

機械学習による NLOS 検知モデルの構築と 移動体測位への適用に向けた検討

Development of a NLOS Signals Detection model by Machine Learning and its Application to mobile positioning

谷村晴生, 辻井利昭

大阪公立大学

Haruki Tanimura, Toshiaki Tsujii

Osaka Metropolitan University

Abstract In urban areas, the accuracy of GNSS positioning is degraded by the reception of reflected signals. This research aims to improve positioning accuracy by detecting and removing reflected signals using machine learning. In addition, we have also investigated a new classification index for mobile receivers.

1 はじめに

1.1 研究背景

現在 GNSS(Global Navigation Satellite System)は、カーナビゲーションやスマートフォンの位置情報など様々な分野で使用されており、人々の生活に欠かせないものとなっている。また、近年ではドローンの自律飛行にも GNSS 測位が活用されており、レベル 4 と呼ばれる有人地帯での目視外での自律飛行が実現することにより、配送やインフラ点検、災害支援などでの活躍が期待される[1]。しかしながら、都市部などの高層建築物が多い環境においては、壁面等で反射した GNSS 信号を受信してしまうことにより測位精度が大きく劣化してしまうという問題が生じる。都市部でのドローンの自律飛行を想定するにあたり、安全性の観点から測位精度の改善は非常に重要な課題となっている。

1.2 研究目的

GNSS 測位において反射波の影響を低減する手法として様々な手法が提案されている。例えば、プレーンアンテナを用いて反射波到来方向のゲインを下げることで反射波の影響を低減するという手法がある。他にも、3Dmap を用いることで幾何学的に反射波を予め検知するという手法がある。

以上の手法以外にも多くの手法が検討されているが、いずれの場合においても別途高性能で高価な機器が必要な場合が多く、一般に広く利用されるドローンに搭載することを考慮すると適切な手法とは言えない。ドローンに搭載する測位機器は、小型で廉価であることが望ましい。そこで、本研究では機械学習を用いることで、一般的なアンテナと受信機のみで用いることができる反射波検知モデルの構築を試みた。また、作成したモデルを実際の測位に適用し、検知された反射波を測位から除外することで測位精度を向上させることを目的としている。

2 反射波による測位誤差

GNSS 信号は大きく 3 つの信号形態に分けることができる(図 1)。直接波のみを受信している LOS(line-of-sight), 直接波と反射波を受信している Multipath, 反射波のみを受信している NLOS(non-line-of-sight)である。反射波を受信している Multipath と NLOS には誤差が含まれており, Multipath は低減すること, NLOS においては測位に利用しないことが望ましいとされている。

Multipath 環境においては, 反射によって伝搬される距離が直接波よりも長いため, 反射波の受信時刻は直接波に対して遅れることになる。拡散されたコードのシンボル長の 2 倍よりも長い場合, 受信機は Multipath を容易に判別することができる。受信機が直接波を追尾している限り, そのように大きく遅延して到来する反射波は受信機の性能にほとんど影響を与えない。しかし, 数十, 数百 ns の短時間だけ遅れて到来する反射波は, 受信機内部で生成するレプリカコードと受信した信号の相関波形をひずませる。遅れてくる距離に応じて誤差は変化するものの, 上限はある。

直接波が受信されない NLOS 環境においては, 誤差の上限は無限大であり, 大きな誤差が生じる場合が多い。そのため, NLOS 衛星を測位から除外することによって, 測位精度が向上することが期待できる。

本研究においては, 直接波を受信している LOS と Multipath をまとめて DLOS(direct-line-of-sight)とする。そして, 測位に最も影響を及ぼす NLOS 衛星を機械学習によって検知し, 測位から除去した。




図1 衛星信号の分類について

3 機械学習のアルゴリズム

3.1 ランダムフォレスト

本研究では, NLOS 検知モデルを作成する学習アルゴリズムとしてランダムフォレストを用いた。ランダムフォレストは決定木という学習アルゴリズムを組み合わせたアンサンブル学習の一種である。アンサンブル学習とは, 複数の学習アルゴリズムを組み合わせることで 1 つの学習モデルを作成する方法であり, ランダムフォレストでは複数の決定木を組み合わせることで, 単純な構造で分類性能, 汎化性能ともに優れている。ランダムフォレストの概略図を図 2 に示す。ランダムフォレストのアルゴリズム作成, 運用は大きく次の 4 つの手順に分けることができる。

