

深層学習を利用した GNSSとIMUの統合測位解のミスFix推定

東京海洋大学

小林海斗、久保信明

第67回宇宙科学技術連合講演会 OS50-4 2G05

2023/10/18 富山

1. 背景
2. 深層学習を利用したミスFix推定
3. 実データの収集
4. ミスFixの推定
5. 入力特徴量の調整による推定結果の改善
6. まとめ

1. 背景

- ◆自動運転や運転補助としてcmレベルの精度が得られるRTK-GNSSの利用が期待されている。
- ◆しかし高層ビル街、トンネル、高架下などではRTKの測位精度が劣化、または測位不可能になる。
- ◆これを解決する手法としてはIMU (慣性計測装置)の加速度・角速度情報でGNSSを補完する**統合測位**が提案されている。
- ◆このため、各社統合測位が可能なGNSSとIMUを統合させたモジュールを販売している。



ublox F9R
(RTK+IMU+Speed Sensor)



Septentrio AsteRx-i3
(RTK+IMU)



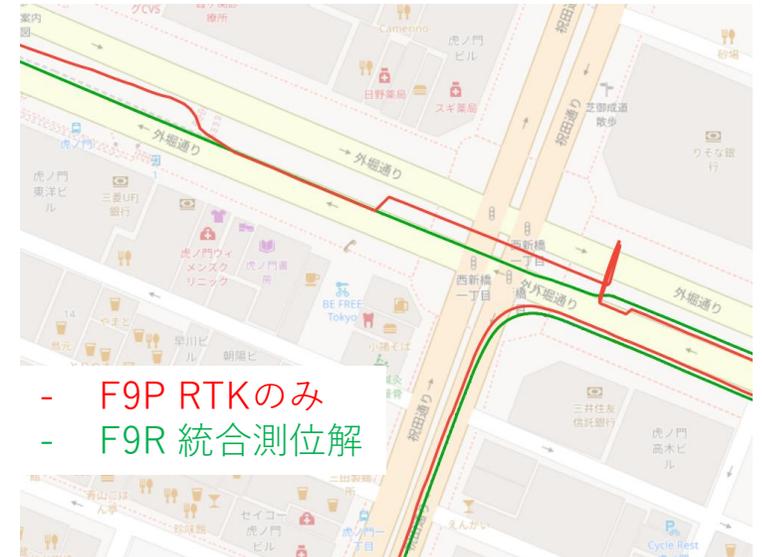
Trimble POSLV
(RTK+Heading+INS+Speed Sensor)

1. 背景

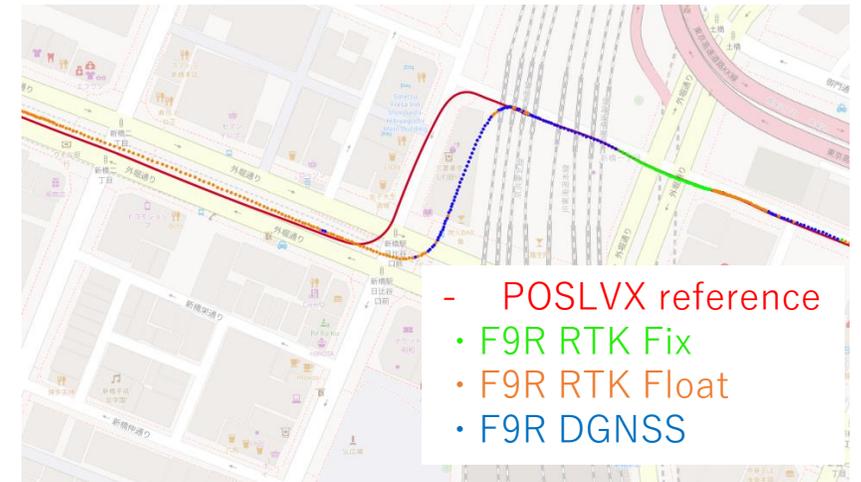
- ◆例としてublox F9Rの統合測位結果を示す。
- ◆IMUのないF9Pと比べると、F9Rでは高架下でもスムーズな軌跡を出力できている。
- ◆しかしハイエンドのPOSLVX125と比べると、**30cm以上の誤差**がある箇所もある。



- ◆低コストのGNSS受信機とIMUを使用した場合、統合測位をしても大きな誤差を持つことがある。
- ◆通常のRTKと異なり統合測位解は大きな誤差をFixステータスのみで判断できない。
- ◆今回**水平30cm以上の誤差を持つ統合測位解をミスFixと定義した。**



F9PとF9Rの比較



POSLVXとF9Rの比較

1. 背景

- ◆ 先行研究で3Dマップから計算した衛星可視性と実際の走行データを機械学習して、**任意の箇所でRTKがFixするかどうかの予測**を行った。

Kobayashi, Kaito, Kubo, Nobuaki, "RTK Availability Prediction Using a 3D City Model and Machine Learning," Proceedings of the 2023 International Technical Meeting of The Institute of Navigation, Long Beach, California, January 2023, pp. 580-590.

