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）

共同研究者：朝比奈雄太（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），高橋労太（苫小牧高専）

研究背景：MADnessパラメータ（ϕ_{BH}）の重要性

Cygnus A の観測イメージ

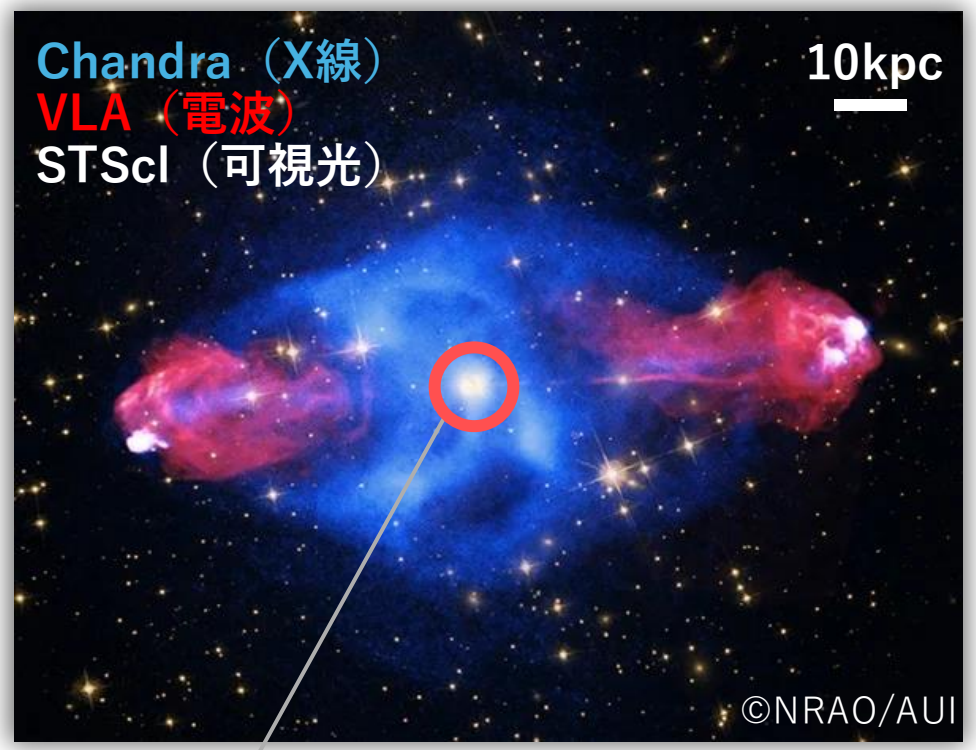

質量降着率で無次元化した磁束のことで，
ジェットのパワーを示す指標．

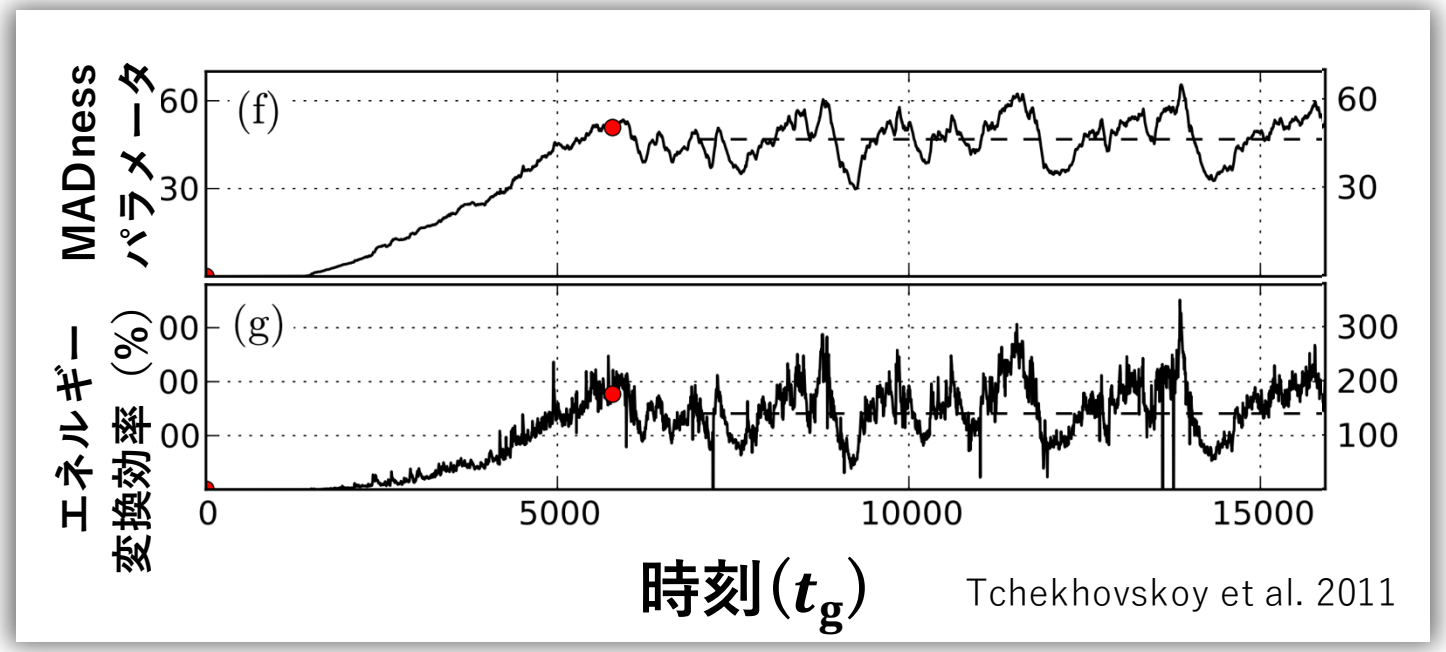

ジェットの駆動機構の理解には
ϕ_{BH}の情報が重要である

ϕ_{BH}とジェットのエネルギー変換効率が
相関していることが示唆されている

ϕ_{BH}が分かればジェットのエネルギー変換効率が分かるが，観測でϕ_{BH}を求めるのは困難

研究目標：機械学習を用いた推定を目指す

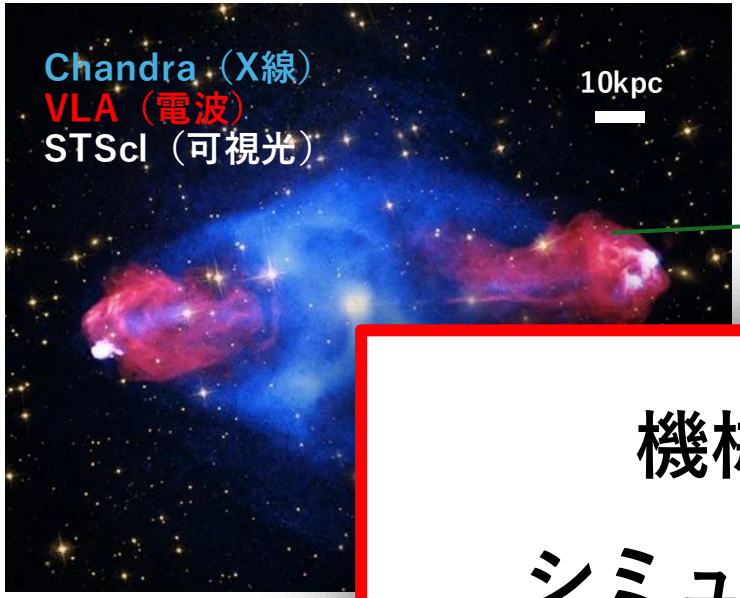

（観測で得られる量）

運動光度
放射光度

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を用いて検証する

（観測で得るのが難しい量）

本発表の範囲

機械学習モデル

あらかじめ
シミュレーションデータ
を用いて学習済み

推定

質量降着率
磁束
MADnessパラメータ