- ① データの母集団から重複込みでランダムにデータを取り出す（ブートストラップ法）
- ② 取り出した各データから決定木を成長させる
- ③ 手順①，②を作成する決定木の数だけ繰り返す
- ④ 決定木ごとの予測をまとめ，多数決に基づいてクラスラベルに割り当てる

このブートストラップ法を用いたアンサンブル学習の構築手法はバギングと呼ばれ，ランダムフォレストを構築するうえで主流な方法である。この手法では，複数の予測結果を使うことによって，予測値の散らばりを減らすことができる。また，ランダムフォレストにおいては，決定木の分岐に用いる特徴量もランダムに選択される。これによって，異なる決定木どうしが似通って予測精度が低下することを防ぐことができる。

3.2 決定木

決定木において，分岐の条件となる部分をノードと呼び，決定木の分類を示す末節の部分を葉と呼ぶ。それぞれのノードでどのように進むべきかの条件を与えられ，葉に最終的な出力結果が対応付けられる（図 3）。決定木はモデル学習の際に得られるノードの条件を把握できるため，作成したモデルがブラックボックスになりにくい。また，モデル構築の際に利用される情報利得から特徴量ごとの重要度を算出することができ，特徴量の評価を行いやすい。その他にも，統計的な検定を行い，モデルの性能を簡単に確かめることができるという長所がある。

決定木の学習は情報利得の最大化に基づいて行われる。情報利得(IG)は次のように定義される。

$$IG(D_p, f) = I(D_p) - \sum_{j=1}^m \frac{N_j}{N_p} I(D_j) \quad (1)$$

ここで， f は分割を行う特徴量であり， D_p は親のデータセット， D_j は j 番目の子ノードのデータセットである。 I は不純度を数値化したものであり， N_p は親ノードのサンプルの総数， N_j は j 番目の子ノードのサンプル数である。不純度はノードが純粋でない度合いを表したものであり，異なるクラスのサンプルがノードにどの程度の割合で混ざっているかを定量化する指標である。(1)式より，情報利得は親ノードと子ノードの不純度の差で与えられることが分かる。つまり，子ノードの不純度が低いほど情報利得は大きくなる。(1)式は一般的に 1 つの親ノードから m 個の子ノードに分岐する場合を対象として情報利得を定式化した，多くの場合は二分決定木を実装しており，本論文においても後者を採用している。つまり，(1)式の j は $right$ と $left$ に分割することができ，次のように表される。

$$IG(D_p, f) = I(D_p) - \frac{N_{right}}{N_p} I(D_{right}) - \frac{N_{left}}{N_p} I(D_{left}) \quad (2)$$

次に，不純度を示す指標，分割条件として本論文ではジニ不純度 I_G を採用した。ジニ不純度は次のように定義される。

$$I_G(t) = \sum_{i=1}^c p(i|t)(1 - p(i|t)) = 1 - \sum_{i=1}^c p(i|t)^2 \quad (3)$$

ここで、 c はクラスの数、 $p(i|t)$ は特定のノード t においてクラス i に属するサンプルの割合を表す。したがって、2値分類で I_G が最も小さくなるのは、ノードのクラスが純粋な時であり、 $I_G = 0$ となる。一方で、最も大きくなるのは、クラスが完全に混合されている場合であり、 $I_G = 1 - \sum_{i=1}^2 (0.5)^2 = 0.5$ となる。ジニ不純度は直感的に誤分類の確率を最小化する条件であると解釈できる。

また、特徴量ごとのそれぞれのノードでの情報利得を合算することで、重要度を算出することができる。重要度は相対的な値であり、各特徴量の重要度を足し合わせると1になる。