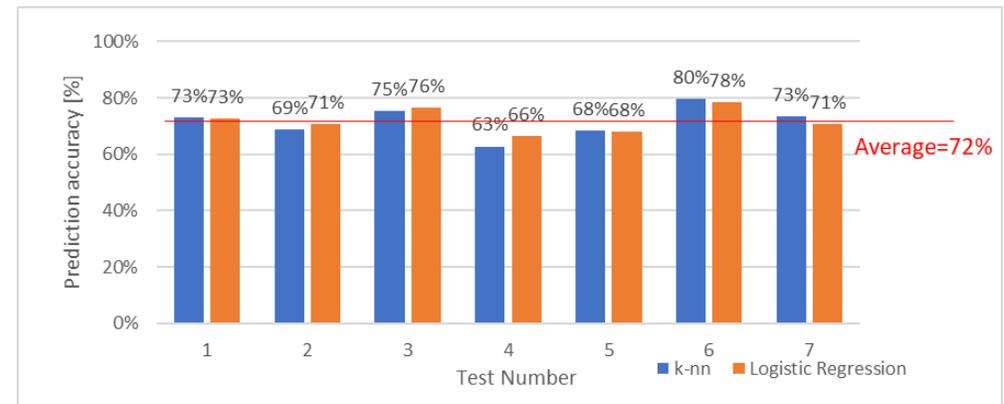
- ◆ この研究では**72%**の確率でRTK Fixの可否を予測できた。
- ◆ 同じように深層学習を利用して統合測位解のミスFixを推定できないか？

4. Collection of datasets

◆ In the prediction term, Fix type (Q) of test dataset is predicted using training datasets.

Objective variable		Explanatory variables											
GPSW	GPST[sec]	Q	Lat_ref[deg]	Lon_ref[deg]	Hgt_ref[m]	LOS_n	NLOS_n	PDOP	sky_rate	GQ	E	C	R
2225	279821.4		35.68497079	139.7608481	41.111	22	18	1.473134	0.678333	3	3	2	10
2225	279821.4		35.68495011	139.7608313	41.133	22	18	1.473141	0.683889	3	3	2	10
2225	279821.8		35.68492959	139.7608151	41.118	23	17	1.431955	0.684167	4	3	2	10
2225	279822		35.68490908	139.760799	41.097	23	17	1.431943	0.687083	4	3	2	10
2225	279822.2	?	35.68488845	139.7607822	41.148	23	17	1.431953	0.692222	4	3	2	10
2225	279822.4		35.68486781	139.7607662				1.431962	0.692361	4	3	2	10
2225	279822.4		35.68484703	139.7607511				1.43197	0.695833	4	3	2	10

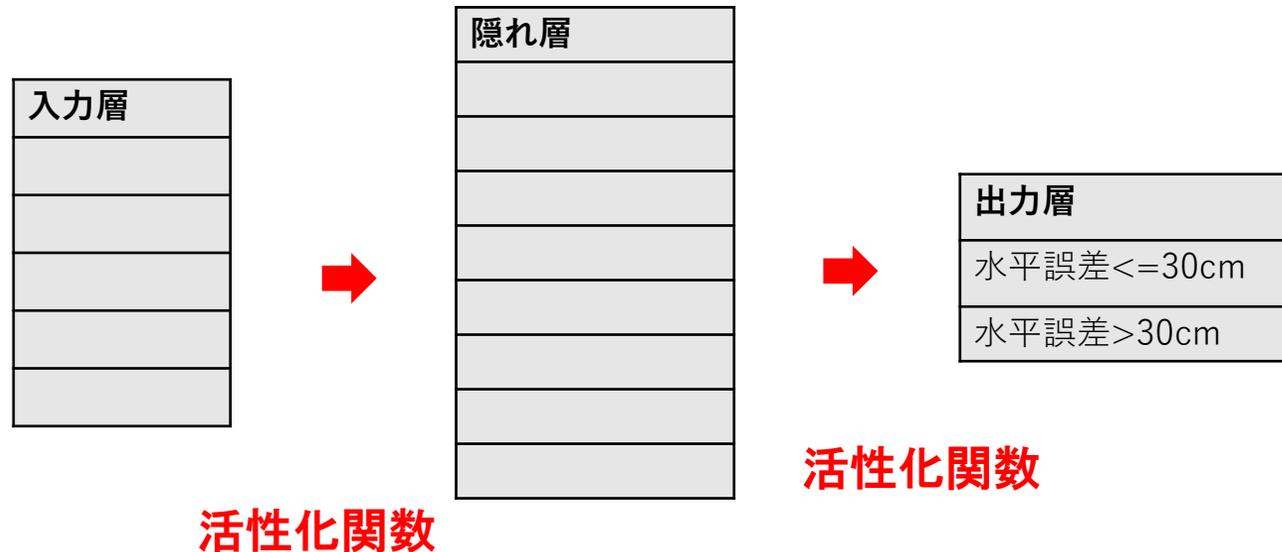
TUMSAT GNSS Lab



Prediction Accuracy of RTK Fix or Not

2. 深層学習を利用したミスFix推定

- ◆ 深層学習は入力層、隠れ層、出力層からなる。
- ◆ 入力層に特徴量を入れて、出力層で統合測位解がミスFixかどうかの判定結果を出力する。
- ◆ 隠れ層と活性化関数はユーザーによる調整が必要。
- ◆ また推定精度を上げるには入力層に何のデータを入れるかが重要。
- ◆ 今回はKerasというPythonライブラリーを使用した。



