

機械学習モデルによる軽量で高精度な方向推定の実現

田中 圭[†] 島崎 仁司[†] 大柴 小枝子[†]

1. はじめに

近年、屋内における設備の点検や物の運搬などの業務にドローンをはじめとする無人機が使用されるケースが増えている。業務に使用される無人機を制御する上で、無人機の位置を把握することは非常に重要であり、位置を誤れば業務を遂行できないだけでなく、事故を招く恐れもある。位置推定技術としては GPS(Global Positioning System) に代表される GNSS(Global Navigation Satellite System) が広く用いられるが、屋内では衛星の電波が届きにくく正確な位置推定が行えない。

昨今、屋内で位置推定する技術の一つとして Bluetooth5.1 で追加された方向検知機能を用いる方法が注目されている。この技術は CTE(Constant Tone Extension) と呼ばれる無変調の電波をアレーアンテナで受信し、何らかの処理を加えることで電波の到来方向を推定することができる。この処理の仕方は様々であり、従来の方法としては MUSIC(Multiple Signal Classification)[1] や ESPRIT(Estimation of Signal Parameters via Rotational Invariance Techniques)[2] などのスペクトル推定法が用いられることが多い。これらの方法は高い精度で到来方向を推定できるが、計算量が多く、小型無人機に搭載される計算力に制限があるコンピュータではリアルタイムでの推定が難しいという問題がある。[3]

一方で、ニューラルネットワークをはじめとする機械学習を用いた方向推定手法も提案されている。これらの手法は従来の方法に比べて計算量が少なく、リアルタイムでの推定が可能であるという利点がある。[3] しかし、機械学習モデルによる方向推定手法は汎用性に課題があり、距離やアレーアンテナの形状に依存したモデルが学習されることがある。本研究では、機械学習モデルによる方向推定手法の汎用性を向上させることを目指し、最初の段階として、汎用性は低いが高速に動作するモデルを提案する。そして、提案したモデルと従来の方向推定手法である MUSIC の方向推定精度と計算量の比較を行った。その結果、機械学習モデルの誤差の絶対値平均は 0.6777° で、誤差の絶対値平均が同程度の MUSIC に対して 400 分の 1 以下の実行時間で推定できることを明らかにした。

2. 従来の方向推定手法と機械学習を用いた手法

電波を用いた方向推定では、図 1 のようにアレーアンテナの素子間の距離と各素子の位置における等位相面間の距離の関係から到来方向を推定するのが基本である。実際の処理においては、アレーアンテナの各素子から得られる時系列信号を様々な方法で処理することで到来方向を推定する。よく用いられるのが MUSIC や ESPRIT などのスペクトル推定法である。MUSIC はアレーアンテナの素子間の相関を表す共分散行列に対して固有値分解を行い、固有値の小さい固有ベクトルに対応する方向を推定する方法である。ESPRIT は共分散行列の特異値分解を行い、信号空間と雑音空間を分離し、信号空間の基底ベクトルを用いて位相シフトを計算し、到来方向を推定する方法である。

これらの方法は高い精度で到来方向を推定できるが、計算量が多く、リアルタイムでの推定が難しいという問題がある。




図 1: アレーアンテナの到来方向推定

機械学習モデルによる方向推定手法は従来の方法に比べて計算量が少なく、リアルタイムでの推定が可能であるという利点がある。機械学習モデルによる方向推定手法は、モデルの入力に何を用いるかによって大きく分けられる。入力には、アレーアンテナの素子から得られる時系列信号をそのまま用いる方法や、共分散行列を用いる方法がある。共分散行列はアレーアンテナの素子間の相関を表す行列であり、アレーアンテナの素子から得られる時系列信号を用いる方法に比べて、計算量が少なく、ノイズの影響を受けにくいという利点がある。[5] また、機械学習モデルによる方向推定手法は、モデルの構造によって大きく分けられる。モデルの構造には、ニューラルネットワーク (NN) の他に、k 近傍法 (kNN)、サポートベクターマシン (SVM)、Extreme Gradient Boost (XGB) を用いた決定木などがある。[5] これらのモデルは、モデルの構造によって推定精度や計算量が異なる。

