用いた拘束条件付与により、複数時刻の特徴点を同時に利用してマッチングを行うことが可能となった。これによりマッチングできる特徴点数が一時的に減少するシーンにおいても多数の特徴点を用いたマッチングを行うことができるためローカライズ精度の劣化を防ぐことができる。実際の走行データを用いて評価を行った結果、提案手法によるローカライズ精度向上が確認され、その効果はマッチングできる特徴点数が少ない環境であるほど大きくなることが分かった。マッチングできる特徴点数を意図的に 10 個まで減らした場合においても、コース全体の中で位置誤差 0.3m 以下を達成できる場所の割合は 95%以上であり、提案手法の実用性の高さを確認することができた。

5 章 結論

本章では、ここまでに述べた研究の背景および実施内容と結果についてまとめる。また、今後の展望と課題についても述べる。

5. 1 本研究のまとめ

本研究では、自動車の自動運転に利用可能なシームレスかつ高精度な位置推定を汎用センサで実現すること目的とし、カメラ画像、ジャイロ、車輪速、GPS の統合による高精度測位手法を提案した。

1 章では、近年において運転支援システムの進化が加速度的に進み、安全性・利便性・快適性・環境性などの自動車性能の全面的向上に大きく寄与したことを示した。さらなる高性能化・高機能化が進む運転支援システムにおいて車両位置推定は重要な要素技術であり、精度、ロバスト性、コストを高い次元で満足することが求められる。そこで本研究では、運転支援システムの終着点とも言える自動運転システムの実用化を目指し、高精度(誤差 0.3m 内)かつシームレスな測位を汎用センサのみの構成で実現することを目的とすることを示した。

2 章では、世の中の測位技術を絶対測位と推測航法に分けて示した。絶対測位は、衛星測位型と地図利用型に大別でき、衛星測位型では精度・コスト面に問題がないが、屋内や都心部など上空遮蔽環境での使用が課題であり、地図利用型ではマップマッチング、カメラ、LiDAR などのアプローチなどがあるが、それぞれ精度・ロバスト性・コストに課題がある。また、推測航法では、INS、カメラ、LiDAR、GPS を用いたアプローチがあるが、やはり各方法では精度・ロバスト性・コストの全てを満足することは困難である。そこで本研究では、カメラ画像をベースとした汎用センサとの統合により、絶対測位・推測航法の性能改善を目指すことを示した。

3 章では、推測航法の改善手法について述べた。本研究では、屋内外において高精度な推測航法が可能であり、かつ市販車に搭載可能なコスト性を合わせ持つカメラ画像を用いた推測航法 (VO : Visual Odometry) に着目し、精度向上のための課題解決を行った。VO はカメラ画像中の静止物体の動きから相対的に自車の動きを推定する手法であるため、画像中に移動物を含む場合、精度劣化要因となる。また、VO では絶対方位が得られないため方位誤差が蓄積し軌跡誤差が増大する恐れがある。本研究ではこれら二つの課題に対し、改善策の提案を行った。まず、方位の蓄積誤差については、GPS のドップラーシフトと INS の時系列タイトカップリング型統合によって得た絶対方位推定結果を用いて VO の方位誤差を補正する手法を提案した。従来、GPS のドップラーシフトのみを用いた場合には可視衛星数が 4 以上ある場合しか絶対方位が得られなかったのに対し、提案手法では衛星数が 4 未満となる場合でも絶対方位推定が可能となり、これにより都心部のような環境に

においても VO の方位誤差を高頻度に補正できるようになった。都心部で評価を行った結果、従来手法に比べて、誤差が約 3 割低減することを確認した。また、画像中の移動物の問題については、INS とパターン認識技術を用い、移動物上のオプティカルフローを検出・除去する手法を提案した。従来、INS やパターン認識を各々用いた移動物検出手法が提案されていたが、これらはそれぞれ精密さやロバスト性に課題があった。これに対し、提案手法ではまず、INS により大まかに移動物上のオプティカルフローを検出した後、パターン認識により得られた車両検出領域を用いて精緻化処理を行う統合型の移動物検出を行うことで、移動物上のオプティカルフローを正確に検出・除去できるようになった。都心部で評価を行った結果、従来手法に比べて軌跡誤差が 2 割以上低減することを確認した。

