

3Dマップと機械学習を用いたRTK測位可用性の予測

2022/11/02


第66回宇宙科学連合会 OS-36 2108

東京海洋大学 小林海斗

1. 目的
2. 3Dマップを利用した衛星環境の予測
3. 機械学習用モデルの作成
4. K近傍法によるRTK測位ステータスの予測(多クラス分類)
5. K近傍法によるRTK測位ステータスの予測(二値分類)
6. ロジスティクス回帰分析によるRTK測位ステータスの予測(二値分類)
7. 考察とまとめ


1. 目的

- ◆ITS(Intelligent Transport Systems)や測量、ICTコンストラクションなどの分野では、cmレベルで自己位置を測位できるGNSS測位手法の1つ、RTK-GNSSが利用されている。
- ◆しかし、RTK測位はGNSS衛星からの「搬送波」を利用するため、衛星が良く観測できないような厳しい環境ではcm級の測位解を得られないことが多い。



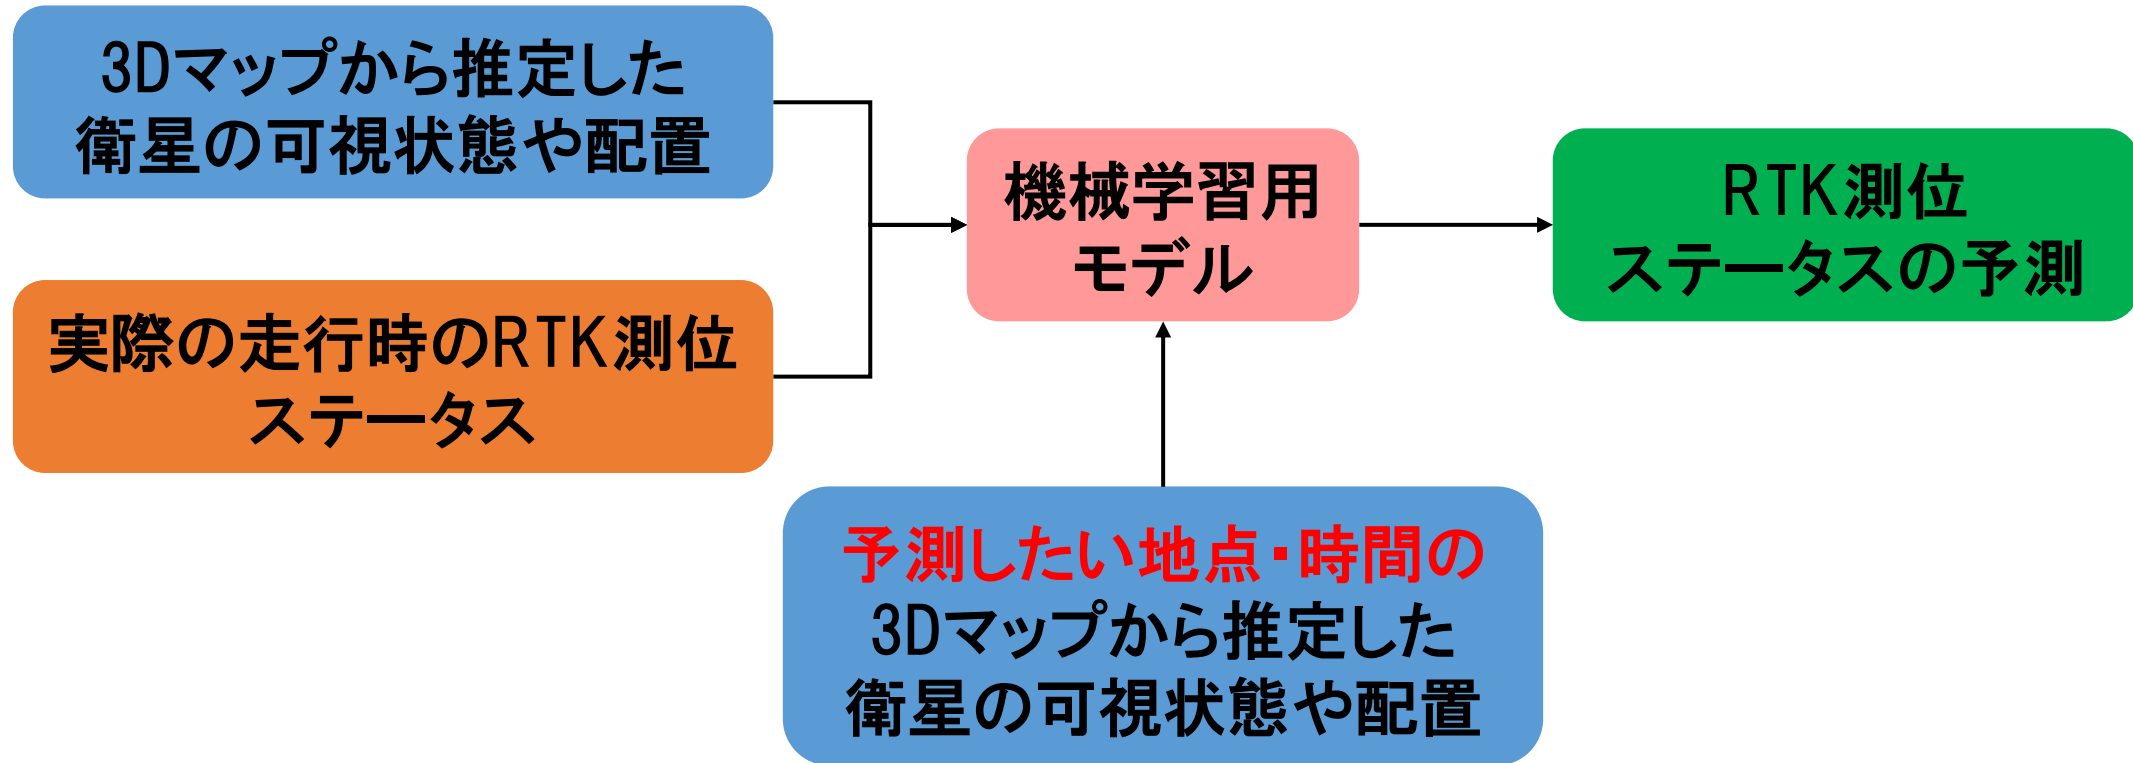
1. 目的

- ◆ RTKを行うときその解は3種類に分けられる。cmレベルを担保する解はRTK Fix解と呼ばれる。
- ◆ 任意の地点でどの解が得られるかどうかを予測するのは利用者の経験に頼ることが多い。
- ◆ しかし、自動運転や建設現場では事前にどこでRTK Fix解が得られ、どこで得られないかを知りたいという需要がある。
RTK Fixしない環境で高額な受信機類を導入しても意味がないため。



1. 目的

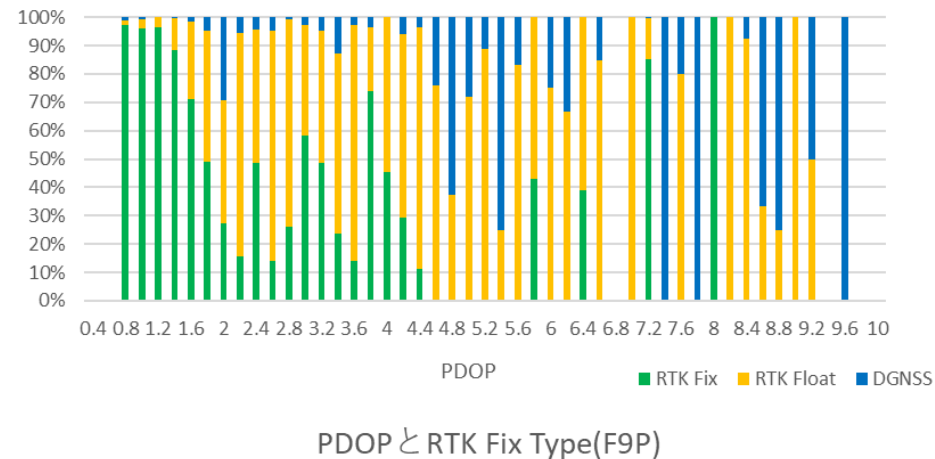
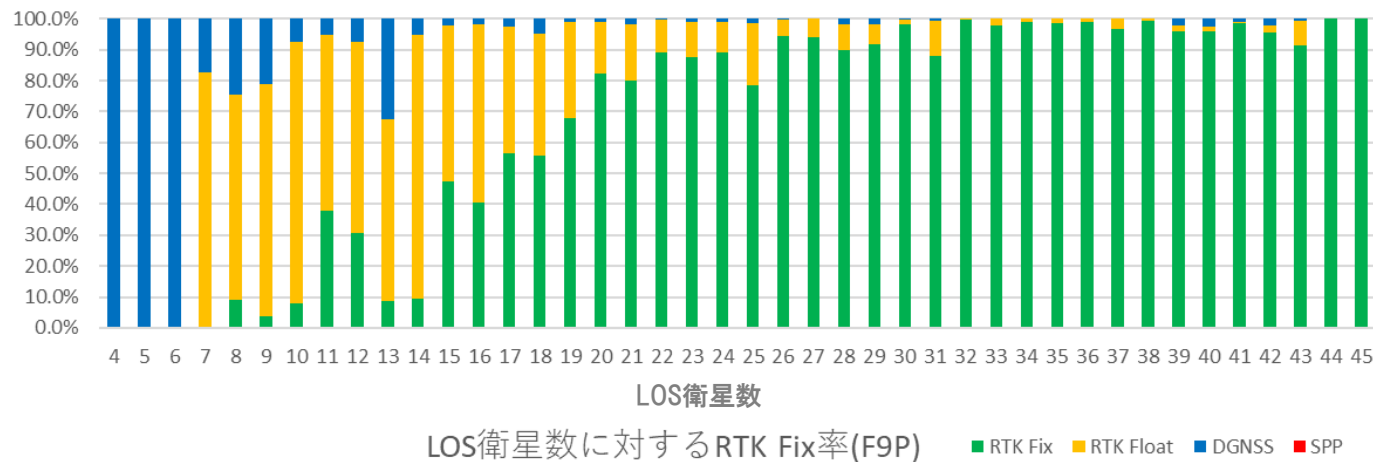