以上の説明をもとに、分割された子ノードを新たな親ノードとして再帰的に学習を続けていく。学習は不純度が0になるまで続けることも可能であるが、多くの場合過学習になってしまう。過学習とは、学習データに対する精度の向上を重視しすぎることによって未知のデータに対する精度が下がってしまう状態を指す。これを防ぐために、あらかじめ決定木の最大深さを決めておく、葉のデータ数が一定以下になる場合は分類をやめる、といった手法が用いられることが多い。特に、本論文では衛星データを用いており、取得した周辺環境や衛星配置は実験ごとに大きく異なることが予想され、より汎化的なモデルを作成することが重要である。よって本研究では最大深さは5に設定し、葉の最小データ数は全データの1%に設定した[2]。

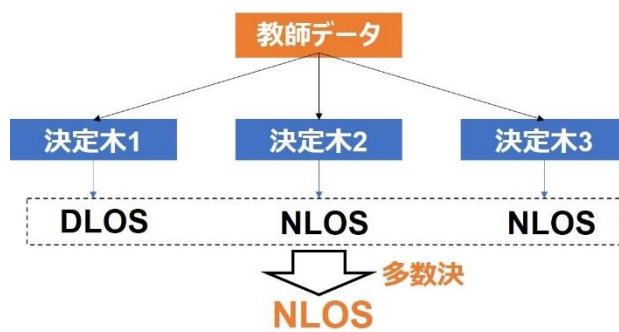


図2 ランダムフォレストの概略図




図3 決定木の概略図

4 NLOS 検知モデルの作成

4.1 信号のラベルづけ手法

機械学習を用いて NLOS 検知モデルを作成するにあたって、あらかじめ教師データを NLOS と DLOS に分類する必要がある。本研究では、GNSS 信号の性質を利用し、このラベルづけを行った。GNSS 衛星からの信号は、進行方向に対して右回りの螺旋を描く右旋円偏波(Right Hand Circular Polarization)として到来する。しかしながら、建物の壁面等で反射することにより、進行方向に対して左回りの螺旋を描く左旋円偏波(Left Hand Circular Polarization)の成分が大きくなるという性質がある。なお、本論文では以降右旋円偏波を RHCP、左旋円偏波を LHCP と記すこととする。

本論文では、RHCP, LHCP のそれぞれで取得したデータのうち、次節で詳細について述べる信号強度に着目する。信号強度は信号の強さ、つまり品質を評価する指標である。よって、直接波を受信している場合は RHCP の信号強度のほうが LHCP の信号強度よりも大きくなり、反射波のみを受信している場合はその逆になると考えられる。よって、各衛星からの信号について、RHCP と LHCP の信号強度の差をとることにより信号の種類を分類してラベル付けできる。具体的には、RHCP と LHCP の信号強度の差が正であれば DLOS, 負であれば NLOS であるというラベル付けを行った[3]。

4.2 分類に使用する特徴量

機械学習モデルを作成する際には、用いる特徴量を決める必要がある。特徴量とは、分類において用いる、特徴の強弱を表す数値である。あらかじめ自分で決めておく必要があり、この決め方によってモデルの分類性能は変化する。本研究では、衛星仰角(EL), 搬送波電力対雑音電力密度(C/N_0), C/N_0 の標準偏差(C/N_{0std})の 3 つの特徴量を使用した[2]。それらの特徴量の一覧を表 1 に示し、それぞれの特徴量について以下で説明する。

表 1 用いる特徴量

特徴量	記号	単位
衛星仰角	EL	deg
搬送波電力対雑音電力密度	C/N_0	dB-Hz
搬送波電力対雑音電力密度の標準偏差	C/N_{0std}	dB-Hz

● 衛星仰角

観測地点からの衛星の仰角。一般的に、衛星仰角が小さいほど建物などの影響で反射波を受信しやすい。よって、NLOS の方が DLOS に比べて小さくなると考えられる。