4 章では、絶対測位の改善手法について述べた。本研究では、屋内外において比較的精度良くコスト的な課題が少ない絶対測位手法として、カメラ画像と地図 DB 中の特徴点マッチングによる自転車位置推定（以下、ローカライズ）の精度向上に取り組んだ。ローカライズの精度向上のためには、カメラ画像と地図 DB 間でより多くの特徴点をマッチングすることが重要となるが、従来では周辺物が少ないシーンや照明変動が生じるシーンではマッチングできる特徴点数が減少しローカライズによる測位精度が劣化する問題があった。これに対し、本研究では時系列画像の利用および INS の観測値との統合を行うことで、マッチングできる特徴点数が見かけ上増加するため、周辺環境の影響による測位精度の劣化を防ぐことができることを示した。実際の走行データを用いて評価を行った結果、提案手法による測位精度向上が確認され、その効果はマッチングできる特徴点数が少ない環境であるほど大きくなることが分かった。マッチングできる特徴点数を意図的に（10 個まで）減少した場合においても、コース全体の中で位置誤差 0.3m 以下を達成できる場所の割合は 95% 以上であり、提案手法の実用性の高さを確認することができた。

本研究では推測航法と絶対測位の性能を向上し、その効果をそれぞれ示した。一方、自動運転に適用するためには絶対測位と推測航法を統合後の最終的な位置誤差が要求精度（誤差 0.3m 以下）を満たす必要がある。本研究では絶対測位を改善することで多くの場所で誤差 0.3m 以下の測位が可能となることを示したが、多様な走行環境では絶対測位で十分な精度が得られないシーンが避けられないため、そのような区間においては推測航法を用いた補間を行うことで位置精度を維持する必要がある。提案手法による推測航法の誤差は走行距離 100m あたり 0.4m 程度であるため、推測航法によって位置誤差 0.3m 内を維持できる距離は、例えば、補間直前の絶対測位誤差が 0.2m であれば 25m 程度、絶対測位誤差が 0.1m であれば 50m 程度となる。今後は多様な走行環境において、このような推測航法による補間が必要となる区間がどの程度の頻度で生じるか、また、推測航法によってその区間の位置精度をどれだけ維持できるか実証していく。

5. 2 今後の課題と展望

本論文では、推測航法と絶対測位の性能をそれぞれ向上し、汎用センサのみの利用で測位精度 0.3m 実現に近づいたことを示した。以下では、本研究の今後の課題および展望について箇条書きで述べる。

・課題

【推測航法と絶対測位の統合】

本研究では、実験データ取得の都合上、推測航法および絶対測位の改善手法の効果を個別に示したが、最終的には推測航法と絶対測位の統合の結果得られる位置精度を評価する必要がある。両者の統合には EKF(Extended Kalman Filter)などを用いた方法が考えられるが、その際には推測航法と絶対測位それぞれの誤差を正確に見積もる手法の確立などが課題となる。

【計算時間の削減】

本研究では、測位性能向上の原理確認を主眼としリアルタイム動作の実証に重きを置かなかったため、現状の実装では推測航法(VO)において 1frame あたり 1～5 秒程度、絶対測位(ローカライズ)では 1frame あたり 1～2 秒程度の時間を要する。しかしながら、原理的な計算コストが特別大きい訳ではないため、実装方法の改善によりリアルタイム動作が可能であると考えられる。実用化のためにはリアルタイム評価も重要な条件となるため、計算時間削減のための実装は今後の課題となる。

【評価データの多様化/多数化】

本研究では推測航法、絶対測位共に都心部を主な評価対象としたが、実際に自動運転システムへの適用に向けた実用評価を行う場合には、多様な評価が必要となる。雨天時、夜間、トンネルの中、曲がりくねった山道、など様々な環境での評価を多数行い、課題抽出と改善の繰り返しによって、測位システムの信頼性向上を行うことは自動運転の実用化に至るプロセスにおいて不可欠である。