- ◆本研究では任意の場所でRTK Fix解が得られるかどうかを予測することを試みた。



- ◆事前にRTK Fix解が得られるか予測できることでRTKを利用したシステムの導入がしやすくなると考えられる。

2. 3Dマップを利用した衛星環境の予測



- ◆ 先行研究*より、LOS(Line-Of-Site)衛星の数やLOS衛星のDOPがRTK Fixの可能性と関連があることがわかっている。
- ◆ これの他にRTKの計算に重要な2重位相差の数や各仰角における衛星の数に関連する。



*Rei Furukawa and Nobuaki Kubo, "Prediction of Fixing of RTK-GNSS Positioning in Multipath Environment Using Radiowave Propagation Simulation", IPNTJ, Vol.10 No.2, 2019, pp13-22


2. 3Dマップを利用した衛星環境の予測

- ◆3Dマップは国土交通省の提供しているPLATEAU projectのマップを使用した。現在国内56都市の3Dマップデータが無償で公開されている。
- ◆今回は東京23区のDEM(Digital Elevation Map)、LOD1建物モデル、橋梁モデルの3種類を読み込み、使用した。
- ◆先行研究ではGPS-Studioというソフトを使用したけど、モデルの読み込み量に制限があったため、unityエンジンを使用してシミュレーションソフトを制作した。



2. 3Dマップを利用した衛星環境の予測


- ◆ 3Dマップ内に衛星配置と自己位置を呼び出し、Ray-casting法でLOS衛星とNLOS衛星の判別を行った。
- ◆ 衛星配置はアルマナックというGNSSの衛星軌道情報を使用した。これは1週間先までの衛星位置を仰角・方位角で0.001度以下の精度で予測できる。
- ◆ Ray-casting法は自己位置と衛星の間にRayを飛ばし、間に障害物があるかどうかを判別する方法。



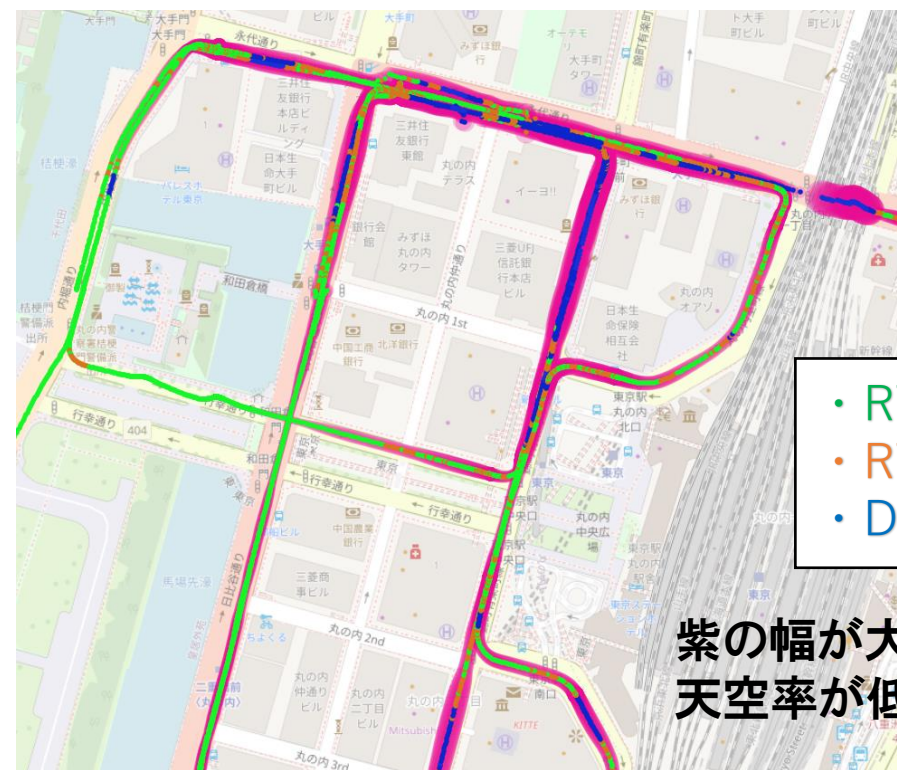
緑:LOS衛星
赤:NLOS衛星

2. 3Dマップを利用した衛星環境の予測

- ◆ 天空率もRay-casting法により計算した。
- ◆ 2度グリッドで上空を分割し、Rayが障害物に当たらなかった割合を天空率とした。
- ◆ 天空率 = $\frac{\sum no_blocked}{180 \times 45}$



天空率の計算イメージ
(実際は2度グリッドで計算)



紫の幅が大きいほど
天空率が低い

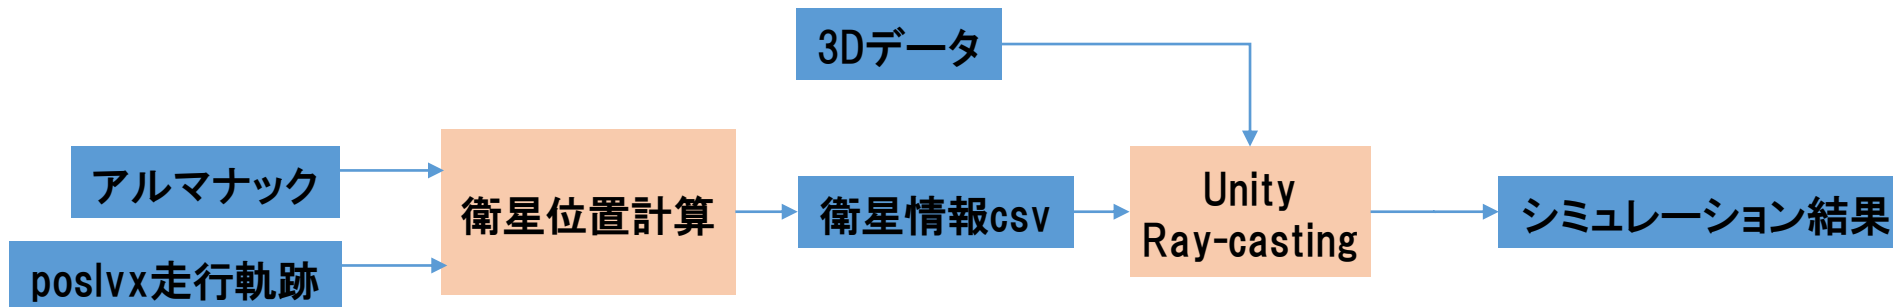
Fixタイプと天空率

2. 3Dマップを利用した衛星環境の予測

- ◆通常のGNSS測位の座標で3Dモデル内の走行軌跡を作成するとGNSSの誤差で間違ったシミュレーション結果になってしまう。
- ◆そのため走行軌跡の取得にはPOSLVXというRTK-GNSS+ヘディングセンサー+INS+速度センサーが組み合わさったリファレンスシステムを使用した。
- ◆衛星環境のシミュレーション結果として右表の内容を出力した。

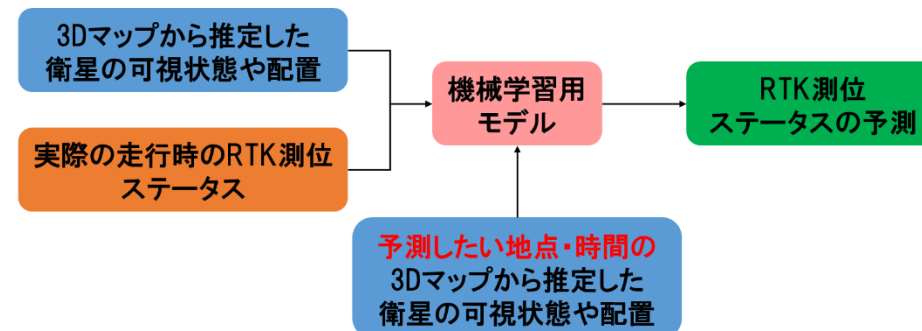
各衛星システムでの二重位相差の数

LOS_n	NLOS_n	PDOP	sky rate	GQ	E	C	R
22	18	1.473134	0.678333	3	3	2	10
22	18	1.473141	0.683889	3	3	2	10
23	17	1.431935	0.684167	4	3	2	10
23	17	1.431943	0.687083	4	3	2	10
23	17	1.431953	0.692222	4	3	2	10
23	17	1.431962	0.692361	4	3	2	10
23	17	1.43197	0.695833	4	3	2	10

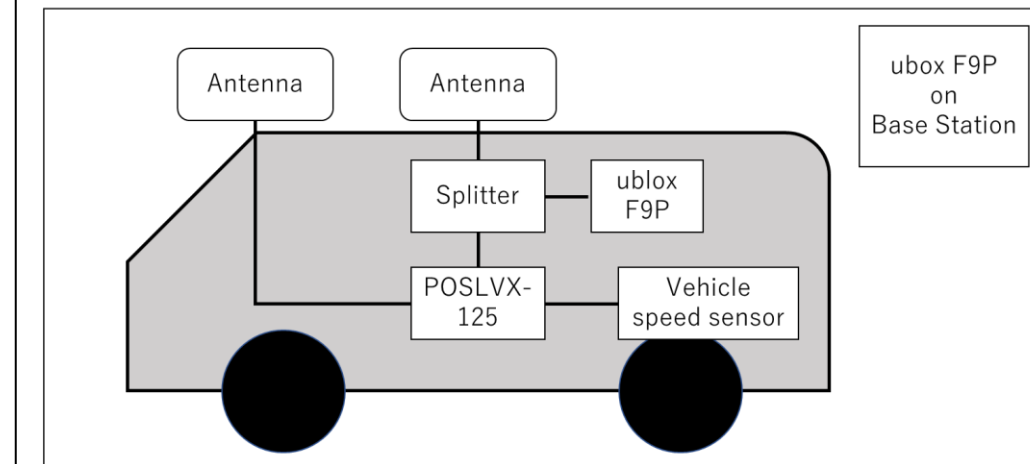


3. 機械学習用モデルの作成

- ◆ 3Dマップから推定した衛星の可視状態や配置と実際の走行時のRTK測位ステータスを組み合わせて機械学習用モデルを作成する。
- ◆ 走行データの取得は
 - ・ F9P受信機 (RTK測位用)
 - ・ POSLVX (→正しい走行軌跡)を搭載した車両で行った。
- ◆ 走行時には9P内部のRTKはフィルターが入るため、RTKは瞬時ARを使用した後処理で行った。


