

複数のセンサーによる 推測航法に関する研究

東京海洋大学大学院
海運ロジスティクス専攻
林鵬(1255025)

発表概要

2

1. 背景と目的

2. GNSS/センサーを用いる統合方法

- 手法1:線形カルマンフィルタによる統合手法
- 実験1及び結果

- 手法2:拡張カルマンフィルタによる統合手法
- 実験2及び結果

3. まとめ

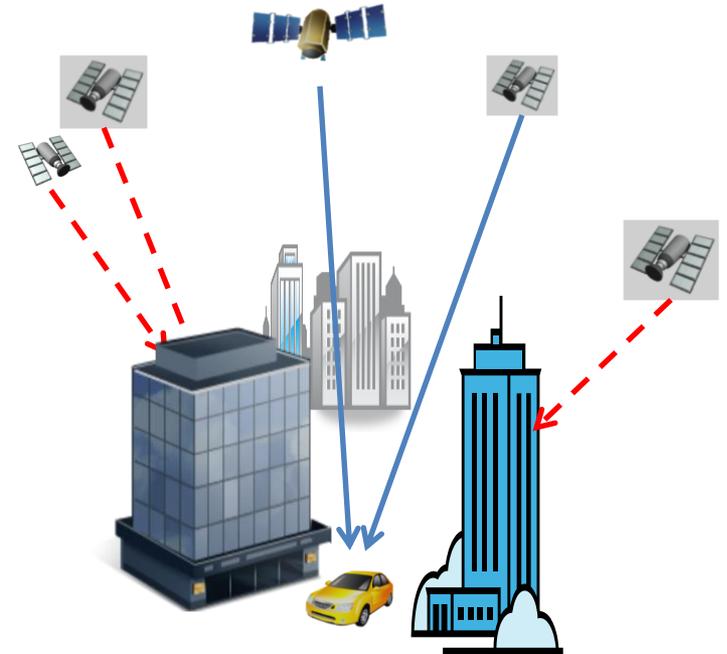
背景

3

都市部では電波が遮断され、測位解が得られないことがある。

IMU(Inertial Measurement Unit慣性計測装置)や車軸パルスは周囲の環境に依存せず、短時間内においては連続的に高精度の計測ができる。

IMUはMEMSジャイロとFOG (Fiber Optic Gyro)の2種類がある。特に、FOGの精度は高い。



	観測値	環境	精度	価格
GNSS	位置	依存する	高い	安価
MEMSジャイロ	方位角速度	依存しない	センサ依存	安価
FOG	方位角速度	依存しない	センサ依存	高価
車軸パルス	速度	依存しない	高い	安価

研究目的

4

★目的

GNSSと複数のセンサーを統合することにより、都市部でも連続的に、高精度の測位を実現すること。

★センサーの組み合わせ

手法1:MEMSジャイロ + 加速度センサー + 車軸パルス + GNSS

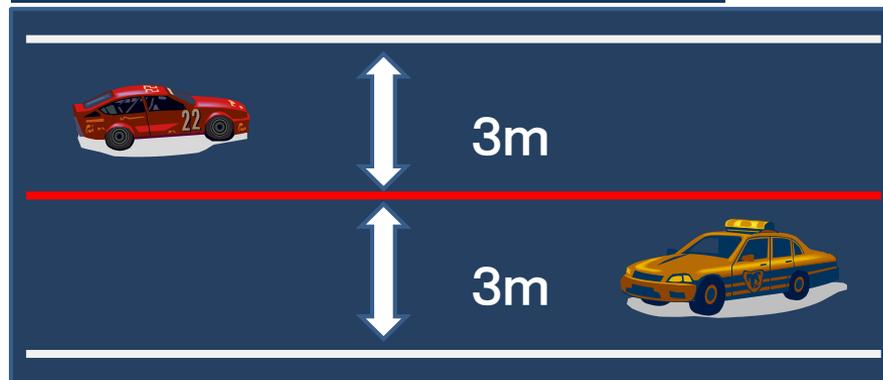
手法2:FOG + 車軸パルス + GNSS

★TARGET:

車が道路の真中で走っている時、
車線判別することができること。

水平精度:1.5m以内

通常の二車線道路:1車線3m



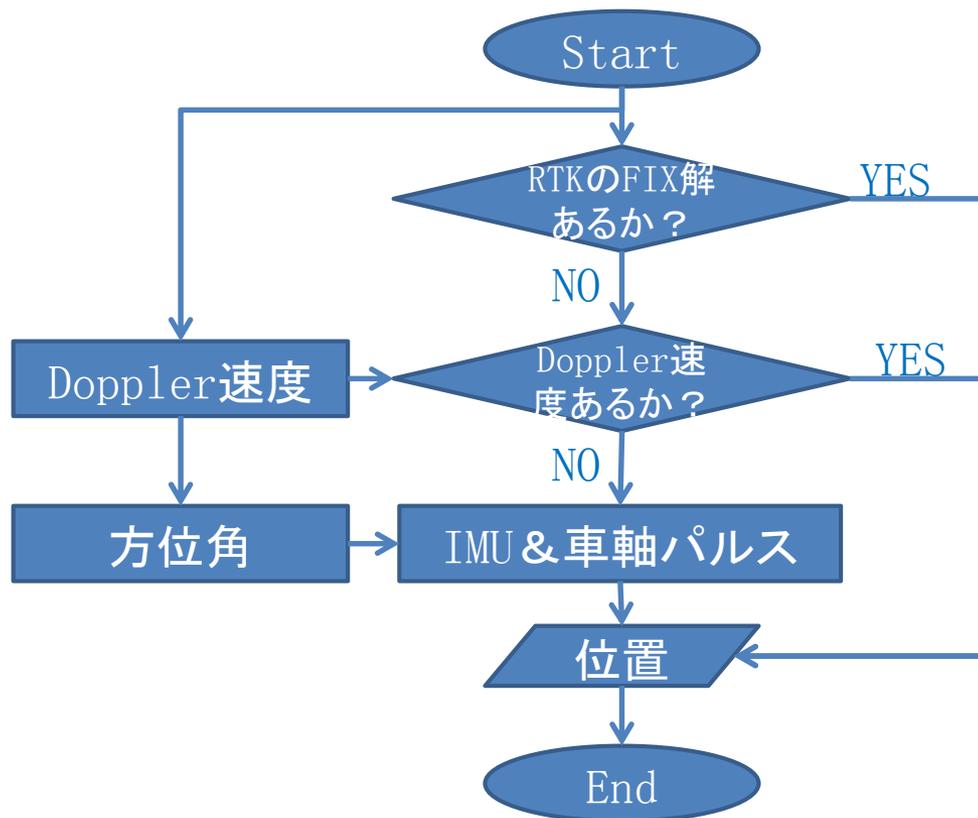
手法1:

