

# GPS 信号の種類に応じた重みづけによる測位精度の改善

秋月勇樹, 辻井利昭 (大阪公立大学)

Improvement of GPS positioning accuracy by applying weight according to GPS signal type  
Yuki Akizuki, Toshiaki Tsujii (Osaka Metropolitan University)

Key Words: GPS, Measurement Weight, LOS, NLOS, Multipath

## Abstract

GPS positioning accuracy deteriorates significantly in environments surrounded by tall buildings, such as urban areas, and in environments surrounded by trees, such as mountainous areas. This is due to the fact that GPS signals contain reflected waves, and positioning accuracy can be improved by excluding reflected waves. However, excluding too many reflected waves leads to a reduction in the number of visible satellites and deterioration of satellite geometry. The objective of this research is to improve positioning accuracy by using machine learning to classify GPS signals, and then applying appropriate weights to the classified signals according to their types for effective use.

## 1. はじめに

近年, 無人配送や危険な場所におけるインフラ点検に UAV (Unmanned Aerial Vehicle) を活用することが注目されている. 実際に, 離島への無人配送などで UAV の活用は始まっているが, 都市部などでそれらを見かけることはない. これは UAV に用いる GPS (Global Positioning System) の測位精度が原因であり, GPS 信号の反射・回折によるマルチパスや遮蔽の影響を受ける環境下において, 測位精度が大きく劣化するためである. このような課題に対して, アレーアンテナや両円編波アンテナ, 3DMap などを利用して GPS 信号の反射波の影響を低減する手法があるが, いずれにしても特殊な機器の必要性, 高価格化, 大型化などのデメリットがある<sup>[1][2][3]</sup>. また, 反射波を除外することで測位精度を改善する手法もあるが, 反射波を過剰に除外すると, 可視衛星数の減少や衛星の幾何学的配置 (DOP) の悪化につながり, 逆に測位精度が悪化することがある<sup>[4]</sup>.

都市部において UAV の自動運転を実現するためには, 特殊な機器を利用せず, 小型かつ低価格な構成で, 測位精度を改善することが必要である. そこで, 本研究では, 劣悪な受信環境下において GPS を用いた測位精度を向上させることを目標に, GPS 信号の種類に応じて適切な重みづけを施して, 衛星を有効利用する手法を提案する. ここで, 重みとは各衛星の測距誤差分散の逆数である. 先述したように GPS 信号の種類に応じて測距誤差は大きく変動するため, より高精度な測位結果を得るためには, GPS 信号の種類に応じて適切な重みづけを施すことが重要である. 測距誤差は一般的に衛星仰角  $EL$  [deg] と搬送波対雑音電力密度比  $C/N_0$  [dBHz] の 2 つの指標を用いて表すことが多いが, これらは異なる特性を持っている.  $EL$  は受信機ノイズや大気遅延の影響を反映する一方で,  $C/N_0$  は受信環境特有の誤差, 特に GPS 信号の反射・回折によるマルチパスや遮蔽の影響を反映する<sup>[5]</sup>. 本研究では, これら 2 つの指標を組み合わせて利用することにより, 測位精度を向上させることを目指した.

研究の流れとしては, まず, 劣悪な受信環境下において静止体実験を行い, データを習得した. 次に, 機械学習を利用して信号分類モデルを作成し, 作成したモデルを利用して実験データを分類した. そして, 分類したデータをもとに  $EL$  と  $C/N_0$  それぞれに対して測距誤差モデルを作成した. 続いて, 測距誤差モデルに最小二乗法を適用して近似曲線を算出し, 重みを決定した. 最後に, 決定した重みを実際に測位に適用し, 水平方向誤差と高度方向誤差が向上するかどうかを確認した. 今回の実験データにおいて, 水平方向誤差は最大で 26.95%, 高度方向誤差は最大で 21.03% 改善した.