シミュレーションデータについて

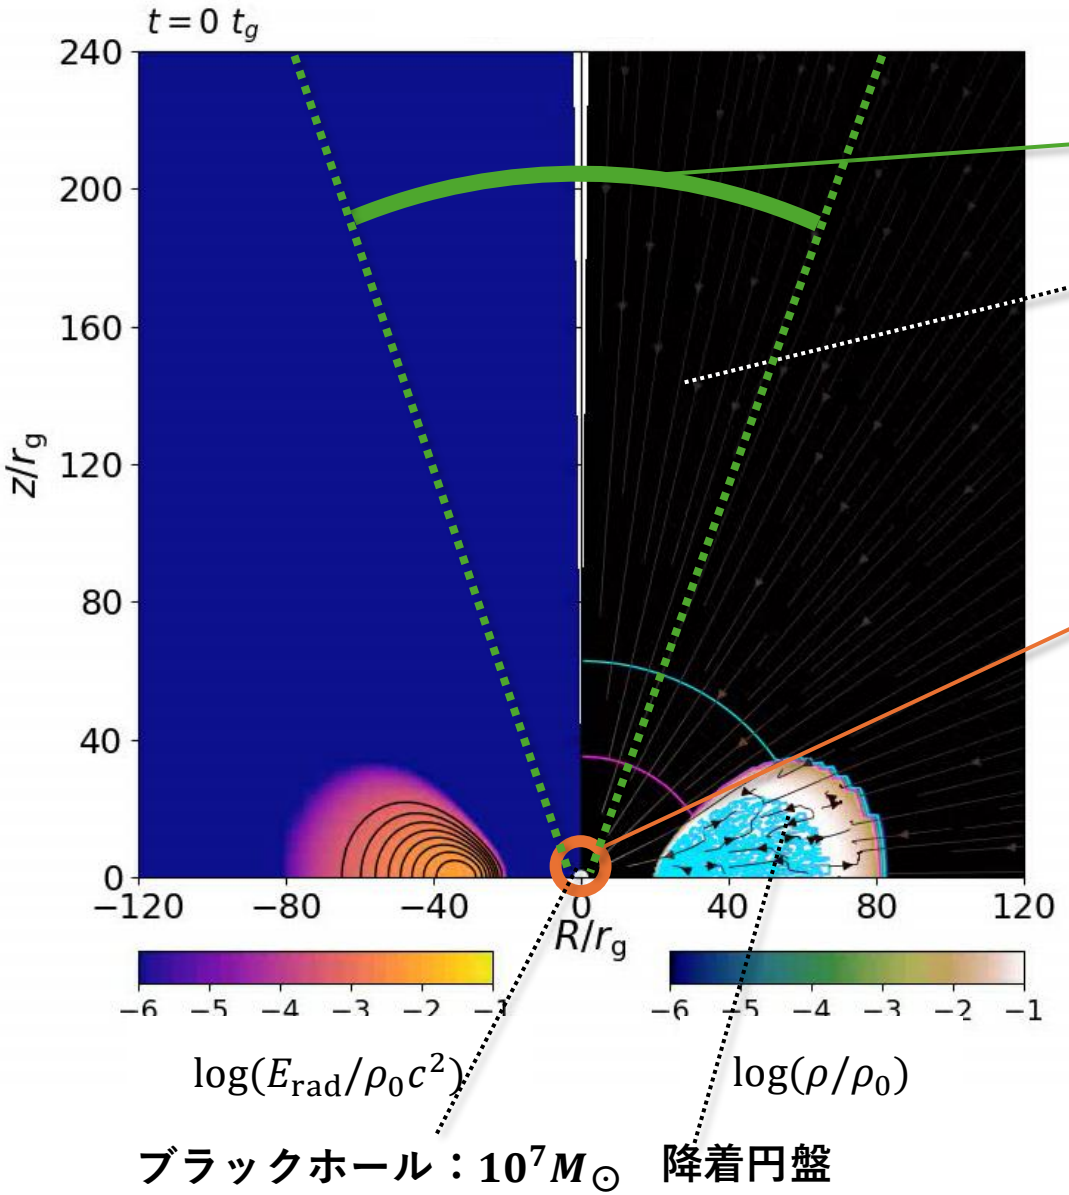

円弧の領域で運動光度と放射光度を計算

ジェット

運動光度：$L_{\rm kin}$
放射光度：$L_{\rm rad}$　**（$L_{\rm Edd}$で規格化）**

質量降着率：$\dot{m}\ (=\frac{\dot{M}}{L_{\rm Edd}/c^2})$
磁束：Φ
MADパラメータ：$\phi_{\rm BH}(\propto \Phi/\sqrt{\dot{M}})$

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, $\dot{m} \ll 1$）

➢ ブラックホールのスピンパラメータ：$0, 0.3, 0.7, 0.9$

➢ データ間隔：**0~$15,000 t_{\rm g}$で$10 t_{\rm g}$ごと**（$t_{\rm g} = GM/c^3$）

ブラックホール：$10^7 M_\odot$　**降着円盤**

(Yoshioka in prep.)

本研究で用いた機械学習手法

LightGBM…表形式データに強い勾配ブースティング決定木(GBDT)を高速に実装したライブラリ

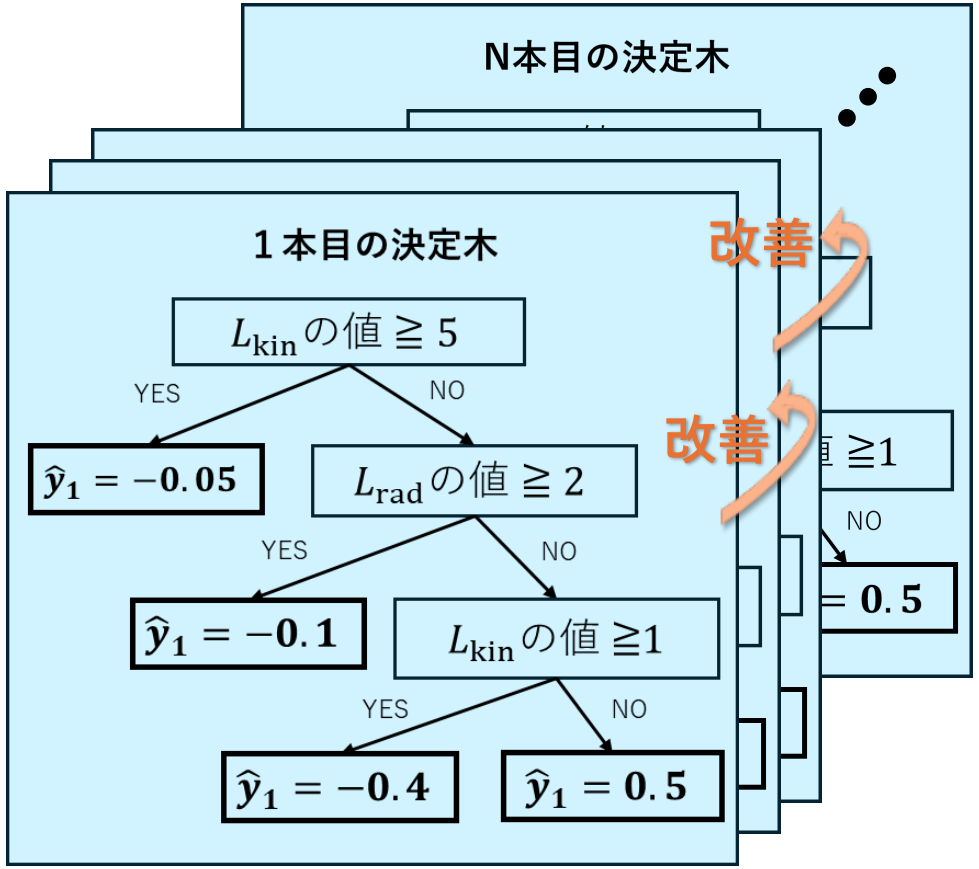

決定木…入力値の条件分岐で予測を行う小さなモデル

➢ **GBDTでは損失関数の負の勾配を学習しながら**

