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）

MADnessパラメータ（ϕ_{BH}）の重要性

Cygnus A の観測画像

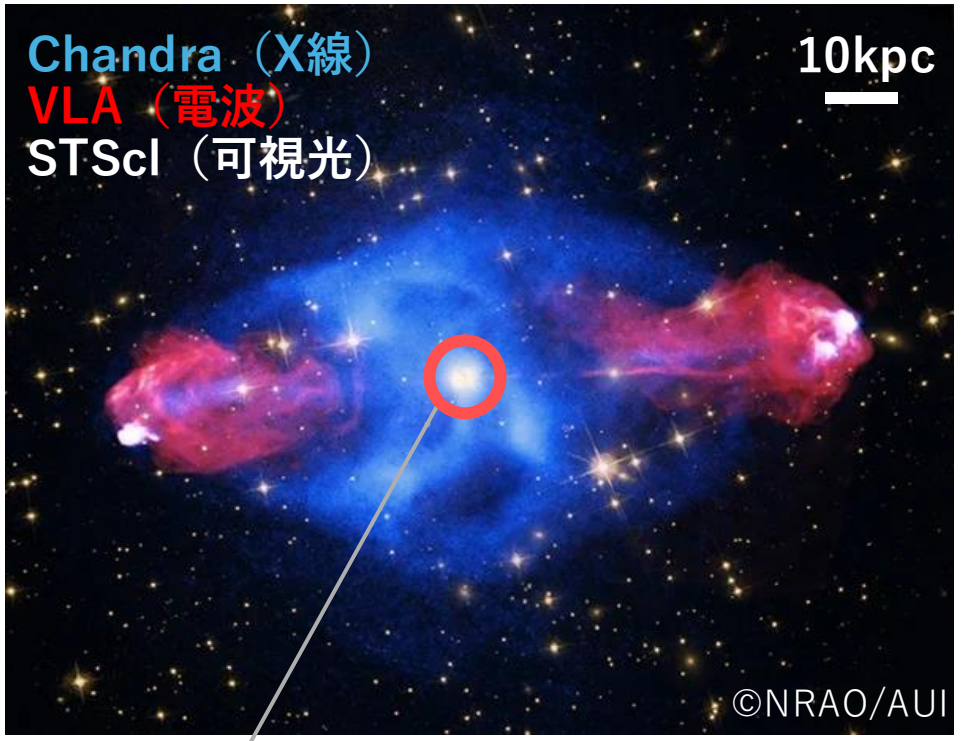

ジェットの駆動機構の理解には
ϕ_{BH}の情報が重要である

MADnessパラメータ：$\phi_{BH} \propto \Phi/\sqrt{\dot{M}_{in}}$

$\Phi, \dot{M}$：ブラックホール表面での磁束、質量降着率