● 搬送波電力対雑音電力密度

信号電力を雑音電力密度で除したもの。GNSS 信号でよく用いられる信号の品質を評価する指標であり、信号強度とも呼ばれる。本論文においても以降これを信号強度と表記する。GPS 信号は、拡散されている状態では信号を通過させるために広い帯域を必要とする。一方で、逆拡散が終わった後は狭帯域スペクトルとなるため、帯域を必要としない。信号電力は逆拡散の前後で同じであるが、雑音電力は帯域幅に比例して大きくなってしまう。そこで、電力が周波数一様に分布していると考えて、単位周波数あたりの雑音電力を用いることで、信号帯域通過幅に影響されずに信号の品質を評価することができる。また、以下の(4)式のようにすることで単位を dB-Hz とする場合が多い。

$$C/N_0 = 10 \log_{10} \left(\text{信号電力(W)} / 1\text{Hz あたりの雑音電力 (W/Hz)} \right) \quad (4)$$

衛星信号は一般的に、反射の際に信号強度が減衰する。よって、NLOS は DLOS に比べて信号強度が小さくなると考えられる。

- 搬送波電力対雑音電力密度の標準偏差

観測された前後 N エポックの信号強度の標準偏差を表す指標であり、以下の(5)式で定義される。

$$C/N_{0std} = \sqrt{\frac{1}{N} \sum_{n=i-N}^i (C/N_0(t_{i-n}) - C/N_{0mean})^2} \quad (5)$$

ここで、 $C/N_0(t_{i-n})$ は $i-n$ エポックにおける信号強度、 C/N_{0mean} は信号強度の平均値である。なお、本研究では、 $N = 100$ とした。NLOSの方が信号強度のばらつきが大きく、信号強度の標準偏差は大きくなると考えられる。

4.3 静止データ取得とモデルの評価

教師データに使用するデータの取得には ANTCOM 社の両円偏波アンテナを使用した(図 4)。両円偏波アンテナは、同軸上で RHCP と LHCP の両円偏波を受信することができ、端子ごとにそれぞれの受信信号を送信する。また、受信機にはアンテナの RHCP、LHCP の 2 つの端子を同時に接続できる Septentrio 社の AsteRx-i3 を使用した(図 5)。本実験では、この受信機を用いて RINEX(Receiver Independent Exchange format)形式のデータを出力させた。取得する RINEX 形式のデータには、時刻や疑似距離、信号強度などの情報を含む観測データ(observation data)と衛星の軌道情報を含む航法データ(navigation data)がある。

実験方法として、大阪公立大学中百舌鳥キャンパス構内の、直接波、反射波を両方受信できると期待できる環境(図 6、図 7)において、データレート 1Hz でデータを 1 時間取得した。信号を取得する衛星は GPS、Galileo、QZSS とした。次に、取得した RHCP と LHCP のエポックごとの信号強度の差分をとり、その正負に応じて信号を NLOS、DLOS にラベルづけした。

本研究では、機械学習のモデル作成、評価に Python のライブラリである scikit-learn[4]を用いた。また、取得したデータの RINEX 変換、測位演算には RTKLIB ver.2.4.3 b34[5]を使用した。



図 4 両円偏波アンテナ




図 5 受信機



図 6 実験環境(B3 棟と B4 棟の間)



図 7 実験環境(B5 棟横)

表 2 混合行列

		Predicted Class	
		NLOS	DLOS
Actual Class	NLOS	1431 TP(True Positive)	1146 FN(False Negative)
	DLOS	516 FP(False Positive)	11991 TN(True Negative)

表 3 各分類スコア

正答率	0.89
NLOS 再現率	0.56
NLOS 適合率	0.73
DLOS 再現率	0.96
DLOS 適合率	0.91

次に、全データのうち、8 割を学習データ、2 割を検証データとし、作成した NLOS 検知モデルの評価を行った。混合行列と各分類スコアをそれぞれ表 2、表 3 に示す。なお、表 2 は NLOS を True とした場合の混合行列を表す。また、正答率 ACC (accuracy), 再現率 REC (recall), 適合率 PRE (predict)は表 2 を用いて以下の(6)式から(10)式で定義される。

