

機械学習を用いたブラックホールの質量降着率と磁束の推定

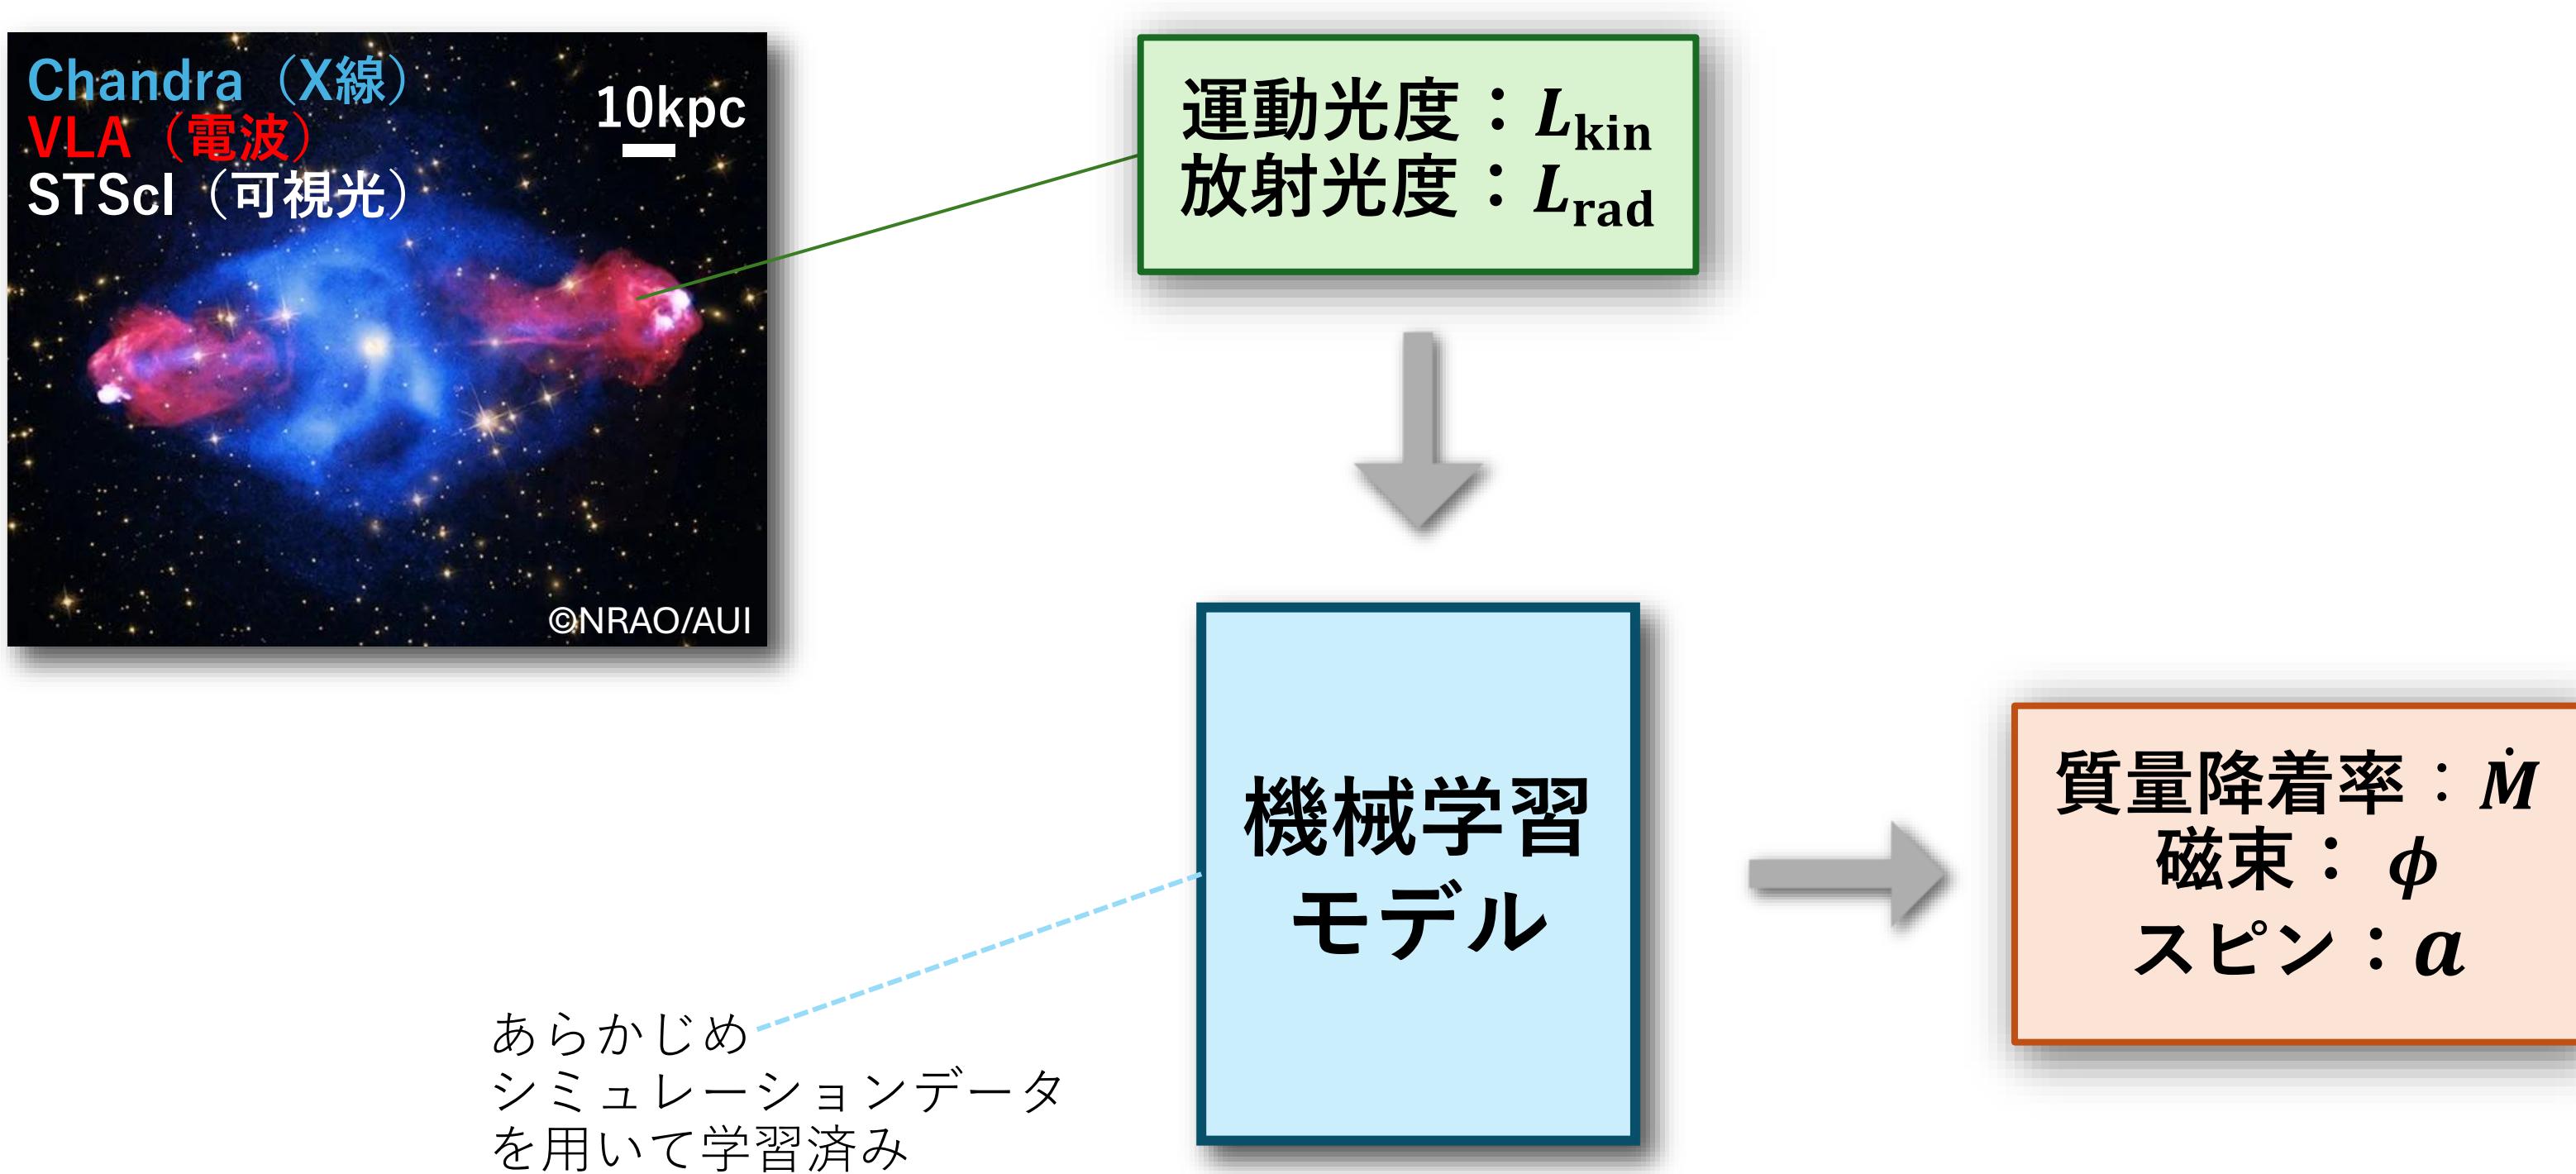
松藤勇希（筑波大学M1），朝比奈雄太（駒澤大学・筑波大学），大須賀健（筑波大学），芳岡尚悟（京都大学・筑波大学），高橋博之（駒澤大学）