2. 深層学習を利用したミスFix推定

特徴量として以下7つを設定した。

1. LOS継続衛星数

搬送波のハーフサイクルアンビギュイが決定する6秒以上可視状態にある衛星数。3Dマップを使用したRay-Launching法で計算した。

2. LOS継続衛星のPDOP

3. 最終RTK Fixからの経過時間

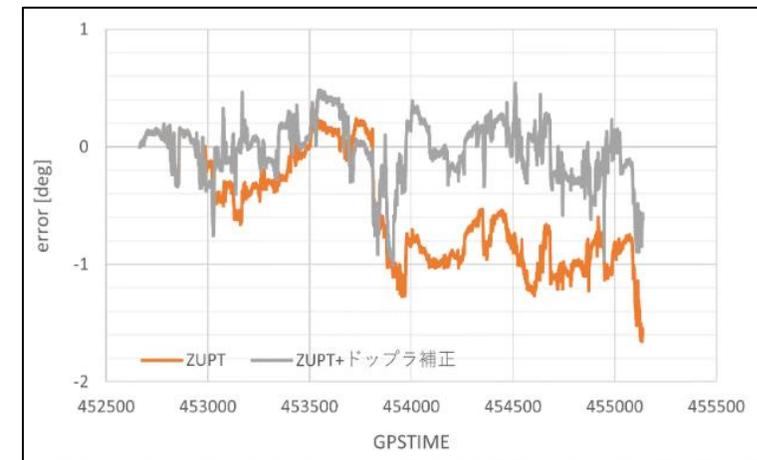
デッドレコニングでは通常最後に得られたRTK Fix解をカルマンフィルタに使用するので、この時間が長くなるとIMU誤差が蓄積していく。