機械学習モデルによる到来方向推定は、モデルの汎用性が課題となる。モデルの汎用性が低いと、モデルの学習に用いたデータセットに含まれないデータに対して推定精度が低くなる。[4] モデルの汎用性を高めるためには、モデルの学習に用いるデータセットを多様化することが有効である。逆に、モデルの学習に用いるデータセット次第で、従来の方向推定手法にはない特徴、例えばマルチパスに対する耐性などを持つモデルが生まれる可能性がある。また、この分野の研究では、送受信機の距離の変化に対応するモデルについてはあまり考察がなされておらず、到来方向の推定をとばして直接位置推定を行う手法についての研究が多い。

このように、機械学習モデルは、既存の方向推定手法に比べて計算コストが低いという利点があるが、モデルの汎用性には課題がある。本研究では、機械学習モデルによる方向推定手法の汎用性を向上させることを目指すが、まずは汎用性をもたせる前の最もシンプルなモデルを作成し、そのモデルと従来の方向推定手法である MUSIC の方向推定精度と計算量の比較を行う。

[†]京都工芸繊維大学大学院工芸科学研究科
Graduate School of Science and Technology,
Kyoto Institute of Technology

3. 本研究で扱う方向推定手法

3.1. 問題設定

本論文では、図 2 の示す 3 次元空間の原点に置かれたアレーアンテナを用いて、原点を中心とする半径 10m の球面上で様々な位置をとる送信源の方向を推定する問題を考える。アレーアンテナは 6 つの素子からなるUCA(Uniform Circular Array)を用いる。UCA の半径は $\frac{\lambda}{2}$ で、 λ は Bluetooth のチャンネルの周波数の一つである 2.426 GHz の電波の波長である。方位角 θ_a はアレーアンテナの中心から 1 番目の素子の方向を基準として反時計回りに角度を表す。仰角 θ_e はアレーアンテナの平面を基準として上向きを正とする角度を表す。また、信号源は 1 つとし、マルチパスの影響は考慮しない。加えて、アレーアンテナの素子および送信源はオムニアンテナであるとする。




図 2: 問題設定

3.2. 処理の流れ

アレーアンテナの素子から得られる時系列信号から各素子の信号同士の相関をとり、 6×6 の共分散行列 R_{xx} を求める。MUSIC ではこの共分散行列に対して固有値分解を行い、固有値の小さい固有ベクトルに対応する方向 (θ_a と θ_e) を探索する。その際 $0^\circ \leq \theta_a \leq 360^\circ$ と $0^\circ \leq \theta_e \leq 90^\circ$ の範囲の 2 次元平面を特定の分解能の格子状に区切り、格子点の中からもっともらしい方向を探索する。そのため、分解能と計算量のトレードオフがある。本研究では、3 通りの分解能 (0.1° , 1° , 2°) で探索を行い、比較するが、MUSIC の計算量を削減するために、それぞれ $5^\circ \rightarrow 1^\circ \rightarrow 0.1^\circ$, $5^\circ \rightarrow 1^\circ$, $5^\circ \rightarrow 2^\circ$ と段階的に探索範囲を狭める処理を実装した。合計計算点数はそれぞれ、1949, 1508, 1423 である。

本研究では、機械学習モデルとしてニューラルネットワークを使用し、モデル構造を簡略にするために、方位角と仰角で推定するモデルを分け、方位角を推定するモデル(方位角モデル)と仰角を推定するモデル(仰角モデル)の 2 つのモデルを作成する。機械学習モデルは MUSIC と同様に共分散行列 R_{xx} を作成した後、共分散行列の冗長な部分を省き、複素数である各要素を実部と虚部に分けることで、30 個の実数を得る前処理を行う。この 30 個の実数を、方位角モデルと仰角モデルにそれぞれ入力し、方位角 θ_a と仰角 θ_e を推定する。