線形カルマンフィルタによる統合手法

5

統合手法の優先順位:

1. RTKのFIX解がある場合、**FIX解**を使用する。
2. RTKのFIX解がない場合、ドップラー**速度ベクトル**を使用して位置を計算する。
3. 両方ともない場合、推測して得られた**方位角と速度**より、位置を計算する。

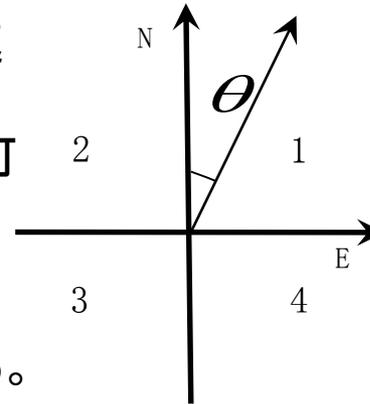


手法1:

ドップラー速度ベクトルによる方位角

6

- ドップラー周波数を計測することにより、移動体の速度情報(緯度経度高度方向の速度)を得ることができる。**3次元速度ベクトル**のため、直接方位角を計算することが可能である。
- 方位角は右のように計算することができる。



- 1: $\theta = \pi / 2 - \arctan(V_N / V_E)$
- 2: $\theta = \pi / 2 + \arctan(V_N / V_E)$
- 3: $\theta = 3\pi / 2 - \arctan(V_N / V_E)$
- 4: $\theta = 3\pi / 2 + \arctan(V_N / V_E)$

θ : 方位角
N : 緯度方向
E : 経度方向
V : 移動体の水平速度

条件設定	
ドップラー方位角1	速度ベクトルによる方位角
ドップラー方位角2	ドップラー方位角1 + ①
ドップラー方位角3	ドップラー方位角1 + ① + ②
ドップラー方位角4	ドップラー方位角1 + ① + ② + ③
①	低速のデータ(1 m/s 以下)を排除する
②	車軸パルスと比較して速度変化が激しいデータを排除する
③	ジャイロと比較して角速度の変化が激しいデータを排除する

手法1:

線形カルマンフィルタによる複合方位角

7

★方位角の推定は以下の状態方程式と観測方程式からなる基本システムによって表現することができる。

$$x = (\varphi, w) \quad (\text{方位角, 方位角速度})$$

$$\begin{aligned} x(k+1) &= Ax(k) + bw(k) \\ y(k) &= c^T x(k) + v(k) \end{aligned} \quad A = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix}$$

★観測値:

- ① ドップラー方位角
- ② ジャイロからの方位角速度

★カルマンフィルタを適用し整理すれば、最終的に状態ベクトルの最小分散推定量を求めるアルゴリズムが得られる。

$$\begin{aligned} \hat{x}(k|k-1) &= A\hat{x}(k-1) \\ P(k|k-1) &= AP(k-1)A^T + Q_k \end{aligned} \quad R = \begin{bmatrix} \sigma_{\Psi_g}^2 & 0 \\ 0 & \sigma_{\Psi_g}^2 \end{bmatrix}$$

$$K(k) = \frac{P(k|k-1)c}{c^T P(k|k-1)c + R(k)}$$

$$\hat{x}(k|k) = \hat{x}(k|k-1) + K(k)(y(k) - c^T \hat{x}(k|k-1))$$

$$P(k|k) = P(k|k-1) - K(k)c^T P(k|k-1)$$

手法1:

線形カルマンフィルタによる複合速度

8

★速度の推定は以下の状態方程式と観測方程式からなる基本システムによって表現することができる。

$$x = (v, a) \quad (\text{速度, 加速度})$$

$$\begin{aligned} x(k+1) &= Ax(k) + bw(k) \\ y(k) &= c^T x(k) + v(k) \end{aligned} \quad A = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix}$$

★観測値:

- ① 車軸パルスによる速度
- ② 加速度センサーによる加速度

★カルマンフィルタを適用し整理すれば、最終的に状態ベクトル の最小分散推定量を求めるアルゴリズムが得られる。

$$\begin{aligned} \hat{x}(k|k-1) &= A\hat{x}(k-1) \\ P(k|k-1) &= AP(k-1)A^T + Q_k \end{aligned} \quad R = \begin{bmatrix} \sigma_{\Psi_g}^2 & 0 \\ 0 & \sigma_{\Psi_s}^2 \end{bmatrix}$$