## 2. 機械学習による信号分類

GPS 信号の種類に応じて適切な重みづけを施すためには, 取得したデータを信号の種類に応じて分類しなければならない. そこで, 先行研究を参考に機械学習を用いて信号分類を行った<sup>[6]</sup>. 詳細は参考文献を参照されたい. モデルの構築と検証のフローチャートを Fig.1 に示す. まず, あらかじめ信号の種類をラベルづけした教師データをもとに信号分類モデルを作成した. 次に, 作成したモデルを検証データに適用し, 検証データの信号を DLOS (direct-line-of-sight) と NLOS (none-line-of-sight) の 2 つに分類した. 一般的に, GPS 信号は大きく 3 つに分けられることが多い (Fig.2). 直接波のみを受信する LOS (line-of-sight), 直接波と反射波を受信

する Multipath, 反射波のみを受信する NLOS である. Multipath と NLOS 共に誤差は含まれるが, 一般的に NLOS の方が誤差が大きくなることから, 本研究では LOS と Multipath を合わせて DLOS と仮称し, NLOS との二値分類を行った. そして, それぞれの信号に対して適切な重みを適用し, 測位精度の改善を図った. ここで, 学習アルゴリズムには汎化性能に優れたランダムフォレストを採用し, モデルの特徴量は衛星仰角  $EL$  [deg], 搬送波対雑音電力密度比  $C/N_0$  [dBHz], 擬似距離残差  $resp$  [m] の 3 つを利用した. 一般的に NLOS では  $EL$  と  $C/N_0$  が小さく,  $resp$  が大きい傾向にある. 本研究で使用した信号分類モデルの正答率 (ACC) と再現率 (REC) を Table.1 に示す. 正答率は 90% を超え, 再現率も最低値が 87% と, 高精度で分類できていると考えられる.