3.3. 学習と推論

本研究では、図 3 のシナリオを想定しており、学習と推論の 2 ステップからなる。学習ではシミュレーションで作成した大量の共分散行列 R_{xx} と到来方向 θ (方位角 θ_a または仰角 θ_e) のペアからなるデータセットを用意し、無人機とは別の外部の環境でモデルの学習を行う。推論では無人機上のコンピュータで学習したモデルに R_{xx} を入力して方向 θ の推論を行う。




図 3: シナリオ

学習に用いるデータセットは、シミュレーションで作成するが、シミュレーションでは時系列信号から共分散行列を作成することは行わず、送信源とアレーアンテナの各素子との距離から、各素子の位置での位相を計算し、差をとることで共分散行列を作成する。具体的にはまず、送信源と素子 i ($i = 1, 2, \dots, 6$) の距離 L_i を座標から計算し、

$$\phi_i = 2\pi(f_c + f_{CTE})\frac{L_i}{c} \quad (1)$$

として各素子での位相を計算する。ここで、 f_c は Bluetooth の周波数で 2.426 GHz、 f_{CTE} は CTE の周波数で 250 kHz、 c は光速である。次に、

$$R_{xx}(i, j) = e^{j(\phi_i - \phi_j)} \quad (i, j = 1, 2, \dots, 6) \quad (2)$$

として共分散行列を作成し、機械学習モデルの入力とする。出力となる方位角 θ_a と仰角 θ_e は、送信源の座標から計算する。アレーアンテナは原点に固定し、送信源の座標を半径 10m の球面上に分布させる。このとき、球面上に一樣に分布させるために、方位角 θ_a は一樣乱数、仰角 θ_e は一樣乱数に逆コサインをとって生成する。

3.4. ハイパーパラメータとモデル構造

データセットは、共分散行列 R_{xx} と到来方向 θ のペアを 3,033,000 個作成し、そのうち 3,000,000 個を学習用データセット、30,000 個を検証用データセット、3,000 個をテスト用データセットとする。その他のハイパーパラメータを表 1 に示す。

表 1: ハイパーパラメータ

ソルバー	ADAM
損失関数	MSE
エポック数	10
ミニバッチサイズ	3000
初期学習率	0.9
学習率減衰	0.1

ADAM は勾配降下法の一つであり、学習量を自動で調整することができる。MSE は Mean Squared Error の略であり、出力と正解の差の二乗和を損失関数として用いる。

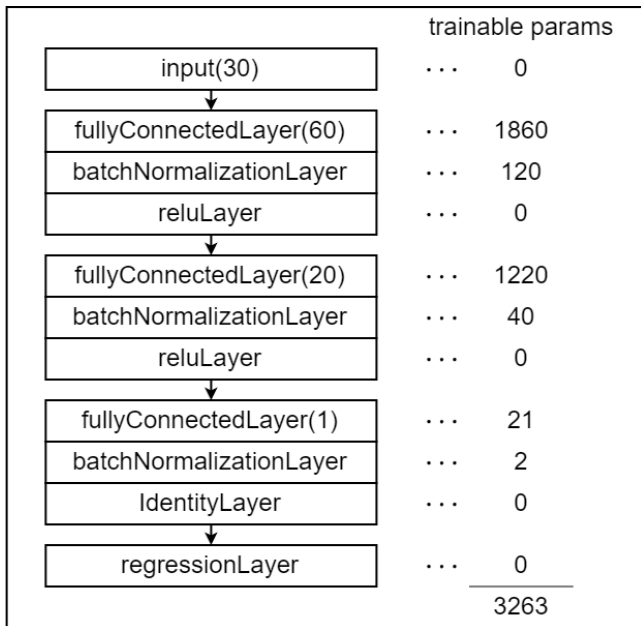


図 4: モデル構造

モデルの構造を図 4 に示す。方位角モデル、仰角モデルともに、入力層では 30 個の入力を受け取り、中間層では全結合層、バッチノーマライゼーション層、活性化関数層のセットを 3 つ繰り返す。中間層のノード数は順に 60, 20, 1 とする。出力層では回帰層をおいているが、これは学習時の誤差計算に用いるためであり、値は素通りすることから、中間層の 3 つ目の全結合層が実質的な出力層となる。活性化関数は 1 つ目と 2 つ目の中間層に ReLU 関数、3 つ目の中間層には恒等関数を用いる。バッチノーマライゼーション層は、学習時にミニバッチごとに入力を正規化する層であり、学習を安定化させる効果がある。