$$K(k) = \frac{P(k|k-1)c}{c^T P(k|k-1)c + R(k)}$$

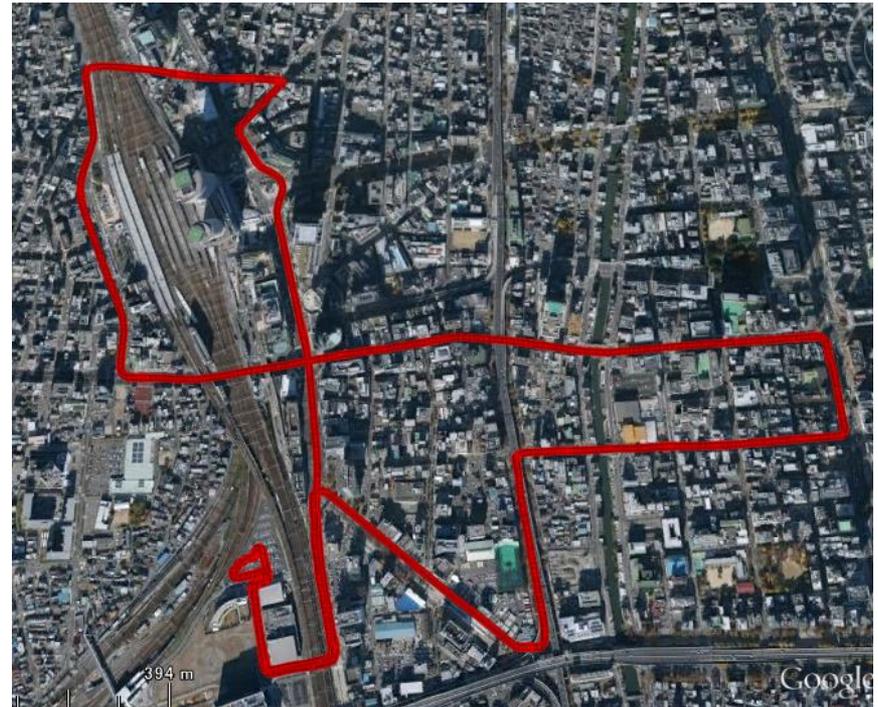
$$\hat{x}(k|k) = \hat{x}(k|k-1) + K(k)(y(k) - c^T \hat{x}(k|k-1))$$

$$P(k|k) = P(k|k-1) - K(k)c^T P(k|k-1)$$

実験1

9

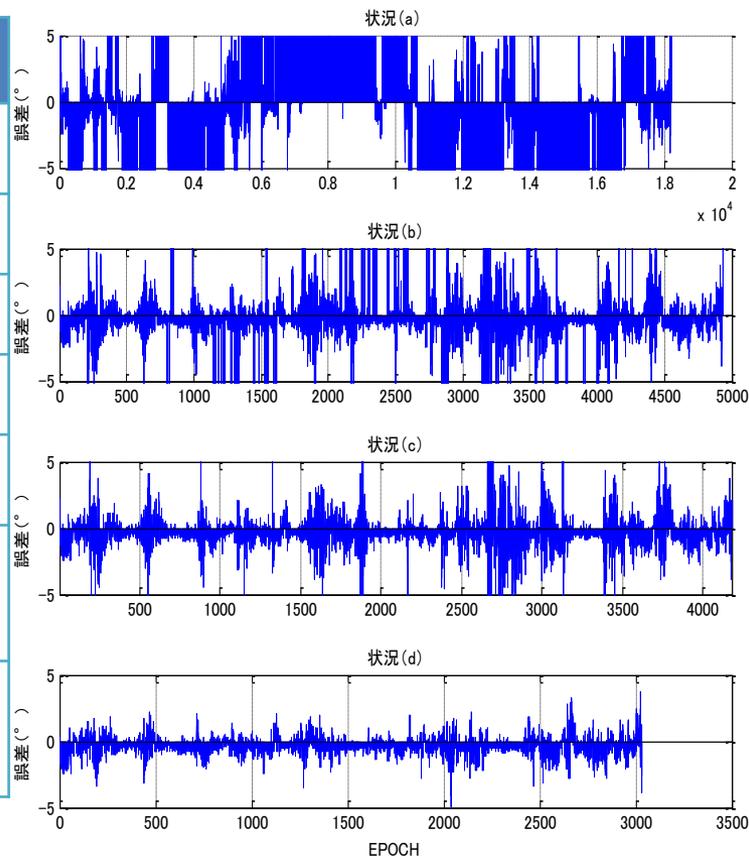
- 1、場所:名古屋駅周辺 (電波の遮蔽が多くて、測位環境が非常に悪い場所)
- 2、時間: 2013年3月8日
- 3、真値: POS/LV
(レファレンスとして利用)
- 4、衛星利用条件:
 - マスク 15 度
 - HDOP < 10
 - 受信すべき信号強度
- 5、データ: EPOCH: 18201 (約30分)
 - RTK: 5機以上、誤差が 1 m 以上のwrong FIXがなく、測位率約44%
 - ドップラー速度、MEMSジャイロ、加速度センサーと車軸パルス



手法1: ドップラー速度ベクトルによる方位角

10

方位角(単位:°)	絶対誤差平均値	標準偏差
ドップラー方位角1	70.92	89.36
ドップラー方位角2	3.89	18.86
ドップラー方位角3	0.91	1.42
ドップラー方位角4	0.64	0.74
①	低速のデータ(1m/s以下)を排除する	
②	車軸パルスと比較して速度変化が激しいデータを排除する	
③	ジャイロと比較して角速度の変化が激しいデータを排除する	

