

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

筑波大学M1 松藤勇希

共同研究者：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）


研究背景：ブラックホールジェットの重要性



巨大ブラックホール（SMBH）から噴射される

AGNジェットは銀河の形成に深くかかわっている


研究背景：ブラックホールジェットの重要性



巨大ブラックホール (SMBH) から噴射される
AGNジェットは銀河の形成に深くかかわっている

スピン, 質量降着率, 磁束

研究背景：スピンパラメータや質量降着率の重要性




巨大ブラックホールから噴射される相対論的
ジェットは銀河の形成に深くかかわっている

スピン，質量降着率，磁束

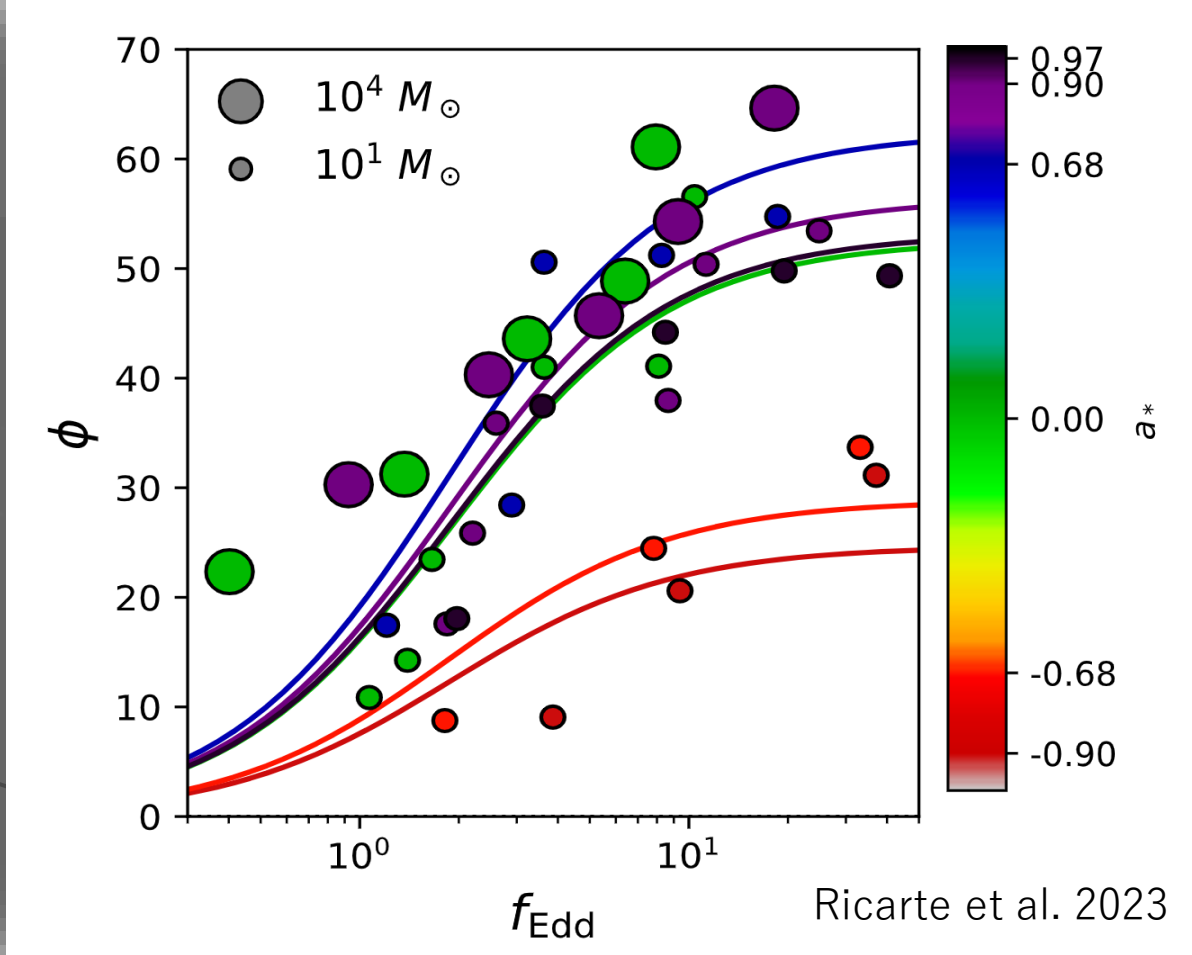
スピンが大きいほどジェットの
エネルギー変換効率は大きい

©NRAO/AUI

研究背景：スピンパラメータや質量降着率の重要性




スピンが大きいほどジェットの
エネルギー変換効率は大きい




降着率が大きいほど磁束が大きい

研究背景：スピンパラメータや質量降着率の重要性



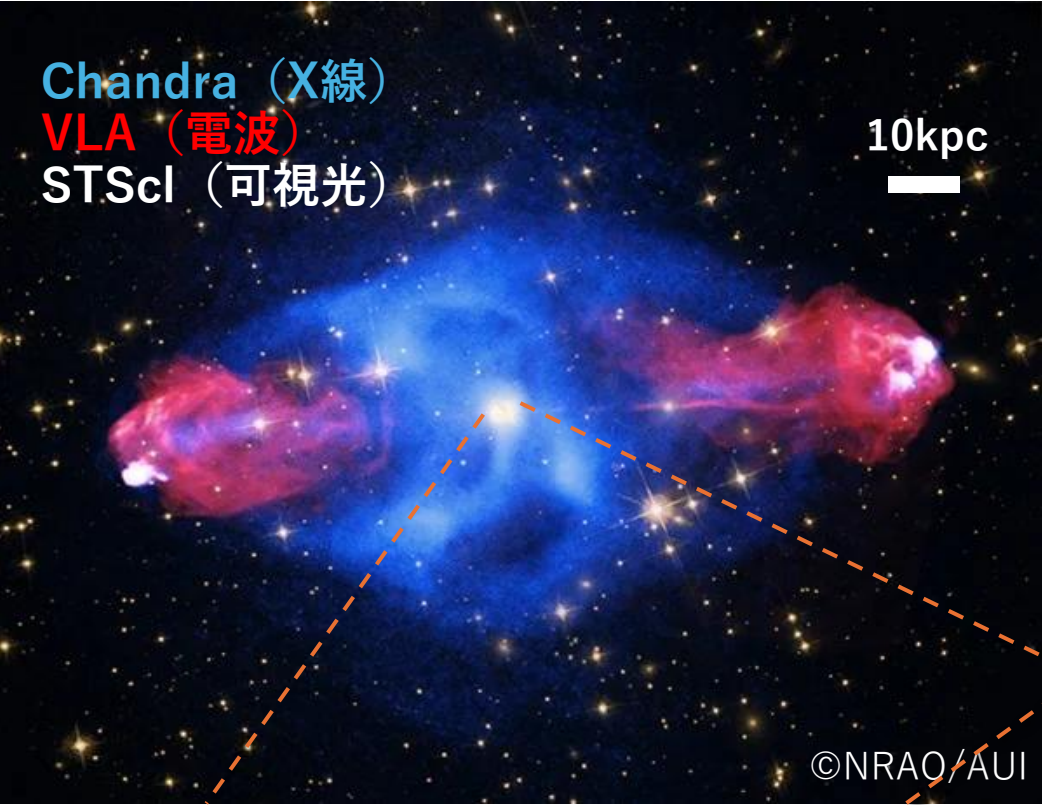
スピンが大きいほどジェットのエネルギー変換効率は大きい





降着率が大きいほど磁束が大きい

➡ スピンや質量降着率が、ジェットのエネルギー効率や磁束に影響を及ぼす