3.5. 実装及びテスト環境

本研究では実装、学習、テストのすべてで MATLAB R2023b を用いた。学習には、MATLAB の Deep Learning Toolbox を用いた。テストには Ryzen 7 5800X3D, 64GB RAM を搭載した PC を用いた。実行時間の計測は MATLAB の timeit 関数を用いて行った。

4. 結果

学習結果を図 5 から図 8 に示す。




図 5: RMSE の推移 (方位角モデル)




図 6: 損失の推移 (方位角モデル)




図 7: RMSE の推移 (仰角モデル)




図 8: 損失の推移 (仰角モデル)

図は学習用と検証用のデータセットに対する損失関数および RMSE(二乗平均平方根誤差) の推移を示しており、反復回数(1000 回で 1 エポック)が進むにつれて損失関数、RMSE ともに減少していることがわかる。また、テスト用データセットに対する推定値の誤差の絶対値平均を表 2 に示す。ここで、方向誤差とは、方位角と仰角で決まるベクトルの、推定方向と正しい方向とのなす角度である。実行時間は、MUSIC では共分散

行列から方位角と仰角を推定する処理にかかる時間を示し、機械学習モデルでは 30 個の実数を入力から方位角と仰角を推定する処理にかかる時間を示す。テストではデータセットに対する 3000 回の推定をまとめて行うため、表には 3000 回まとめて行った実行時間を 3000 で割った、推定 1 回あたりの実行時間を示している。

表 2: 推定誤差と実行時間

	方位角 θ_a 誤差		
	最大	最小	平均
ML モデル	160.5997°	0.0000°	1.0610°
MUSIC(2°)	93.7257°	0.0002°	0.5839°
MUSIC(1°)	93.7257°	0.0000°	0.2891°
MUSIC(0.1°)	91.7257°	0.0000°	0.0598°
	仰角 θ_e 誤差		
	最大	最小	平均
ML モデル	1.2543°	0.0000°	0.1101°
MUSIC(2°)	1.6072°	0.0008°	0.5495°
MUSIC(1°)	1.4276°	0.0000°	0.2542°
MUSIC(0.1°)	1.4276°	0.0000°	0.0446°
	方向誤差		
	最大	最小	平均
ML モデル	95.3228°	0.0044°	0.6777°
MUSIC(2°)	1.7954°	0.0331°	0.7511°
MUSIC(1°)	1.4276°	0.0112°	0.3504°
MUSIC(0.1°)	1.4276°	0.0002°	0.0527°
	実行時間		
ML モデル	30.3809 μ s		
MUSIC(0.1°)	17.3427 ms		
MUSIC(1°)	13.4460 ms		
MUSIC(2°)	12.6887 ms		

機械学習モデルの誤差は、方位角が平均 1.0610°、仰角が 0.1101° であり、方向誤差が 0.6777° である。一方、MUSIC の誤差は、分解能が 0.1° のとき、方位角が 0.0598°、仰角が 0.0446° であり、方向誤差が 0.0527° であり、いずれも機械学習モデルの誤差よりも小さくなっている。MUSIC の分解能が 1° のときの誤差は、方位角が 0.2891°、仰角が 0.2542° であり、方向誤差が 0.3504° であり、仰角の誤差のみ機械学習モデルが小さくなっている。MUSIC の分解能が 2° のときの誤差は、方位角が 0.5839°、仰角が 0.5495° であり、方向誤差が 0.7511° であり、いずれも機械学習モデルの誤差よりも大きくなっている。実行時間は、機械学習モデルが 30.3809 μ s であり、MUSIC は 17.3427 ms, 13.4460 ms, 12.6887 ms といずれも十数 ms であり、機械学習モデルに比べて非常に大きい結果が得られた。