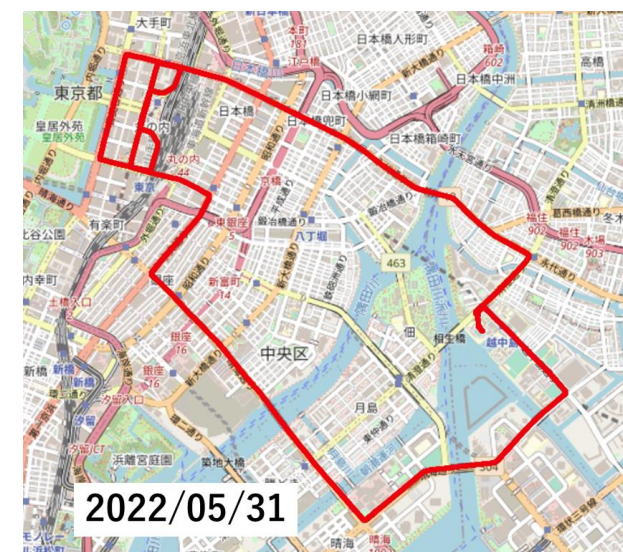
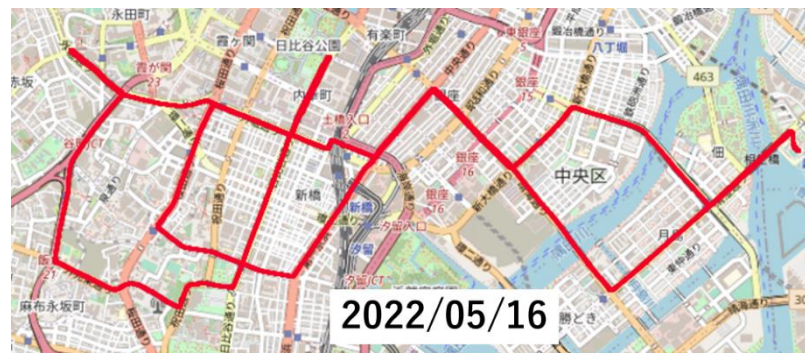
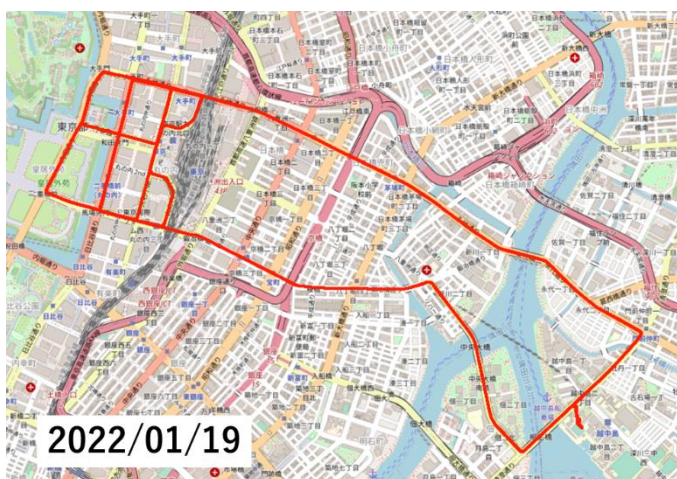


Name	Detail
ublox F9P	Dual-Frequency multi GNSS RTK receiver
POSLVX-125	High accuracy positioning system for reference
AT1675-540TS	GNSS triple frequency antenna



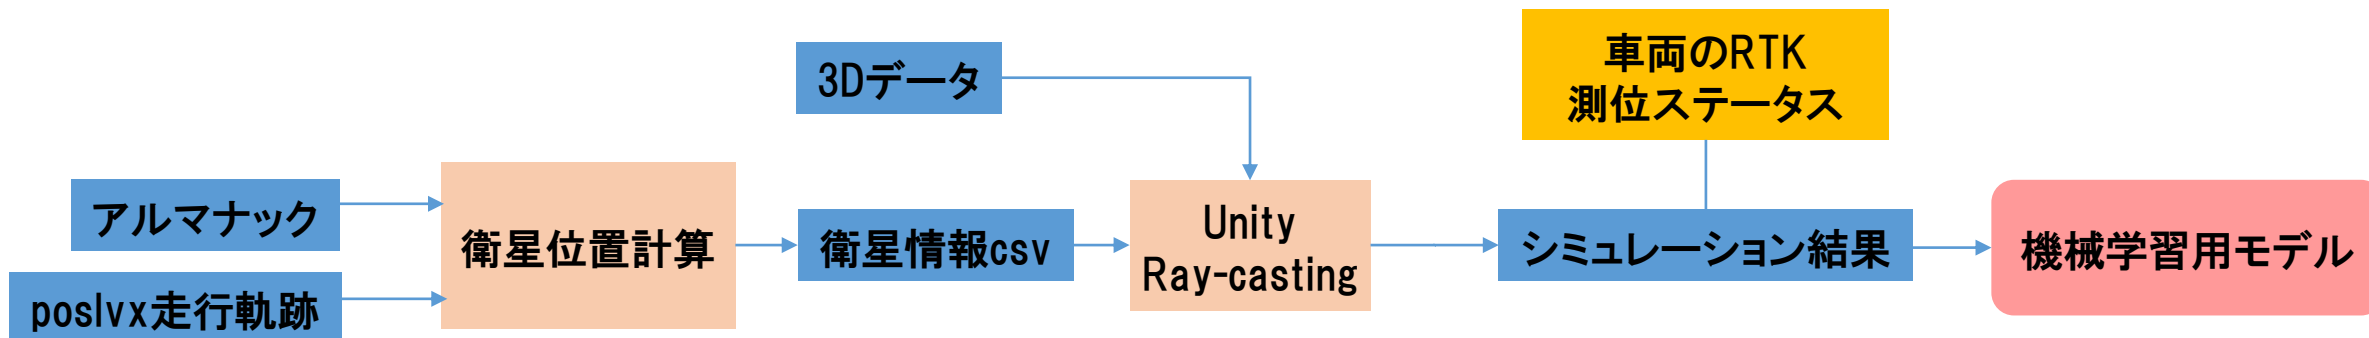
3. 機械学習用モデルの作成

- ◆ PLATEAUで3Dマップが整理されている東京23区内で5回走行した。同じ道路の走行はできるだけ避けた。
- ◆ 総走行時間は約3時間で、5Hzでデータを取得したためデータ数は83539個だった。



3. 機械学習用モデルの作成

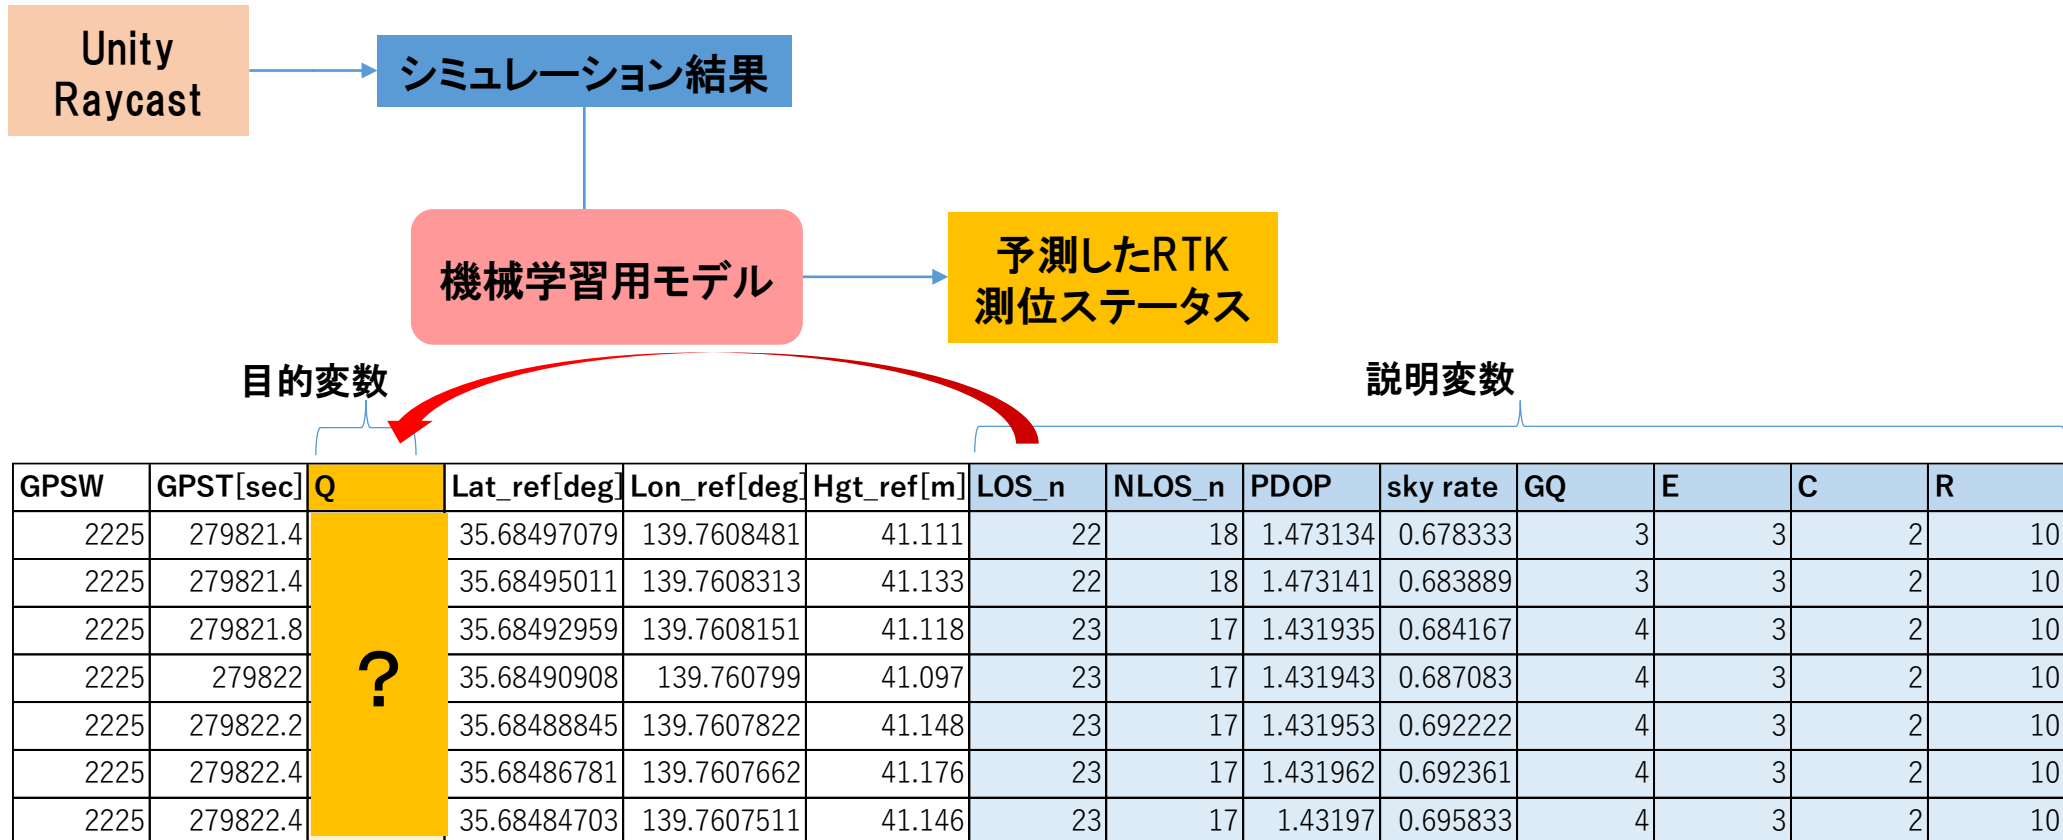
- ◆まずPOSLVXの正しい走行軌跡を利用して、走行中の衛星環境を3Dマップで推定した。
- ◆次に3Dマップで推定した衛星環境とその時の車両のRTK測位ステータスを紐づけした。