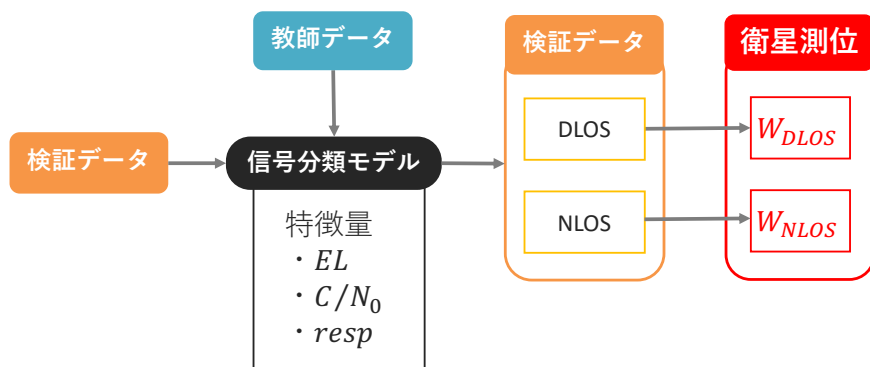


Fig.1 モデルの構築と検証のフローチャート

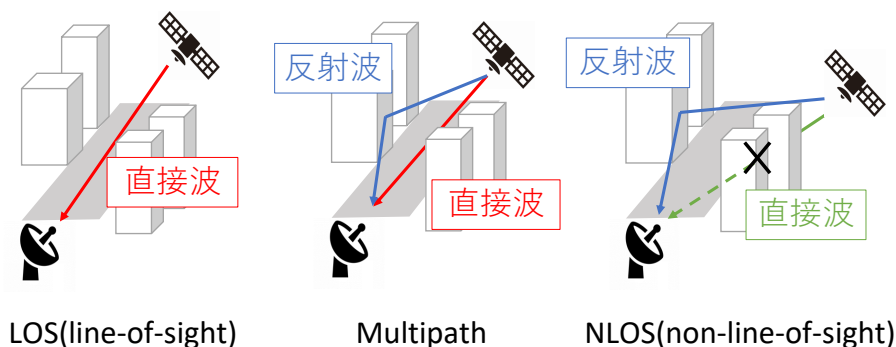


Fig.2 GPS 信号の種類

Table.1 分類モデルの正答率と再現率

	ACC	REC(DLOS)	REC(NLOS)
(%)	92.8	95.4	87.0

### 3. 測距誤差モデルと近似曲線

#### 3.1 測距誤差モデル

測距誤差モデルとは, ある指標に対する  $resp$  の分布を示したものである<sup>[7]</sup>. 今回は  $EL$  と  $C/N_0$  の 2 つの指標に対して測距誤差モデルを作成した. また, 機械学習の有用性を確認するため, それぞれの指標について, 分類なしの場合, DLOS のみの場合, NLOS のみの場合の 3 つに分類してモデルを作成した. オープンスカイ環境においてデータを取得し, 取得したデータを分類せずにプロットした測距誤差モデルの例を Fig.3 に示す. Fig.3 の左図より,  $EL$  が小さいほど  $resp$  が大きくなり,  $EL$  が 30[deg] 以上でほぼ一定となっていることが分かる. また, Fig.3 の右図より,  $C/N_0$  が小さいほど  $resp$  が大きくなる傾向がある.  $C/N_0$  が 25[dBHz] 未満のデータにおいて,  $resp = 0$  となっているが, これらの衛星は測位に使用されていなかった. そのため, 以降では  $C/N_0$  が 25[dBHz] 未満のデータを削除した.




Fig.3 測距誤差モデル (左図 :  $EL$ , 右図 :  $C/N_0$ )

### 3.2 近似曲線

先で作成した測距誤差モデルを利用して近似曲線  $\sigma = f(x, \alpha)$  ( $f$ は関数,  $x$ は2つの指標,  $\alpha$ はパラメータ) を作成することにより, ある指標に対する  $resp$  がどの程度の値になるかを決定することができる. そして, 決定した  $\sigma$  の2乗の逆数を重みとして測位に適用することで, 衛星を有効に利用することができる.

近似曲線の作成方法は2通り考えられる. 1つ目は測距誤差モデルの全てのデータを利用して近似曲線を引く手法である. この手法は計算が簡易であるが, GPSのデータに偏りがある場合, 近似曲線も偏ってしまうデメリットがある. 2つ目は, ある指標に対して, ある範囲の値ごとに  $resp$  のRMSを算出し, 算出したRMSをもとに近似曲線を引く手法である. この手法は計算が煩雑であるデメリットはあるが, GPSのデータに偏りがあった場合でも, 近似曲線が偏りにくいというメリットがある. 本研究では後者を採用し,  $EL$ ,  $C/N_0$ ともに0.1ごとに  $resp$  のRMSを算出したのちに, 近似曲線を算出した.

また, 近似曲線として利用する関数の型についても2通り考えられる. 1つ目は, 多項式近似を利用する関数の型である. 2つ目は, 先行研究で利用されていた関数の型である<sup>[5]</sup>. 多項式近似は過剰なフィッティングにつながる可能性があることを考慮して, 本研究では後者を採用した. 近似曲線として利用する関数の種類は2つある. 1つ目は,  $resp-EL$ グラフの近似曲線として利用する  $\sigma_{EL} = a/\sin EL$  である. 2つ目は,  $resp-C/N_0$ グラフの近似曲線として利用する  $\sigma_{C/N_0} = \sqrt{d \cdot 10^{-0.1 \cdot C/N_0}}$  である. 近似曲線から算出した  $\sigma_{EL}$  と  $\sigma_{C/N_0}$  の二乗から誤差分散を算出し, その逆数を重みとして設定する. さらに,  $EL$ の誤差分散  $\sigma_{EL}^2$  と  $C/N_0$ の誤差分散  $\sigma_{C/N_0}^2$  を複合的に利用する新たな誤差分散として,  $\sigma_{EL-C/N_0}^2 = (a/\sin EL)^2 + d|10^{-0.1 \cdot C/N_0} - 10^{-0.1 \cdot C/N_{0nom}(EL)}|$  を導入する.  $C/N_{0nom}(EL)$  は各衛星の  $EL$  に対する  $C/N_0$  の基準値であり,  $C/N_0-EL$ グラフの近似曲線から算出した (Fig.4). なお, このデータは, 先のモデル作成で利用したオープンスカイ環境のデータである.