4. LOS継続衛星のL1帯SNR平均値

LOS継続衛星数が同じでもSNRが低い場合マルチパスの影響が大きいと考えられる。



3DマップにはPLATEAUプロジェクトのLOD2を使用



時間経過によるIMU誤差の蓄積

2. 深層学習を利用したミスFix推定

特徴量として以下7つを設定した。

5. 車両速度

速度が早いほどIMUの Heading 補正精度が良い。

6. RTKのFixタイプ

GNSSの測位ステータス

RTK Fix/RTK Float/DGNSS/No Fix

ごとに誤差値を設定した。

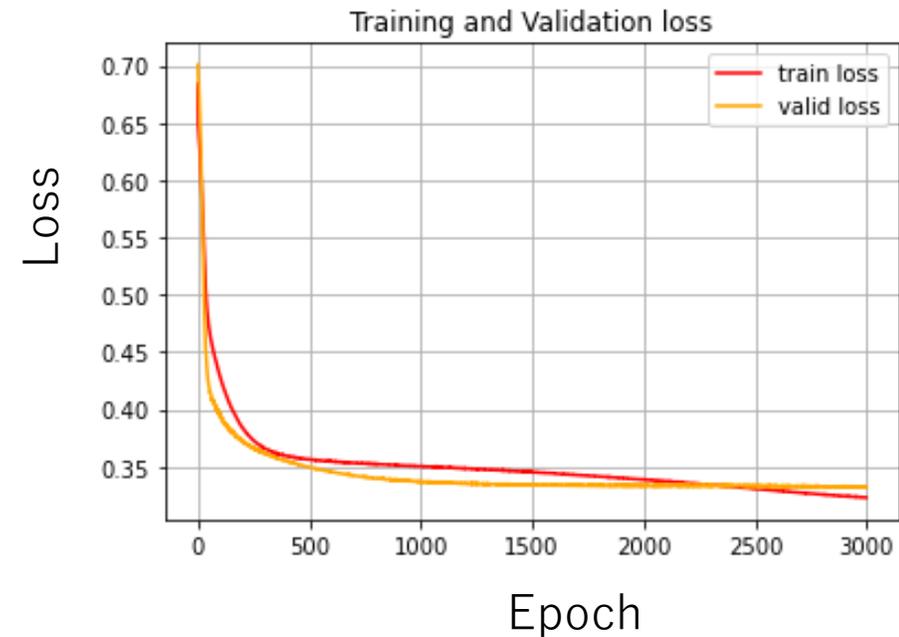
2. 深層学習を利用したミスFix推定

Keras D-NNの設定

- ◆ 隠れ層: 1層
- ◆ 隠れ層のノード数: 9
- ◆ 活性化関数: Sigmoid
- ◆ 学習回数: 2000回

パラメーターを変えながら複数のデータで損失関数を作成し、**train loss**と**valid loss**が理想的なものを見つけた。

- ・train loss : 学習データに対するモデルの最適化度合い
- ・valid loss : テストデータに対するモデルの最適化度合い



あるデータの損失関数

2. 深層学習を利用したミスFix推定

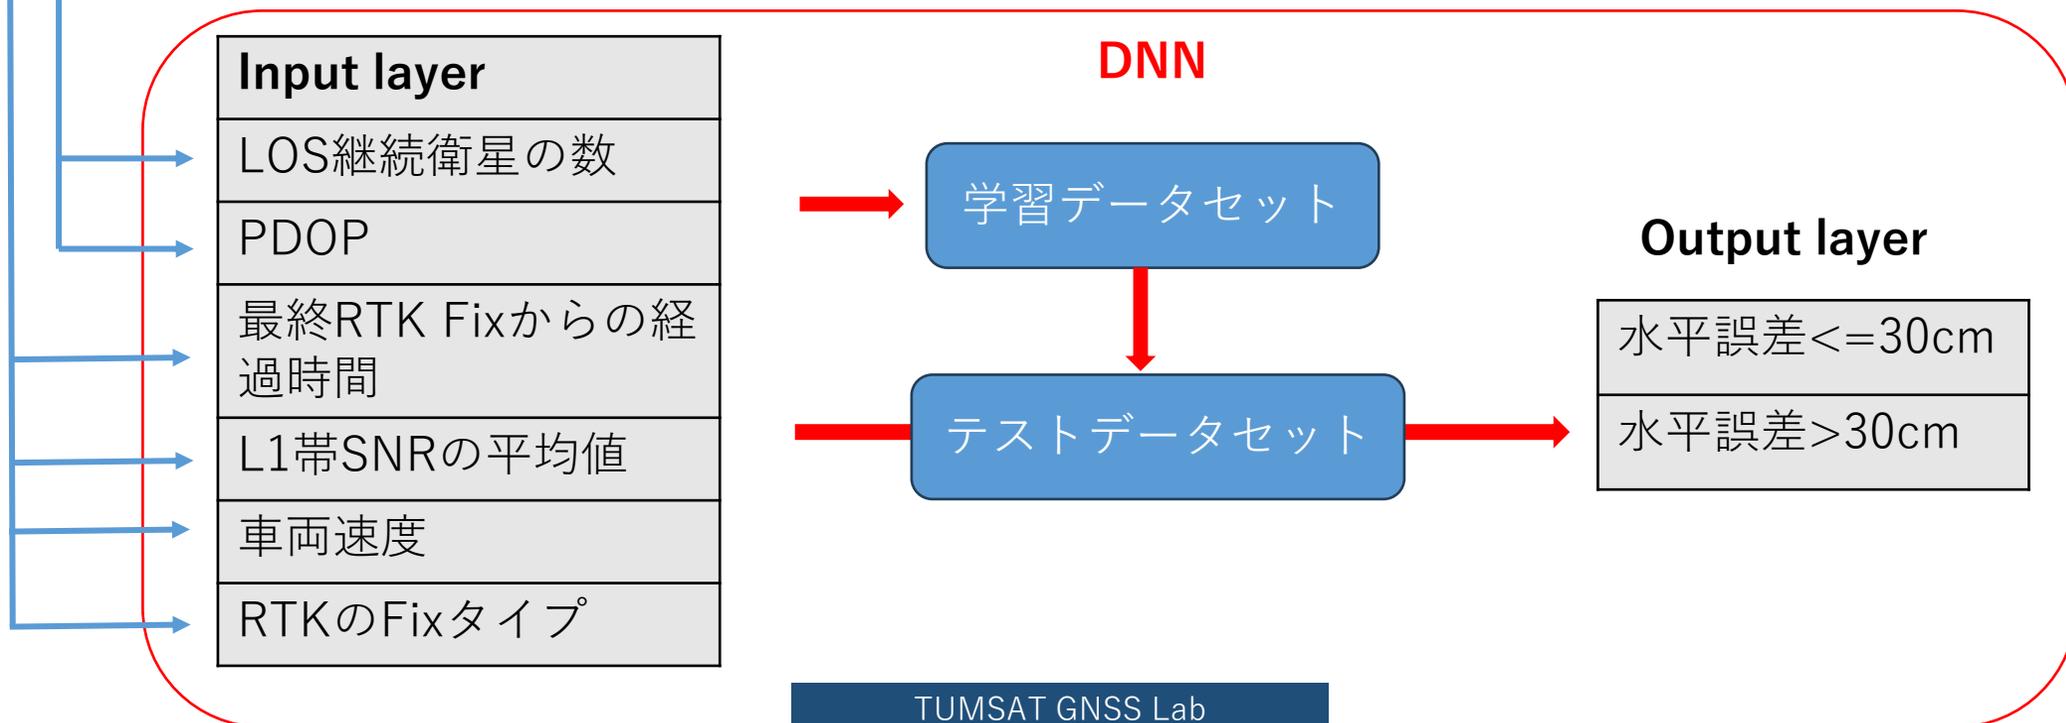


GNSS観測データ

時刻, 座標

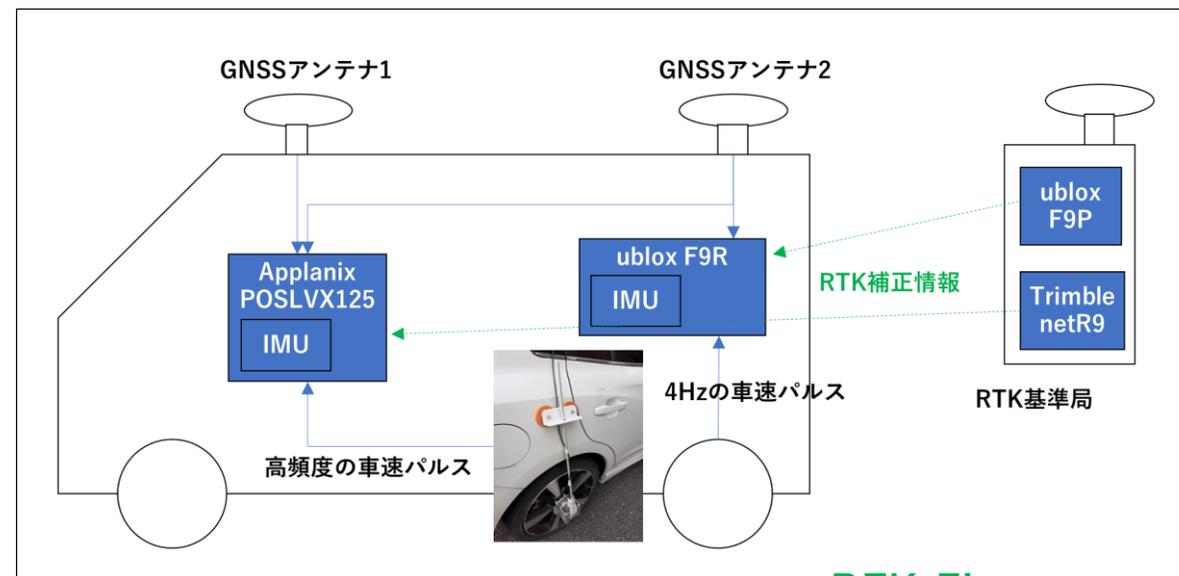


全体のフロー