【安価な地図 DB 生成手法の評価】

本研究では地図 DB の生成方法に主眼を置かないため、LiDAR や POSLV などを用いてローカライズ用地図 DB 生成を行ったが、システムの実用性向上のためには地図 DB の生成コストも考慮に入れたシステム設計が必要となる。近い将来的にカメラ画像のみを用いて高精度かつ安価な地図生成が可能となる見通しであるため、今後、これらの地図 DB を導入しローカライズ性能の実証を行っていく必要がある。

・展望

【ローカライズのための新特徴量の提案】

本研究では、最も汎用的な手法として特徴点を利用したローカライズ手法をベースとしたが、特徴点以外の特徴量(オブジェクト、線など)との併用や、新たな特徴量の提案・利用によりローカライズ性能をさらに向上できる可能性がある。また、地図 DB を構成する特徴量の選び方によって、ローカライズの計算コストや、地図 DB のデータ容量などにも影響を及ぼすため、特徴量の精査を行っていくことは重要である。

【クラウドを介した複数車両の協調】

近年、車両の運転支援システムは車両単独型のシステムから、クラウドを介した複数車両協調型のシステムへ移行しつつある。市販車両全体のセンサ観測値をクラウドサーバに集約することで膨大なデータの集約が可能となり、これらデータに基づき空間情報や自車の状態を推定することで車両単独の観測値を利用した場合よりも高精度な推定が可能となる。例えば、ある地点で観測した複数車両のカメラ画像に基づき画像中に見える特徴点位置を推定することで、LiDAR を利用した場合と同等の特徴点地図 DB の生成が可能となることが期待される。また、近傍にいる複数の車両のセンサ観測データをリアルタイムに共有し、その整合性を評価することでカメラ画像や GPS などの観測誤差が大きいデータを精度良く除去できるようになり、測位精度向上に寄与することが期待される。

【インフラシステムとの協調】

今後、自動運転に必要な測位精度を確保する手段として、路側のインフラシステムとの協調による測位手法も考えられる。例えば、交差点などに設置された定点カメラにて交差点周辺に存在する全ての車両位置を把握し、その情報を周辺車両全体で共有することにより、交差点内における自車(および他車)の位置を正確に把握することができるようになる。今後、自動運 IT 化の波に伴いインフラ設備も整っていくと予想されるが、当面の間は都市部の交差点など有用性が高いスポットに限られると考えられるため、インフラ協調はオプションとしての利用が想定される。

謝辞

本論文は筆者が豊田中央研究所に勤務すると同時に、東京海洋大学の博士課程に在籍する中で執筆したものであり、周囲の多くの方々のご協力を経て完成に至りました。ここに皆様への感謝の意を記したいと思います。

まず、社会人である筆者を研究室に受け入れて下さり、本研究のご指導および多大なるご協力をいただきました久保先生に感謝を申し上げます。衛星測位研究の第一人者である久保先生とは共同研究を通してお付き合いさせていただいたのをきっかけに、2015年より大学の博士課程の学生として受け入れていただけることになりました。入学後しばらくの間は思うように研究が進捗せず、ゼミに参加するのも少し気が重いこともありましたが、いつも進捗報告をポジティブに受け止め励ましていただいたことで、前向きな気持ちで研究に取り組むことができました。また、学会を立ち上げ、他の研究者を巻き込み、各方面で精力的に情報発信を行う様子は、一流研究者のあるべき姿として大変勉強になりました。

本論文の副査を務めていただきました海洋大の庄司先生、電子航法研の坂井先生に心より感謝を申し上げます。お二方には多大な労力とお時間を引き換えに、本論文の査読および公聴会の審査を務めていただき、本研究の質を高める上で重要なご意見を多数いただくことができました。いただいたご意見を活かし、今後より良い方向に研究を進めていきたいと思えます。

安田先生はじめ研究室メンバーの皆様には感謝を申し上げます。研究室メンバーの皆様にはゼミにて貴重なご意見をいただくと共に、専門分野の重なりが薄い箇所でも関心を持って多くの質問をいただいたことで、より分かりやすい形で研究内容を伝えたいと思う気持ちが強くなったように思います。また、現役学生の皆様と関わることで原点に帰り新鮮な気持ちで研究に取り組むことができたように思います。