要旨

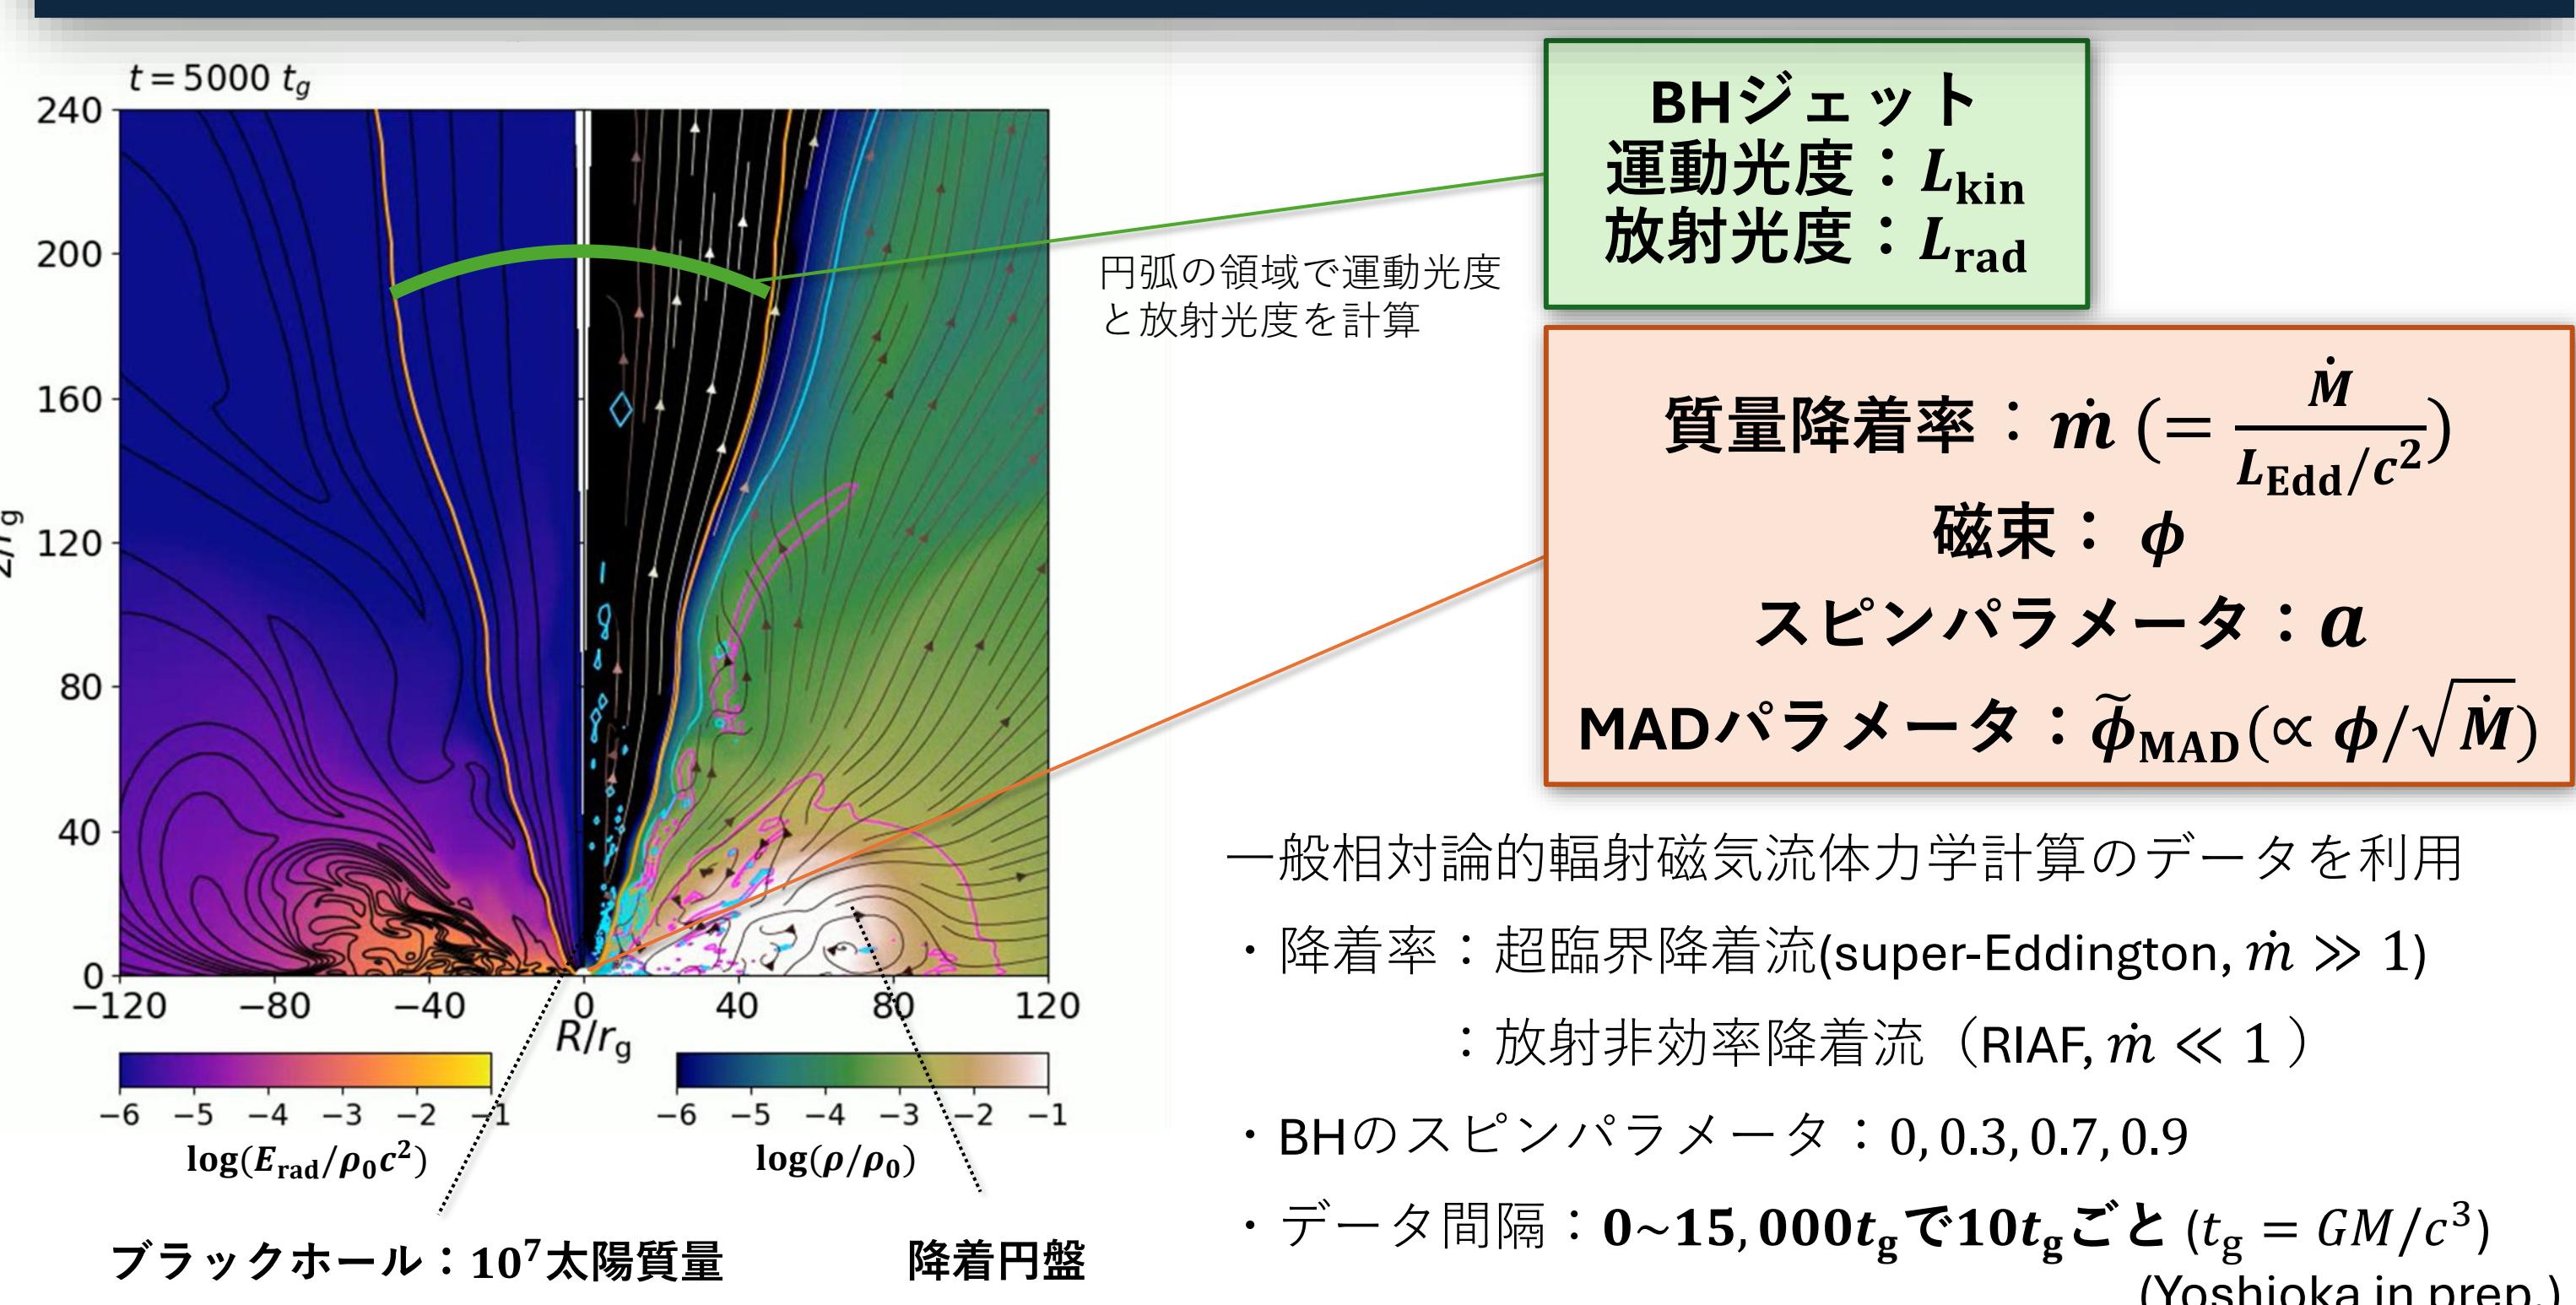
観測から制限することが困難なブラックホール（BH）の質量降着率や磁束、スピンを、天体の放射光度および運動光度から推定する機械学習手法を提案する。シミュレーションデータを用いたテストで決定係数0.99を達成する有力な手法である。