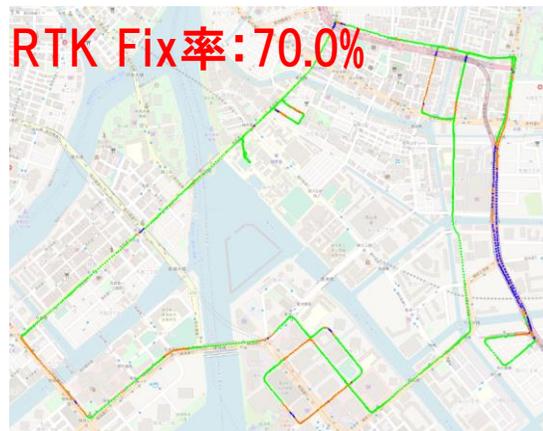


3. 実データの収集

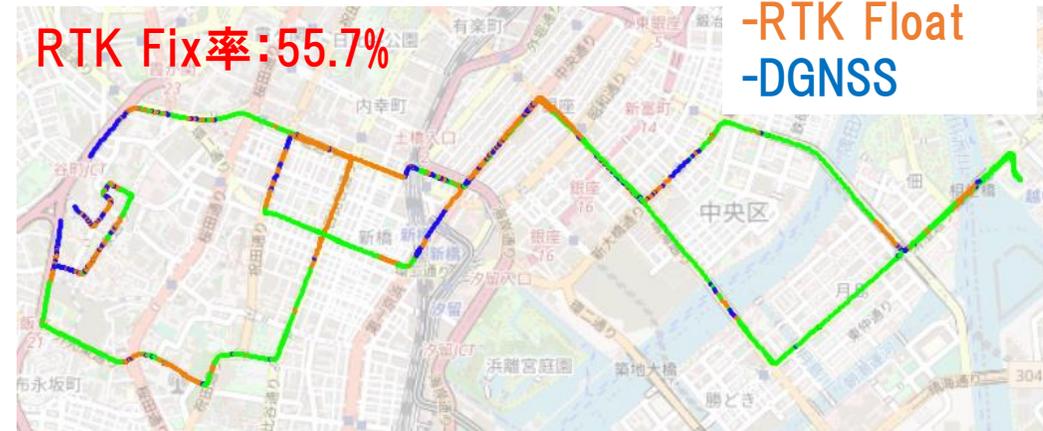
- ◆ 東京都内で3回走行実験を行い、3つのデータセットを作成した。(1Hz、合計10202エポック)
- ◆ F9RとリファレンスであるPOSLVX125の差が**30cm以上の場合ミスFix**と判定をして学習データセットの正解とした。
- ◆ データセットの観測データもF9Rのものを使用した。



データセット1



データセット2



データセット3

4. ミスFixの推定

- ◆ 交差検証を行って深層学習の結果を評価した。

テストNo. \ データセット	No.1	No.2	No.3
Test 1	テスト	学習	学習
Test 2	学習	テスト	学習
Test 3	学習	学習	テスト

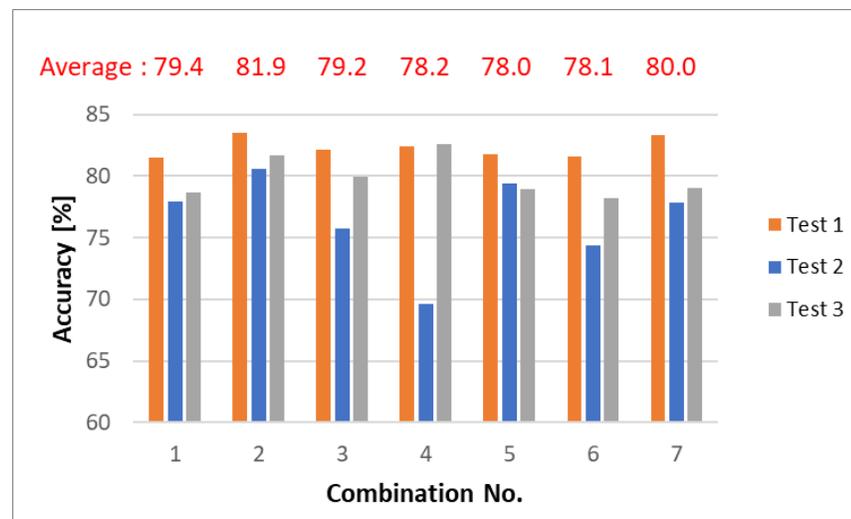
- ◆ RTK Fixが得られていない区間の統合測位解のミスFix判定精度を知りたかったため、**統計値はRTK Fixしなかった区間のみで評価した。**
- ◆ 正答率は良いがTPR(True Positive Rate)が**37.1%**と低かった。
- ◆ これは誤差30cm以下の場所をミスFixと推定してしまっている割合が多いことを示す。

	Accuracy (%)	TPR (%)	FPR (%)
Test 1	81.5	33.1	8.2
Test 2	77.9	46.5	9.2
Test 3	78.7	31.8	11.5
Average	79.4	37.1	9.6