決定木を追加していき，誤差を段階的に補正していく

機械学習モデルの評価方法について

シミュレーションデータ					
時刻 (t_g)	入力		出力		
	L_{kin}	L_{rad}	$\dot{m}$	Φ	ϕ_{BH}
…	…	…	…	…	…
5910	14	4	4	3	2
…	…	…	…	…	…
6000	16	6	4	7	1.7
6010	17	7	6	5	0.8
…	…	…	…	…	…

学習 →

機械学習モデル

機械学習モデルの評価方法について

シミュレーションデータ					
時刻 (t_g)	入力		出力		
	L_{kin}	L_{rad}	$\dot{m}$	Φ	ϕ_{BH}
…	…	…	…	…	…
5910	14	4	4	3	2
…	…	…	…	…	…
6000	16	6	4	7	1.7
6010	17	7	6	5	0.8
…	…	…	…	…	…

学習に未使用のデータ

入力

機械学習モデル

予測

予測値		
$\dot{m}$	Φ	ϕ_{BH}
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

シミュレーションデータ					
時刻 (t_g)	入力		出力		
	L_{kin}	L_{rad}	$\dot{m}$	Φ	ϕ_{BH}
…	…	…	…	…	…
5910	14	4	4	3	2
…	…	…	…	…	…
6000	16	6	4	7	1.7
6010	17	7	6	5	0.8
…	…	…	…	…	…