		目的変数		説明変数										
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	1	35.68497079	139.7608481	41.111	22	18	1.473134	0.678333	3	3	2	10	
2225	279821.4	1	35.68495011	139.7608313	41.133	22	18	1.473141	0.683889	3	3	2	10	
2225	279821.8	1	35.68492959	139.7608151	41.118	23	17	1.431935	0.684167	4	3	2	10	
2225	279822	1	35.68490908	139.760799	41.097	23	17	1.431943	0.687083	4	3	2	10	
2225	279822.2	1	35.68488845	139.7607822	41.148	23	17	1.431953	0.692222	4	3	2	10	
2225	279822.4	1	35.68486781	139.7607662	41.176	23	17	1.431962	0.692361	4	3	2	10	
2225	279822.4	1	35.68484703	139.7607511	41.146	23	17	1.43197	0.695833	4	3	2	10	

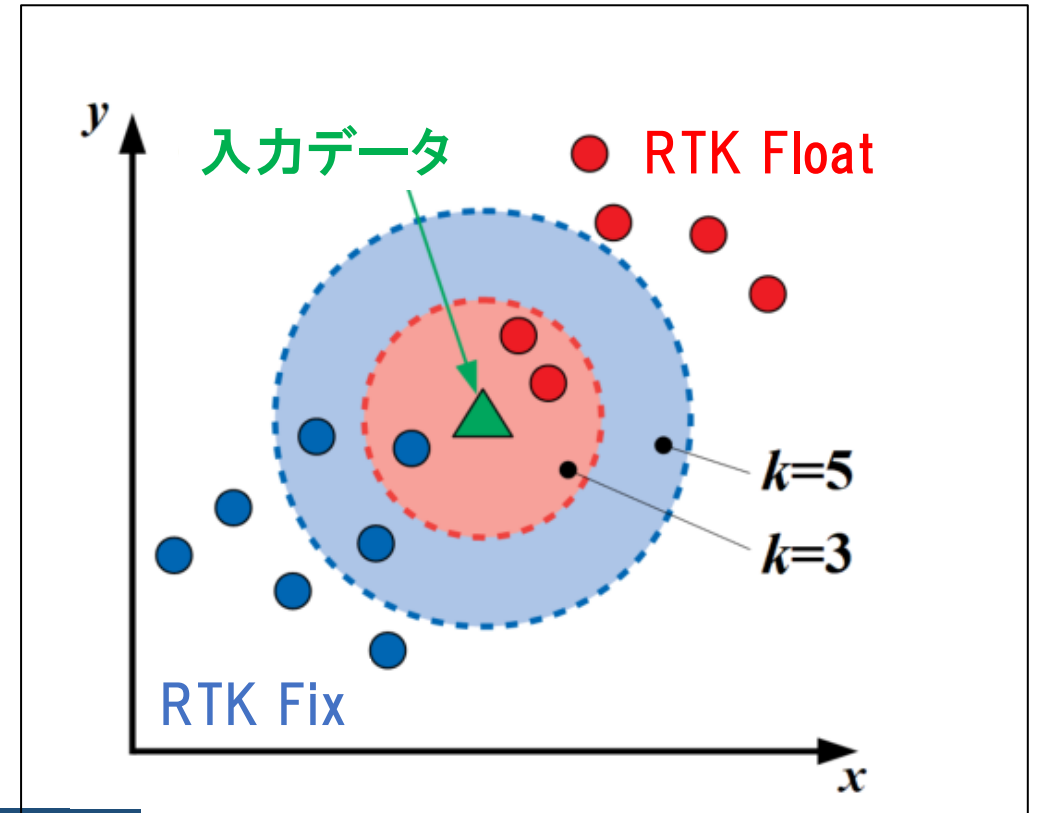
4. K近傍法によるRTK測位ステータスの予測

- ◆機械学習では原因側のデータを説明変数、結果として欲しいデータを目的変数と呼ぶ。
- ◆今回は3Dマップで推定した衛星環境が説明変数でRTK測位ステータス(Q)が目的変数となる。



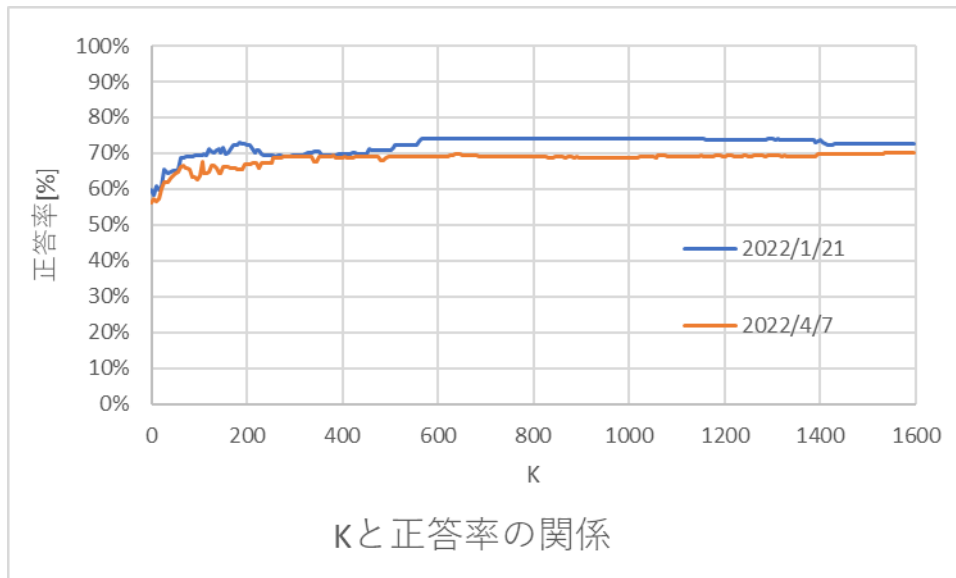
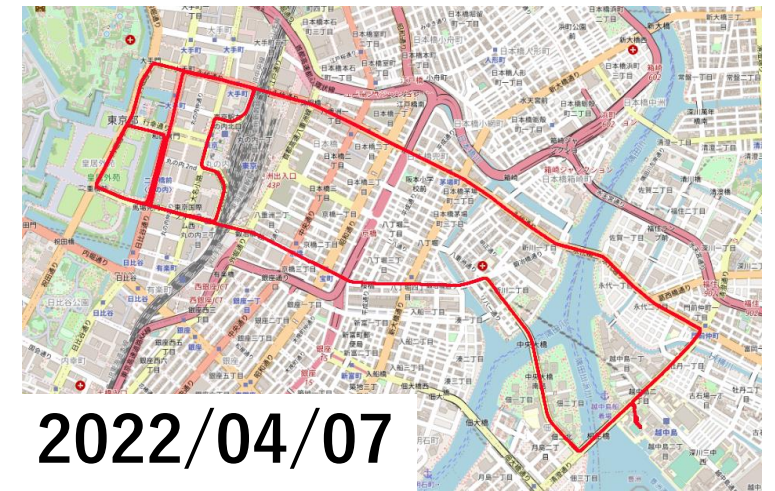
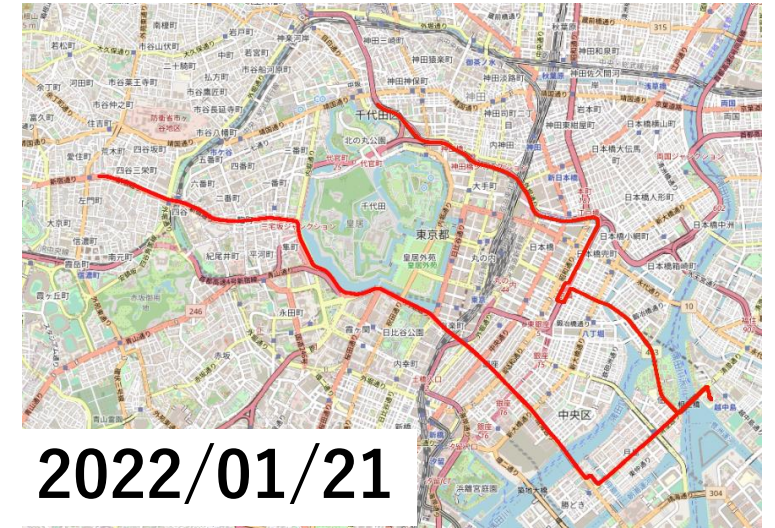
4. K近傍法によるRTK測位ステータスの予測(多クラス分類)