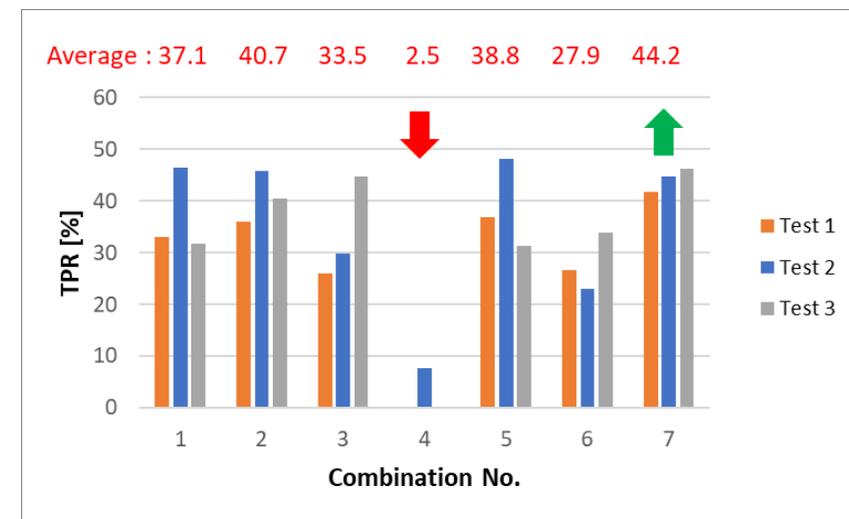
5. 入力特徴量の調整による推定結果の改善

- ◆ 推定パフォーマンスを改善するために入力特徴量の推定への寄与具合を調査した。
- ◆ 入力特徴量の組み合わせを追加で6パターン用意し、それぞれの推定パフォーマンスを比較した。
- ◆ 正答率についてはどの組み合わせによって大きな差はなかった。
- ◆ TPRは「最終RTK Fixからの経過時間」がないとき最低に、「RTK Fixタイプ」がないときに最高となった。

入力特徴量\組み合わせ	1	2	3	4	5	6	7
LOS継続衛星の数	✓		✓	✓	✓	✓	✓
PDOP	✓	✓		✓	✓	✓	✓
最終RTK Fixからの経過時間	✓	✓	✓		✓	✓	✓
L1帯SNRの平均値	✓	✓	✓	✓		✓	✓
GNSS速度の大きさ	✓	✓	✓	✓	✓		✓
RTK Fixタイプ	✓	✓	✓	✓	✓	✓	



各組み合わせの正答率



各組み合わせのTPR

5. 入力特徴量の調整による推定結果の改善

◆「最終RTK Fixからの経過時間」が統合測位のミスFix推定に最も寄与する。

◆「RTK Fixタイプ」は推定に悪い影響を与える。

ことがわかる。

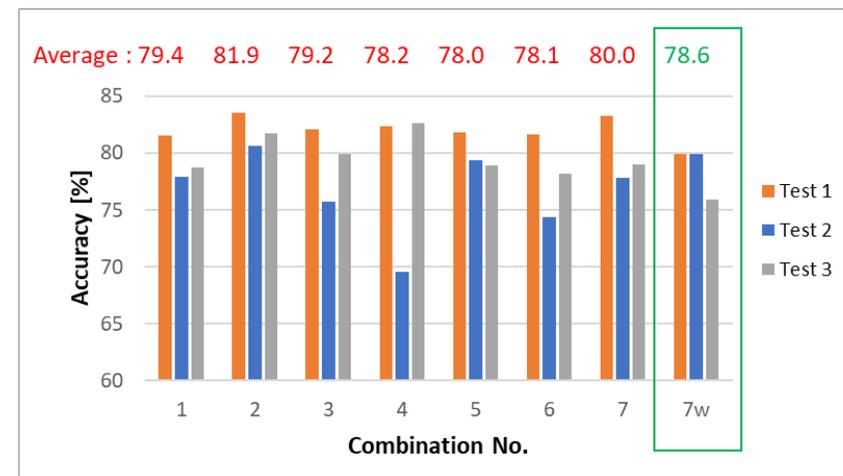
◆この結果より「最終RTK Fixからの経過時間」に重みを加え、「RTK Fixタイプ」は入力特徴量から削除した。