研究背景：観測の限界




(イメージ)



質量集中度は？
ブラックホールは？

研究目標：機械学習を用いた推定を目指す



(観測で得られる量)

運動光度： L_{kin}
放射光度： L_{rad}

機械学習による推定が可能か否かを
シミュレーションデータの範囲で検証する

本発表の範囲

あらかじめ
シミュレーションデータ
を用いて学習済み

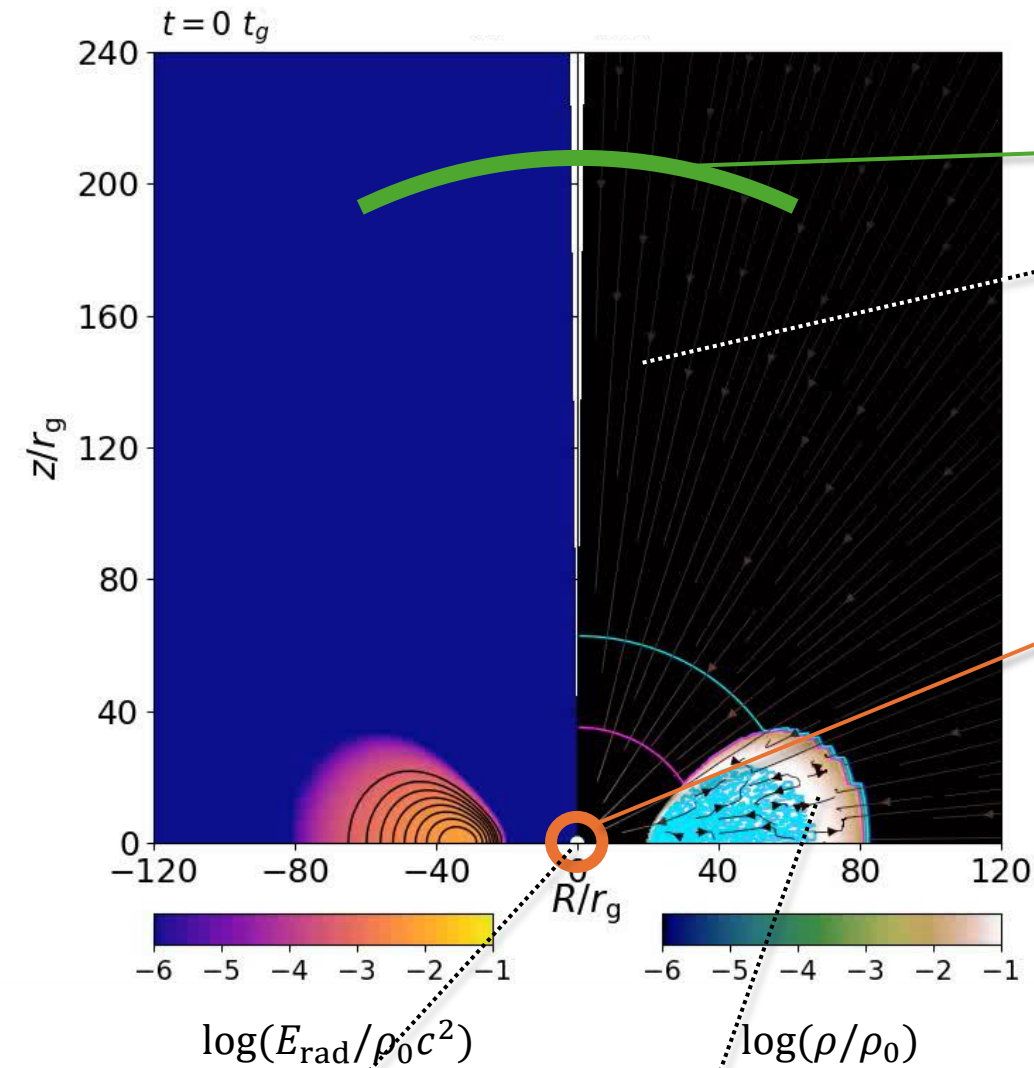
機械学習モデル

推定

(観測で得るのが難しい量)

質量降着率： \dot{M}
磁束： Φ

シミュレーションデータについて



ブラックホール： 10^7 太陽質量

降着円盤

ジェット

運動光度： L_{kin}
放射光度： L_{rad}

質量降着率： $\dot{m} (= \frac{\dot{M}}{L_{\text{Edd}}/c^2})$

磁束： ϕ

スピンパラメータ： a

MADパラメータ： $\tilde{\phi}_{\text{MAD}} (\propto \phi/\sqrt{\dot{M}})$

一般相対論的輻射磁気流体力学計算のデータを利用

- 降着率：超臨界降着流(super-Eddington, $\dot{m} \gg 1$)

- 放射非効率降着流 (RIAF, $\dot{m} \ll 1$)

- BHのスピンパラメータ：0, 0.3, 0.7, 0.9

- データ間隔：0~15,000 t_g で10 t_g ごと ($t_g = GM/c^3$)

(Yoshioka in prep.)