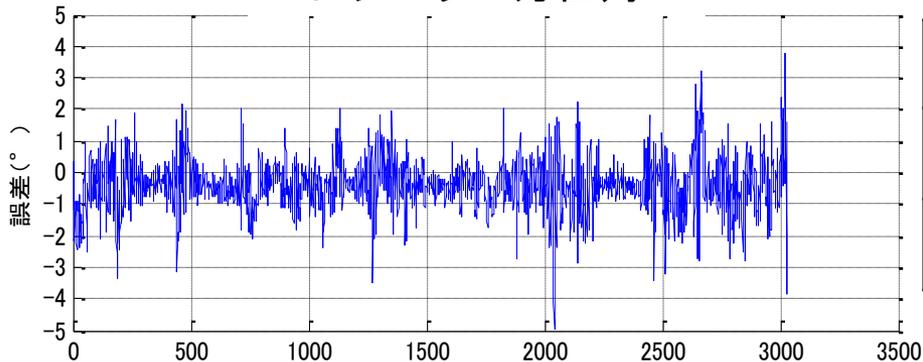


★精度の低いデータを排除し、精度の高い方位角を抽出することができた。

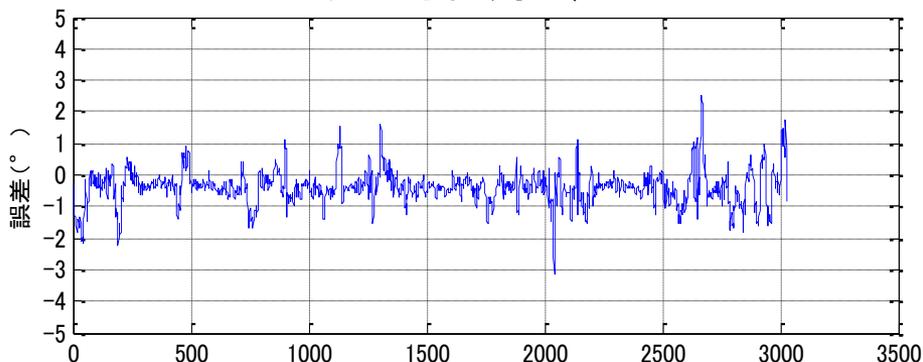
手法1: 線形カルマンフィルタによる複合方位角

11

ドップラー方位角 4



ドップラー方位角 4 / ジャイロ



方位角 (°)	絶対誤差平均値	標準偏差
ドップラー方位角 4	0.64	0.74
ドップラー方位角 4 / ジャイロ	0.52	0.52

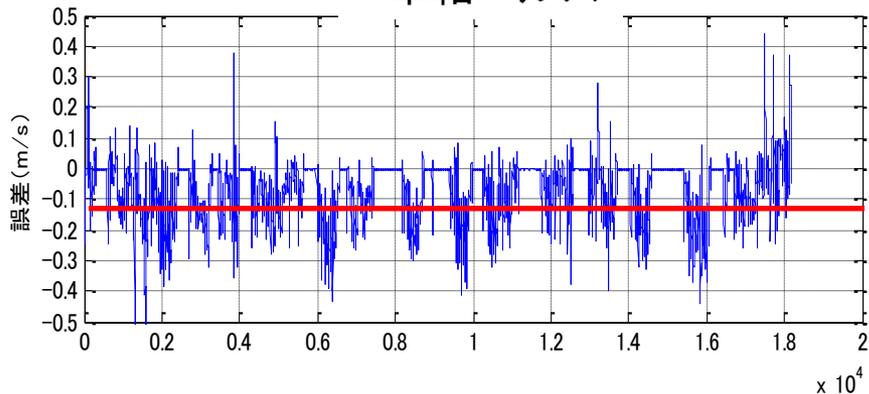
上の結果はドップラー方位角4、下の結果はドップラー方位角4とジャイロを統合した方位角である。

★統合することにより、ドップラー方位角4と比べ、精度の向上が見られる。

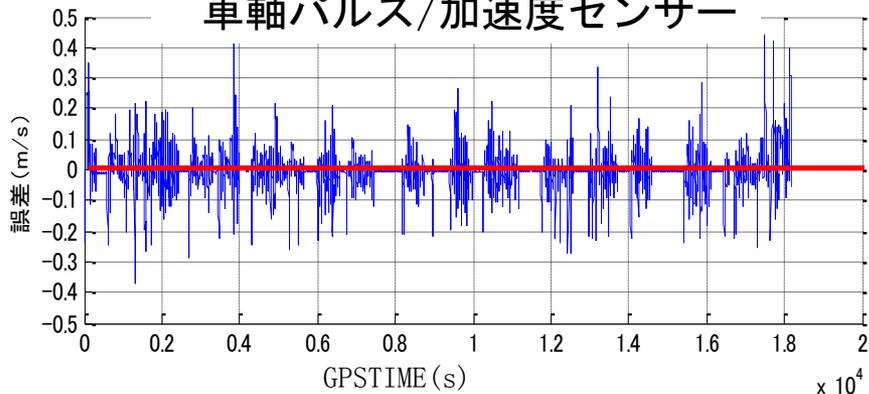
手法1: 線形カルマンフィルタによる複合速度

12

車軸パルス



車軸パルス/加速度センサー



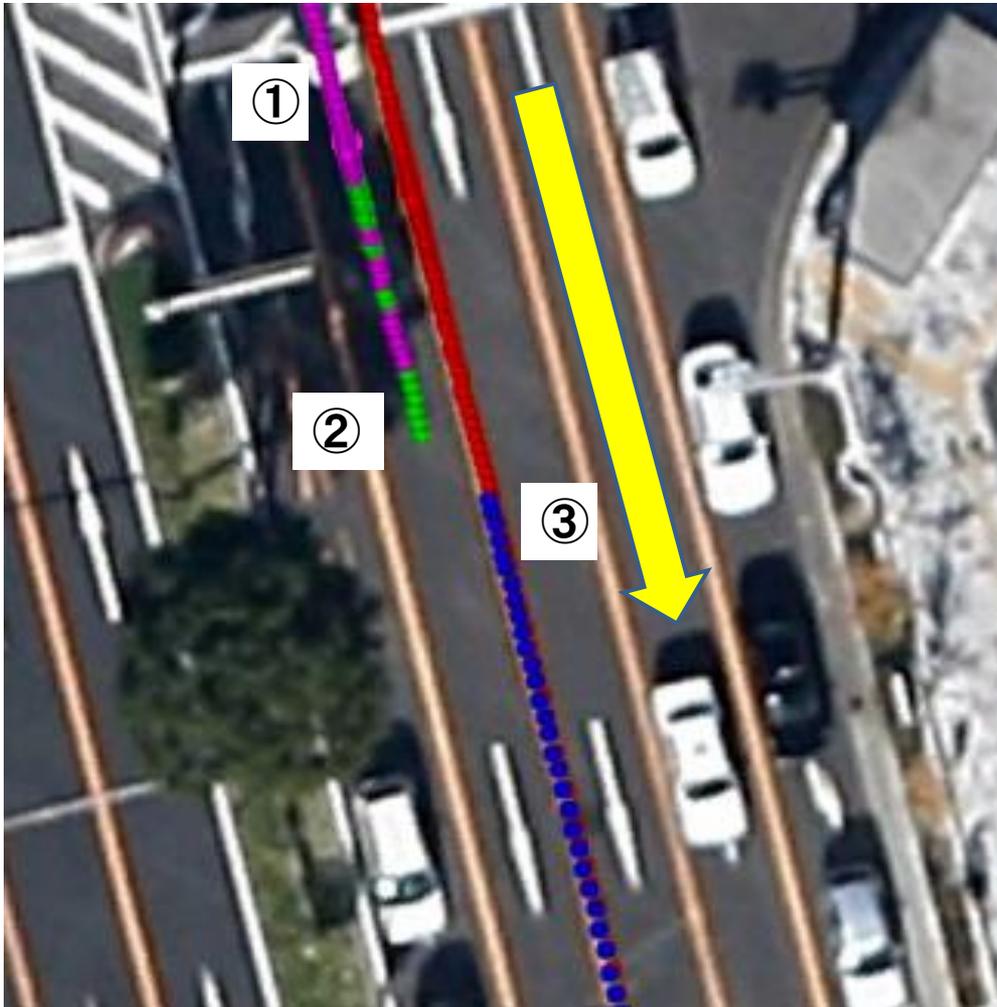
速度 (m/s)	絶対誤差平均値	標準偏差
車軸パルス	0.0735	0.087
車軸パルス/加速度センサー	0.0261	0.048