正解値

比較して評価

機械学習モデル

予測

予測値		
$\dot{m}$	Φ	ϕ_{BH}
4	13	1.1
9	17	1
2	3	4

推定結果①

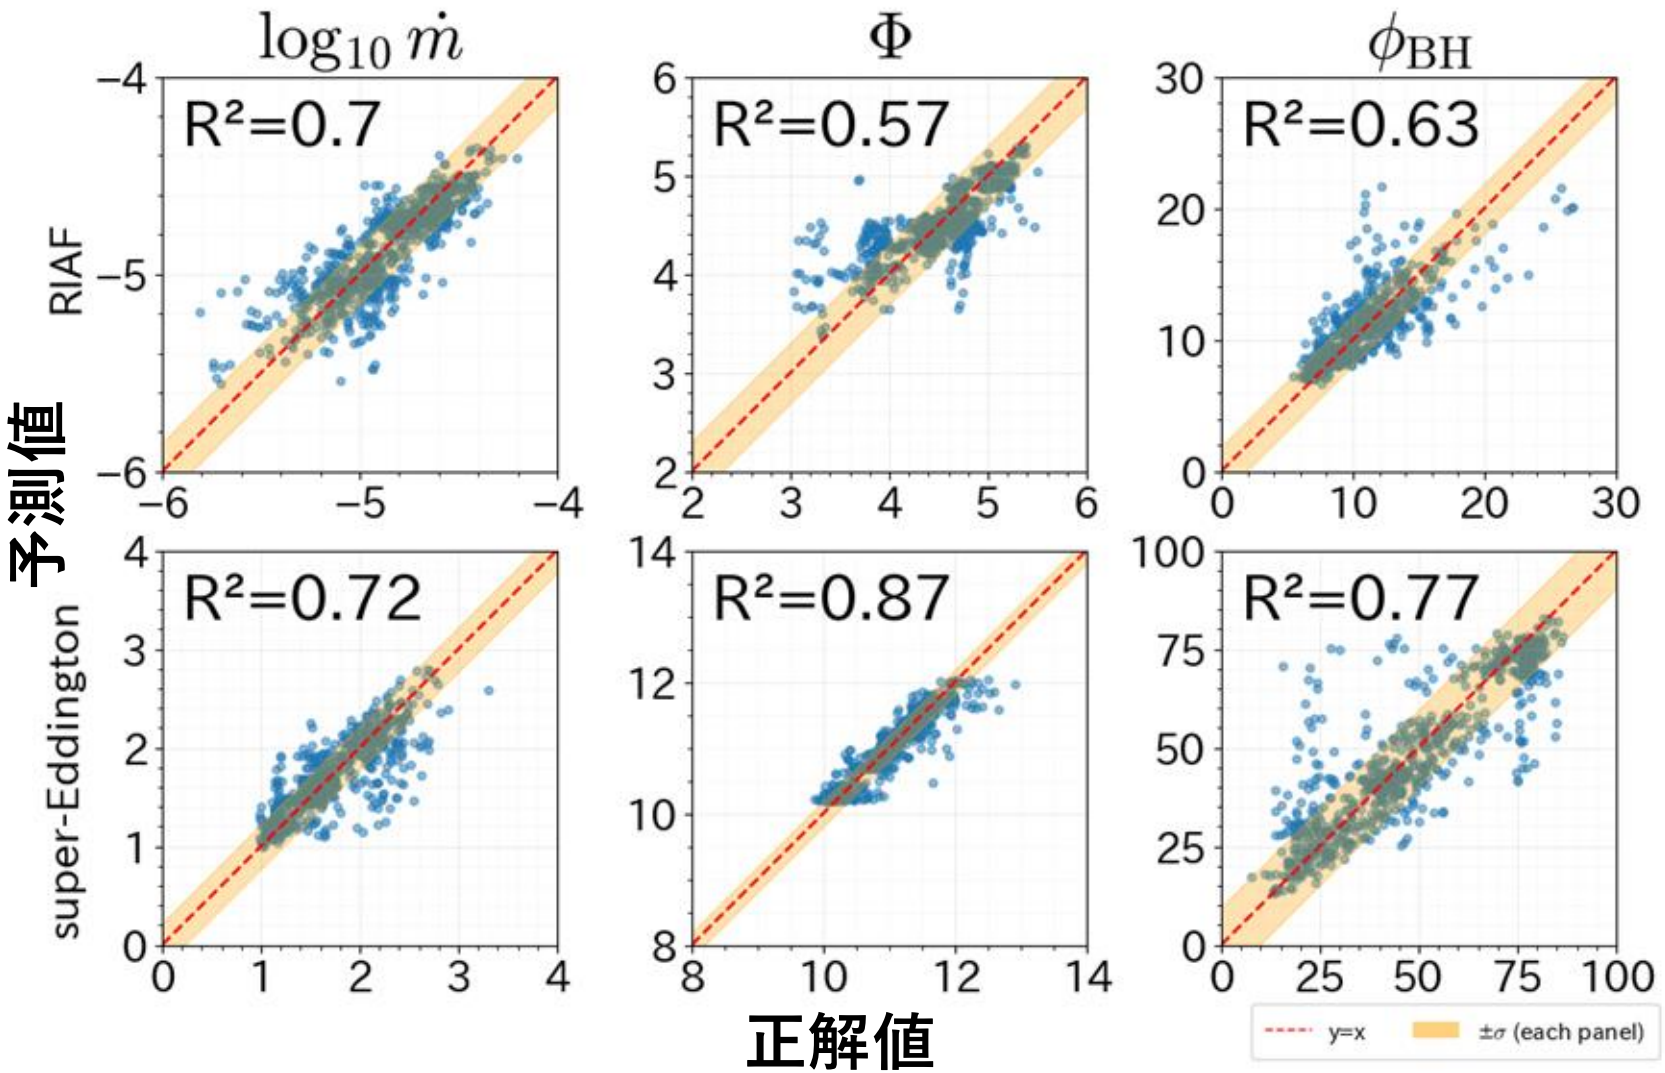

評価指標は決定係数：

$$R^2 = 1 - \frac{\Sigma_i \ (\text{正解値}_i - \text{予測値}_i)^2}{\Sigma_i \ (\text{正解値}_i - \text{正解値の平均値})^2}$$