教師データについて

教師データ						
時刻(t_g)	入力		出力			
	L_{kin}	L_{rad}	質量降着率 (\dot{m})	磁束(ϕ)	MAD パラメータ ($\tilde{\phi}_{\text{MAD}}$)	スピン(a)
5000	10	0.1	1	3	1.5	0
5010	11	1	2	8	2	0
5020	12	2	3	5	3	0
5030	13	3	5	7	1.2	0
5040	14	4	4	3	2	0
5050	15	5	6	18	3	0
...
15000	37	15	7	10	3	0

× 8モデル

入力値として別の時刻の L_{kin} の値を追加

教師データ									
時刻(t_g)	入力								
	L_{kin}	L_{rad}							
...							
9000	10	0.1							
9010	11	1							
9020	12	2							
9030	13	3							
9040	14	4							
9050	15	5							
9060	16	6							
...							

入力値として別の時刻の L_{kin} の値を追加

教師データ									
時刻(t_g)	入力								
	L_{kin}	L_{rad}	$L_{kin,-10}$						
...							
9000	10	0.1							
9010	11	1							
9020	12	2							
9030	13	3	12						
9040	14	4							
9050	15	5							
9060	16	6							
...							

入力値として別の時刻の L_{kin} の値を追加

教師データ									
時刻(t_g)	入力								
	L_{kin}	L_{rad}	$L_{kin,-10}$	$L_{kin,-20}$...	$L_{kin,-1000}$			
...							
9000	10	0.1							
9010	11	1							
9020	12	2							
9030	13	3	12	11	...	1			
9040	14	4							
9050	15	5							
9060	16	6							
...							

入力値として別の時刻の L_{kin} の値を追加

教師データ									
時刻(t_g)	入力								
	L_{kin}	L_{rad}	$L_{kin,-10}$	$L_{kin,-20}$...	$L_{kin,-1000}$	$L_{kin,+10}$...	$L_{kin,+1000}$
...							
9000	10	0.1							
9010	11	1							
9020	12	2							
9030	13	3	12	11	...	1	14		103
9040	14	4							
9050	15	5							
9060	16	6							
...							

入力値として別の時刻の L_{rad} の値も追加

教師データ								
時刻(t_g)	入力							
	L_{kin}	L_{rad}	$L_{\text{kin},-1000}$...	$L_{\text{kin},+1000}$	$L_{\text{rad},-1000}$...	$L_{\text{rad},+1000}$
...						
9000	10	0.1						
9010	11	1						
9020	12	2						
9030	13	3	11	...	1	14		103
9040	14	4						
9050	15	5						
9060	16	6						
...						

} 402列

機械学習モデルに与える教師データ

教師データ（シミュレーションデータ）							
時刻(t_g)	入力			出力			
	L_{kin}	L_{rad}	...	質量降着率 (\dot{m})	磁束(ϕ)	MAD パラメータ ($\tilde{\phi}_{\text{MAD}}$)	スピン(a)
5000	11	10.1	...	1	3	1.5	0
5010	11.1	10.11	...	2	8	2	0
5020	12	10.2	...	5	12	1.2	0
...	0
14000	101	20.1	...	5	13	5	0

× 8モデル

総サンプル数：7200(900 × 8)のうち80%を学習に，20%を評価に使用

手法：勾配ブースティング決定木ベースのLightGBM

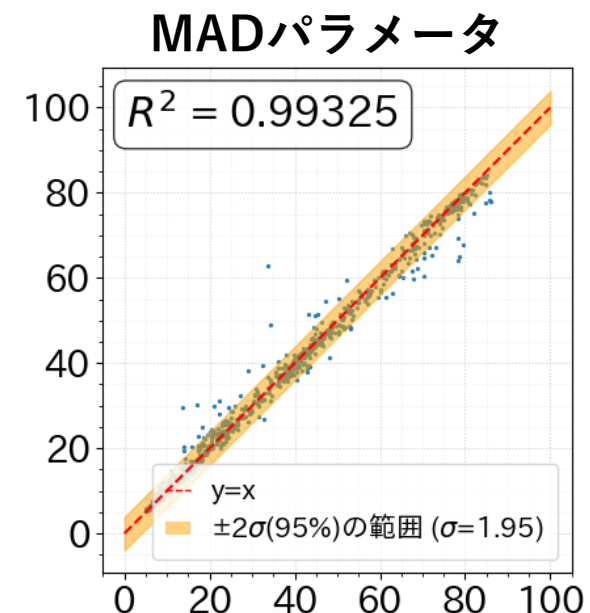

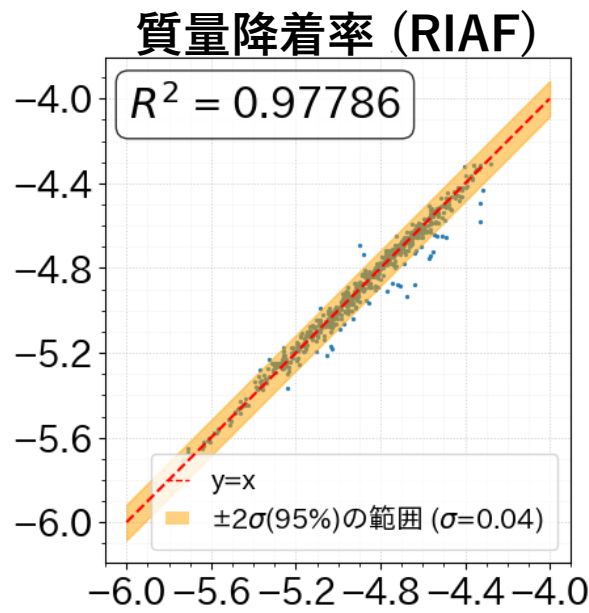
評価指標：決定係数 $\left(R^2 = 1 - \frac{\sum_i (\text{正解値}_i - \text{予測値}_i)^2}{\sum_i (\text{正解値}_i - \text{正解値の平均値})^2} \right)$

1に近いほど良い




誤差率の標準偏差 ± 2σ に含まれるデータの割合

Accuracy (= (正解数 / 全データ数))