<背景と目的> 質量降着率やスピンの推定手法の課題とその代替手法

銀河進化に対するブラックホールジェットの影響を理解するには、BHの質量降着率や磁束、スピンなどBH近傍の物理量の推定が不可欠である。The Event Horizon Telescope Collaborationによるスピンや磁場構造の計測が試みられているが、十分とは言えず、しかも適用天体はごく僅かである。そこで本研究では、直接観測することが難しいBHの降着率、磁束、スピンを、比較的容易に観測可能な天体の放射と運動光度から推定する新しい機械学習モデルを開発する。



<セットアップ> シミュレーションデータについて



<教師データ> 入力値として時系列情報の追加の有無

①時系列情報の追加無し：シミュレーションデータをそのまま教師データに使う

| 時刻(t_g) | 入力 | | シミュレーションデータ | | | | 出力 | | |
|-------------|------------------|------------------|-------------|--------------------|--------------|---|----|--|--|
| | L_{kin} | L_{rad} | スピン(a) | 質量降着率(\dot{m}) | 磁束(ϕ) | MADパラメータ($\tilde{\phi}_{\text{MAD}}$) | | | |
| 5000 | 11 | 1 | 0 | 1 | 3 | 1.5 | | | |
| 5010 | 11.1 | 1.1 | 0 | 2 | 8 | 2 | | | |
| 5020 | 11.2 | 1.2 | 0 | 1 | 5 | 2 | | | |
| ... | ... | ... | ... | ... | ... | ... | | | |
| 15000 | 101 | 20.1 | 0 | 6 | 20 | 7 | | | |

×スピン4 モデル
×降着率2 モデル

②時系列情報の追加あり：シミュレーションデータに100 t_g 前後の時刻の運動光度と放射光度を入力値として追加

| 時刻(t_g) | シミュレーションデータ | | | | | | 出力 | | | |
|-------------|--------------------|------------------|-----------------------|-----------------------|-----------------------|-----------------------|------------|--------------------|--------------|---|
| | L_{kin} | L_{rad} | $L_{\text{kin},-100}$ | $L_{\text{kin},+100}$ | $L_{\text{rad},-100}$ | $L_{\text{rad},+100}$ | スピン(a) | 質量降着率(\dot{m}) | 磁束(ϕ) | MADパラメータ($\tilde{\phi}_{\text{MAD}}$) |
| 5000 | 11 | 1 | 10 | 12 | 0 | 2 | 0 | 1 | 3 | 1.5 |
| 5010 | 11.1 | 1.1 | 10.1 | 12.1 | 0.1 | 2.1 | 0 | 2 | 8 | 2 |
| ... | 追加入力値(100 t_g 前) | | | ... | ... | ... | ... | ... | ... | ... |
| 5200 | 13 | 3 | 12 | 14 | 2 | 4 | 0 | 1 | 5 | 2 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 5300 | 14 | 4 | 13 | 15 | 3 | 5 | 0 | 3 | 5 | 1 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 5400 | 15 | 5 | 14 | 16 | 4 | 6 | 0 | 6 | 20 | 7 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 14000 | 101 | 91 | 100 | 102 | 90 | 92 | 0 | 3 | 6 | 2 |

×スピン4 モデル
×降着率2 モデル

総サンプル数：7200(900スナップショット × 8モデル)のうち80%を学習に、20%を評価に使用

評価指標：決定係数 ($R^2 = 1 - \frac{\sum_i (\text{正解値}_i - \text{予測値}_i)^2}{\sum_i (\text{正解値}_i - \text{正解値の平均値})^2}$)， $\pm 2\sigma$ (σ : 標準偏差)に
1に近いほど良い

含まれるデータの割合、Accuracy (= (正解した数) / (すべての数))

本研究では、決定木による機械学習手法の1つであるLightGBMを用いた。

学習・評価方法について

(手順1) 学習

| 入力 | 出力 | シミュレーションデータ | | | | |
|------|-----|------------------|------------------|-----|-------|-----|
| | | L_{kin} | L_{rad} | スピン | 質量降着率 | 磁束 |
| 5000 | 0.3 | 0.1 | 0 | 1 | 3 | 1.5 |
| 5010 | 0.6 | 0.4 | 0 | 2 | 8 | 2 |
| 5020 | 1 | 1.3 | 0 | 2.5 | 10 | 2 |
| 5030 | 2 | 2 | 0 | 5 | 12 | 1.2 |
| 5040 | 5 | 2.5 | 0 | 10 | 16 | 0.8 |
| ... | ... | ... | ... | ... | ... | ... |