1に近いほど良い

オレンジの網掛は残差が正規分布に従うと仮定した時の±σの範囲（σは残差の標準偏差）

決定係数は0.57~0.87程度であり，ある程度推定はできているが未だ分散は大きい

改善策：$100t_g$前と$200t_g$前の光度も入力値に追加

教師データ					
時刻 (t_g)	入力		出力		
	$L_{\rm kin}$	$L_{\rm rad}$	$\dot{m}$	Φ	$\phi_{\rm BH}$
…	…	…	…	…	…
5800	10	0.1	1	3	1.5
5810	11	1	2	8	2
…	…	…	…	…	…
5900	13	3	5	7	1.2
5910	14	4	4	3	2
…	…	…	…	…	…
6000	16	6	4	7	1.7
6010	17	7	6	5	0.8
…	…	…	…	…	…

×８モデル
（降着率２通り×スピン４通り）

□ のデータを用いて
□ を推定

改善策：$100t_g$前と$200t_g$前の光度も入力値に追加

教師データ										
時刻 (t_g)	入力						出力			
	L_{kin}	$L_{\mathrm{kin},100t_g}$	$L_{\mathrm{kin},200t_g}$	L_{rad}	$L_{\mathrm{rad},100t_g}$	$L_{\mathrm{rad},200t_g}$	$\dot{m}$	Φ	ϕ_{BH}
…	…	…	…	…	…	…	…	…	…	…
5800	**10**	8	6	**0.1**	0.5	1	1	3	1.5
5810	11	9	7	1	0.6	2	2	8	2
…	…	…	…	…	…	…	…	…	…	…
5900	**13**	10	8	**3**	0.1	0.5	5	7	1.2
5910	14	11	9	4	1	0.6	4	3	2
…	…	…	…	…	…	…	…	…	…	…
6000	**16**	**13**	**10**	**6**	**3**	**0.1**	**4**	**7**	**1.7**
6010	17	14	11	7	4	1	6	5	0.8
…	…	…	…	…	…	…	…	…	…	…