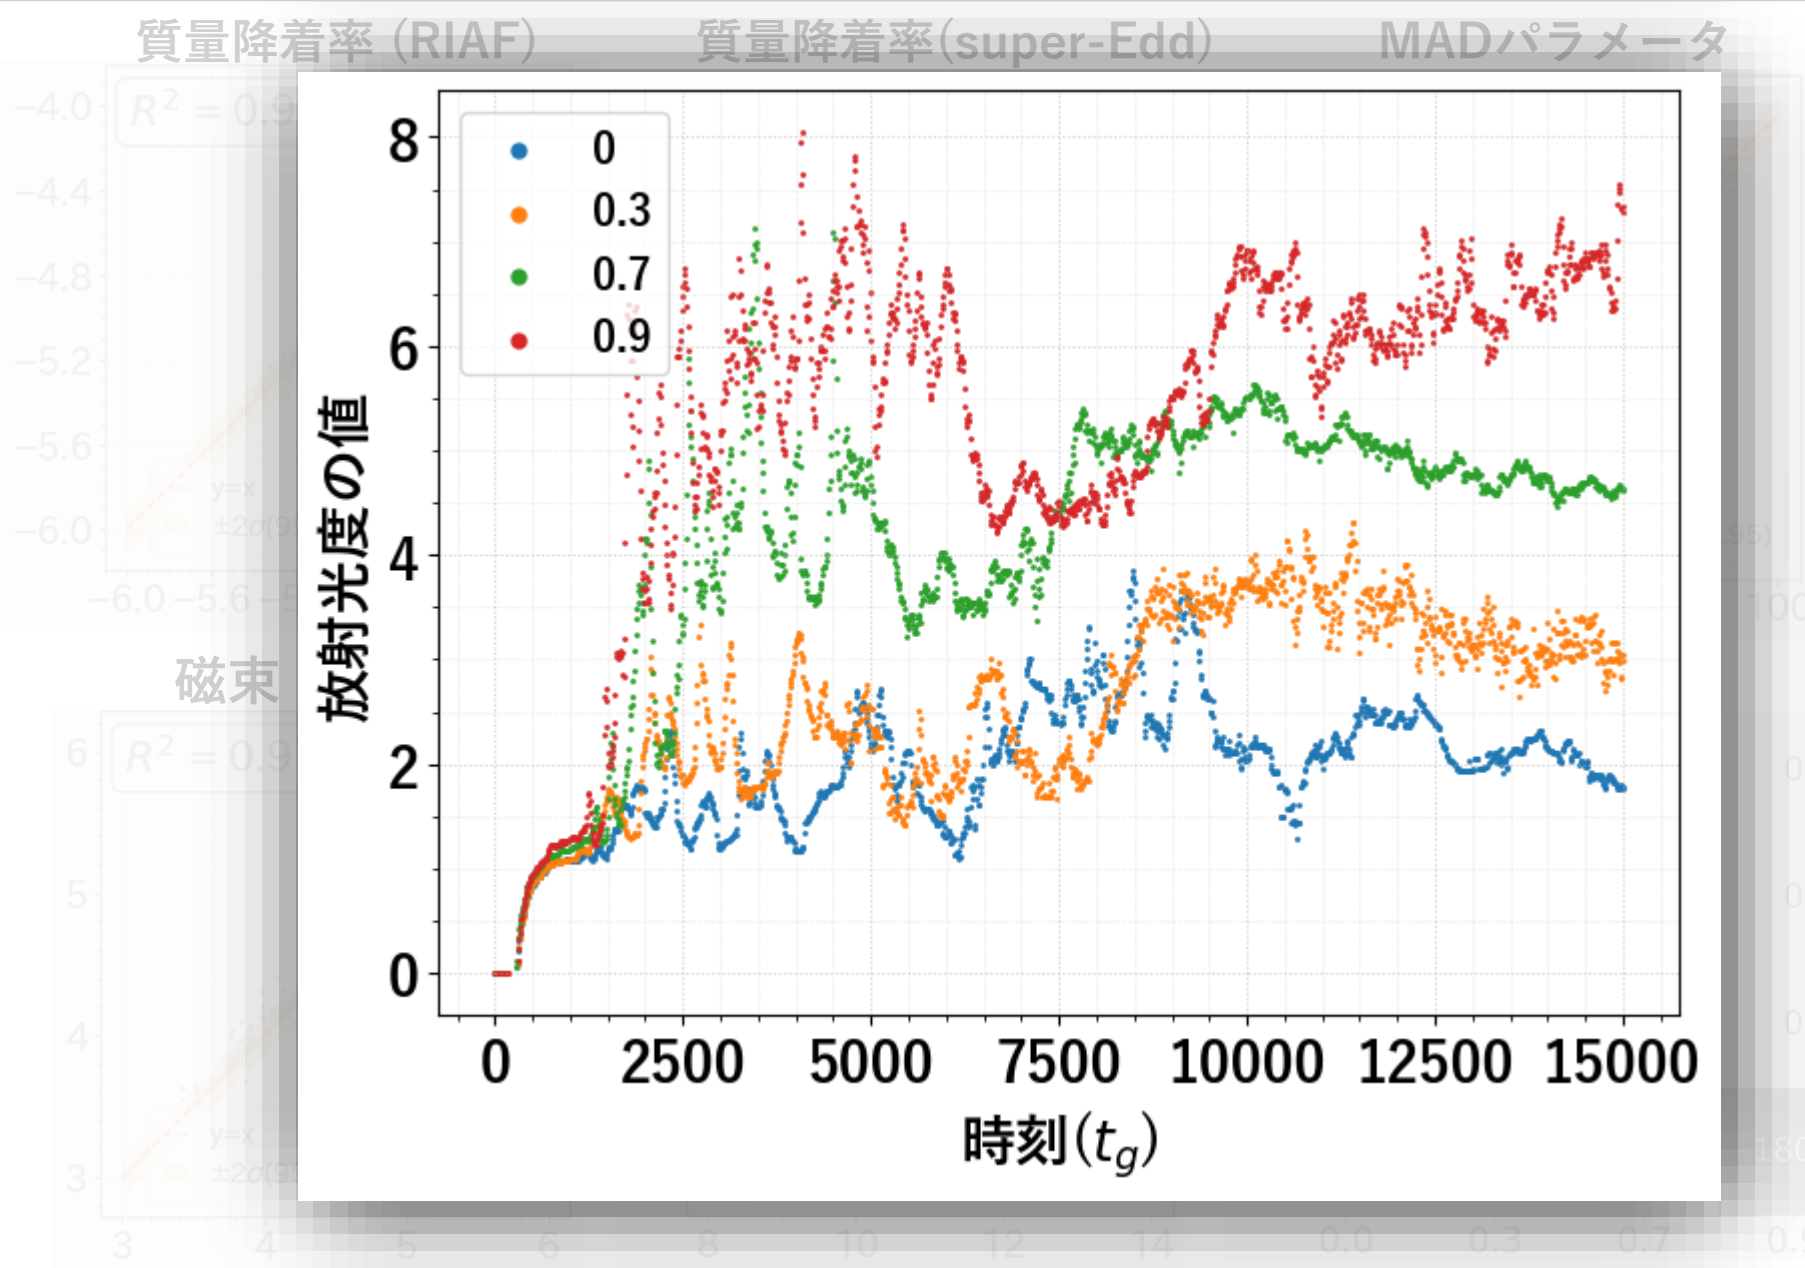
推定結果（横軸：正解値，縦軸：推定値）



決定係数は**0.97~0.99**であり，良く推定できている。
スピンについては正答率100%



推定結果（横軸：正解値，縦軸：推定値）

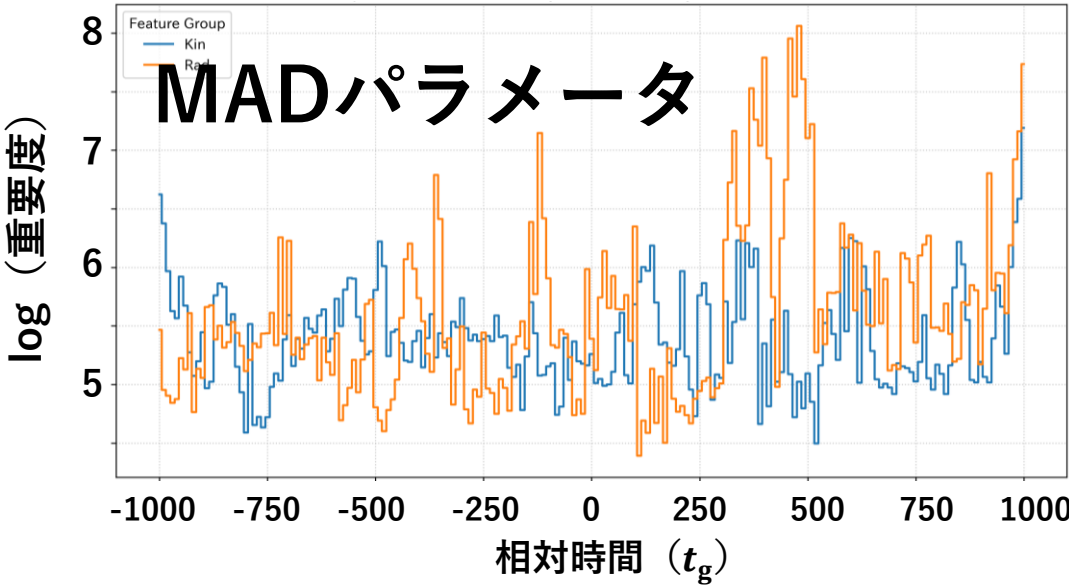




決定係数は0.97~0.99
であり，良く推定できている。

スピンについては正答率100%

**スピンの推定は
比較的容易**

運動光度と放射光度の重要度



運動光度

放射光度

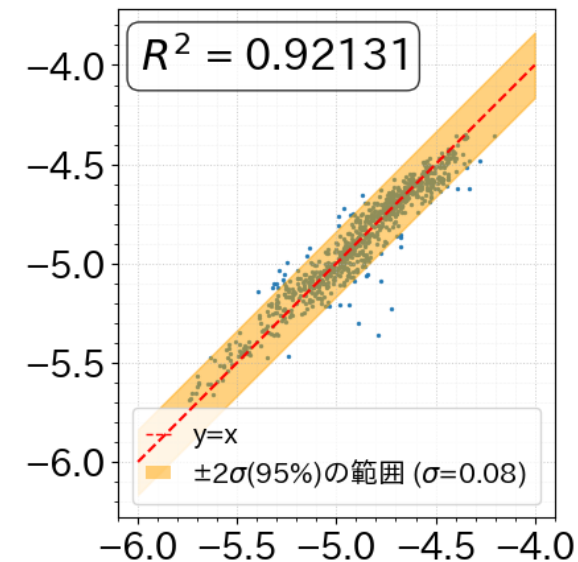