- ◆ 複数の説明変数から複数の目的変数を推測する問題は **多クラス分類** と呼ばれる。
- ◆ 目的変数は
 - ・ RTK Fix
 - ・ RTK Float
 - ・ DGNSの三種類存在する。
- ◆ 今回はK近傍法という手法を利用した。K近傍法では入力データの周囲K個のサンプルを参照して多数決で目的変数を決定する。



4. K近傍法によるRTK測位ステータスの予測(多クラス分類)

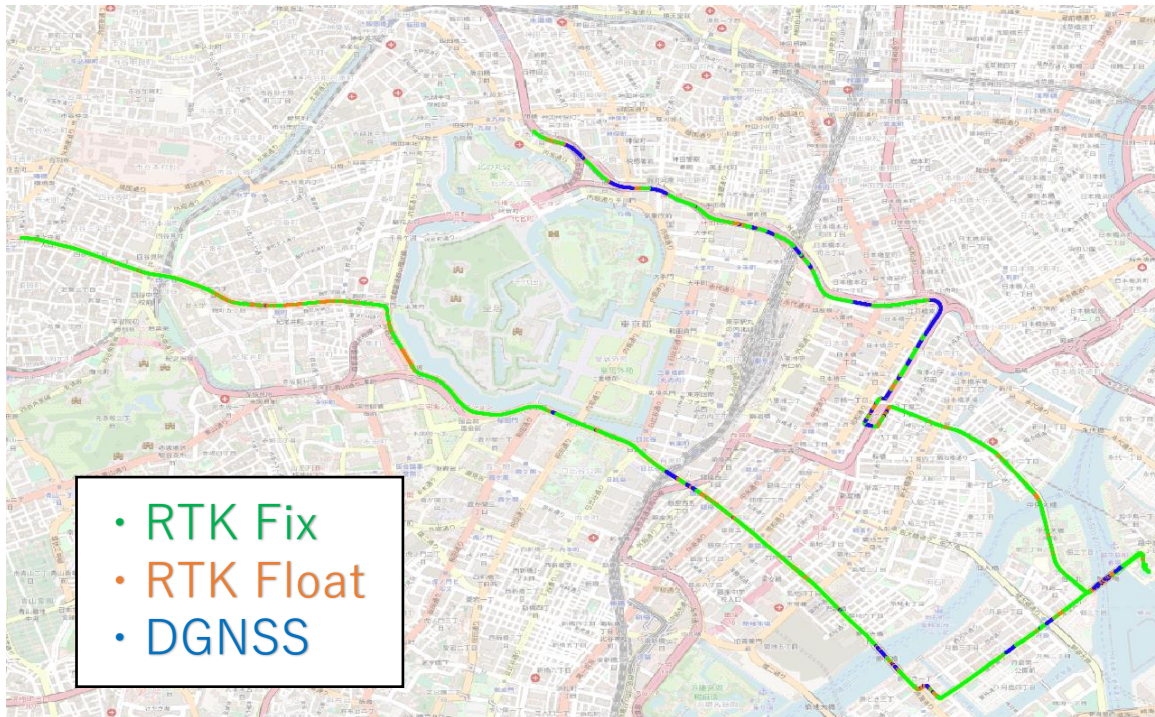
- ◆テストデータには2022/01/21と2022/04/07のデータを使用した。
- ◆K近傍法を使う上で今回用意した教師データではどの程度のKの値が相応しいかわからないので、Kを1~400までの範囲で変化させそれぞれの正答率を確認した。
- ◆Kを増やすと正答率が増加するが、K=600くらいからは横ばいになる。
- ◆このため今回はK=800で予測を行った。



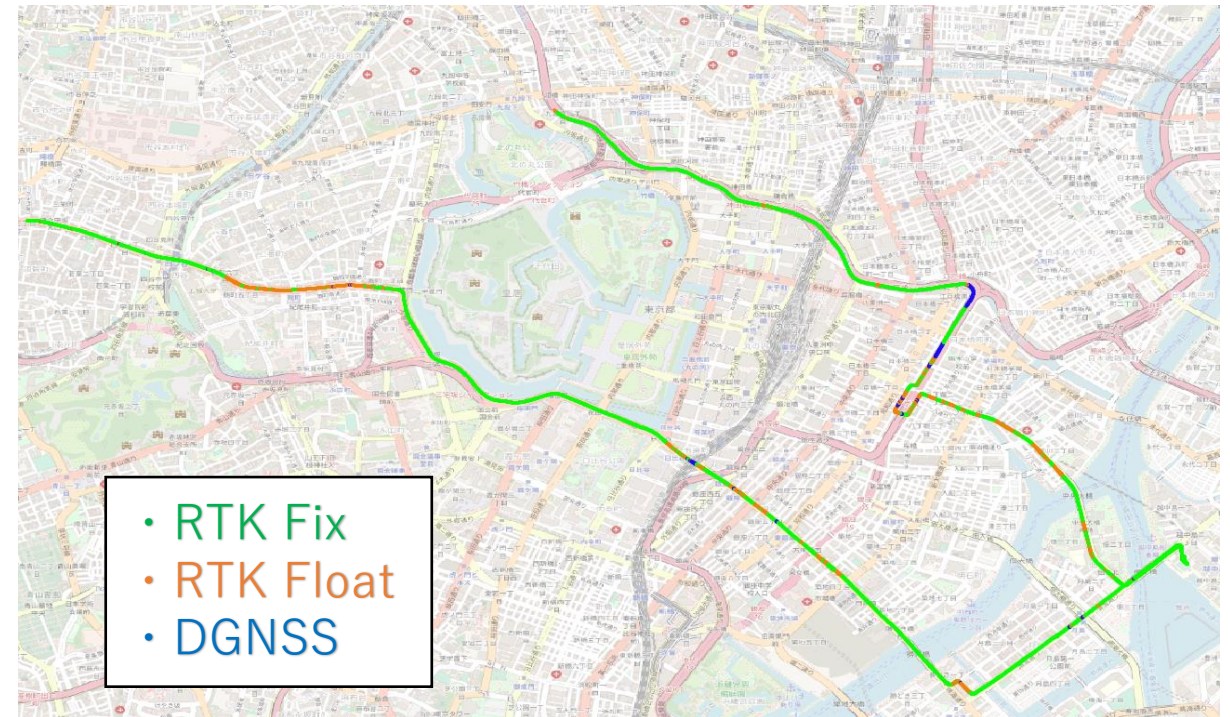
4. K近傍法によるRTK測位ステータスの予測(多クラス分類)

◆2022/01/21データの評価

Fix Type	RTK[epoch]	Prediction is correct[epoch]	Accuracy[%]
RTK Fix	8502	7319	86.1%
RTK Float	2608	1431	54.9%
DGNSS	891	141	15.8%
Total	12001	8891	74.1%



実際の測位ステータス




予測した測位ステータス

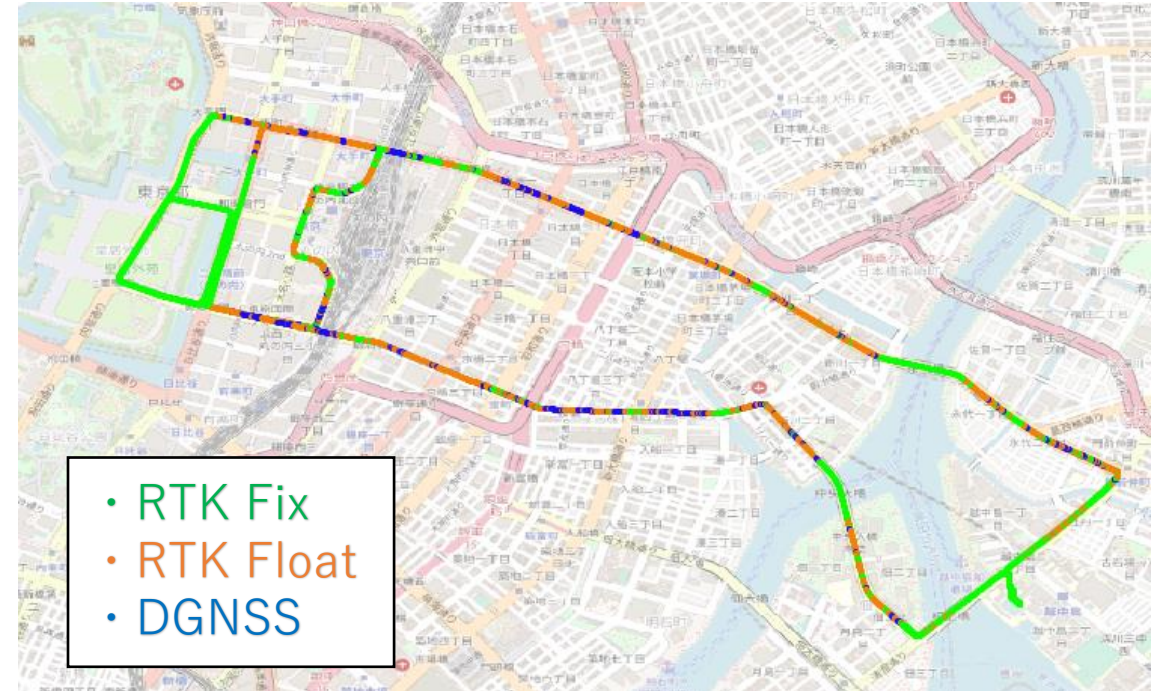
4. K近傍法によるRTK測位ステータスの予測(多クラス分類)