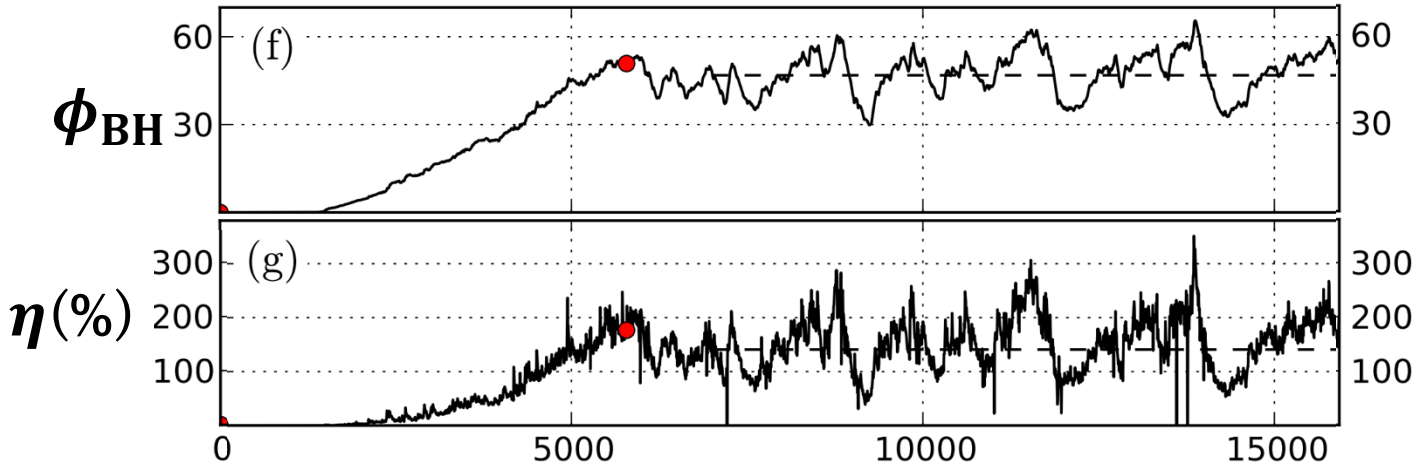

Tchekhovskoy+2011

エネルギー変換効率：
$\eta \propto$（ジェットのパワー）$/ \dot{M}_{in}$

ϕ_{BH}とジェットのη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かもしれないが，観測でϕ_{BH}を求めるのは困難

先行研究：BH周囲の磁場状態の推定

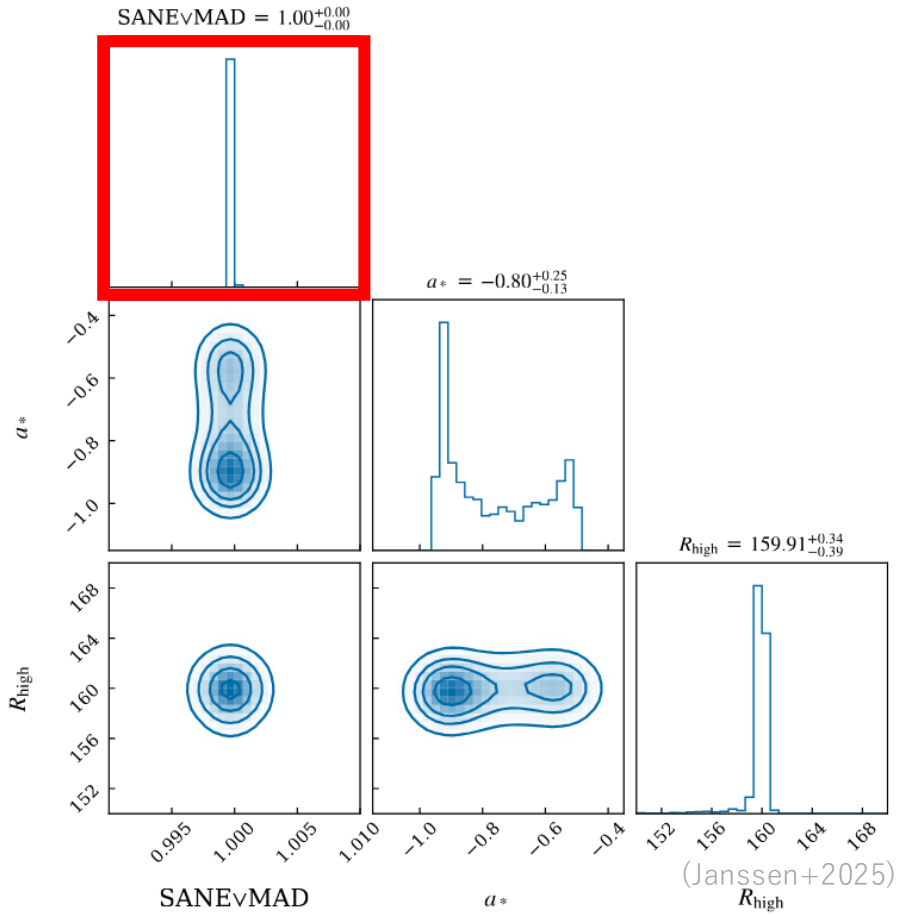

(Janssen+2025)