※重要度：ある時刻の物理量(\dot{m} , ϕ , $\tilde{\phi}_{\text{MAD}}$, a)を推定するのに、どの時刻の運動光度と放射光度が効いているのかを示したもの

入力値として別の時刻の L_{kin} の値を追加②

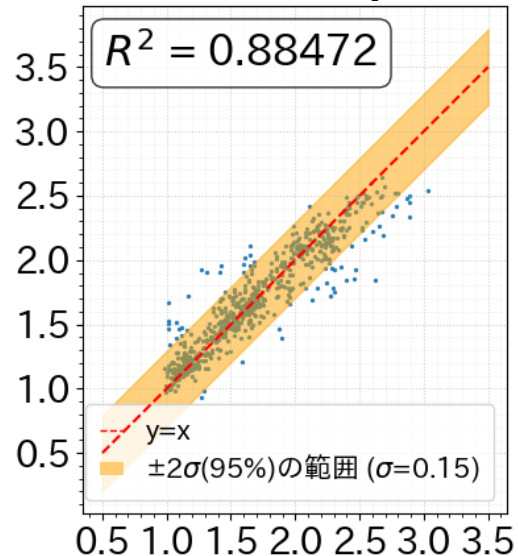
[illegible]

推定結果： $-50t_g$ と $-100t_g$ の L_{kin} と L_{rad} を入力値に追加（横軸：正解値，縦軸：推定値）


質量降着率 (RIAF)



質量降着率(super-Edd)