◆2022/04/07データの評価

Fix Type	RTK[epoch]	Prediction is correct[epoch]	Accuracy[%]
RTK Fix	11041	8334	75.5%
RTK Float	4221	2955	70.0%
DGNSS	1323	189	14.3%
Total	16585	11478	69.2%




実際の測位ステータス



予測した測位ステータス

5. K近傍法によるRTK測位ステータスの予測(二値分類)

- ◆4/7の予測結果からFloat解とDGNSS解の区別が現在のアルゴリズムでは難しいことがわかった。
- ◆3値の他クラス分類からRTK FixするORしないの二値分類に変更して予測を試みた。

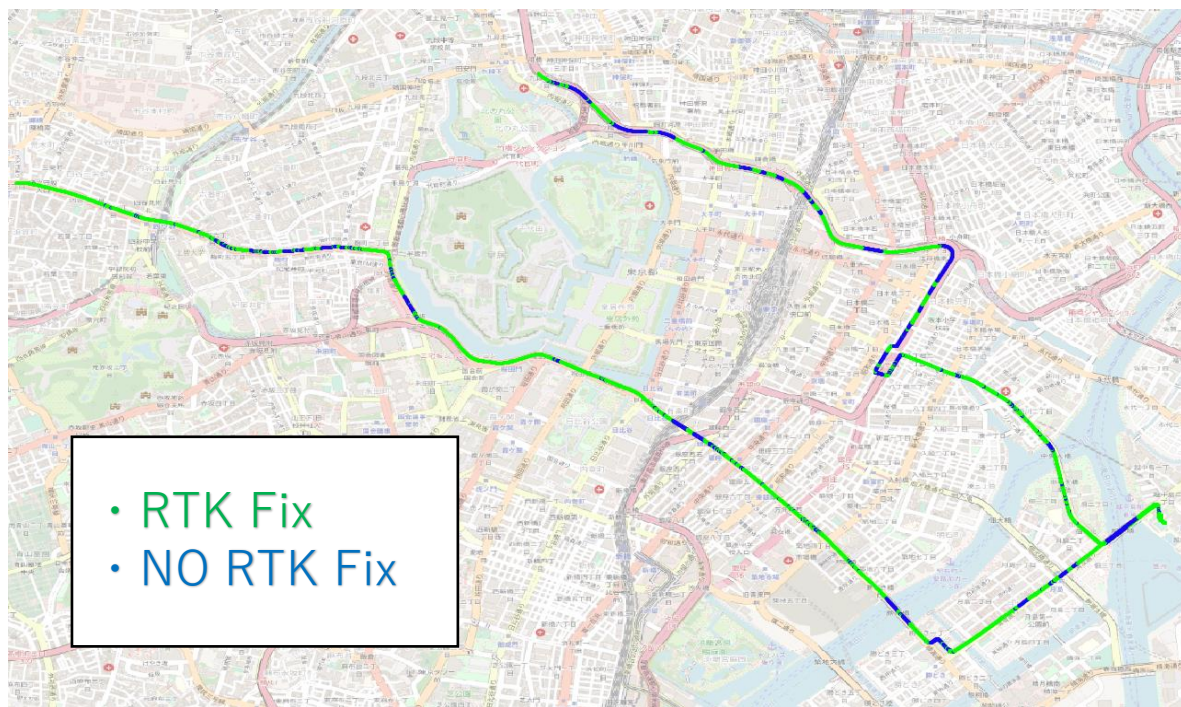


- ◆二値化は機械学習前のデータセットの段階で行っている。
- ◆まずK近傍法を利用した。Kの値は多クラス分類のときと同じくK=800とした。

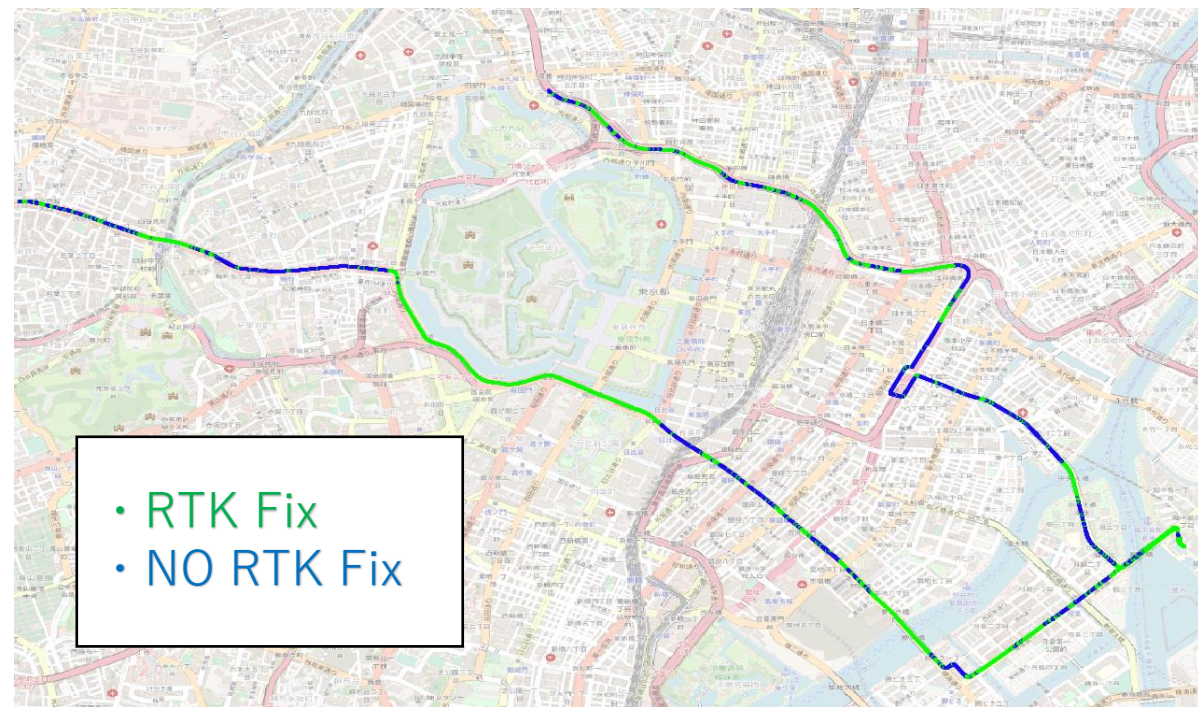
5. K近傍法によるRTK測位ステータスの予測(二値分類)

◆2022/01/21データの評価

Fix Type	RTK[epoch]	Prediction is correct[epoch]	Accuracy[%]
RTK Fix	8502	6008	70.7%
No RTK Fix	3499	2332	66.6%
Total	12001	8340	69.5%



実際の測位ステータス

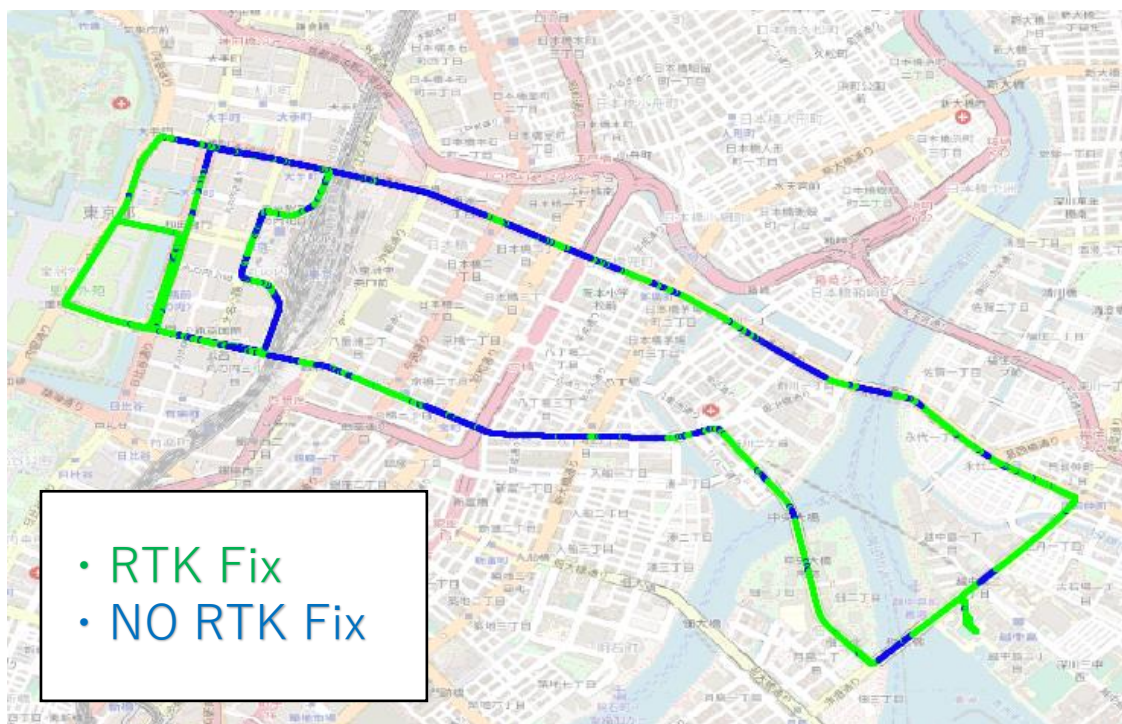


予測した測位ステータス


5. K近傍法によるRTK測位ステータスの予測(二値分類)

◆2022/04/07データの評価

Fix Type	RTK[epoch]	Prediction is correct[epoch]	Accuracy[%]
RTK Fix	11041	7099	64.3%
No RTK Fix	5544	4945	89.2%
Total	16585	12044	72.6%