×８モデル
（降着率２通り×スピン４通り）

□ のデータを用いて
□ を推定

推定結果②：過去の光度も入力値に追加した場合

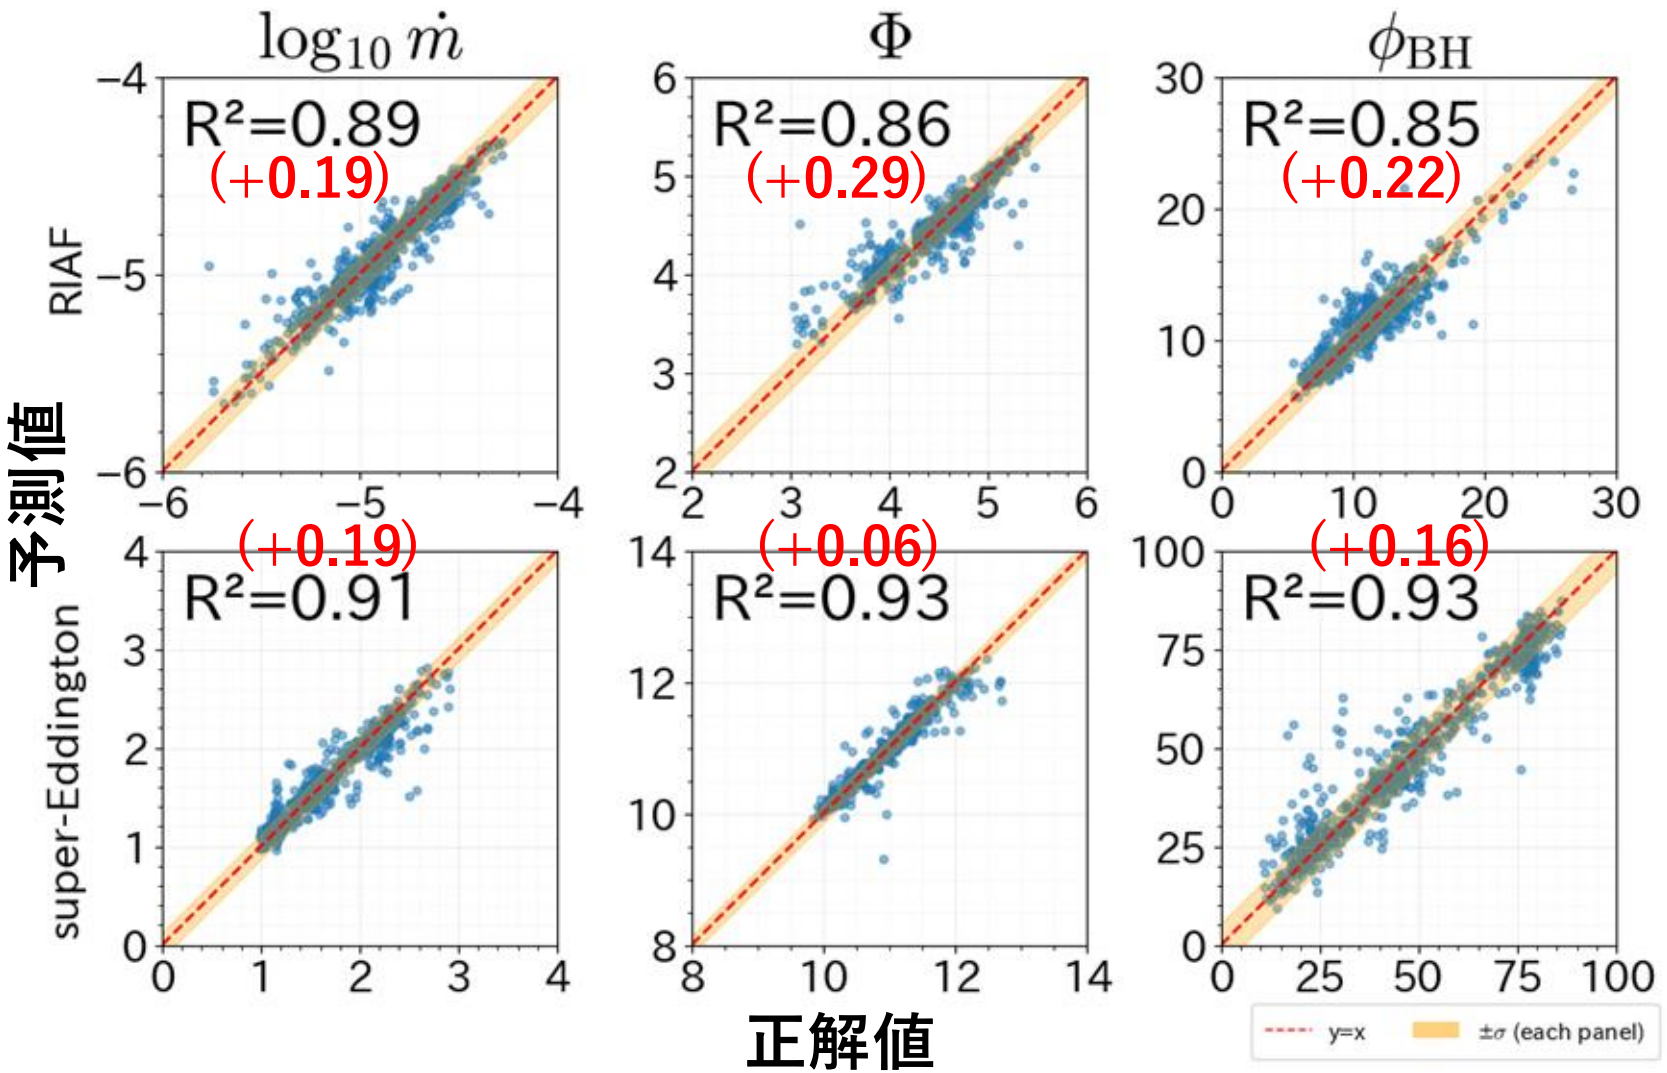

評価指標は決定係数：

$$R^2 = 1 - \frac{\Sigma_i \ (\text{正解値}_i \ - \ \text{予測値}_i)^2}{\Sigma_i \ (\text{正解値}_i \ - \ \text{正解値の平均値})^2}$$

1に近いほど良い

赤字は結果①と比較した値

決定係数は0.85~0.93程度であり，全てのターゲットに対して，結果①に比べて精度が向上した．

推定結果③：$L_{\mathrm{kin}}, L_{\mathrm{kin},100t_g}, L_{\mathrm{kin},200t_g}$のみを入力値とした場合