また、多大な支えをいただきました豊田中央研究所の皆様にも感謝を申し上げます。小島部長には、入社時より職場先輩としてご指導をいただき、公私共に大変お世話になりました。博士課程進学の際も気持ちを後押ししていただき、多くのご助言をいただきました。こうして博士論文を完成に至ることができたのも、これまでの積み重ねのご指導と支えがあったからだと思っております。

元測位チームメンバーの寺本さん、鈴木(ポ)さん、小島さん、岩瀬さん、目黒さん(現、名城大)とはチームとして仕事をさせていただく中で多くのことを学ばせていただきました。チーム発足時、知識経験共に未熟であった筆者に対しご指導と支えをいただくことで成長し、最終的に測位ロジックの製品化という大きな成果創出を成し遂げることができました。この成功体験はメンバー全員の力が合わさって成し得たものであり、筆者が研究者として歩みを進める中で自信を得る転機となりました。

牧戸室長とは、測位ロジックの製品化と改良などに関わる所から一緒に仕事をさせていただき、昨年からは研究室のマネージャーとして大変お世話になりました。専門知識に関わる部分ではもちろんのこと、研究者としての幅広い経験談や心構えなど、研究生生活を行う上で重要となる知見を多く授けていただきました。

また、博士在学中にマネージャーとしてご指導いただきました、小川さん、城殿さん、町田さん、後藤さんには、学位取得を温かく見守っていただき、多くのご協力をいただきました。そして、同じ研究室メンバーの皆様、近くで声をかけていただいた皆様など、多くの方々の支えが力となりました。改めて、皆様に心より感謝を申し上げます。

また、学位取得に際し、家族の皆様の協力も大きな支えとなりました。度々の東京出張や学費捻出にも文句ひとつ言わず、いつも暖かな居場所を作ってくれた妻、そしていつも癒しを与えてくれた息子に、心より感謝します。そして、いつも応援の言葉をいただいた武山家、早川家の家族の皆様にも多くの力を与えていただきました。この場を借りて、感謝を申し上げます。本当にどうもありがとうございました。

ここに皆様への感謝を申し上げた一方で、博士号取得はゴールではなく、研究者としてのスタート地点だという思いもあります。今後、博士課程で得た助走を活かし、研究者としてのキャリアを自分らしく後悔なく描いていければと思います。

参考文献

- [1] M.A.S.Kamal, et. al, “Ecological Vehicle Control on Roads with Up-Down Slopes”, IEEE Transactions on Intelligent Transportation Systems, Vol.12, Issue.3, pp.783-794, 2011
- [2] “トヨタ自動車 HP プリクラッシュセーフティ”,
<http://www.toyota.co.jp/jpn/tech/safety/technology/technology_file/pre_crash/pb.html>
(accessed 2017/12/04)
- [3] “トヨタ自動車 HP レーンキーピングアシスト”,
<http://www.toyota.co.jp/jpn/tech/safety/technology/technology_file/active/lka.html>
(accessed 2017/12/04)
- [4] “トヨタ自動車 HP 統合安全コンセプト”,
<<http://www.toyota.co.jp/jpn/tech/safety/concept/>> (accessed 2017/12/04)
- [5] “トヨタ自動車 HP 自動運転技術”,
<http://www.toyota.co.jp/jpn/tech/automated_driving/> (accessed 2017/12/04)
- [6] “トヨタ自動車 HP CORROLA 歴代モデル”,
<<http://www.toyota.co.jp/jpn/auto/heritage/corolla/collection/>> (accessed 2017/12/04)
- [7] “トヨタ自動車 HP レーダクルーズコントロール”,
<http://www.toyota.co.jp/jpn/tech/safety/technology/technology_file/active/radar.html>
(accessed 2017/12/04)
- [8] R.L.Easton, et. al, “The Navigation Technology Program”, The Institute of Navigation Global Positioning System, Vol.I, pp.15-20, 1980
- [9] C.A.Bartholomew, et. al, “Satellite Frequency Standards”, The Institute of Navigation Global Positioning System, Vol.I, pp.21-28, 1980
- [10] 坂井丈泰, “GPS 技術入門”, 東京電機大学出版局, 2003,
- [11] G.J.Morgan-Owen, et. al, “Differential GPS positioning”, Electronics & Communication Engineering Journal, Vol.7, Issue.1, pp.11-21, 1995
- [12] 坂井丈泰, 他, “GPS における選択利用性(SA)の解除”, 日本航海学会誌, No.145, pp.42-48, 2000
- [13] L. Dai, et al., “A Study on GPS/GLONASS Multiple Reference Station Techniques for Precise Real-Time Carrier Phase-Based Positioning”, In Proc. the International Technical Meeting of ION GPS, pp.392-403, 2001
- [14] Zong Wu, et al., “Improving Accuracy of the Vehicle Attitude Estimation for Low-Cost INS/GPS Integration Aided by the GPS-Measured Course Angle”, IEEE Transactions on Intelligent Transportation System, Vol.14, No.2, 2014
- [15] S.Kim, et al., “Node Based Map Matching Algorithm for Car Navigation System”, In Proc. 29th International Symposium on Automotive Technology & Automation, pp.121-126, 1996