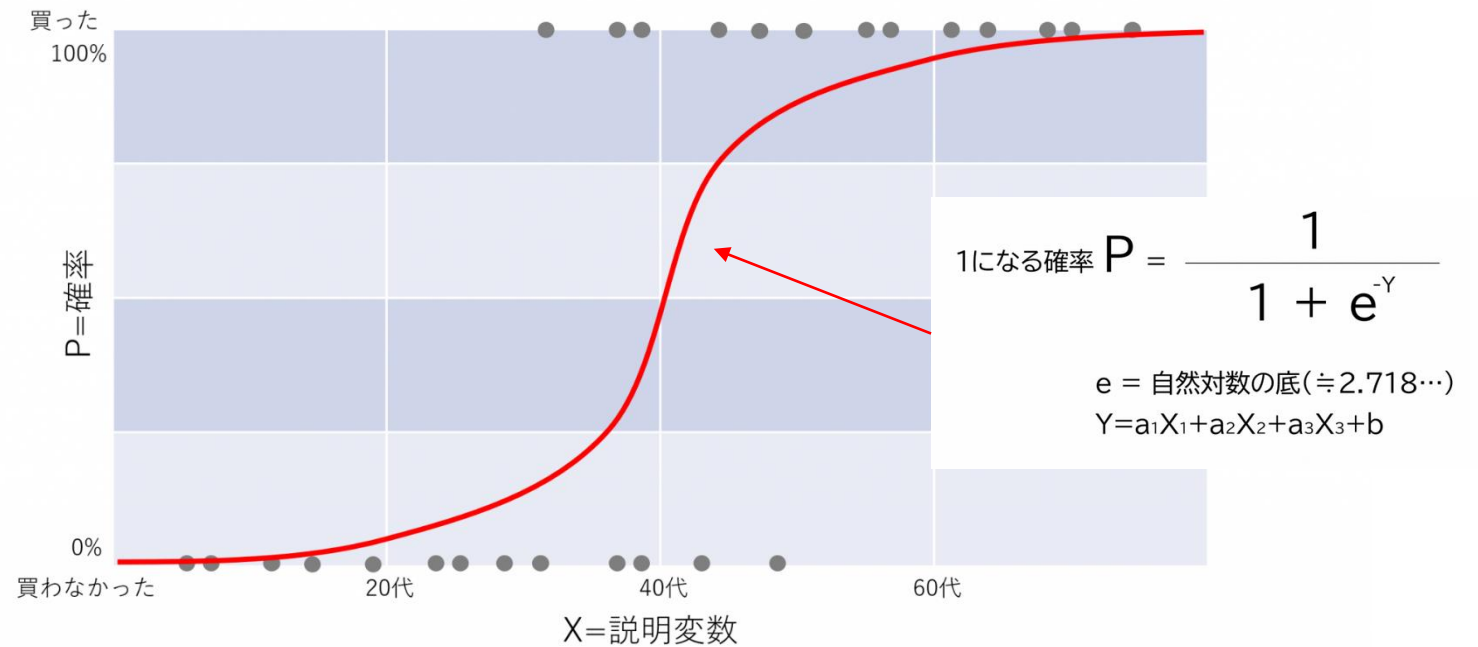
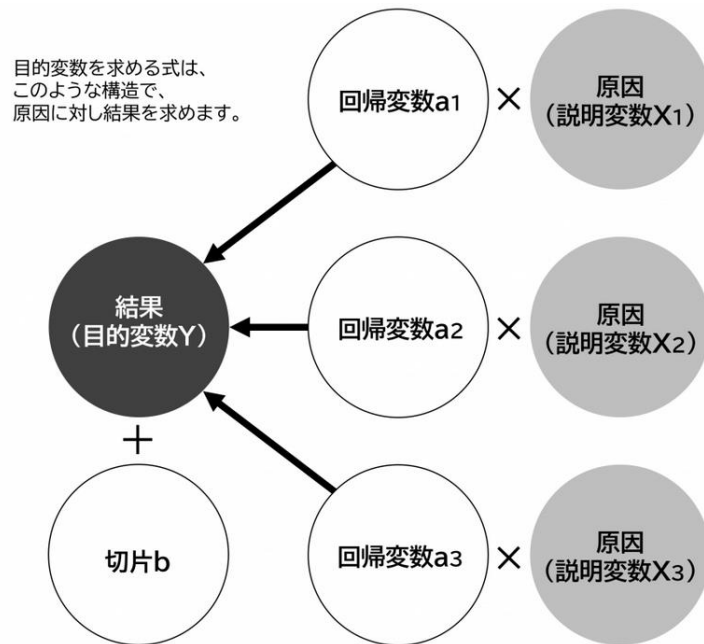
実際の測位ステータス



予測した測位ステータス

6. ロジスティクス回帰分析によるRTK測位ステータスの予測(二値分類)

- ◆二値分類ではロジスティクス回帰分析という分類アルゴリズムも使用できるため、これについても評価を行った。
- ◆ロジスティクス曲線によって1か0になるかの確率Pを求め、その確率から0と1に分類する。

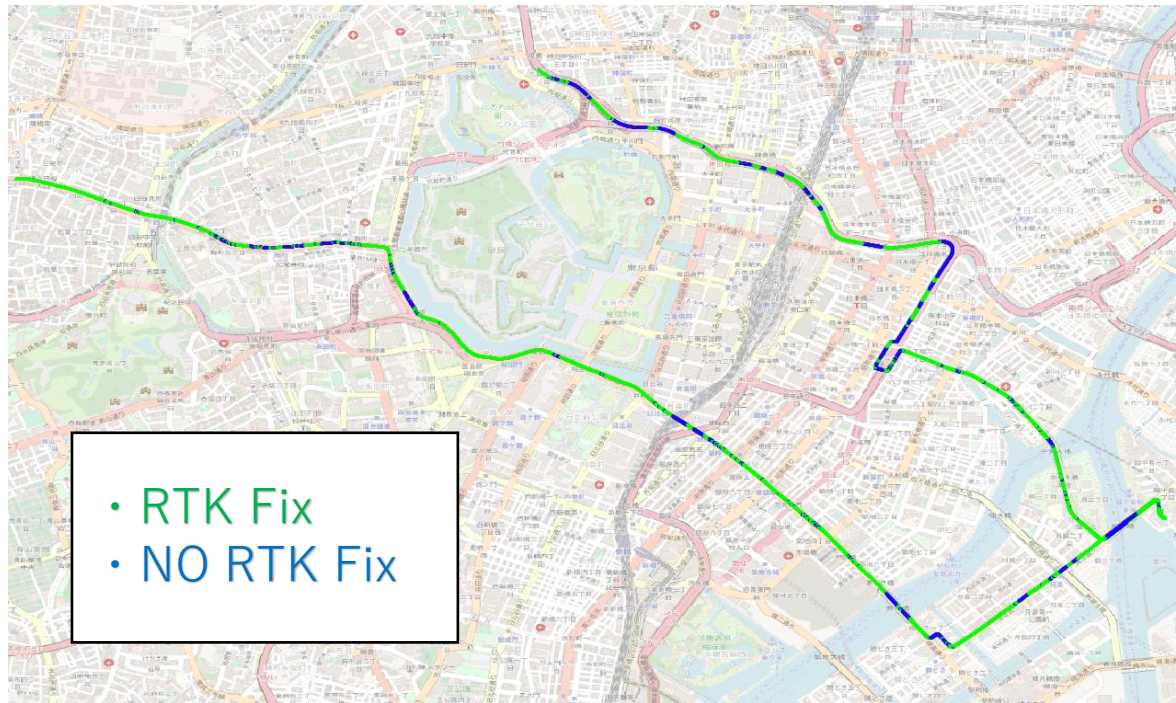


* <https://mktg.xfader.jp/2022/04/12/4437/>

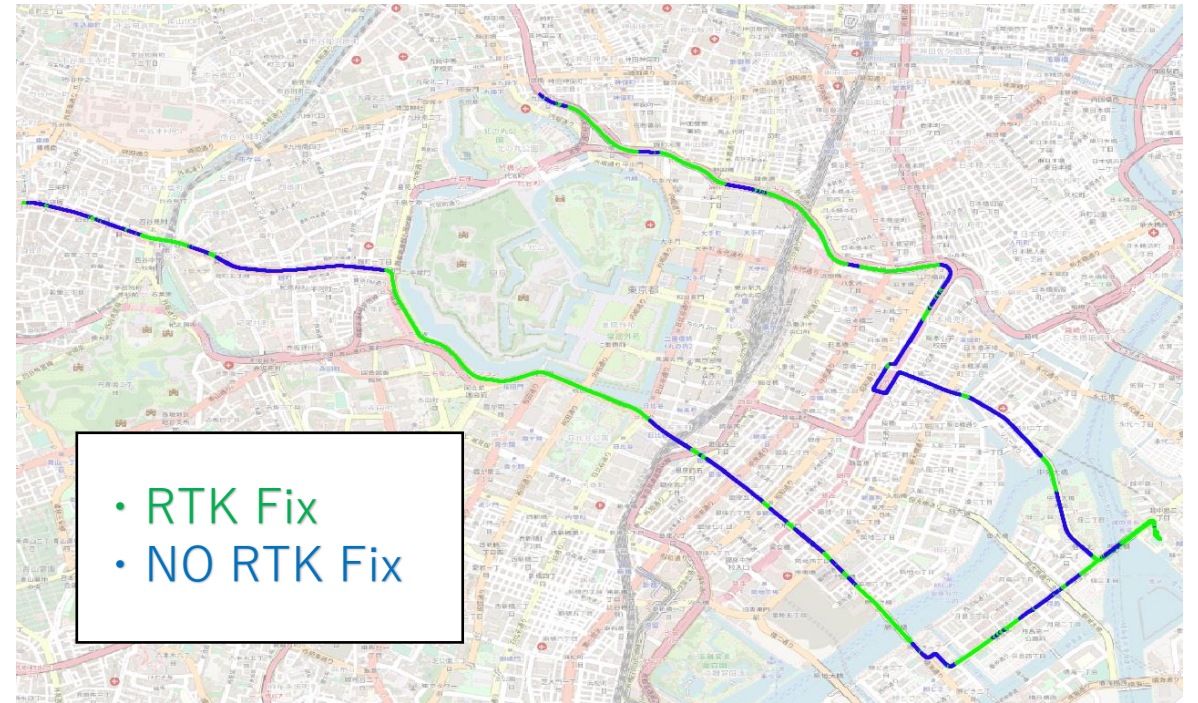
6. ロジスティクス回帰分析によるRTK測位ステータスの予測(二値分類)