上の結果は車軸パルスの速度誤差で、下の結果は加速度センサーと車軸パルスを統合した速度誤差である。

★統合することにより、車軸パルスのみと比べ、精度の向上が見られる。

手法1:位置推測

13



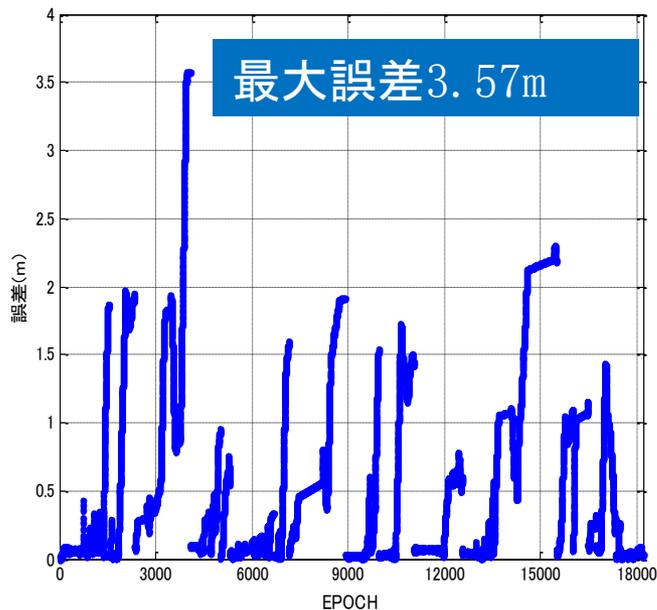
- RTKのFIX解
- ドップラー速度
- IMU
- POSLV

手法1の結果

14

	測位率	誤差平均値 (m)	標準偏差 (m)
RTK	5679 (31.2%)	0.05	0.02
doppler	2302 (12.6%)	0.53	0.60
IMU	10220 (56.2%)	0.93	0.74
ALL	18201 (100%)	0.60	0.71

水平誤差	測位率
1m	74.6%
1.5m	85.7%
2m	93.7%



1. GNSSのみで約44%の利便性をセンサと統合することで**100%**に向上した。
2. 統合することにより、水平誤差**1.5m以内の割合は85.7%**で、**2m以内の割合は93.7%**になった。
3. 最大誤差約**3.57m**であった。

手法2:

拡張カルマンフィルタによる統合手法

15

★拡張カルマンフィルタ:

非線形システムを各時刻において線形化し、それぞれの時刻において線形カルマンフィルタを適用するというフィルタリング手法である。

★時刻kにおける変数:

座標 $(xe(k), yn(k))$ 速度スケールファクター $vsf(k)$

方位角 $azi(k)$ ジャイロのバイアス $wbias(k)$

状態変数: $x(k) = (xe(k), yn(k), azi(k), vsf(k), wbias(k))$ 観測値: RTKのFIX解

★非線形システム

状態方程式 $x_t = f(x_{t-1}, \mu_{t-1}, \omega_{t-1})$

観測方程式 $y_t = h(x_t, v_t)$

x_k : 状態量ベクトル w_k : プロセスノイズ

y_k : 観測値ベクトル v_k : 観測ノイズ

f 非線形関数、前の状態から推定値を与える。

h 線形関数 $h(x) = (xe(k), yn(k))$ RTK測位結果

手法2:

拡張カルマンフィルタによる統合手法

16

★状態量の予測は以下の方程式を用いる。

$$f(x) = \begin{cases} xe(k+1) = xe(k) + v_s(k)(1 - vsf(k)) \cos(azi(k)) \\ yn(k+1) = yn(k) + v_s(k)(1 - vsf(k)) \sin(azi(k)) \\ azi(k+1) = azi(k) + (w_{gyro}(k) - w_{bias}(k)) \Delta t \\ vsf(k+1) = vsf(k) - \frac{vsf(k)}{\tau_{sf}} \Delta t \\ w_{bias}(k+1) = w_{bias}(k) - \frac{w_{bias}(k)}{\tau_{bs}} \Delta t \end{cases}$$

$v_s(k)$ 車軸パルスからの速度 $w_{gyro}(k)$ ジャイロからの角速度

拡張カルマンフィルタでは状態方程式を線形化するため、非線形関数 f を各時刻でヤコビアン (Jacobian) を計算する。

$$A(k) = \frac{\partial f}{\partial x}$$

★拡張カルマンフィルタのアルゴリズム:

事前状態推定値 $\hat{x}(k | k-1) = f(\hat{x}(k-1))$

事前誤差共分散行列 $P(k | k-1) = A(k)P(k-1)A^T(k) + \sigma_w^2(k)bb^T$

カルマンゲイン $K(k) = \frac{P(k | k-1)c(k)}{c^T(k)P(k | k-1)c(k) + \sigma_v^2(k)}$

状態推定値 $\hat{x}(k | k) = \hat{x}(k | k-1) + K(k)(y(k) - h(\hat{x}(k | k-1)))$

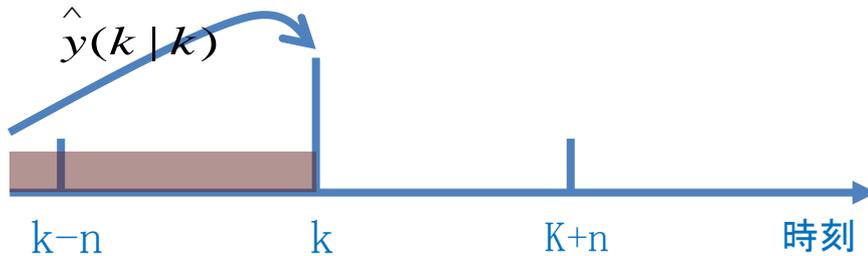
事後誤差共分散行列 $P(k | k) = P(k | k-1) - K(k)c^T(k)P(k | k-1)$

手法2:

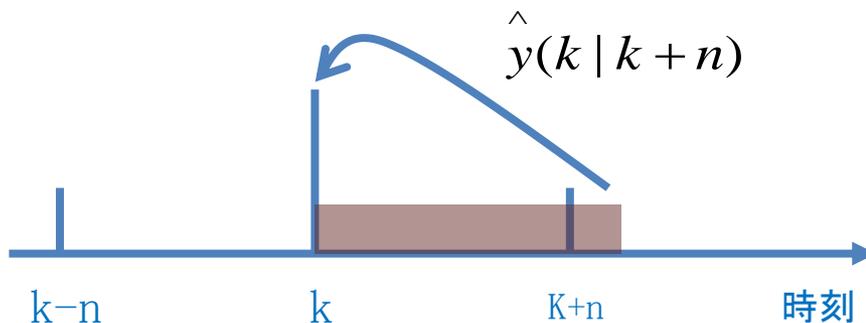
順方向推測、逆方向推測、両方向を合わせる推測

17

★ 順方向推測: 現時刻までのデータで現時刻の状態変数を推定する。



★ 逆方向推測: 現時刻以後のデータで現時刻の状態変数を推定する。



★ 両方向を合わせる推測

線形カルマンフィルタにより

$$P(k) = ((P1(k))^{-1} + (P2(k))^{-1})^{-1}$$

$$X(k) = P(k) * (P1(k) \setminus X1(k) + P2(k) \setminus X2(k))$$

$P1(k)$ 順方向推測結果の誤差共分散

$P2(k)$ 逆方向推測結果の誤差共分散

$X1(k)$ 順方向推測結果 (状態変数)

$X2(k)$ 逆方向推測結果 (状態変数)

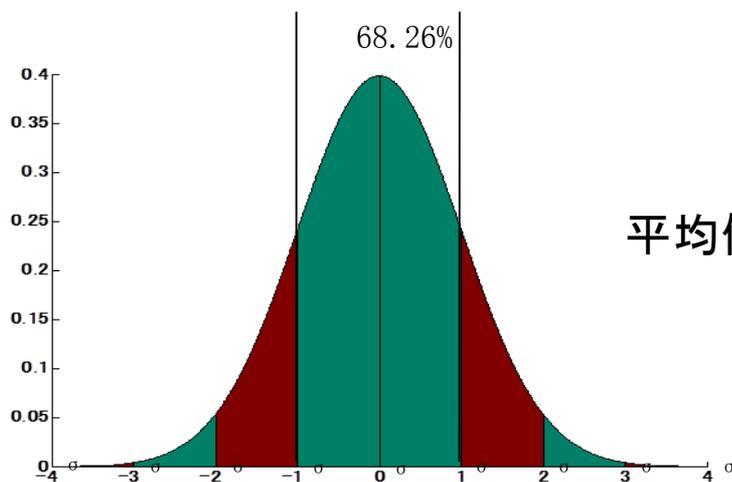
手法2は後処理であるが、その一部(順方向測位)はリアルタイムに測位することができる。

手法2:

Wrong FIX検出

18

カルマンフィルタでは、観測雑音を平均値0、分散 σ^2 の白色雑音であると仮定されている。



$$1\sigma : \sigma = \sqrt{P_x(k) + P_y(k)}$$

$$\text{平均値からのずれ} : \Delta d_{xy}(k) = \sqrt{(x_R - x)^2 + (y_R - y)^2}$$

★ 平均値からのずれは $n\sigma$ 以内にある場合、正しくFIXしたと見なされる。

★ 平均値からのずれは $n\sigma$ 以外にある場合、wrong FIXと見なされる。

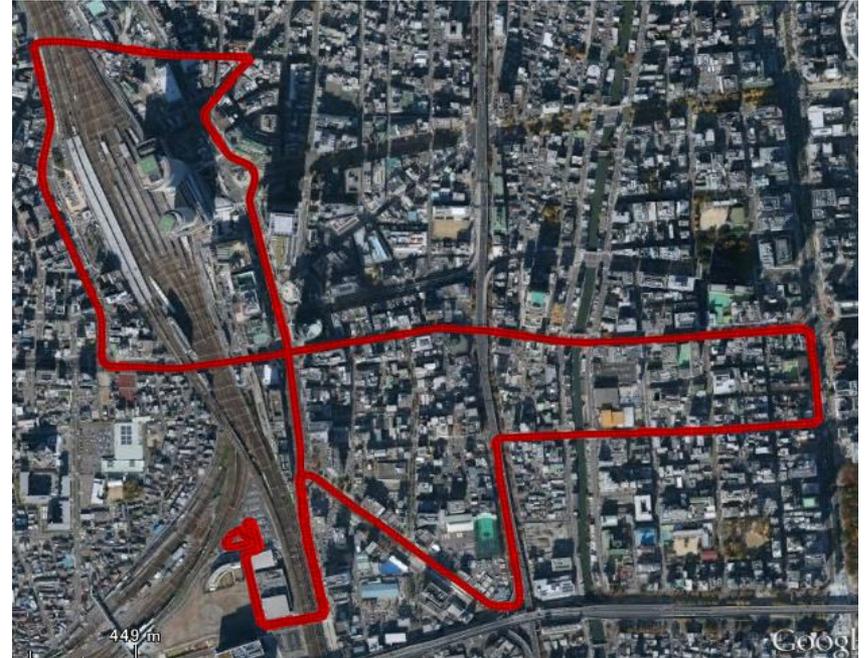
★ データを分析するとき、 n の値を調整することによって、大きい誤差を検出することができる。

0からのずれ	$\pm 1\sigma$	$\pm 2\sigma$	$\pm 3\sigma$
確率	68.26%	95.44%	99.74%

実験2

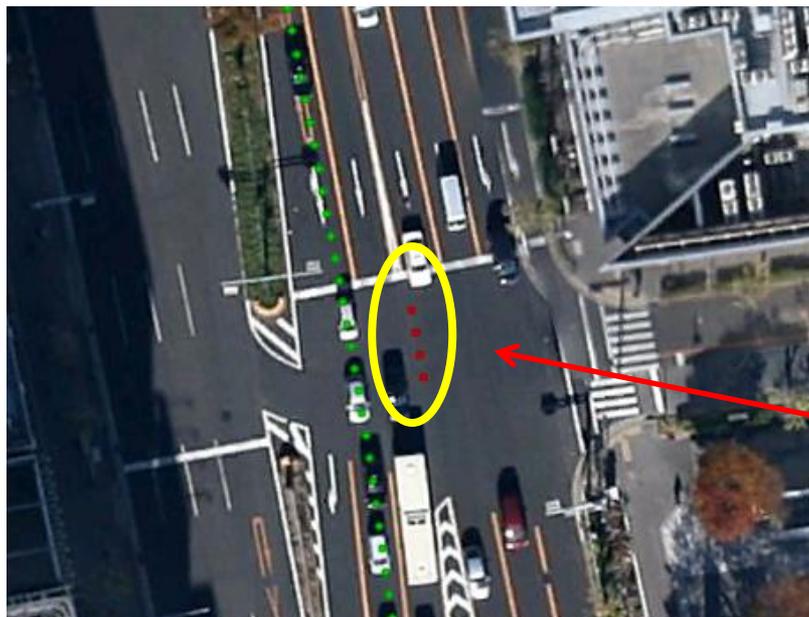
19

1. 場所: 名古屋駅周辺
2. 時間: 2013年11月26日
3. 真値: POS/LV
(レファレンスとして利用)
4. 衛星利用条件:
 - マスク 15 度
 - HDOP < 10
 - 受信すべき信号強度
5. データ: EPOCH: 11801 (約20分)
 - RTK: (5機以上、5Hz、FIX率が約57%)
 - FOG: 約20Hz
 - *車軸パルスのデータを得られなかったため、POSLVの速度に平均が0m/s、標準偏差が2cm/sの白色雑音を載せて代用した。
6. 解析手法: リアルタイム⇒手法2の順方向推測、後処理⇒手法2