◆重み付けは経過時間[sec]を二乗することで行った。

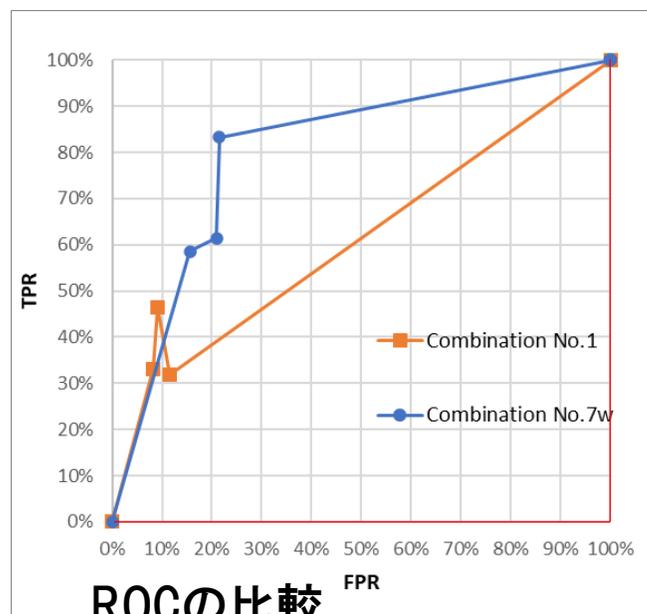
この組み合わせを**7w**とする。

5. 入力特徴量の調整による推定結果の改善

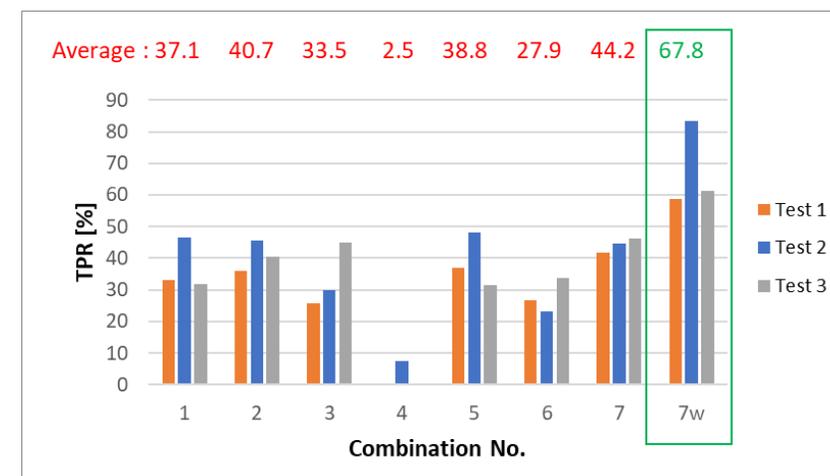
- ◆ 組み合わせ7wの結果を示す。
入力特徴量の変更以外は同一条件。
- ◆ 正答率は78.6%と若干低下したが、TPRは37.1%から**67.8%**に大幅に改善した。
- ◆ 深層学習の推定精度を評価するROC(Receiver Operation Curve)の面積AUCの値は0.609から**0.801**に上昇した。