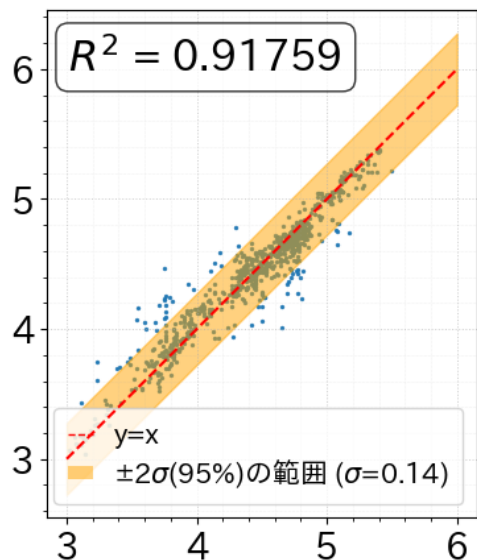
MADパラメータ




決定係数は**0.88~0.97**であり，先の結果よりも精度は落ちているがそれでも良く推定できている。

スピンについては正答率99.5%


磁束 (RIAF)




磁束 (super-Edd)



スピンの正答率




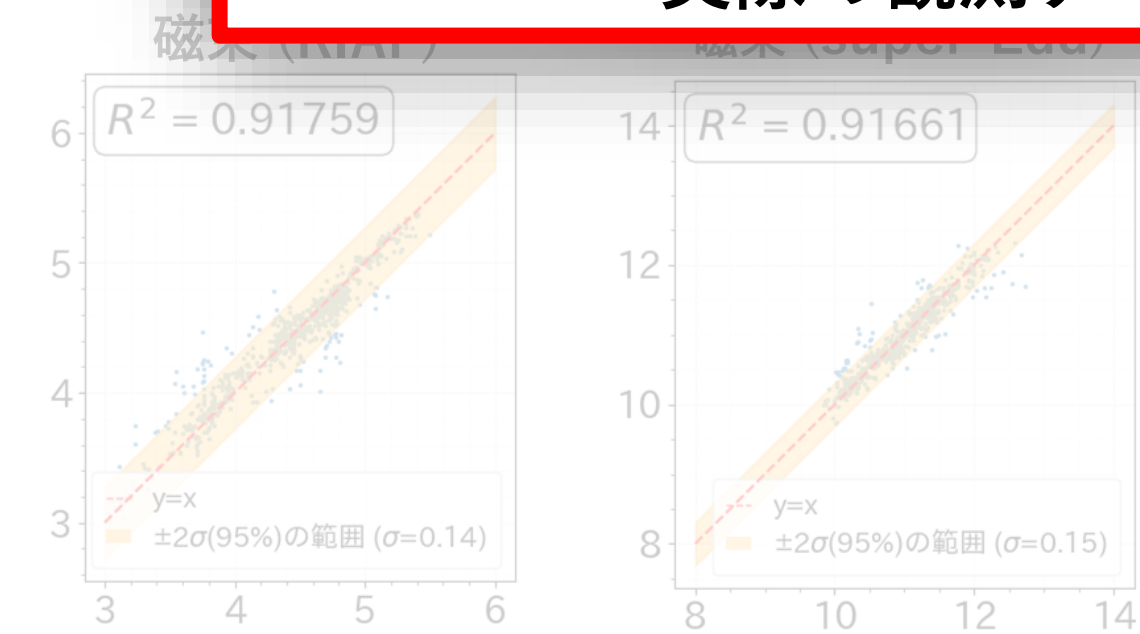
推定結果：-50 t_g と-100 t_g の L_{kin} と L_{rad} を入力値に追加（横軸：正解値，縦軸：推定値）



決定係数は0.88~0.97
であり，先の結果よりも精度
は落ちているがそれでも良く
推定できている

精度99.5%

入力値の数を402列から6列にしても同程度での推定が可能
→実際の観測データへの適用可能性あり



まとめと今後の展望

目的：機械学習による推定が可能か否かをシミュレーションデータの範囲で検証

結果：



- ✓シミュレーションデータの範囲においては**十分な精度で推定**することができた
- ✓推定するのに重要な時刻を特定し、**より少ない入力でも同程度の精度で推定**することができた

今後の展望



- ・教師データの疎密を改善することでより強固な機械学習モデルを作成する
- ・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
- ・M87などの観測との比較







Appendix

Super-Eddington



RIAF







本研究で用いた機械学習手法

LightGBM

…勾配ブースティング決定木(GBDT)
を実装したライブラリ




①GBDTベースのアルゴリズム
⇒特徴量の重要度がわかる



各特徴量の、情報利得（損失関数の減少量）に基づいて重要度が計算される。

②層ごとではなく葉ごとにツリーを作成
⇒計算の高速化



これまでのGBDTベースのアルゴリズムを実装したライブラリと違って、余計な計算はしない。


機械学習モデルの評価方法について

教師データ（シミュレーションデータ）					
	入力		出力		
	L_{kin}	L_{rad}	質量降着率	磁束	MADパラメータ
Data_1	0.3	0.1	1	3	1.5
Data_2	0.6	0.4	2	8	2
Data_3	1	1.3	2.5	10	2
Data_4	2	2	5	12	1.2
Data_5	5	2.5	10	16	0.8
...



機械学習モデルの評価方法について

教師データ（シミュレーションデータ）					
	入力		出力		
	L_{kin}	L_{rad}	質量降着率	磁束	MADパラメータ
Data_1	0.3	0.1	1	3	1.5
Data_2	0.6	0.4	2	8	2
Data_3	1	1.3	2.5	10	3
Data_4	2	2	5	12	4
Data_5	5	2.5	10	16	0.8
...



機械学習モデル

学習に未使用のデータ

機械学習モデルの評価方法について

教師データ（シミュレーションデータ）					
	入力		出力		
	L_{kin}	L_{rad}	質量降着率	磁束	MADパラメータ
Data_1	0.3	0.1	1	3	1.5
Data_2	0.6	0.4	2	8	2
Data_3	1	1.3	2.5	10	3
Data_4	2	2	5	12	4
Data_5	5	2.5	10	16	0.8
...

入力

学習に未使用のデータ


機械学習モデル

予測

予測値		
質量降着率	磁束	MADパラメータ
4	13	1.1
9	17	1
2	3	4

機械学習モデルの評価方法について

教師データ（シミュレーションデータ）					
	入力		出力		
	L_{kin}	L_{rad}	質量降着率	磁束	MADパラメータ
Data_1	0.3	0.1	1	3	1.5
Data_2	0.6	0.4	2	8	
Data_3	1	1.3	2.5	10	2
Data_4	2	2	5	12	1.2
Data_5	5	2.5	10	16	0.8
...