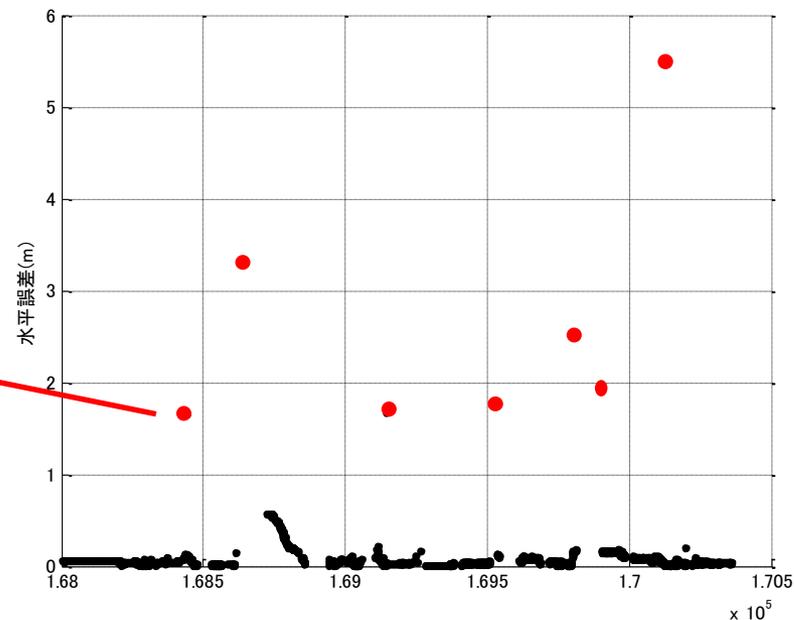


Wrong Fix検出の結果

20



RTK FIX解の誤差



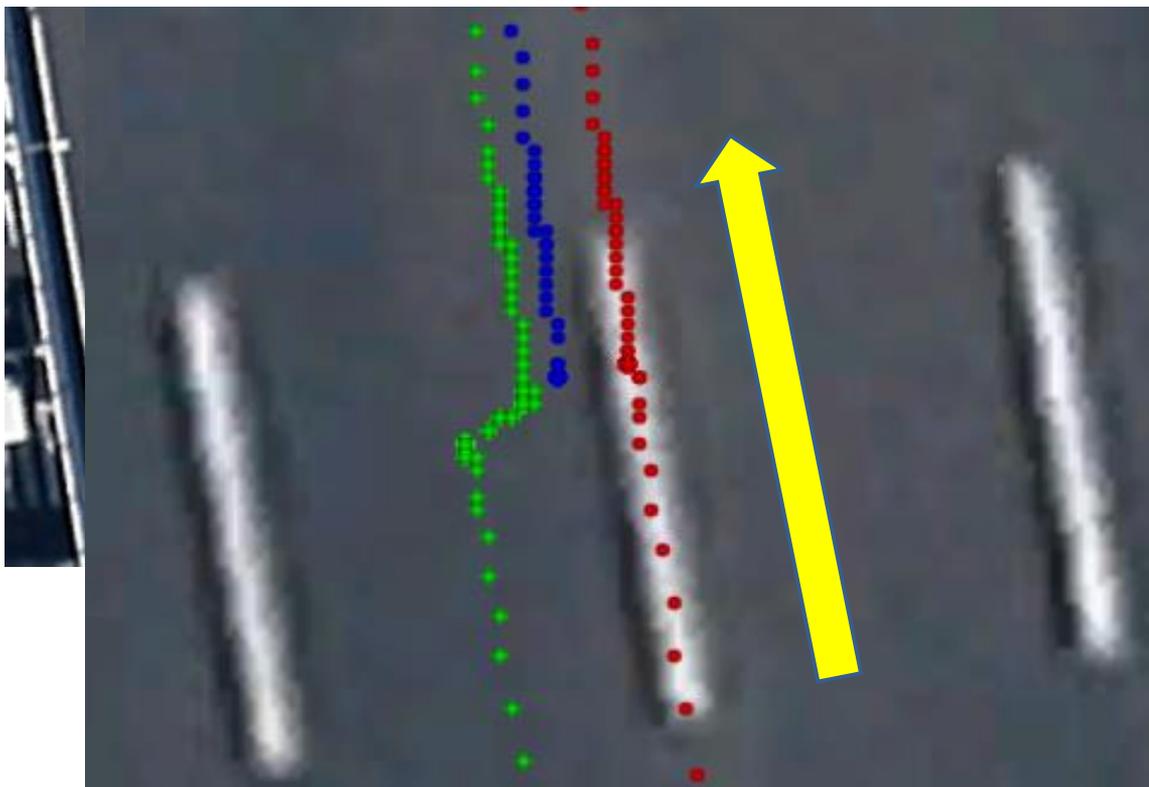
● POSLV ● RTKのwrong FIX

	順方向		逆方向	
	Wrong FIX回数	検出回数	Wrong FIX回数	検出回数
誤差1m以上	15	15	14	14

誤差が大きいwrong FIXをほぼ検出することができた。
水平誤差が2m以上の検出率は100%である。

手法2の位置推定

21



- RTKのFIX解
- 複合の結果
- POSLV

RTKのFIX解が入ってくるたびに複合の誤差が小さくなる。

実験結果

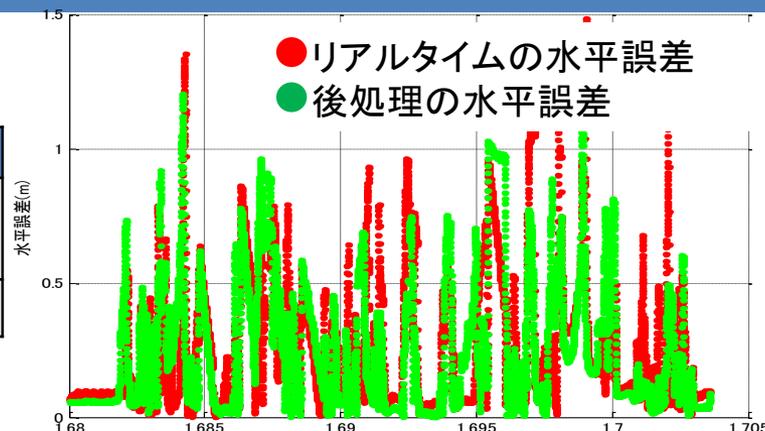
22

方位角誤差(°)

	FOG	リアルタイム	後処理
絶対誤差の 平均値	0.88	0.09	0.09
標準偏差	0.26	0.13	0.12

結果統計

水平誤差	リアルタイム		後処理	
	EPOCH	割合	EPOCH	割合
<1m	11319	95.9%	11545	97.8%
1m~1.5m	393	3.3%	256	2.2%
>1.5m	89	0.8%	—	—
平均値	0.31		0.27	
標準偏差	0.29		0.26	
最大値	1.75		1.26	



- リアルタイム推測による水平絶対誤差が**1.5m以内の割合は99.2%**になった。この結果よりFOGを用いて、リアルタイムに高精度の推測ができることを確認した。
- 後処理による**最大誤差が1.26m**に抑えることができた。車線判別できるレファレンスを作ることができると考えられる。
- 以上の結果よりFOGを使う場合、車線判別は可能であることを確認した。

まとめ1

- ★ 線形カルマンフィルタにより、ジャイロ、加速度センサー、車軸パルスとGNSSを統合する手法を提案した。
- ★ 拡張カルマンフィルタにより、FOG、車軸パルスとRTKを統合する手法を提案した。
- ★ ドップラー速度より方位角の算出方法を紹介し、信頼性の高い方位角を抽出する方法を提案した。
- ★ カルマンフィルタを用いて、速度精度の向上手法を提案した。

まとめ2

- ★ ローコストジャイロを使用する場合、水平絶対誤差が 1.5 m 以内の割合は86%であった。
- ★ 高精度FOGを使用する場合、水平絶対誤差が 1.5 m 以内の割合：**リアルタイム⇒ 99.2%** **後処理⇒ 100%**
- ★ 都市部において、GNSSの利便性をセンサーとの融合で100%に向上した。都市部で連続的、高精度の測位をすることができた。

ご清聴ありがとうございました！