- [16] S.Kim, et al., “Adaptive fuzzy-network-based C-measure map-matching algorithm for car navigation system”, IEEE Transactions on Industrial Electronics, Vol.48, Issue.2, pp.432-441, 2001
- [17] R.W.Wolcott, et al., “Fast LIDAR localization using multiresolution Gaussian mixture maps”, In Proc. International Conference on Robotics and Automation (ICRA), 2015
- [18] I.Baldwin, et al., “Road vehicle localization with 2D push-broom LIDAR and 3D priors”, In Proc. International Conference on Robotics and Automation (ICRA), 2012
- [19] N.Mattern, et al., “Image landmark based positioning in road safety applications using high accurate maps”, In Proc. Conference on IEEE/ION PLANS, 2008.
- [20] D.Fontanelli, et al., “A Fast RANSAC-Based Registration Algorithm for Accurate Localization in Unknown Environments using LIDAR Measurements”, In Proc. International Conference on IEEE CASE, Scottsdale, pp.597-602, 2007
- [21] 小島祥子, 他, “車載外界監視センサを用いた高精度自車運動推定および自車位置推定”, 電子情報通信学会 技術研究報告, ITS-2007-11, 2007
- [22] H. Alismail, et al., “Continuous trajectory estimation for 3D SLAM from actuated lidar”, In Proc. International Conference on Robotics and Automation (ICRA), pp. 6096-6101, 2014.
- [23] B.M.Kitt, et al., “Monocular Visual Odometry using Planar Road Model to Solve Scale Ambiguity”, In Proc. European Conference on Mobile Robots, 2011
- [24] V.Grass, et al., “Precise velocity estimation using a stand-alone GPS receiver”, Journal of the Institute of Navigation, Vol.51, Issue.4, pp.283-292,
- [25] L.Serrano, et al., “A GPS velocity sensor: How accurate can it be? -A first look”, In Proc. ION NTM, pp875-885, 2004
- [26] T.Dharmasiri, “MO-SLAM: Multi Object SLAM with Run-Time Object Discovery through Duplicates”, In Proc. International Conference on Intelligent Robotics System (IROS), 2016
- [27] B.Mu, et al., “SLAM with Objects using a Nonparametric Pose Graph”, In Proc. International Conference on Intelligent Robotics System (IROS), 2016
- [28] D. Nister, et al., “Visual Odometry for Ground Vehicle Applications” Journal of Field Robotics, Vol.23, pp.3-20, 2006.
- [29] J.P. Tardif, et al., “Monocular Visual Odometry in Urban Environments Using an Omnidirectional Camera”, In Proc. International Conference on Intelligent Robotics System (IROS), 2008
- [30] G.Panahandeh, “Exploiting Ground Plane Constraints for Visual-aided Inertial Navigation”, In Proc. Conference on IEEE/ION PLANS, 2012
- [31] R. Newcombe, et al., “DTAM:Dense tracking and mapping in real-time”, In Proc. International Conference on Computer Vision (ICCV), 2011.
- [32] A.Wendel, et al., “Dense reconstruction on-the-fly”, In Proc. European Conference on Computer Vision (ECCV), 2012
- [33] H.Bay, et al., “SURF: Speeded Up Robust Features”, In Proc. European Conference on