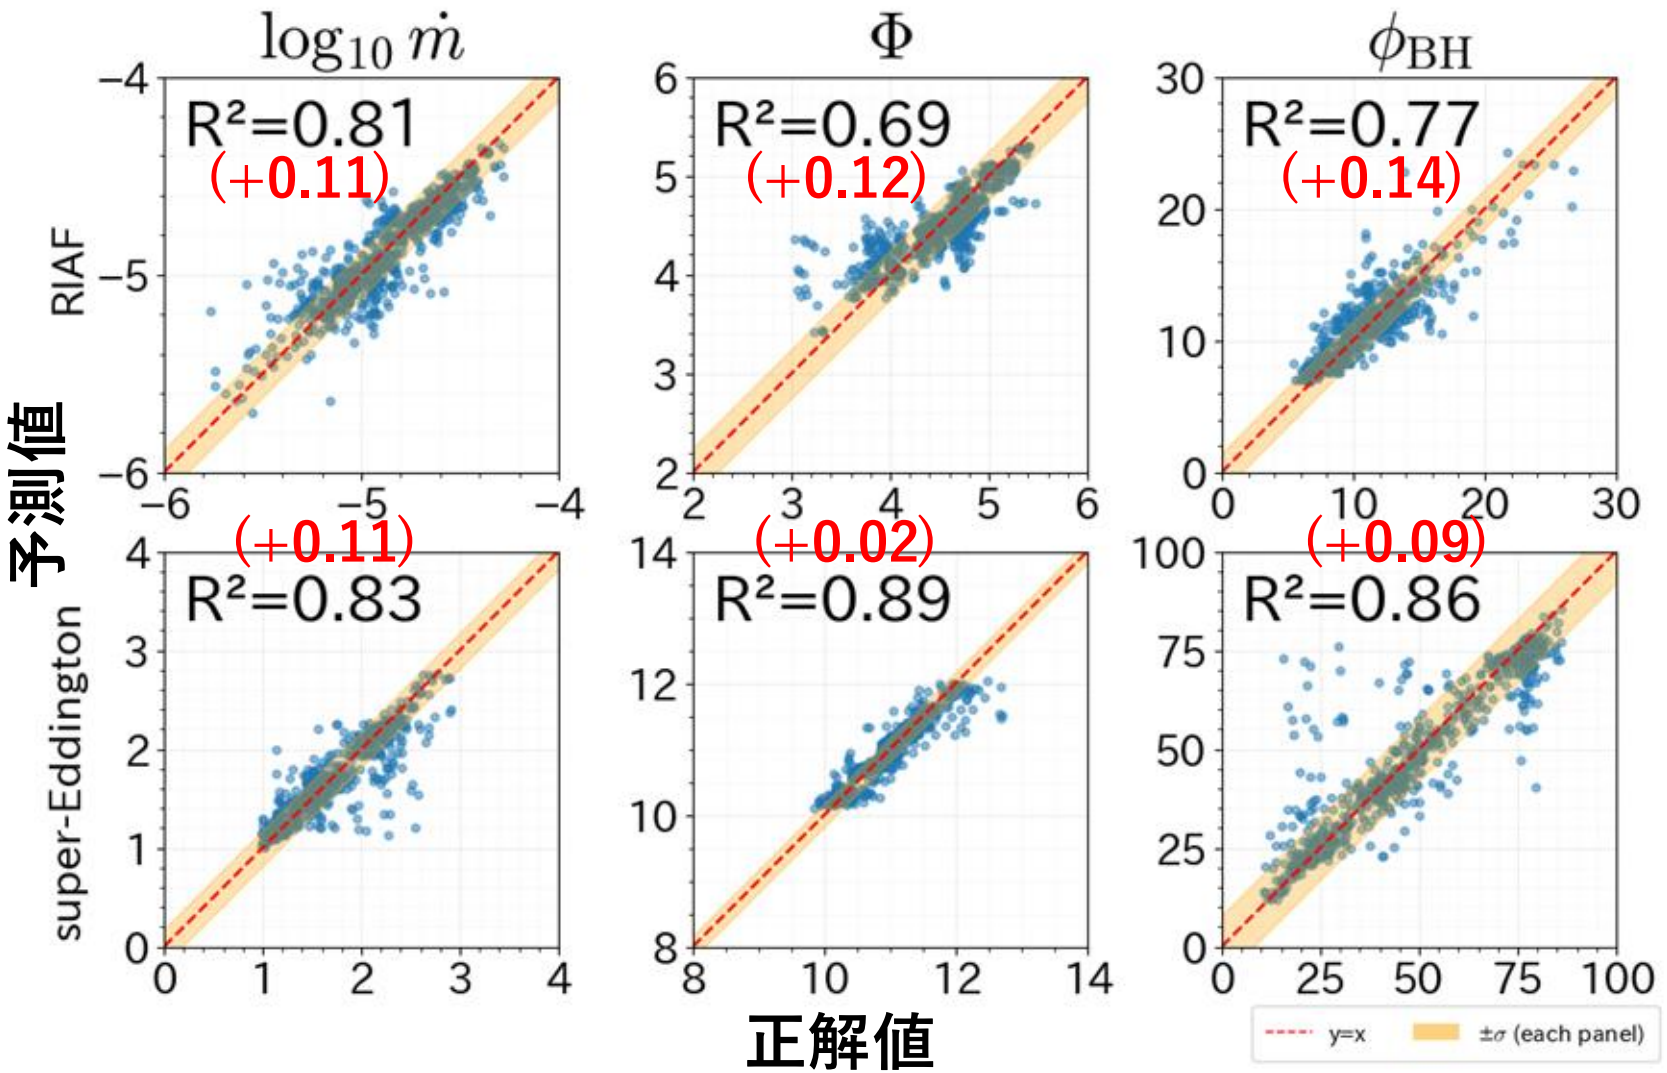

評価指標は決定係数：

$$R^2 = 1 - \frac{\Sigma_i \ (\text{正解値}_i \ - \ \text{予測値}_i)^2}{\Sigma_i \ (\text{正解値}_i \ - \ \text{正解値の平均値})^2}$$

1に近いほど良い

赤字は結果①と比較した値

決定係数は0.69~0.89程度である．入力値の種類を減らしたため決定係数の値は結果②よりも下がるが，それでも結果①よりは精度良く推定できていることが分かる．

推定結果④：$L_{\mathrm{rad}}, L_{\mathrm{rad},100t_g}, L_{\mathrm{rad},200t_g}$ のみを入力値とした場合