シミュレーションデータで学習させた機械学習モデルを用い、EHTによるM87*の観測データからSANE/MADの分類などをした

電波コアシフトから推定されたジェットの磁束

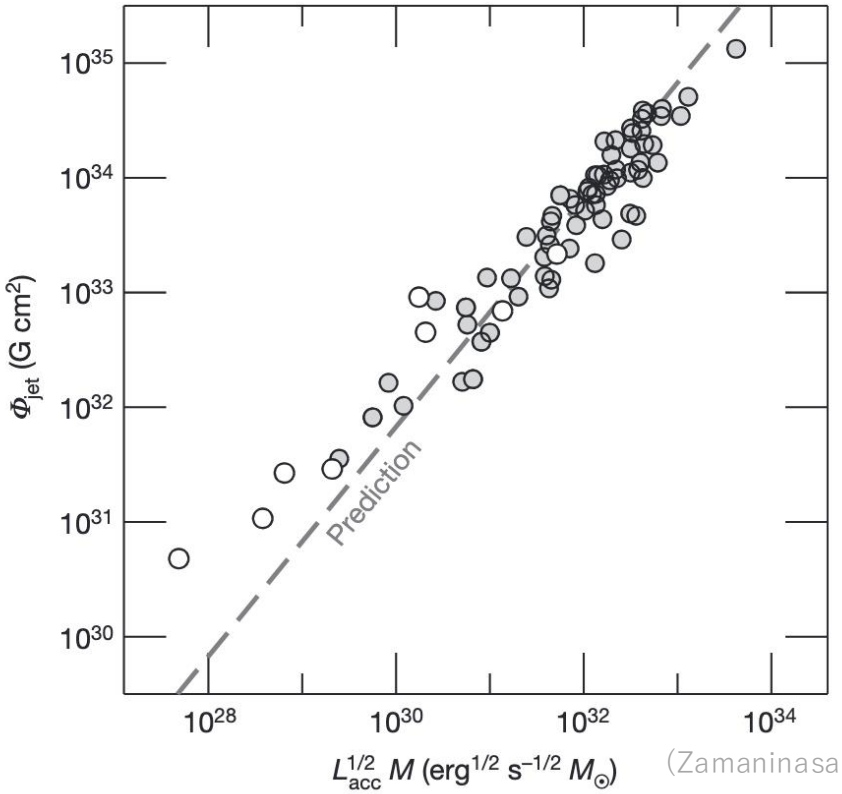

(Zamaninasab+2014)