Computer Vision (ECCV), 2006

- [34] E.Rublee, “ORG: An efficient alternative to SIFTor SURF”, In Proc. International Conference on Computer Vision (ICCV), 2011
- [35] D.G.Lowe, “Distinctive image features from scale-invariant keypoints”, International Journal of Computer Vision, Vol.60, Issue.2, pp.91-110, 2004
- [36] P.F.Alcantarilla, “Fast Explicit Diffusion for Accelerated Features in Nonlinear Scale Spaces”, In Proc. British Machine Vision Conference (BMVC), 2013
- [37] A.J.Davidson, et al., “MonoSLAM: Real-Time Single Camera SLAM”, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.29, Issue.6, 2007
- [38] B.Triggs, et al., “Bundle adjustment - a modern synthesis”, in Vision Algorithm: Theory and Practice. Springer-Verlag LNCS, 2000.
- [39] D.Marquardt, et al., “An algorithm for least-squares estimation of nonlinear parameters”, SIAM Journal on Applied Mathematics, Vol.2, pp.431-441, 1963
- [40] V.Renaudin, et al., “New Method for Magnetometer Based Orientation Estimation”, In Proc. Conference on IEEE/ION PLANS, 2010
- [41] L. Heng, et al., “Autonomous Visual Mapping and Exploration with a Micro Aerial Vehicle”, Journal of Field Robotics, Vol.31, pp.654-675., 2014.
- [42] L.Yi, et al., “A Magnetic-Aided PDR Localization Method Based on the Hidden Markov Model”, In Proc. 30th International Technical Meeting of The Satellite Division of the Institute of Navigation (ION GNSS+), 2017
- [43] J.Meguro, et al., “Road Ortho-Image Generation Based on Accurate Vehicle Trajectory Estimation by GPS Doppler”, In Proc. International Conference on IEEE Intelligent Vehicle Symposium, 2012
- [44] 目黒淳一, 他, “GPS ドップラと慣性センサの統合による車両軌跡推定手法の提案”, 情報処理学会論文誌, Vol.53(1), pp.212-222, 2012
- [45] J.Rehder, et al., “Global pose estimation with limited GPS and long range visual odometry”, In Proc. International Conference on Robotics and Automation (ICRA), 2012
- [46] I. P. Alonso, et al., “Accurate Global Localization Using Visual Odometry and Digital Maps on Urban Environments,” IEEE Transactions on Intelligent Transportation Systems, Vol.13, No.4, pp.1535-1545, 2012
- [47] C.Fouque, et al., “Enhancement of global vehicle localization using navigable road maps and dead-reckoning”. In Proc. Conference on IEEE/ION PLANS, 2008.
- [48] G.Floros, et al., “Openstreetslam: Global vehicle localization using openstreetmaps”, In Proc. International Conference on Robotics and Automation (ICRA), 2013
- [49] M.Fischler, et al., “Random sample consensus: a paradigm for model fitting with application to image analysis and automated cartography”, Communication of the ACM, Vol.24, Issue.6, pp381-395, 1981
- [50] K.Yamaguchi, et al., “Vehicle ego-motion estimation and moving object detection using a