機械学習モデル



予測値		
質量降着率	磁束	MADパラメータ
4	13	1.1
9	17	1
2	3	4

正解値

比較して評価

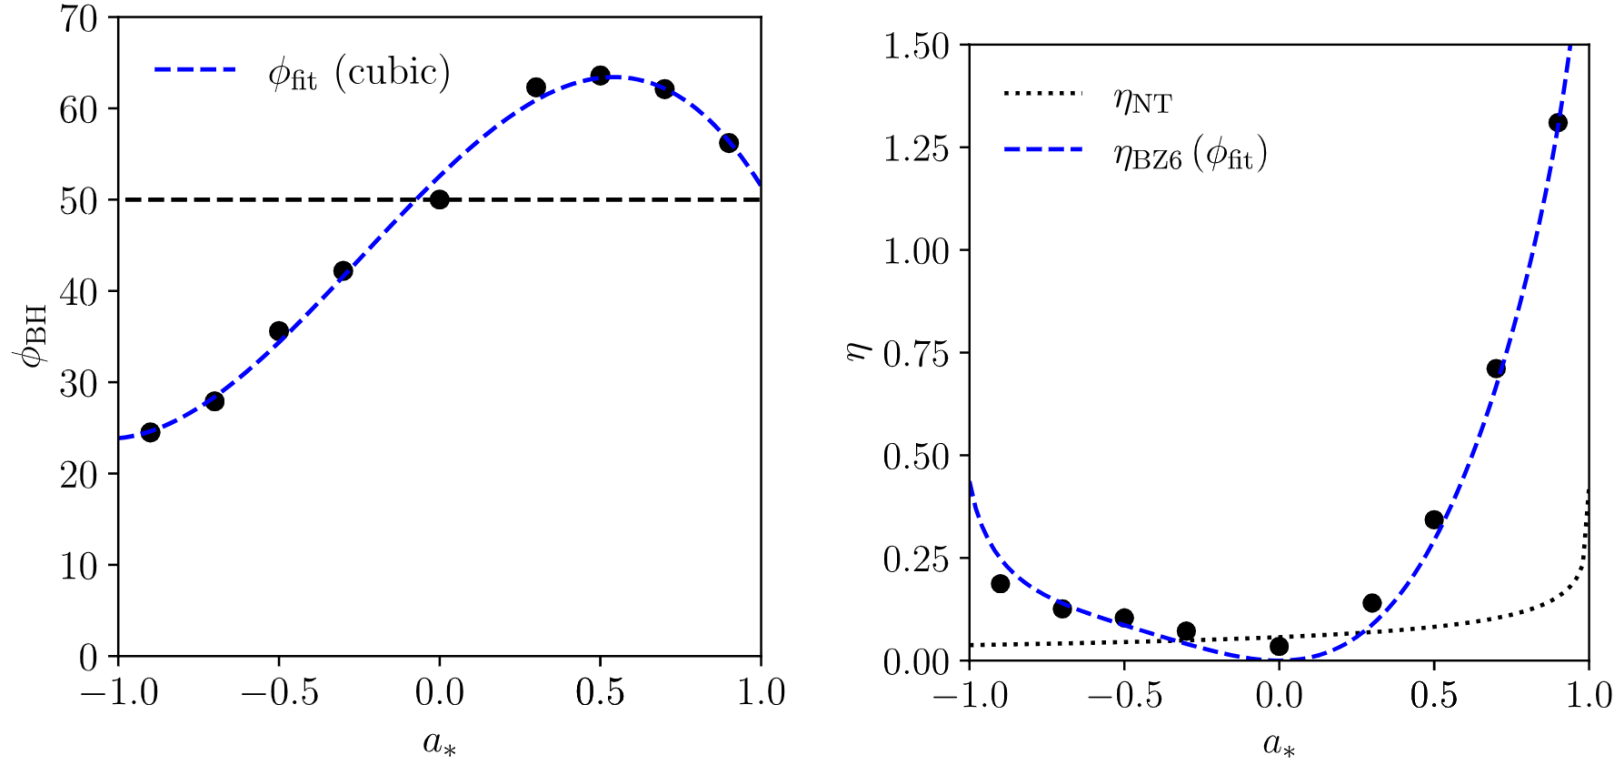


Figure 4. (Left) We show the time-averaged saturated magnetic flux parameter ϕ_{BH} as a function of BH spin a_* (black dots) for the nine simulations described in this paper. The horizontal dashed line, $\phi_{\text{BH}} = 50$, is typically taken as the saturation value of the magnetic flux parameter, but note that ϕ_{BH} is substantially smaller for counter-rotating discs ($a_* < 0$). The dashed blue line is a third-order polynomial fit to $\phi_{\text{BH}}(a_*)$ (equation 9). (Right) We show the outflow energy efficiency factor $\eta = P_{\text{out}}/\dot{M}_0 c^2$ (black dots). For $a_* \gtrsim 0.8$, we find $\eta > 1$, which means that the jet power exceeds the entire rest mass energy flow $\dot{M}_0 c^2$ into the BH. For a given \dot{M}_0 , the jet is much less powerful in the case of a counter-rotating disc. The dotted black line shows the efficiency of a standard [Novikov & Thorne \(1973\)](#) thin accretion disc. The dashed blue line is the BZ6 (equation 10) prediction for the jet power (from [Tchekhovskoy, Narayan & McKinney 2010](#)), obtained by substituting the fitting function for magnetic flux $\phi_{\text{fit}}(a_*)$ from the left-hand panel. The result agrees with the simulations in [Tchekhovskoy et al. \(2012\)](#).




Figure 8. (Left) Time- and azimuth-averaged jet boundary (in black), defined by magnetization $\sigma_M = 1$, for all simulations; we additionally average the jet shape over the upper and lower jet. We fit the jet shape assuming a power-law relationship between the jet width w and height z : $w \propto z^k$ (orange-dashed). The $\sigma_M = 1$ contour for $a_* = 0$ (blue, lower right panel) collapses on to the grid polar axis at $z \approx 60 r_g$, indicating the lack of an extended jet. (Right) The best-fitting jet shape index k as a function of a_* . We indicate spin $a_* = -0.3$ with an open circle to indicate that the fit for k is not well constrained. We do not fit for k in the case of $a_* = 0$.