MAD状態で期待されるBH近傍の磁束

pcスケールのジェットで推定した磁束が、MAD状態のBH近傍で理論的に期待される磁束と整合することを示した

比較的取得しやすい観測量からBHのMADnessパラメータを定量的に推定することは容易ではない

機械学習を用いた定量的な推定を目指す

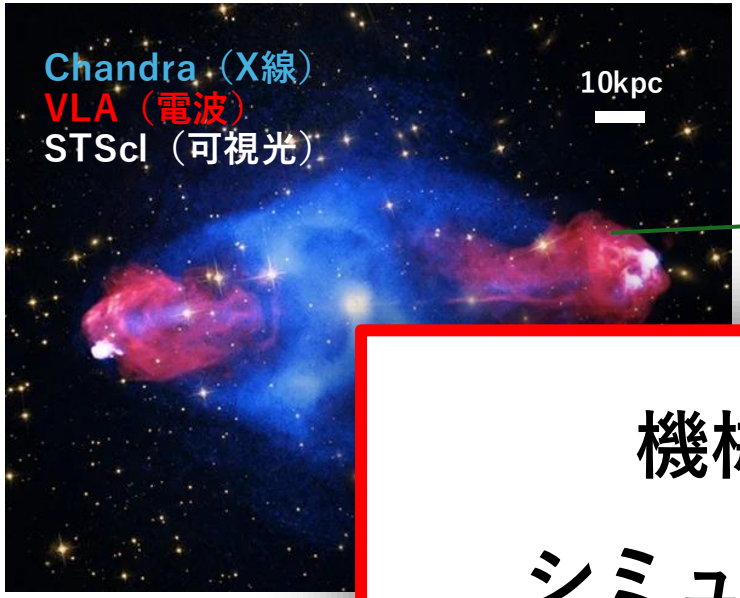

（観測で得られる量）

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

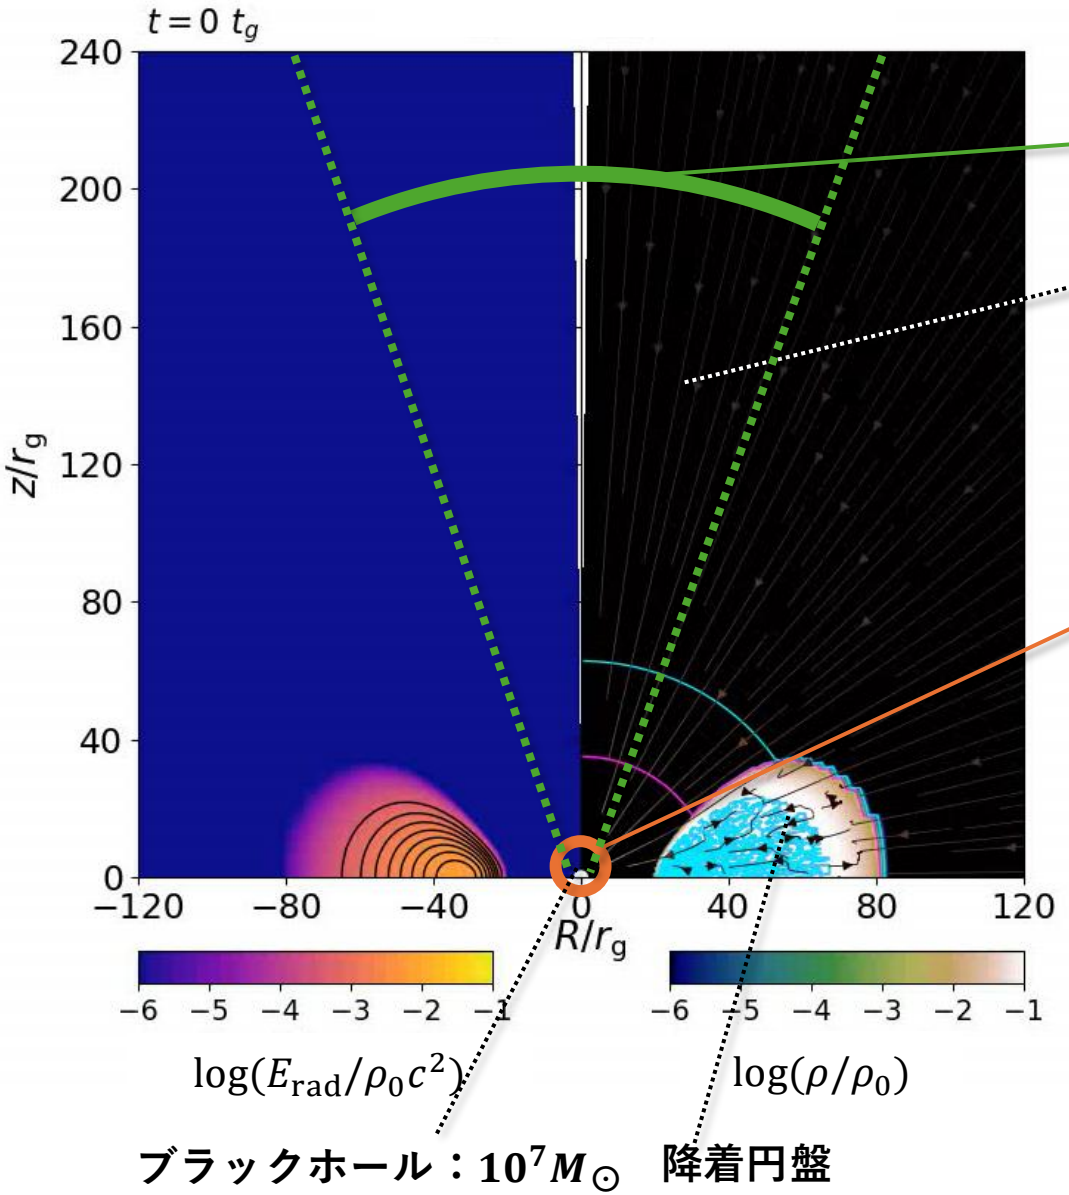

円弧の領域で運動光度と放射光度を計算

ジェット

運動光度：L_{kin}　**（エディントン光度L_{Edd}で規格化）**
放射光度：L_{rad}

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

一般相対論的輻射磁気流体力学計算で得られた**8**ケースのデータを利用

➢ 降着率**2通り**：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**4通り**：$0, 0.3, 0.7, 0.9$