- monocular camera”, In Proc. the 18th International Conference on Pattern Recognition (ICPR), 2006.
- [51] G.Lefaix, et al., “Motion-based Obstacle Detection and Tracking for Car Driving Assistance”, In Proc. the 16th International Conference on Pattern Recognition (ICPR), 2002
- [52] J.Beich, et al., “Vision-Aided Navigation Using a Tightly-Coupled INS and Predictive Rendering Techniques”, International Technical Meeting of the Institute of Navigation, 2011
- [53] C.C.Chu, et al., “Performance Comparison of Tight and Loose INS-Camera Integration”, International Technical Meeting of the Institute of Navigation, 2011
- [54] D.M.Prahl, et al., “Coupling Vanishing Point Tracking with Inertial Navigation to Produce Drift-Free Attitude Estimates in a Structured Environment”, International Technical Meeting of the Institute of Navigation, 2011
- [55] A.Talukder, et al., “Real-time detection of moving objects from moving vehicles using dense stereo and optical flow”, In Proc. International Conference on Intelligent Robotics System (IROS), 2004
- [56] C.F.Olson, et al., “Robust stereo ego-motion for long distance navigation”, In Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2000
- [57] J.Moras, et al., “Moving objects detection by conflict analysis in evidential grids”, In Proc. IEEE Intelligent Vehicles Symposium (IV), 2011.
- [58] C.C.Wang, et al., “Simultaneous Localization And Mapping with Detection And Tracking of Moving Objects”, In Proc. International Conference on Robotics and Automation (ICRA), 2002
- [59] T.Miyasaka, et al., “Ego-motion estimation and moving object tracking using multi-layer lidar”, In Proc. IEEE Intelligent Vehicles Symposium (IV), 2009.
- [60] S.Gupte, et al., “Detection and Classification of Vehicle”, IEEE Transactions on Intelligent Transportation System, Vol.3, No.1, pp.37-47, 2003
- [61] B.Huval, et al, “An empirical evaluation of deep learning on highway driving”, Cornell University Library arXiv, 2015.
- [62] C.Cortes, et al., “Support-Vector Networks”, Machine Learning, Vol.20(3), pp.273-297, 1995
- [63] C.Szegedy, et al., “Deep Neural Networks for Object Detection”, In Proc. Advances in Neural Information Processing Systems (NIPS), 2013
- [64] A.Krizhevsky, “ImageNet Classification with Deep Convolutional Neural Networks”, In Proc. Advances in Neural Information Processing Systems (NIPS), 2012
- [65] 武山洪二郎, 他, ”移動点除去による単眼カメラを用いた運動推定の高精度化”, 電子情報通信学会全国大会予稿集, 2009
- [66] 武山洪二郎, 他, ”単眼カメラ画像を用いた運動推定の信頼度判定手法の開発”, 精密工学会 動的画像処理実利用化ワークショップ, 2011

- [67] 武山洪二郎, 他, ”GPSドップラーを用いた推測航法精度の向上”, 自動車技術会講演予稿集(秋季), 2011
- [68] K.Takeyama, et al., “Trajectory Estimation Improvement Based on Time-series Constraint of GPS Doppler and INS in Urban Areas”, In Proc. Conference on IEEE/ION PLANS, 2012
- [69] 武山洪二郎, 他, ”GPSドップラー/INSタイトカップリングによる走行軌跡推定の提案 -統合測位システム PRECISE の軌跡推定性能の向上”, 自動車技術会論文集, vol.44, No.1, pp199-205, 2013
- [70] K.Takeyama, “A Novel Method of Vehicle Trajectory Estimation with Portable Navigation Device for Dense Urban Environments”, IEICE Transactions on Fundamentals, Vol.E99-A, No.1, 2016
- [71] 武山洪二郎, 他, “単眼カメラと汎用センサ統合による都心部の高精度推測航法”, 情報処理学会論文, 2018
- [72] “Applanix Corporation HP POSLV Specifications”,
<https://www.applanix.com/pdf/specs/POSLV_Specifications_dec_2015.pdf>
(accessed 2017/12/05)
- [73] E.Rosten, et al., “Faster and better: a machine learning approach to corner detection”, IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI), Vol.32, pp.105-119, 2010
- [74] Y. Lee, et al., “Analysis of Range and Position Comparison Methods as a Means to Provide GPS Integrity in the User Receiver”, In Proc. the Institute of Navigation 42nd Annual Meeting, 1986
- [75] K.Takeyama, et al., “Improvement of Dead-reckoning in Urban Areas through Integration of Low Cost Multi-sensors”, IEEE transactions on Intelligent Vehicles, vol.2, issue.4, pp.278-287, 2017
- [76] K.Takeyama, et al., “Visual Odometry with Dynamic Object Detection by Complementary Integration of Optical Flows and Pattern Recognition”, In Proc. 30th International Technical Meeting of The Satellite Division of the Institute of Navigation (ION GNSS+), 2017
- [77] J. Levinson, et al., “Map-Based Precise Vehicle Localization in Urban Environments”, Robotics: Science and Systems, The MIT Press, 2007
- [78] N. Mattern, et al., “Image landmark based positioning in road safety applications using high accurate maps,” In Proc. Conference on IEEE/ION PLANS, 2008
- [79] S.Nedevschi, “Accurate Ego-Vehicle Global Localization at Intersections Through Alignment of Visual Data With Digital Map”, IEEE transactions on Intelligent Transportation Systems, Vol.14, No.2, pp.673-687, 2013
- [80] M. Schreiber, et al., “LaneLoc: Lane marking based localization using highly accurate maps”, In Proc. IEEE Intelligent Vehicles Symposium (IV), 2013.
- [81] A.Irschara, et al., “From structure-from-motion point clouds to fast location recognition”, In Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2009.