近似曲線の算出には, 最小二乗法を利用した. また, 最小二乗法の最適化手法として, Levenberg-Marquardt法を採用した<sup>[8]</sup>. この手法は, 収束は遅いが安定性は高い最急降下法と, 安定性は低いが収束は速い Gauss-Newton法を組み合わせた手法であり, 非線形性が強い関数でも安定して収束するという特徴を持っている.




Fig.4  $C/N_0$ の基準値(赤色の曲線)

## 4. 静止体測位への適用

### 4.1 静止体実験

提案手法の有用性を確認するため、静止体実験を行った。実験環境と実験装置の図を Fig.5 に示す。劣悪な受信環境における提案手法の優位性を確認するため、左右が建物に挟まれた環境で実験を行った。アンテナは Tallysman の TW7972 を、受信機は u-blox の M8P を利用した。データレートは 2Hz で 3 時間程度計測した。



Fig.5 実験環境（左図）と実験装置（右図）

### 4.2 近似曲線の算出

実験データを信号分類モデルに入力し、DLOS と NLOS の 2 種類に分類した。そして、 $EL$  と  $C/N_0$  の 2 つの指標に対して測距誤差モデルを作成し、作成した測距誤差モデルをもとに近似曲線を引いた。まず、 $resp-EL$  グラフの近似曲線を Fig.5 に示す。左図が分類なしで近似曲線を引いた場合、中央図が DLOS のみで近似曲線を引いた場合、右図が NLOS のみで近似曲線を引いた場合を表している。また、この 3 つの近似曲線を重ねて図示したものを Fig.6 に示す。Fig.6 より、DLOS と NLOS をうまく分離できていることが分かる。また、DLOS よりも NLOS の方が  $resp$  は大きいという特徴を捉えることができている。以上の 2 点より、機械学習による分類はうまく行われたと考えられる。次に、 $resp-C/N_0$  グラフの近似曲線を Fig.7 に、3 つの近似曲線を重ねて図示したものを Fig.8 に示す。Fig.8 より、Fig.6 と同様に、機械学習による分類はうまく行われたと考えられる。




Fig.5  $resp-EL$  グラフの近似曲線




Fig.6  $resp-EL$  グラフの近似曲線（重ねて図示）




Fig.7 resp- $C/N_0$ グラフの近似曲線




Fig.8 resp- $C/N_0$ グラフの近似曲線 (重ねて図示)

### 4.3 静止体測位結果

前項で算出した $\sigma_{EL}$ と $\sigma_{C/N_0}$ を利用して重みを算出し、測位に適用した。真値はRTKLIBのstatic測位を利用した<sup>[9]</sup>。また、誤差と誤差改善率の算出にあたり、 $\sigma_{ref} = 0.8/\sin EL$ による重みづけの測位結果を基準として設定した<sup>[7]</sup>。なお、測位方法はいずれも単独測位であり、重み付けには単独測位計算プログラムを利用した<sup>[7]</sup>。機械学習による分類なしの場合（ALLの近似曲線）の誤差と誤差改善率をまとめたものをTable.2に、機械学習による分類ありの場合（DLOSとNLOSの近似曲線）の誤差と誤差改善率をまとめたものをTable.3に示す。表中のH方向は局所座標系における水平方向誤差を表し、V方向は高度方向誤差を表す。また、3d方向は3次元誤差を表す。赤字で記した箇所は誤差が改善していることを示し、赤い太字で記した箇所は分類の有無における同様の誤差分散で比較してより良いことを示す。例えば、 $\sigma_{EL}^2$ を用いた場合、分類ありの方がなしの場合よりもH・V・3d方向全てにおいて誤差が改善されている。本実験データでは、 $\sigma_{C/N_0}^2$ のV方向を除き、分類ありの場合の方がH・V・3d方向における誤差が改善された。