データは $\mathbf{0}$~$\mathbf{15,000}t_{\mathrm{g}}$で$\mathbf{10}t_{\mathrm{g}}$ $(t_{\mathrm{g}} = GM/c^3)$ごとに取得している

(Yoshioka in prep.)

ブラックホール：$10^7 M_\odot$　**降着円盤**

データセットについて

シミュレーションデータ					
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ケース
（降着率２通り×スピン４通り）

□ のデータを用いて
□ を推定

$-200t_{\mathrm{g}}(\equiv \Delta T)$、$-100t_{\mathrm{g}}(\Delta T/2)$の光度も入力値に追加

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}
…	…	…	…	…	…
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ケース
（降着率２通り×スピン４通り）

□ のデータを用いて
□ を推定

$-200t_{\mathrm{g}}(\equiv \Delta T)$、$-100t_{\mathrm{g}}(\Delta T/2)$の光度も入力値に追加

シミュレーションデータ										
時刻	入力						出力			
(t_{g})	L_{kin}	$L_{\mathrm{kin},100t_{\mathrm{g}}}$	$L_{\mathrm{kin},200t_{\mathrm{g}}}$	L_{rad}	$L_{\mathrm{rad},100t_{\mathrm{g}}}$	$L_{\mathrm{rad},200t_{\mathrm{g}}}$	$\dot{m}$	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ケース
（降着率２通り×スピン４通り）