- [82] Y.Li, et al., “Worldwide pose estimation using 3D point clouds”, In Proc. European Conference on Computer Vision (ECCV), 2012.
- [83] T.Sattler, et al., “Improving imagebased localization by active correspondence search”, In Proc. European Conference on Computer Vision (ECCV), 2012
- [84] L.Sv`arm, et al., “Accurate localization and pose estimation for large 3D models”. In Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014
- [85] 武富貴史, 他, ”拡張現実感のための優先度情報を付加した自然特徴点ランドマークデータベースを用いた実時間カメラ位置・姿勢推定”, 電子通信学会論文誌 D, Vol.92(8), pp.1440-1451, 2009
- [86] A.Georgiev, et al., “Localization Methods for a Mobile Robot in Urban Environments”, IEEE Transactions on Robotics, Vol.20, No.5, pp.851-864, 2004
- [87] B.Micusik, et al., “Descriptor Free Visual Indoor Localization with Line Segments”, In Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015
- [88] K.Hirose, et al., “Fast Line Description for Line-based SLAM”, In Proc. British Machine Vision Conference (BMVC), 2012
- [89] S.Choudhary, et al., “SLAM with object discovery, modeling and mapping”, In Proc. International Conference on Intelligent Robotics System (IROS), 2014
- [90] F.Lamberti, et al., “Mixed marker-based/marker-less visual odometry system for mobile robots”, International Journal of Advanced Robotic Systems, Vol.10, Issue.5, 2013
- [91] T.Oskiper, “Multi-Sensor Navigation Algorithm Using Monocular Camera, IMU and GPS for Large Scale Augmented Reality”, In Proc. IEEE International Symposium on Mixed and Augmented Reality (ISMAR), 2012
- [92] J.Liao, et al., “The Development of an Artificial Neural Networks Aided Image Localization Scheme for Indoor Navigation Applications with Floor Plans Built by Multi-platform Mobile Mapping Systems”, In Proc. 30th International Technical Meeting of The Satellite Division of the Institute of Navigation (ION GNSS+), 2017
- [93] S.Zhu, et al., “Video/GIS registration system based on skyline matching method”, In Proc. the 20th IEEE International Conference on Image Processing (ICIP), 2013
- [94] H.Weil, et al., “A Study of Virtual Visual Servoing Sensitivity in the Context of Image/GIS Registration for Urban Environments”, In Proc. the 15 th International Conference on Machine Vision Applications (MVA), 2017
- [95] 王金伐, 他, ”時系列高さ画像の提案とそれを用いた車載カメラ画像と建物モデル間の対応付け”, 電子通信学会論文誌 D, Vol.92(8), pp.1197-1207, 2009
- [96] R.Arroyo, “Fusion and Binarization of CNN Features for Robust Topological Localization across Seasons”, In Proc. International Conference on Intelligent Robotics System (IROS), 2016
- [97] N.Ho, et al., “Localization on Freeways using the Horizon Line Signature”, In Proc. International Conference on Robotics and Automation (ICRA), 2014

- [98] B.Liu, et al., “An Efficient and Accurate Method for 3D-Point Reconstruction from Multiple Views”, International Journal of Computer Vision, Vol.65, Issue.3, pp.175-188, 2005
- [99] S.Agarwal, et al., “Building rome in a day”, In Proc. International Conference on Computer Vision (ICCV), 2009
- [100] Y.Kojima, et al., “High accuracy Local Map generation method based on precise trajectory from GPS Doppler”, International Journal of Automotive Engineering, Vol.3, No.2, pp.63-68, 2012