◆2022/01/21データの評価

Fix Type	RTK[epoch]	Prediction is correct[epoch]	Accuracy[%]
RTK Fix	8502	6370	74.9%
No RTK Fix	3499	2334	66.7%
Total	12001	8704	72.5%



実際の測位ステータス

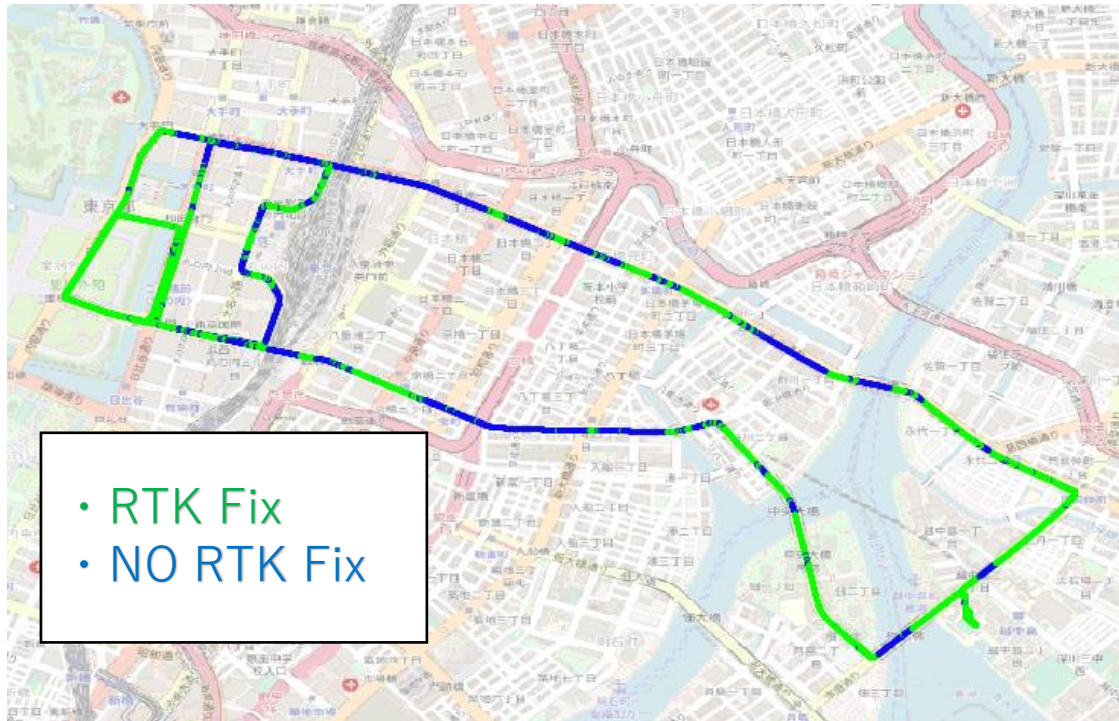


予測した測位ステータス

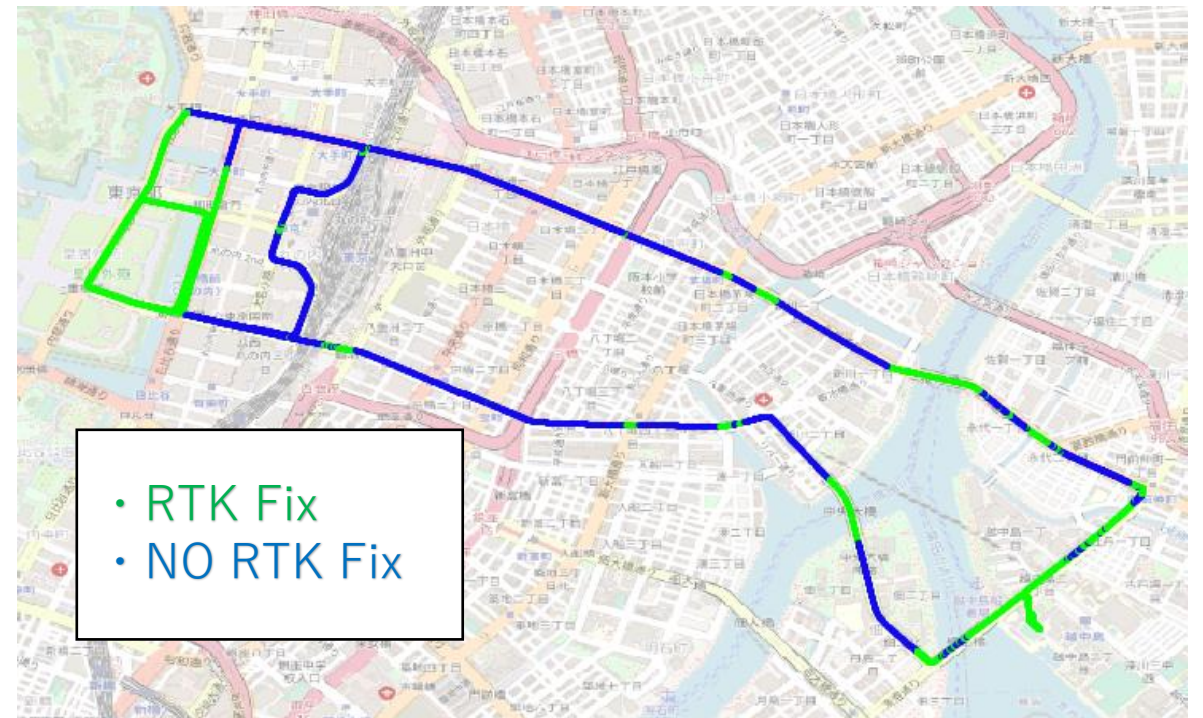
6. ロジスティクス回帰分析によるRTK測位ステータスの予測(二値分類)

◆2022/04/07データの評価

Fix Type	RTK[epoch]	Prediction is correct[epoch]	Accuracy[%]
RTK Fix	11041	6640	60.1%
No RTK Fix	5544	5121	92.4%
Total	16585	11761	70.9%



実際の測位ステータス



予測した測位ステータス

6. ロジスティクス回帰分析によるRTK測位ステータスの予測(二値分類)

- ◆二種類の二値分類手法での予測精度をROC曲線で比較する。
- ◆ROC曲線は真陽性率(TPR)と偽陽性率(FPR)でプロットできる。

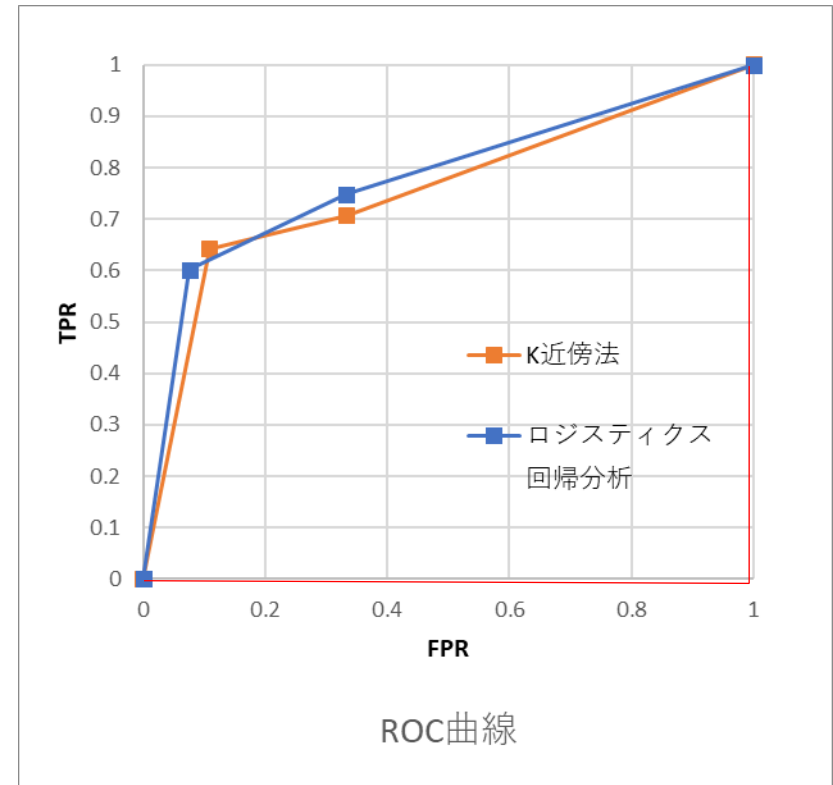
$$TPR = \frac{\text{RTK Fixの予測が正しかったエポック数}}{\text{実際にRTK Fixだったエポック数}}$$

$$FPR = \frac{\text{No RTK FixをRTK Fixとしてしまったエポック数}}{\text{実際にNo RTK Fixだったエポック数}}$$

- ◆グラフと赤線で囲んだ部分の面積が大きいほど予測精度が高いとされるが今回の評価ではロジスティクス回帰のほうが若干精度がよかった。

	K近傍法	
	FPR	TPR
	0	0
4月7日	11%	64%
1月21日	33%	71%
	1	1

	ロジスティクス回帰分析	
	FPR	TPR
	0	0
4月7日	8%	60%
1月21日	33%	75%
	1	1



7. まとめと今後の課題

まとめ

- ◆3Dマップから推測した衛星環境を説明変数とした機械学習で70%程度でRTKの測位ステータスを予測できた。
- ◆2つのアルゴリズムを試したが総合的な優劣をつけることはできなかった。

今後の課題

- ◆テストデータによって予測精度が異なるため交差検証を行う。
- ◆今回使用した以外のRTK測位ステータスに關与するパラメーターを予測に使用できないか検討する。