のデータを用いて
を推定

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

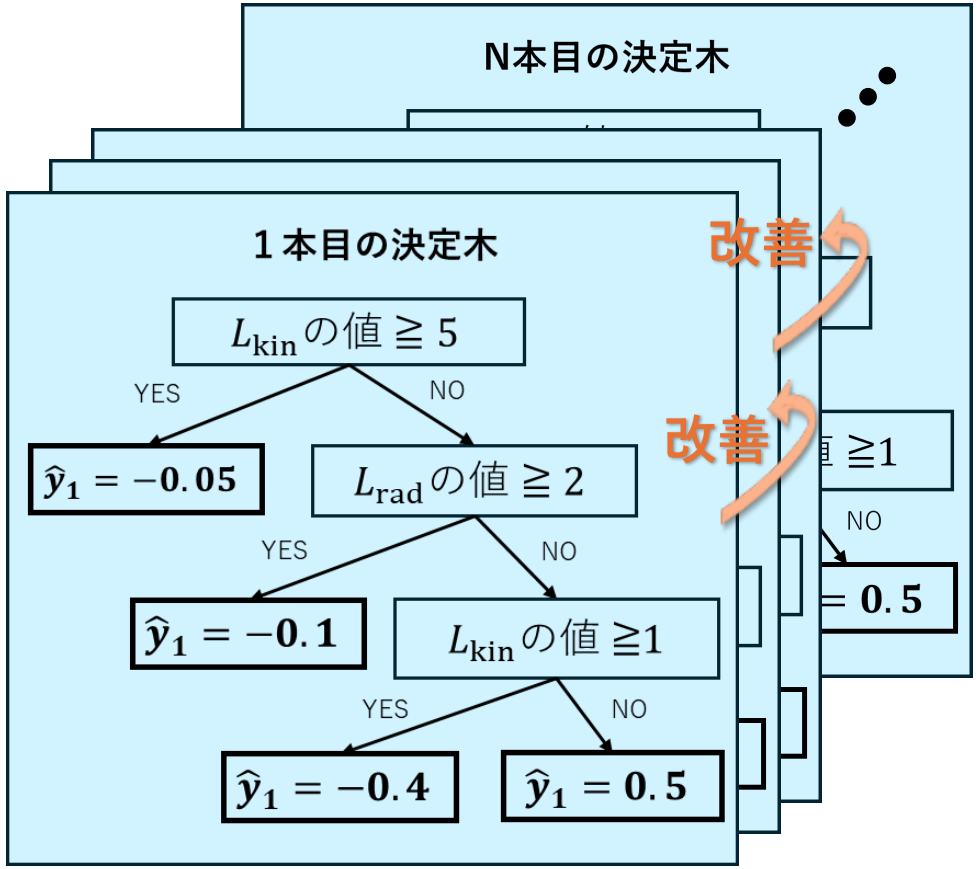

決定木…入力値の条件分岐で予測を行う小さなモデル

➢ **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		
	$L_{\rm kin}$	$L_{\rm kin,100t_g}$	$L_{\rm kin,200t_g}$	$L_{\rm rad}$	$L_{\rm rad,100t_g}$	$L_{\rm rad,200t_g}$	$\dot{m}$	Φ	$\phi_{\rm BH}$
…	…	…	…	…	…	…	…	…	…
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
…	…	…	…	…	…	…	…	…	…

全データの80%
を使って学習



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		
	$L_{\rm kin}$	$L_{\rm kin,100t_g}$	$L_{\rm kin,200t_g}$	$L_{\rm rad}$	$L_{\rm rad,100t_g}$	$L_{\rm rad,200t_g}$	$\dot{m}$	Φ	$\phi_{\rm BH}$
…	…	…	…	…	…	…	…	…	…
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
…	…	…	…	…	…	…	…	…	…

入力

機械学習モデル

推定

学習に未使用のデータ
（全データの20%）

推定値		
$\dot{m}$	Φ	$\phi_{\rm BH}$
1.5	8	2.3
…	…	…
5.5	7	1
3	6.5	2

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}	$L_{\mathrm{kin},100t_g}$	$L_{\mathrm{kin},200t_g}$	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
…	…	…	…	…	…	…	…	…	…