まず、機械学習による分類なしの場合(Table.2)について考察する。H・3d方向においては $\sigma_{EL}^2$ の誤差改善率が最小、 $\sigma_{EL,C/N_0}^2$ の誤差改善率が最大であり、V方向においては、 $\sigma_{C/N_0}^2$ の誤差改善率が最小、 $\sigma_{EL,C/N_0}^2$ の誤差改善率が最大であった。以上より、機械学習による分類がない場合において、 $\sigma_{EL,C/N_0}^2$ による重みづけ手法は有効であると考えられる。また、H・V・3d方向全てにおいて、 $\sigma_{EL}^2$ による重みづけ手法は $\sigma_{ref}^2$ よりも誤差が改善していることから、場所によらず一定の重みづけ関数を適用するよりも、任意の場所におけるデータを利用して算出した重みづけ関数を適用する方が効果的であることがわかる。さらに、H方向においては、 $\sigma_{C/N_0}^2$ の誤差改善率が $\sigma_{EL,C/N_0}^2$ の誤差改善率と同等であることは注目すべき点である。これより、劣悪な受信環境下において、 $\sigma_{EL,C/N_0}^2$ の誤差改善率には $C/N_0$ が大きく寄与していると考えられる。一方で、V方向においては、 $\sigma_{EL,C/N_0}^2$ の誤差改善率は他の2つより圧倒的に大きい。これは、受信機で計測した $C/N_0$ をそのまま利用するのではなく、任意のELにおける $C/N_0$ の基準値である $C/N_{0nom(EL)}$ と $C/N_0$ との差分を誤差として加算したことが大きく影響していると考えられる。

次に、機械学習による分類ありの場合(Table.3)について考察する。H・V・3d方向全てにおいて、 $\sigma_{C/N_0}^2$ の誤差改善率が最小、 $\sigma_{EL,C/N_0}^2$ の誤差改善率が最大であった。すなわち、機械学習による分類がある場合においても、 $\sigma_{EL,C/N_0}^2$ による重みづけ手法は有効であると考えられる。また、 $\sigma_{C/N_0}^2$ のV方向の誤差改善率が著しく低いことは注目すべき点である。先の機械学習なしの場合でも同様に $\sigma_{C/N_0}^2$ のV方向の誤差改善率が低かったことを考慮すると、受信機で計測した $C/N_0$ はV方向の誤差改善率に大きく寄与しないということがわかる。

最後に、機械学習による分類の有無で比較する。先にも述べたように、本実験データでは、 $\sigma_{C/N_0}^2$ のV方向を

除き、分類ありの場合の方がH・V・3d方向における誤差が改善された。これより、機械学習による分類の有用性が確認できる。また、 $\sigma_{EL}^2$ の誤差改善率の向上度合いは注目すべき点である。これは、Fig.6より、DLOSとNLOSの分離度合いが大きいことに起因すると考えられる。一方で、 $\sigma_{C/N_0}^2$ の誤差改善率の向上度合いが小さいことはFig.8より、DLOSとNLOSの分離度合いが小さいことに起因すると考えられる。この原因としては、ELの測距誤差モデルにおいてはELが一様に分布する傾向があるのに対し、 $C/N_0$ の測距誤差モデルにおいては $C/N_0$ の分布が偏る傾向があるためである。

Table.2 機械学習による分類なしの場合

	$\sigma_{ref}^2$	$\sigma_{EL}^2$	$\sigma_{C/N_0}^2$	$\sigma_{EL\_C/N_0}^2$
H方向(m)	<b>10.02</b>	9.49	7.90	7.78
<b>H改善率(%)</b>		<b>5.29</b>	<b>21.16</b>	<b>22.36</b>
V方向(m)	<b>11.60</b>	10.50	10.99	9.46
<b>V改善率(%)</b>		<b>9.48</b>	<b>5.26</b>	<b>18.45</b>
3d方向(m)	<b>15.33</b>	14.15	13.53	12.25
<b>3d改善率(%)</b>		<b>7.7</b>	<b>11.74</b>	<b>20.09</b>