各組み合わせの正答率



ROCの比較



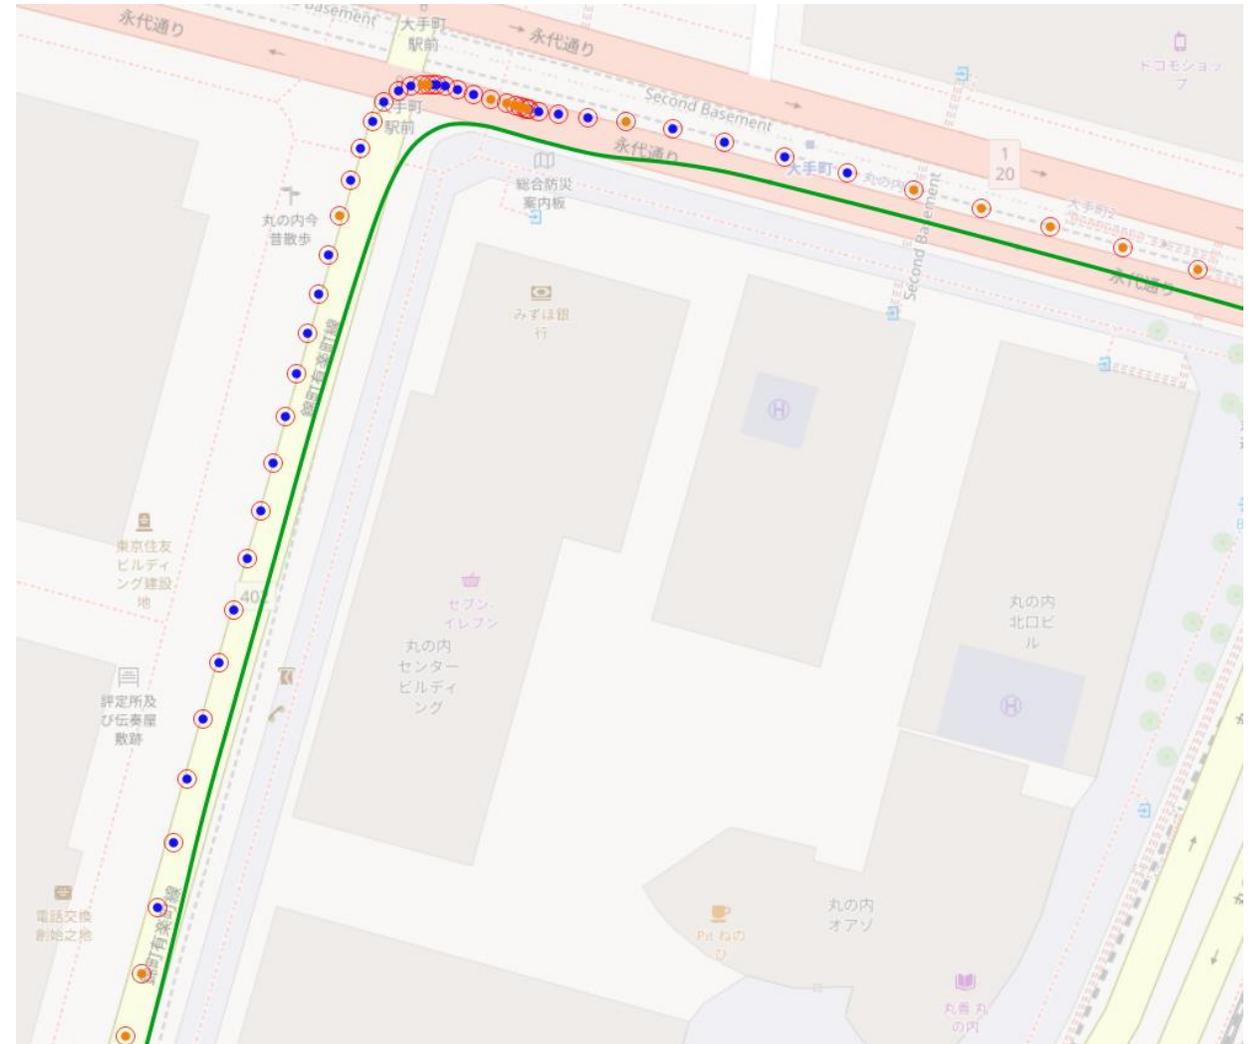
各組み合わせのTPR

5. 入力特徴量の調整による推定結果の改善

◆ 推定結果のプロット

F9RがミスFixしている箇所を正しくミスFixと判定できた例。

- POSLVXリファレンス
- F9R RTK Fix
- F9R RTK Float
- F9R DGNSS
- Prediction is correct



5. 入力特徴量の調整による推定結果の改善

◆ 推定結果のプロット

F9Rが正しくFixしている箇所を正しいFixと判定できた例。

- POSLVXリファレンス
- F9R RTK Fix
- F9R RTK Float
- F9R DGNSS
- Prediction is correct

正しいFixをミスFixと推定した

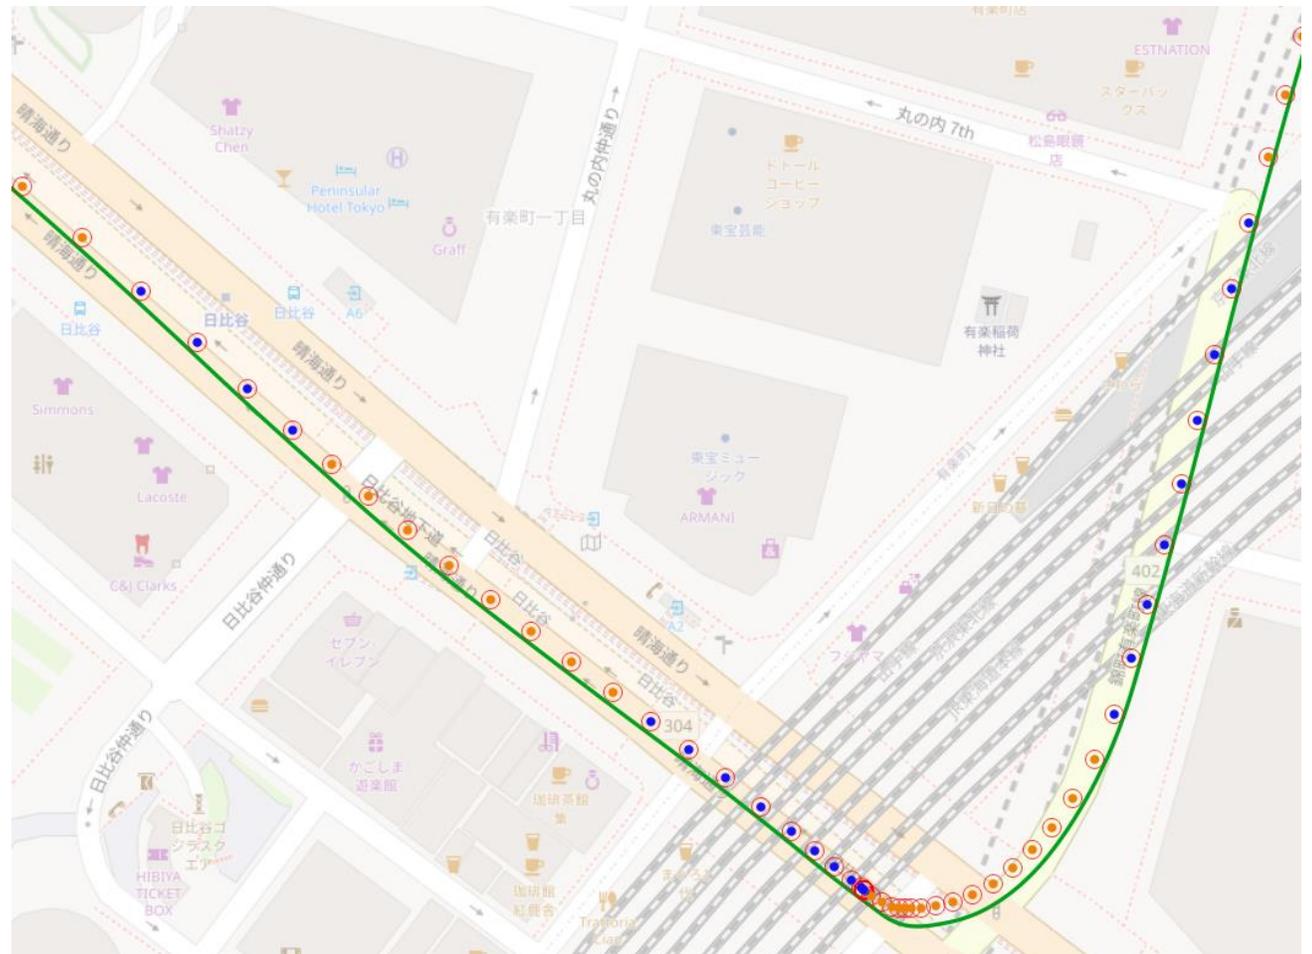


5. 入力特徴量の調整による推定結果の改善

◆ 推定結果のプロット

F9RがミスFixしている箇所を正しくミスFixと判定できた例。

- POSLVXリファレンス
- F9R RTK Fix
- F9R RTK Float
- F9R DGNSS
- Prediction is correct



6. まとめ

まとめ

- ◆ 低コスト受信機・IMUを使用した統合測位解はミスFix(30cm以上の誤差)を出力することがある。
- ◆ 統合測位解ではFixステータスと誤差の関連が小さいので、観測データと衛星可視状態を使用した深層学習で、F9Rの統合測位解がミスFixであるかどうかを推定した。
- ◆ 入力特徴量の組み合わせを変化させて推定精度の良い学習モデルを導き出した。
- ◆ 最終的に正答率78.6%、ROCのAUC=0.801で統合測位解(RTK Fixしなかった区間)のミスFixを推定できた。

今後の課題

- ◆ 推定精度をより向上させる入力特徴量がないか模索する。
- ◆ 深層学習のパラメーターなどを変化させて試行する。
- ◆ F9R以外の統合測位解でも同じような結果が得られるか調査する。