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

$$REC(NLOS) = \frac{TP}{TP + FN} \quad (7)$$

$$PRE(NLOS) = \frac{TP}{TP + FP} \quad (8)$$

$$REC(DLOS) = \frac{TN}{FP + TN} \quad (9)$$

$$PRE(DLOS) = \frac{TN}{FN + TN} \quad (10)$$

正答率は 0.89 と高く、分類モデルとしてうまく機能していることが分かった。しかし、NLOS の再現率、適合率が DLOS のそれらと比較して小さくなっていることが分かった。つまり、DLOS とラベルづけされたデータはほとんどが DLOS と予測できており、DLOS と予測したデータはほとんどが DLOS とラベルづけされたいた。しかし、NLOS とラベルづけされたデータのうち NLOS と予測できていたのは五割強程度であり、NLOS と予測したデータのうち NLOS とラベルづけされていたのは七割程度であった。これは、ラベルづけの段階で DLOS とラベルづけされたデータ数が 12507 であるのに対し、NLOS とラベルづけされたデータ数が 2577 とかなり少なく、NLOS の特徴に対する学習が不十分であることが原因の一つであると考えられる。NLOS をより多く取得できるような環境でのデータを教師データに追加したり、ラベルづけ手法を検討するといったことによりスコアの改善が期待できるのではないかと考えられる。

5 静止体単独測位への適用

作成した NLOS 検知モデルを静止体単独測位に適用し、NLOS と分類された衛星を測位から除外することによって測位精度が向上するかを検証した。測位には RHCP のみを取得する Tallysman 社の通常のパッチアンテナを用いた(図 8)。また、受信機は教師データに使用するデータ取得時と同じ AsteRx-i3 を用いた。実験は、教師データに使用するデータ取得時とは異なり、かつ NLOS が取得されていると期待できる新規環境(図 9)において、データレート 1Hz で約 10 分間の静止体単独測位を行った。なお、測位に用いる衛星は GPS, Galileo, QZSS とした。実験時の衛星配置を図 10 に示す。



図 8 パッチアンテナ



図 9 実験環境(B5 棟と B11 棟の間)

表 4 分類されたエポック数

satellite	NLOS (エポック数)	DLOS (エポック数)
G04	282	466
G08	0	748
G09	261	230
G16	0	748
G18	194	528
G26	30	718
G31	314	431
E07	583	81
E15	0	748
E27	0	748
E30	0	748
E34	0	748
J02	0	748
J03	172	576
J07	0	748




図 10 実験時の衛星配置

NLOS 検知モデルを適用した結果、衛星ごとの NLOS, DLOS に分類されたエポック数について表 4 に示す。本研究では、観測されたエポックのうち、過半数で NLOS と分類された衛星を測位から除外した。結果として、図 10 の赤い丸で示す GPS の 9 番衛星(G09)と、Galileo の 7 番衛星(E07)が過半数のエポックで NLOS であると分類された。

次に、実験地点において、堺の電子基準点との相対測位を行った結果の座標を真値とし、NLOS 除去前と後での測位誤差の比較を行った。測位誤差は、水平方向と高度方向について算出し、評価を行った。それぞれの方向の時系列での誤差の比較について図 11 と図 12 に示す。また、誤差の平均値について表 5 にまとめる。