5. 考察

機械学習モデルは方位角誤差に比べて、仰角誤差が小さいが、これは方位角モデルは 100° 以上の誤差が顕著に大きい点が数点あることに関連している。誤差が顕著に大きい点は方位角が 0° または 360° 付近に多く、これは方位角が 0° から 360° でループし、0° と 360° は同じ方向を示しているにもかかわらず、現在の機械学習モデルでは離れた方向として扱ってしまうことが原因である。そのため、方位角のループを考慮したモデ

ルを作成することで、この問題を解消することが期待される。他に原因として考えられるのは、方位角は仰角に比べ範囲が 4 倍大きく、モデルが十分にフィットできていないということが考えられる。そのため、モデルサイズを大きくすることで解消することが期待できる。

機械学習モデルと MUSIC の方向誤差を比較すると、機械学習モデルは MUSIC の分解能が 2° のときの方向誤差よりも小さいが、MUSIC の分解能が 1° のときの方向誤差よりも大きい。よって機械学習モデルの推定能力は、1° の分解能の MUSIC と 2° の分解能の MUSIC の間であると考えられるが、機械学習モデルの実行時間は 1° の分解能の MUSIC と 2° の分解能の MUSIC のいずれよりも十分小さいため、機械学習モデルと機械学習モデルと同じ推定能力の MUSIC の実行時間を比較しても、機械学習モデルの方が高速であると予想される。

本論文では、実行時間の計測は 3.5 節の環境で行ったが、実際の無人機に搭載可能なコンピュータは、今回の環境に比べ性能が低くなると考えられ、実行時間も増加すると予想される。そのため、実際に無人機に搭載可能なコンピュータに近い Raspberry Pi などの環境での実行時間の計測が必要である。

6. おわりに

本論文では、機械学習モデルによる到来方向推定手法の汎用性の向上を目指す前段階として、最もシンプルなモデルを作成し、そのモデルと従来の方向推定手法である MUSIC の方向推定精度と計算量の比較を行った。その結果、機械学習モデルは MUSIC の分解能が 2° のときの方向誤差よりも少し小さい 0.6777° の誤差であることがわかった。また、機械学習モデルの実行時間は同程度の推定能力の MUSIC の実行時間の 400 分の 1 以下の 30.3809 μ s であることがわかった。これらの結果から、機械学習モデルは MUSIC に比べて十分高速であることがわかった。今後の課題としては、実際の無人機上での推定時に起きうるさまざまな状況下で、機械学習モデルを用いて高精度な方向推定が可能であるかを明らかにする必要がある。そのため、送信機と受信機の距離の変化に対応するモデルをはじめとする、汎用性を向上させたモデルの作成に取り組みたい。

参考文献

- [1] R. Schmidt, "Multiple emitter location and signal parameter estimation," IEEE Trans. Antennas Propag., vol. 34, no. 3, pp. 276-280, 1986
- [2] R. Roy and T. Kailath, "ESPRIT- Estimation of signal parameters via rotational invariance techniques," IEEE Trans. Accous., Speech, Signal Proc., vol. 37, no. 7, pp. 984-995, 1989
- [3] X. Chen, D. Wang, J. Yin and Y.A. Wu, "A Direct Position-Determination Approach for Multiple Sources Based on Neural Network Computation," Sensors, vol. 18, no. 6:1925, 2018
- [4] I. Pisa, G. Boquet, X. Vilajosana and B. Martinez, "On the Generalization of Deep Learning Models for AoA Estimation in Bluetooth Indoor Scenarios," Internet of Things, vol. 26, pp. 101152, 2024
- [5] J. Yu, W.W. Howard, D. Tait and R.M. Buehrer, "Direction-of-Arrival Estimation With A Vector Sensor Using Deep Neural Networks," IEEE VTC2021-Spring, pp. 1-7, 2021