学習

機械学習モデル

(手順2) 推定

| 入力 | 出力 | シミュレーションデータ | | | | |
|------|-----|------------------|------------------|-----|-------|-----|
| | | L_{kin} | L_{rad} | スピン | 質量降着率 | 磁束 |
| 5000 | 0.3 | 0.1 | 0 | 1 | 3 | 1.5 |
| 5010 | 0.6 | 0.4 | 0 | 2 | 8 | 2 |
| 5020 | 1 | 1.3 | 0 | 2.5 | 10 | 2 |
| 5030 | 2 | 2 | 0 | 5 | 12 | 1.2 |
| 5040 | 5 | 2.5 | 0 | 10 | 16 | 0.8 |
| ... | ... | ... | ... | ... | ... | ... |

学習に未使用のデータ

機械学習モデル

推定

(手順3) 評価

| 入力 | 出力 | シミュレーションデータ | | | | |
|------|-----|------------------|------------------|-----|-------|-----|
| | | L_{kin} | L_{rad} | スピン | 質量降着率 | 磁束 |
| 5000 | 0.3 | 0.1 | 0 | 1 | 3 | 1.5 |
| 5010 | 0.6 | 0.4 | 0 | 2 | 8 | 2 |
| 5020 | 1 | 1.3 | 0 | 2.5 | 10 | 2 |
| 5030 | 2 | 2 | 0 | 5 | 12 | 1.2 |
| 5040 | 5 | 2.5 | 0 | 10 | 16 | 0.8 |
| ... | ... | ... | ... | ... | ... | ... |