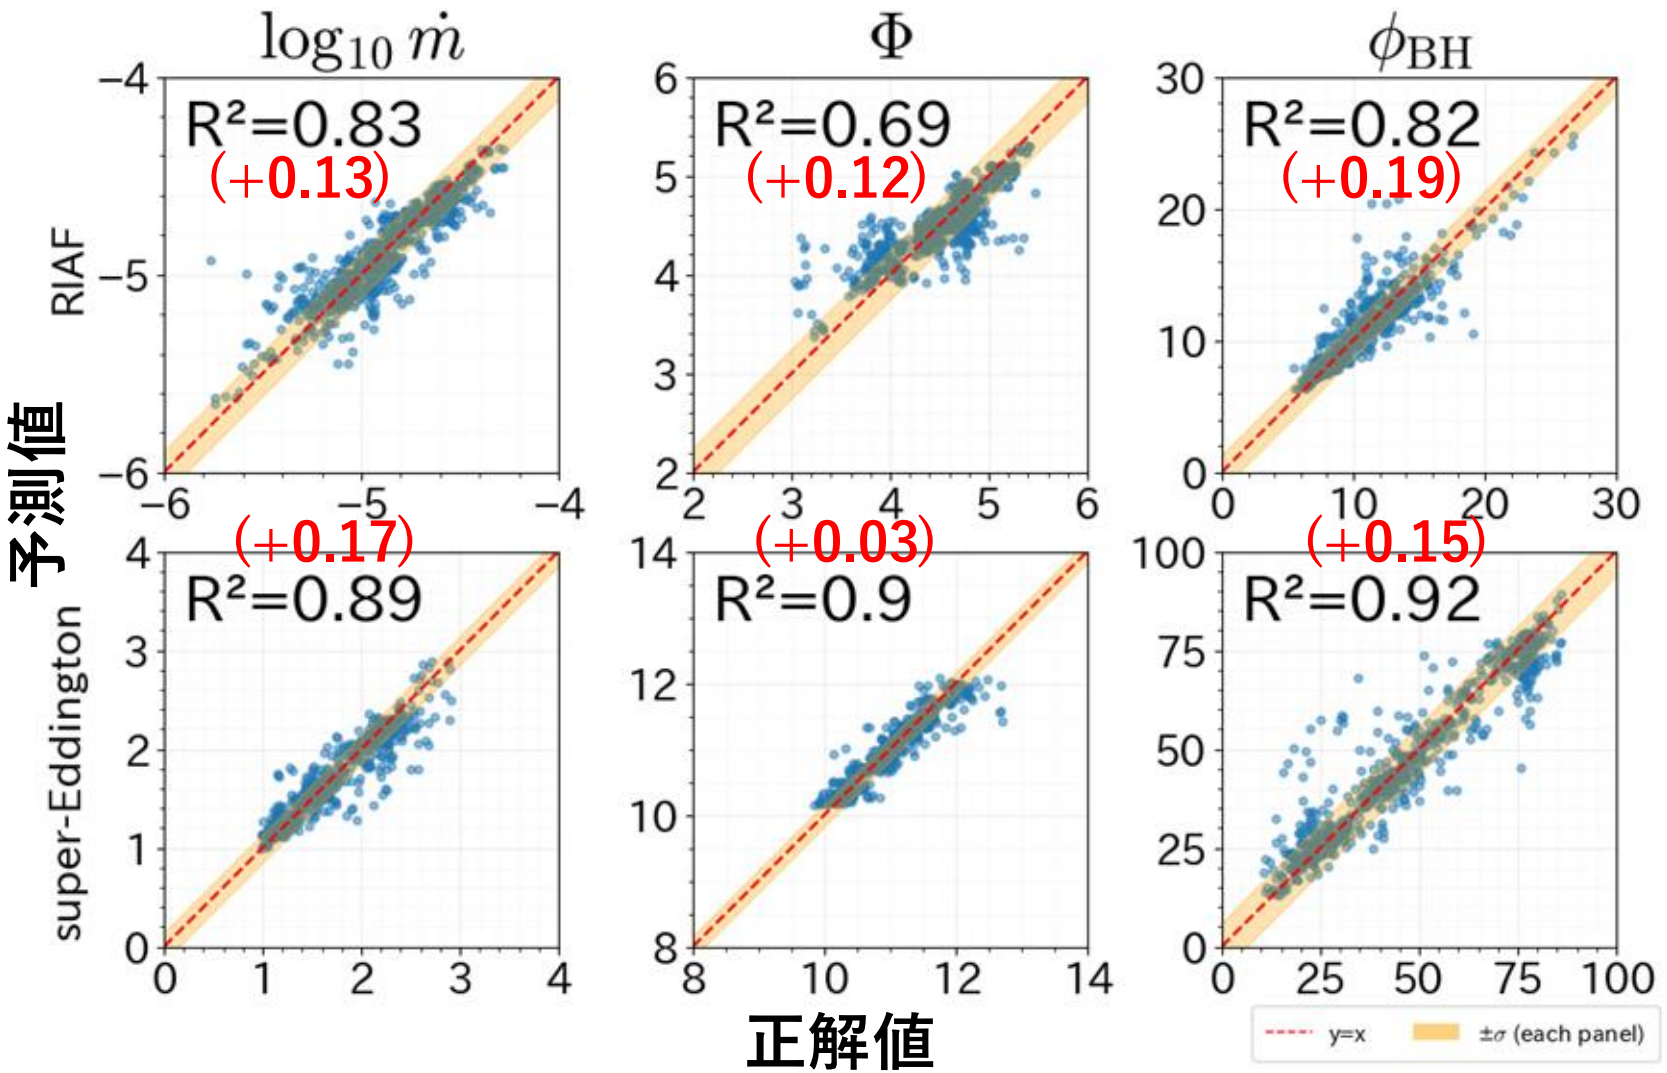

評価指標は決定係数：

$$R^2 = 1 - \frac{\Sigma_i \ (\text{正解値}_i \ - \ \text{予測値}_i)^2}{\Sigma_i \ (\text{正解値}_i \ - \ \text{正解値の平均値})^2}$$

1に近いほど良い

赤字は結果①と比較した値

決定係数は0.69~0.92程度である．結果③と同様，入力値の種類を減らしたため決定係数の値は結果②よりも下がっているが，結果①よりは精度よく推定できていることが分かる．

推定結果のまとめ

モデル（入力値の種類）	推定精度（R^2）
①$L_{\mathrm{kin}}, L_{\mathrm{rad}}$	△ (=0.57~0.87)
②$L_{\mathrm{kin}}, L_{\mathrm{kin},100t_{\mathrm{g}}}, L_{\mathrm{kin},200t_{\mathrm{g}}}, L_{\mathrm{rad}}, L_{\mathrm{rad},100t_{\mathrm{g}}}, L_{\mathrm{rad},200t_{\mathrm{g}}}$	◎ (=0.85~0.93)
③$L_{\mathrm{kin}}, L_{\mathrm{kin},100t_{\mathrm{g}}}, L_{\mathrm{kin},200t_{\mathrm{g}}}$	○ (=0.69~0.89)
④$L_{\mathrm{rad}}, L_{\mathrm{rad},100t_{\mathrm{g}}}, L_{\mathrm{rad},200t_{\mathrm{g}}}$	○ (=0.69~0.92)

✓ 時系列データを追加することで予測精度が向上した.
✓ 放射光度と運動光度の両方を入力値として用いても，予測精度が向上した.

まとめと今後の展望

目的：機械学習手法を用いて，ブラックホールジェットの運動光度と放射光度から
ブラックホールの質量降着率・磁束・MADパラメータの推定が可能か否かを
シミュレーションデータを用いて検証

結果：✓ 時系列データを追加することで予測精度が向上した.
✓ 放射光度と運動光度の両方を入力値として用いても，予測精度が向上した.

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