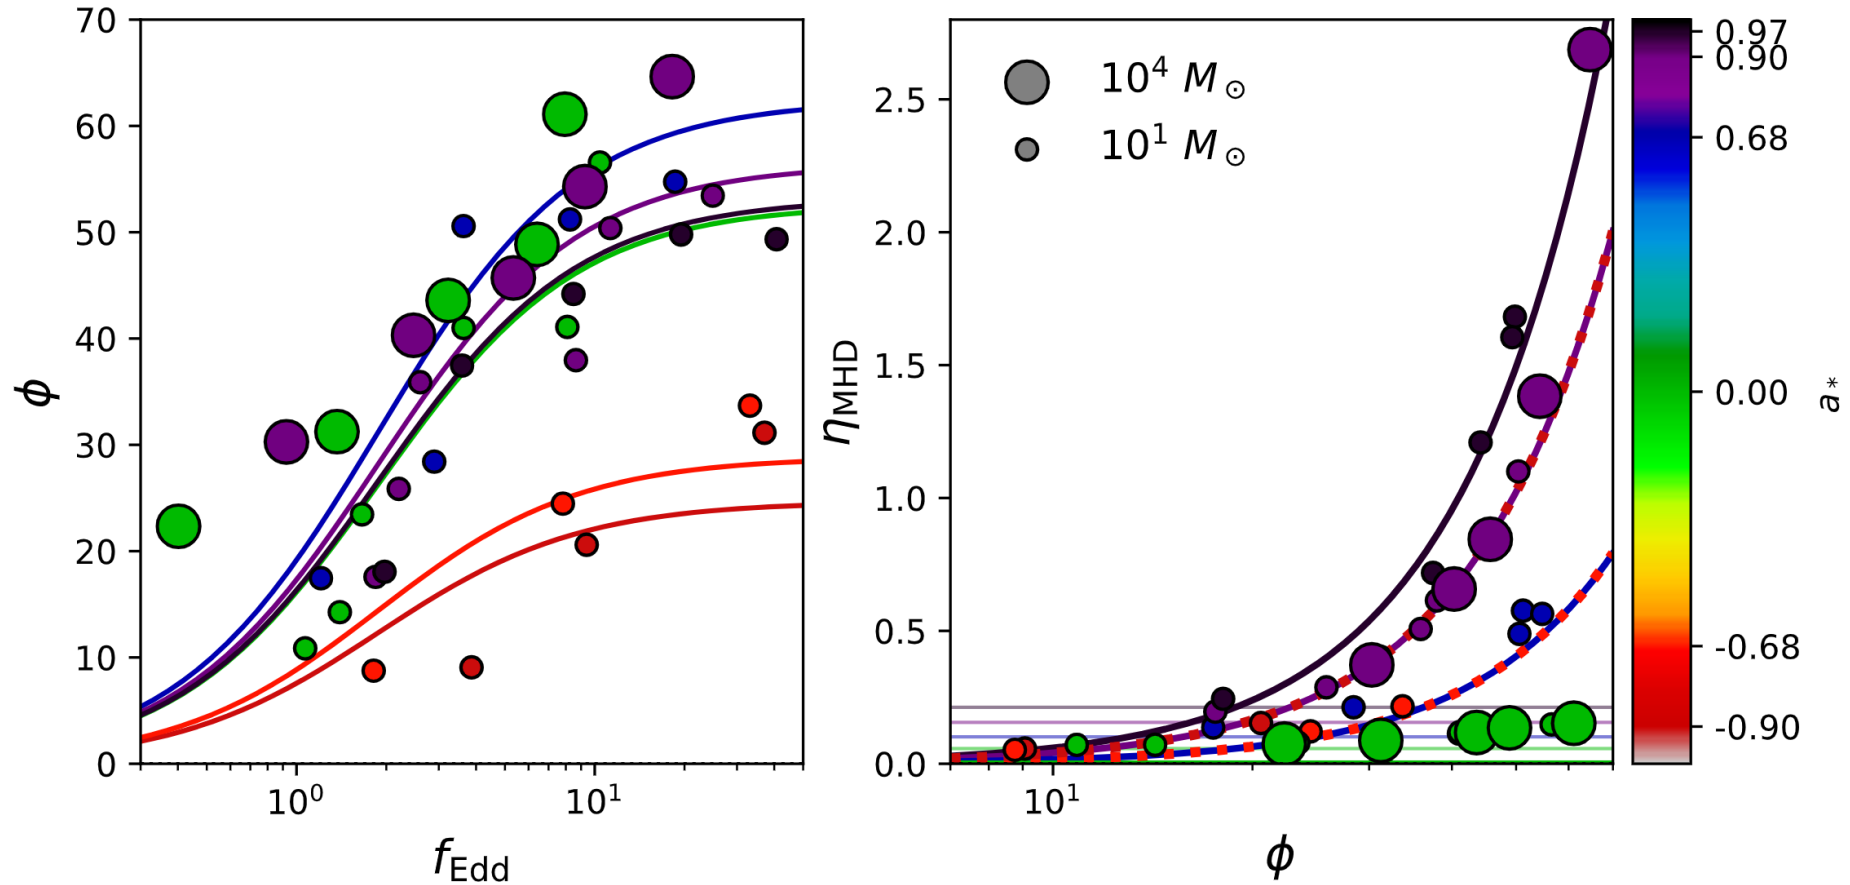




Figure 2. *Left:* Magnetic flux parameter ϕ as a function of Eddington ratio f_{Edd} , where color encodes different values of the BH spin a_* . For each spin sampled by our simulation library, we plot our fitting function (Equation 3) in the appropriate color. *Right:* MHD energy outflow efficiency η_{MHD} as a function of magnetic flux parameter for each of our models. For each spin sampled by our simulation library, we plot the BZ prediction η_{EM} (Equation 5) as colored lines. The agreement is excellent, implying that a BZ-like electromagnetic jet dominates the outflow energy in most of the simulations, except for $a_* = 0$, which features a weaker hydrodynamic outflow. As a point of reference, we plot the radiative efficiencies of thin disks with $a_* \in \{0, 0.68, 0.9, 0.97\}$ as horizontal lines.




降着率

Histogram of Prediction Errors_Min (残差のヒストグラム)



MADパラメータ

Histogram of Prediction Errors_Min (残差のヒストグラム)



磁束