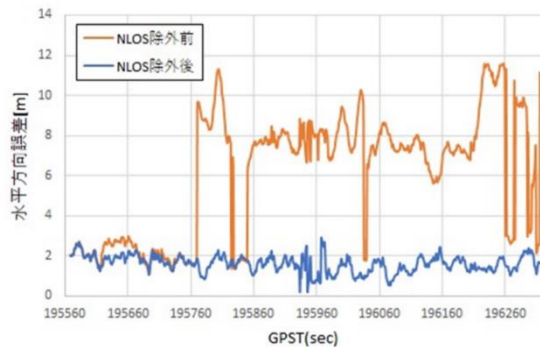


図 11 水平方向の測位誤差

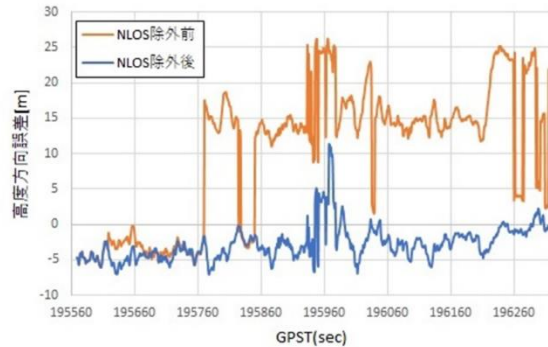


図 12 高度方向の測位誤差

表 5 測位誤差

	NLOS 除去前	NLOS 除去後
水平方向誤差[m]	6.07	1.63
高度方向誤差[m]	12.04	3.28

表 5 より、今回作成した分類モデルを適用して、NLOS と判定された衛星を除去することにより、水平方向で 73.1%、高度方向で 72.8% の大幅な測位誤差の低減が確認できた。また、図 11 と図 12 より、NLOS 除去前は、時間経過に伴う測位誤差の変動が大きいのにに対し、NLOS 除去後においてはある程度一定の誤差のばらつきを保っていることが分かる。ここで、NLOS 除去前と除去後の各誤差の標準偏差を表 6 に示す。

表 6 測位誤差の標準偏差

	NLOS 除去前	NLOS 除去後
水平方向誤差の標準偏差[m]	3.07	0.421
高度方向誤差の標準偏差[m]	9.80	2.49

表 6 より、NLOS 除去によって、測位誤差の改善に加えて、誤差のばらつきが少ない安定した測位が実現できているということが分かる。

6 移動体測位への適用に向けて

ここまでで、静止体単独測位において、両円偏波アンテナを用いて作成したランダムフォレストによる NLOS 検知モデルの一定の成果を確認することができた。次に、移動体測位に向けたモデルの改善について考える。

移動体を対象にするにあたり、まず静止体測位と移動体測位の違いについて考察する。静止体測位であれば、周囲の状況が一定であるため、短時間であれば測位時間内での NLOS, DLOS の変動は少ないと考えられる。よって、静止体単独測位への適用においては、観測時間の過半数で NLOS と判定された衛星を測位の全時間から除外していた。一方で、移動体測位においては、周囲の状況が刻々と変化するため、測位の途中で NLOS, DLOS の変動が起きる可能性が高いと考えられる。こうした移動体の特徴を踏まえ、NLOS 検知モデルに対して、新たな特徴量を追加することで移動体に特有の特徴を反映したモデルの検討を試みた。

本論文では、前章までで作成、適用してきた NLOS 検知モデルに対して、方位角に関する特徴量を追加することを考える[6]。都市部を移動体が走行する場合、進行方向に対して左右の方向にビル等の障害物が多いことが想定される。よって図 13 のように、進路の方向から到来する衛星信号の方が DLOS、左右の方向から到来する信号の方が NLOS である可能性が高いという相関があることが予想される。そこで、この指標を数値的に表すことを考える。本論文においては、図 14 のように移動体の進行方向の方位角を $\theta[\text{deg}]$ とし、衛星 i の方位角を $\phi[\text{deg}]$ としたとき、求める特徴量 AZ_{NLOS} を以下の(11)式で表す。

$$\alpha = |(\phi_i - \theta + 180) \% 360 - 180|$$

$$AZ_{NLOS} = \min(\alpha, 180 - \alpha) \quad (11)$$

この式により、 AZ_{NLOS} は $[0^\circ, 90^\circ]$ で求めることができ、 90° に近いほど進路方向の左右方向に衛星があり、NLOSである可能性が高いという特徴量として期待できる。つまり、 AZ_{NLOS} は衛星が移動体の後方に位置している場合にも、図15のように移動体の進路と衛星のなす方位角の最小値をとることによって対応できる特徴量になる。