Table.3 機械学習による分類ありの場合

	$\sigma_{ref}^2$	$\sigma_{EL}^2$	$\sigma_{C/N_0}^2$	$\sigma_{EL\_C/N_0}^2$
H方向(m)	<b>10.02</b>	7.74	7.85	7.32
<b>H改善率(%)</b>		<b>22.75</b>	<b>21.66</b>	<b>26.95</b>
V方向(m)	<b>11.60</b>	9.28	11.00	9.16
<b>V改善率(%)</b>		<b>20.0</b>	<b>5.17</b>	<b>21.03</b>
3d方向(m)	<b>15.33</b>	12.08	13.51	11.73
<b>3d改善率(%)</b>		<b>21.2</b>	<b>11.87</b>	<b>23.48</b>

## 5. まとめ

以上、「GPS信号の種類に応じた重みづけによる測位精度の評価」と題し、信号分類モデルを利用して、DLOSとNLOSにそれぞれ適切な重みづけを施すことの妥当性を検討した。本研究では、静止体において測位誤差を大きく改善することができた。ただし、本研究では、「DLOSとNLOSに分類してそれぞれの近似曲線を算出する」という操作を行う上で、分類前に多くのデータを必要とすることが課題である。本研究では、データレート2[Hz]で3時間実験を行い、十分なデータを取得したのちに近似曲線の算出を行ったが、データレートが低い場合や計測時間が短い場合は、分類後のデータ数が少なくなり、近似曲線の算出が難しい。また、データレートが高い場合でも、計測時間が短い場合は衛星の配置が変化しにくいいため、分布が偏ってしまう危険性がある。さらに、日時や場所によって近似曲線が変化することも考えられるため、本研究で得た重みを未知のデータに適用した場合、必ず誤差を改善することは限らない。

これらの課題に対して、ビッグデータを用いるという解決策があると考えられる。すなわち、任意の地点において、ユーザーのスマートフォン等から衛星の配置や測位解等を取得し、それをビッグデータとして蓄積することである。これらを近似曲線の算出に利用することができると考えられる。また、近似曲線の算出以外にもユーザーの行動パターンを解析して必要に応じて適切な広告を掲示するなど、様々な利用価値があると考えられる。

## 参考文献

[1] S. Daneshmand ; A. Broumandan ; N. Sokhandan ; G. Lachapelle “GNSS Multipath Mitigation with a Moving Antenna Array” IEEE TRANSACTIONS ON AEROSPACE AND ELECTRONIC SYSTEMS VOL. 49, NO. 1 JANUARY 2013

- [2] Groves PD, Adjrard M. Performance assessment of 3D - mapping - aided GNSS, Part 1: algorithms, user equipment and review. NAVIGATION. 2019; 66: 341 - 362.
- [3] Jiang · Paul D. Groves “NLOS GPS signal detection using a dual-polarisation antenna” GPS Solutions January 2014, Volume 18, Issue 1, pp 15–26
- [4] 東京商船大学大学院 商船学研究科 流通情報工学専攻 鈴木崇史. (n.d.). Retrieved July 30, 2022, from <https://www.denshi.e.kaiyodai.ac.jp/wp-content/uploads/pdf/content1/suzuki.pdf>
- [5] Zhang, Z., Li, B., Shen, Y., Gao, Y., & Wang, M. (2018). Site-specific unmodeled error mitigation for GNSS positioning in urban environments using a real-time adaptive weighting model. Remote Sensing, 10(7), 1157
- [6] 田中晋平, 辻井利昭 (2021). 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 JOURNAL OF THE JAPAN SOCIETY FOR AERONAUTICAL AND SPACE SCIENCES, 69(6), 229–235
- [7] 坂井丈泰, GPS のための実用プログラミング, 東京電機大学出版局, 2007
- [8] Scipy.optimize.curve\_fit#. scipy.optimize.curve\_fit - SciPy v1.9.0 Manual. (n.d.). Retrieved July 30, 2022, from [https://docs.scipy.org/doc/scipy/reference/generated/scipy.optimize.curve\\_fit.html](https://docs.scipy.org/doc/scipy/reference/generated/scipy.optimize.curve_fit.html)
- [9] T. Takasu ” RTKLIB: An Open Source Program Package for GNSS Positioning” <http://www.rtklib.com/> 2020/03/31