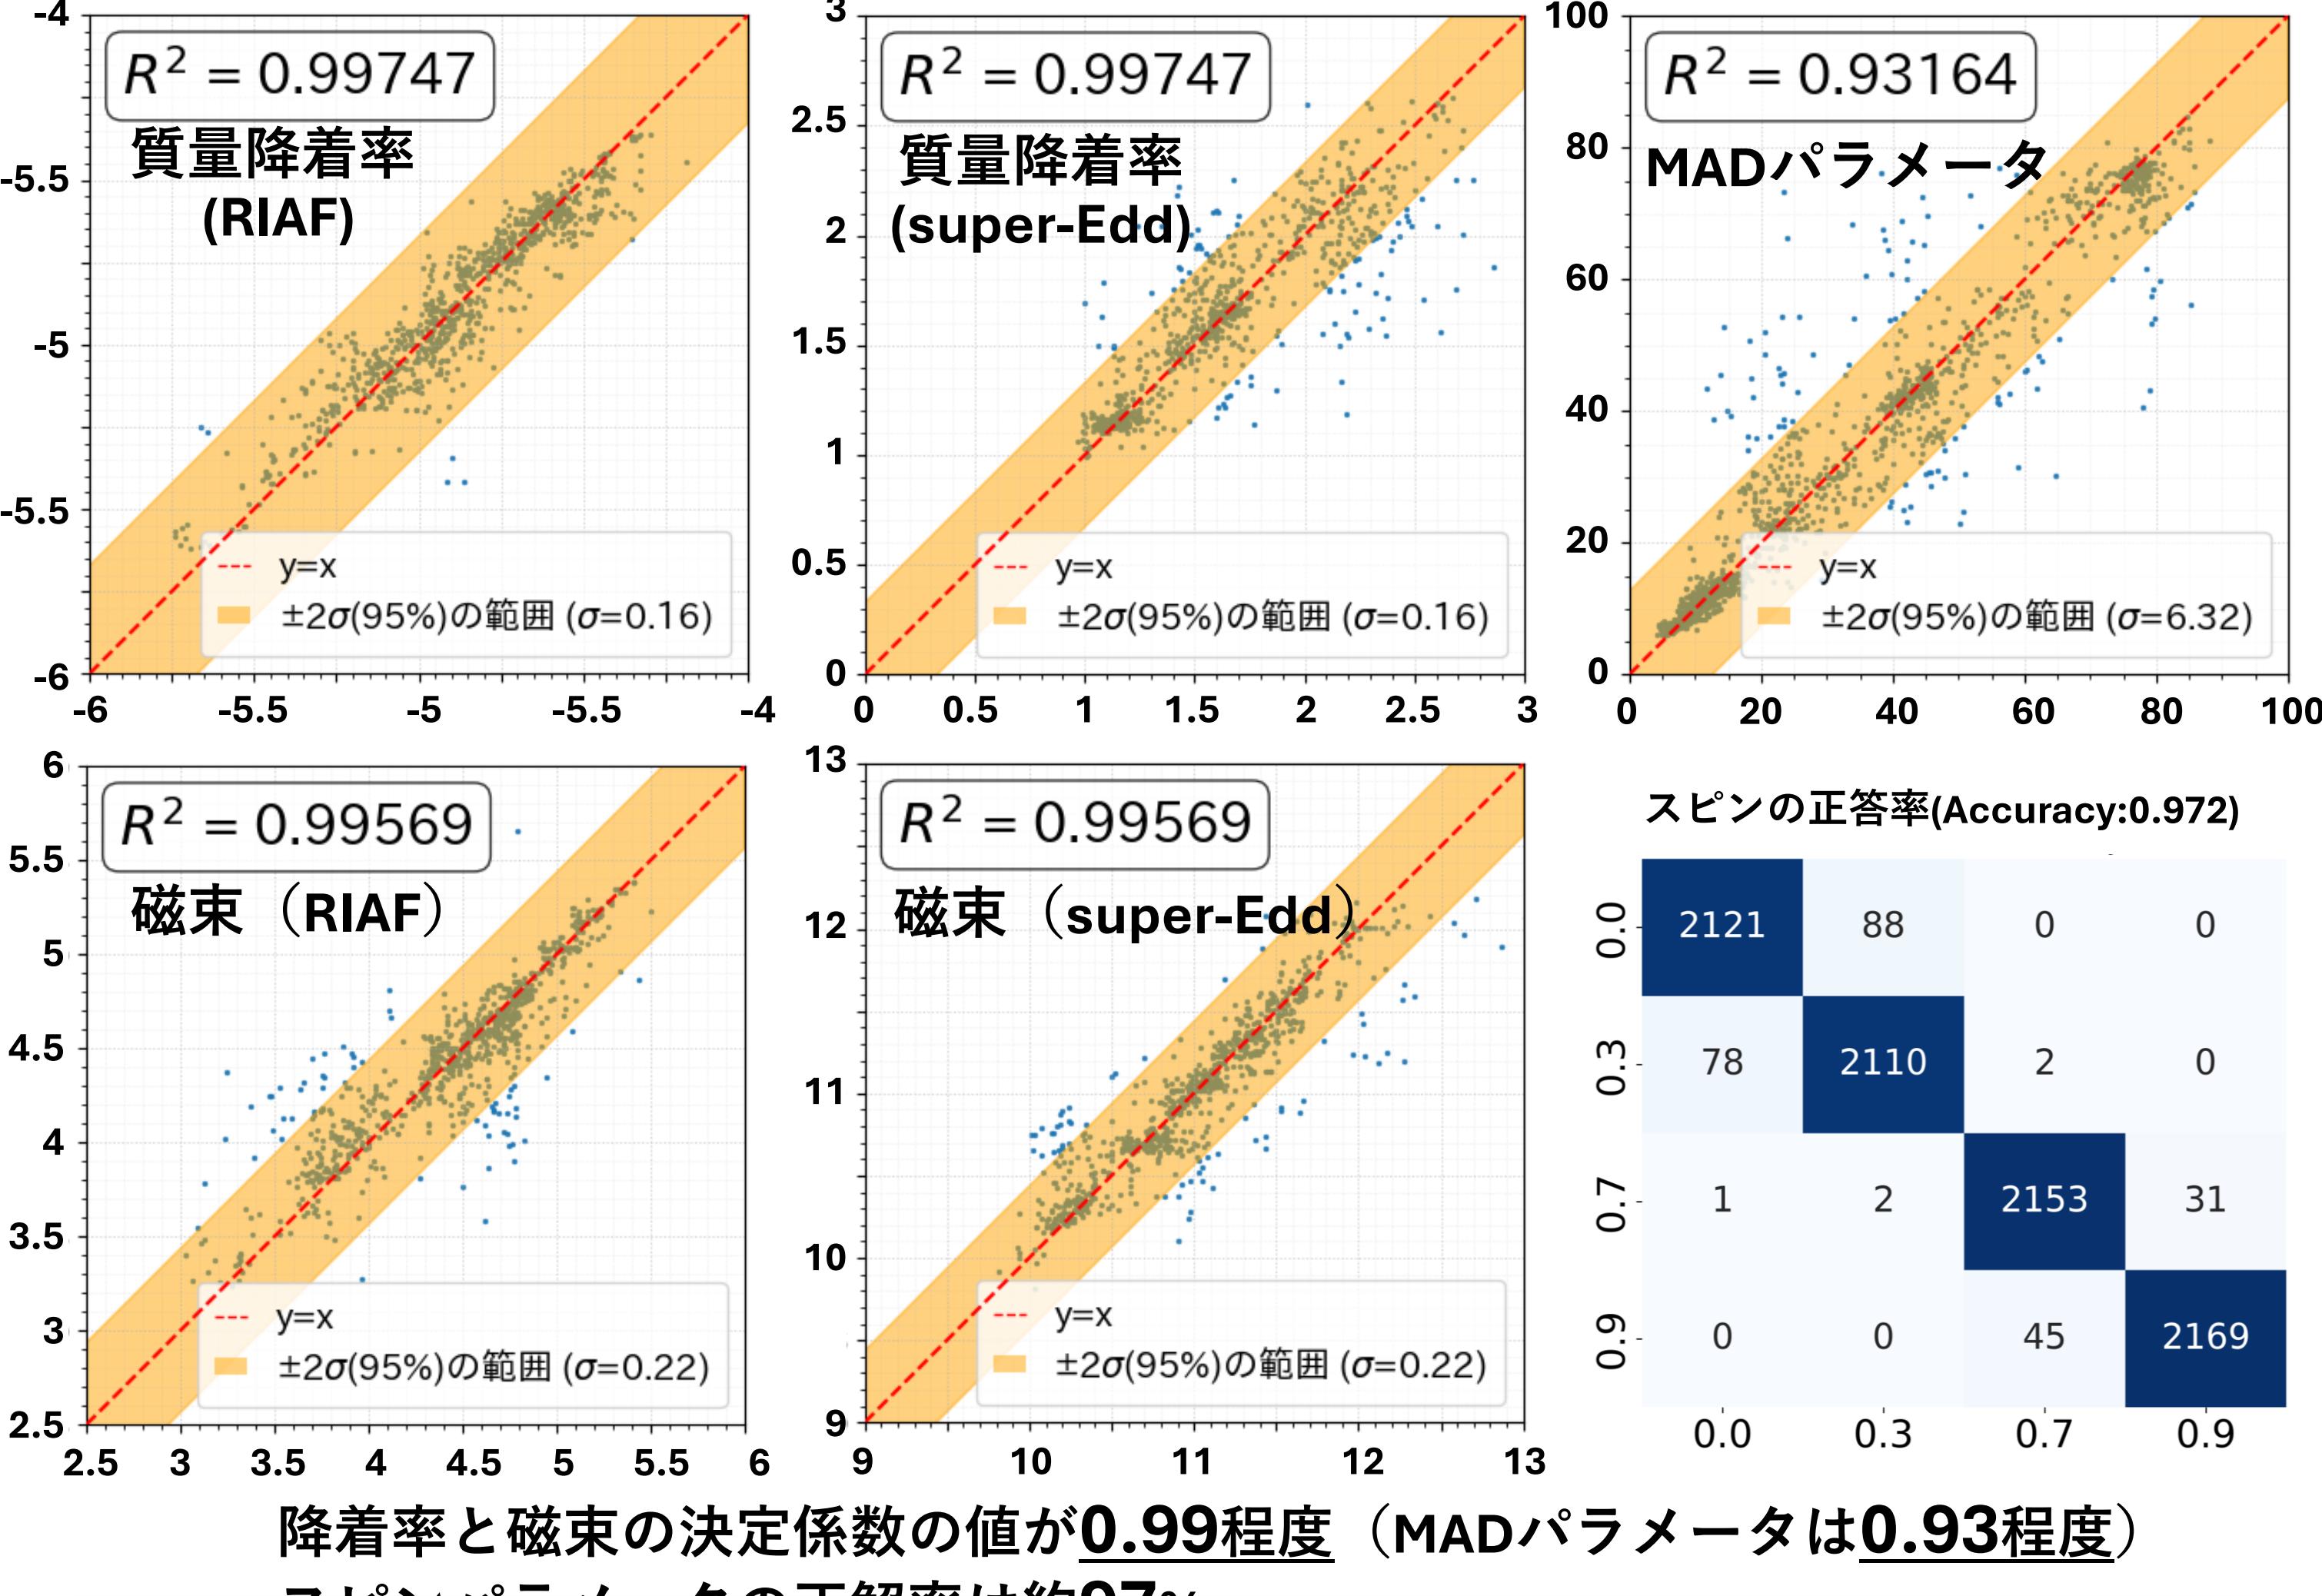
正解値

機械学習モデル

推定

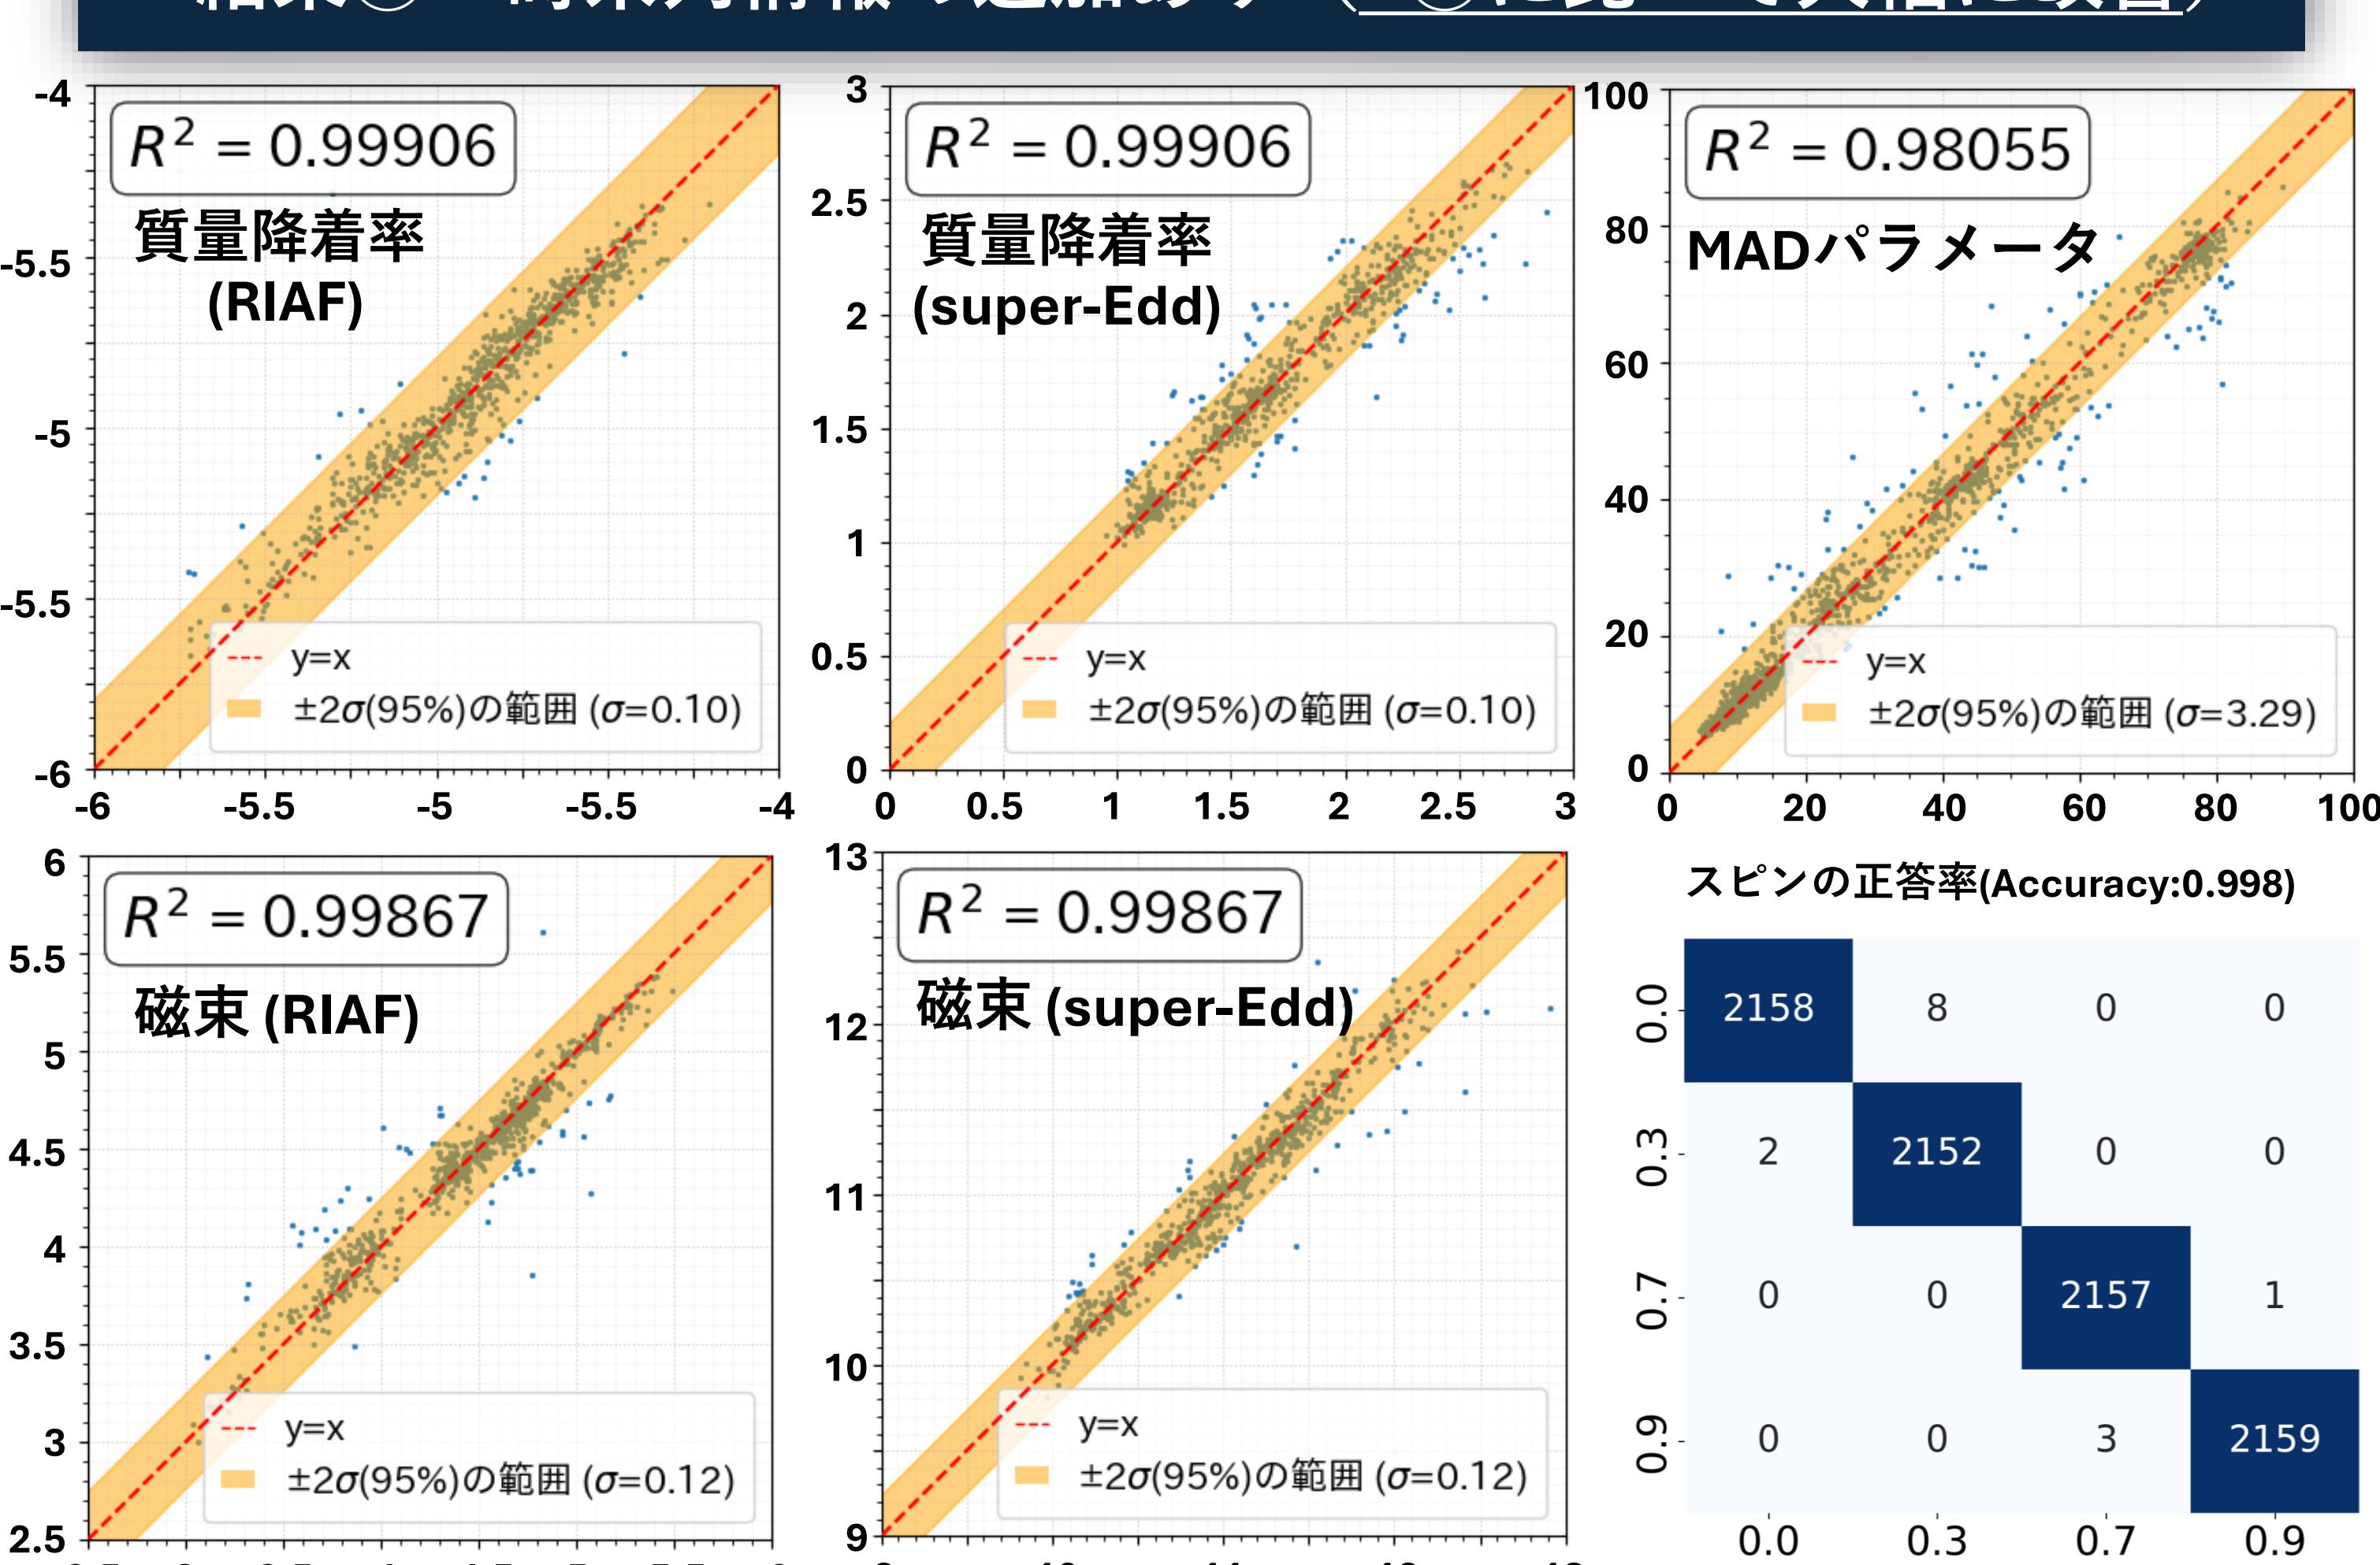
<結果①> 時系列情報の追加無し

推定結果 (横軸：正解値、縦軸：推定値)



降着率と磁束の決定係数の値が0.99程度 (MADパラメータは0.93程度)
スピニパラメータの正解率は約97%

<結果②> 時系列情報の追加あり (→①に比べて大幅に改善)



結論と今後の展望

天体の運動光度と放射光度を入力とし、質量降着率・磁束・MADパラメータ・スピニを推定する機械学習モデルを構築した。テストの結果、決定係数は0.99程度、スピニの正解率は99.8%を記録した。本手法が有効であるといえる。今後は、教師データのデータ分布を均一にすることでより精度の高いモデルへと発展させ、観測データに適用できるようにノイズを入れた学習を実施する。