図13 衛星信号の到来方向と障害物の関係




図14 移動体と衛星の位置関係




図15 AZ_{NLOS} が採用する角度について

表7 AZ_{NLOS} 追加後の用いる特徴量

特徴量	記号	単位
衛星仰角	EL	deg
搬送波電力対雑音電力密度	C/N_0	dB-Hz
搬送波電力対雑音電力密度の標準偏差	C/N_{0std}	dB-Hz
方位角に関する特徴量	AZ_{NLOS}	deg

表 8 混合行列(AZ_{NLOS} 追加後)

		Predicted Class	
		NLOS	DLOS
Actual Class	NLOS	1956	757
	DLOS	529	11842

表 9 各分類スコア(AZ_{NLOS} 追加後)

正答率	0.91
NLOS 再現率	0.72
NLOS 適合率	0.79
DLOS 再現率	0.96
DLOS 適合率	0.94

この AZ_{NLOS} を加えた 4 つの特徴量を改めて表 7 に示す。4 章での NLOS 検知モデル作成時と同様の条件で、特徴量に AZ_{NLOS} を追加して新たに NLOS 検知モデルを作成し、評価を行った。混合行列と各分類スコアを表 8 および表 9 に示す。

表 9 を表 3 と比較すると、 AZ_{NLOS} を追加することで各スコアが向上していることが確認できる。これは、移動体への適用に関わらず、この特徴量が分類に寄与するものであるということを示している。特に、NLOS 再現率は 0.56 から 0.72 と大幅な改善が見られた。NLOS 再現率が大きいうことは、NLOS を DLOS と分類して測位に使用してしまう可能性が低くなるため、有効であると考えられる。

7 まとめと今後の課題

本論文では、両円偏波アンテナを用いた機械学習による信号分類モデルを作成し、NLOS を測位から除外することによる測位精度の向上についての検証を行った。RHCP と LHCP の信号強度の差を利用して教師データのラベル付けを行い、ランダムフォレストによる信号分類モデルを作成したところ、正答率は 0.89 と高く、分類モデルとして機能できる値が得られたが、NLOS の再現率、適合率が DLOS のものと比べて低いという結果になった。また、作成した分類モデルを静止体単独測位に適用した結果、NLOS に分類された衛星を測位から除外することによって、水平方向、高度方向共に大幅な測位誤差の低減を確認することができた。また、測位誤差の標準偏差も小さくなり、NLOS を除外することで安定した測位に繋がることも確認できた。

本論文では、教師データのラベル付けの基準として、RHCP と LHCP の信号強度の差の正負のみに着目したが、実際に NLOS になりやすい衛星は低仰角である場合が多いため、これを考慮したラベル付けの方法によって NLOS の分類スコア向上に繋がるのではないかと考えられる。また、教師データに用いるデータの取得環境を増やすことも有効ではないかと考えられる。

さらに、移動体への適用に向けて、方位角に関する特徴量を追加したモデルの評価を行った。結果として、分類スコアが向上し、 AZ_{NLOS} は信号分類に寄与する特徴量であることが確認できた。今後は実際の移動体で取得したデータに適用することによってその有効性を検証するとともに、移動体特有の環境の変化に対応できるような逐次的な NLOS 除去の方法を考えていきたい。

8 参考文献

- [1] 国土交通省, 無人航空機レベル4 飛行ポータルサイト
<https://www.mlit.go.jp/koku/level4/> (2024 年 9 月 16 日閲覧)
- [2] 田中晋平, 『機械学習を利用した GNSS 信号反射波検知モデルの構築と測位への適用』大阪府立大学修士論文, 2020 年度
- [3] 吉田柊生, 『右旋および左旋円偏波アンテナを用いたマルチパス誤差低減に関する研究』大阪府立大学卒業論文, 2018 年度
- [4] “scikit-learn: Machine Learning in Python”.
<https://scikit-learn.org/stable/>
- [5] T. Takasu. “RTKLIB 2.4.3 b34”.
https://github.com/tomojitakasu/RTKLIB_bin/tree/rtklib_2.4.3
- [6] L. Li, M. Elhaji, Y. Feng, W.Y.Ochieng, “Machine learning based GNSS signal classification and weighting scheme design in the built environment: a comparative experiment” Satellite Navigation, 2023.