正解値

比較して評価

機械学習モデル

推定値		
$\dot{m}$	Φ	ϕ_{BH}
1.5	8	2.3
…	…	…
5.5	7	1
3	6.5	2

推定結果①

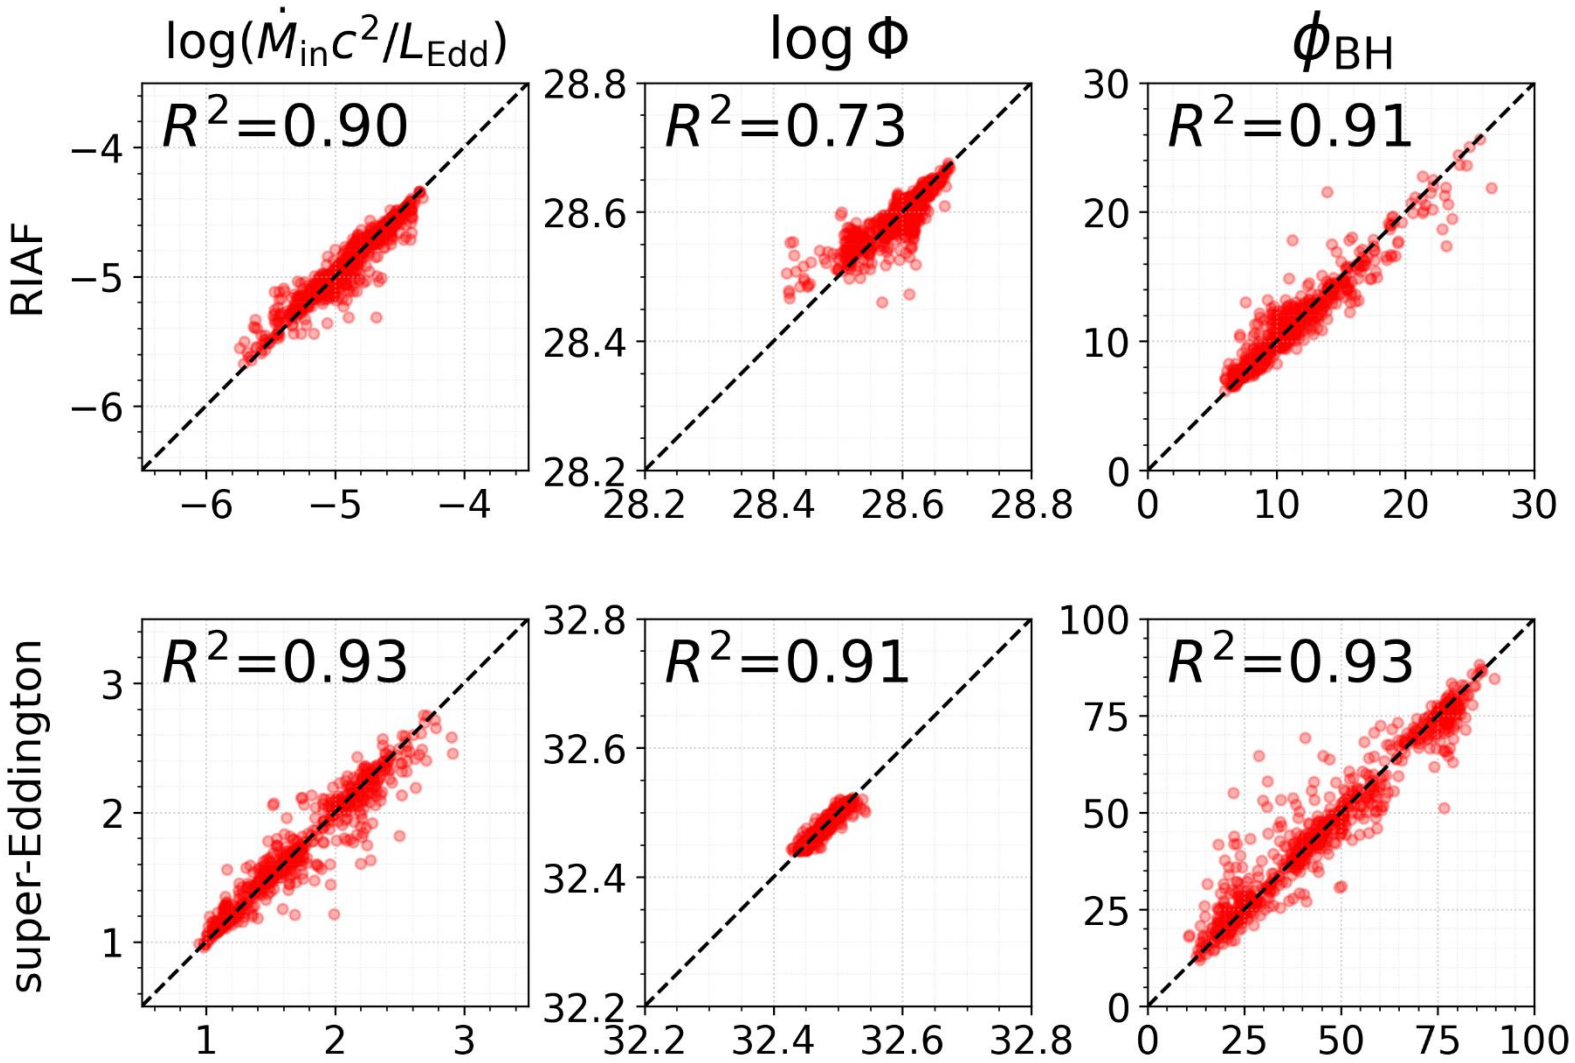

評価指標は決定係数：

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

1に近いほど精度良く
推定できていることを示す

決定係数は0.73~0.93
正解値の傾向を捉えることに成功
していることがわかる

推定結果②（入力値：$L_{\mathrm{rad}}, L_{\mathrm{rad},100t_g}, L_{\mathrm{rad},200t_g}, \sout{L_{\mathrm{kin}}, L_{\mathrm{kin},100t_g}, L_{\mathrm{kin},200t_g}}$）

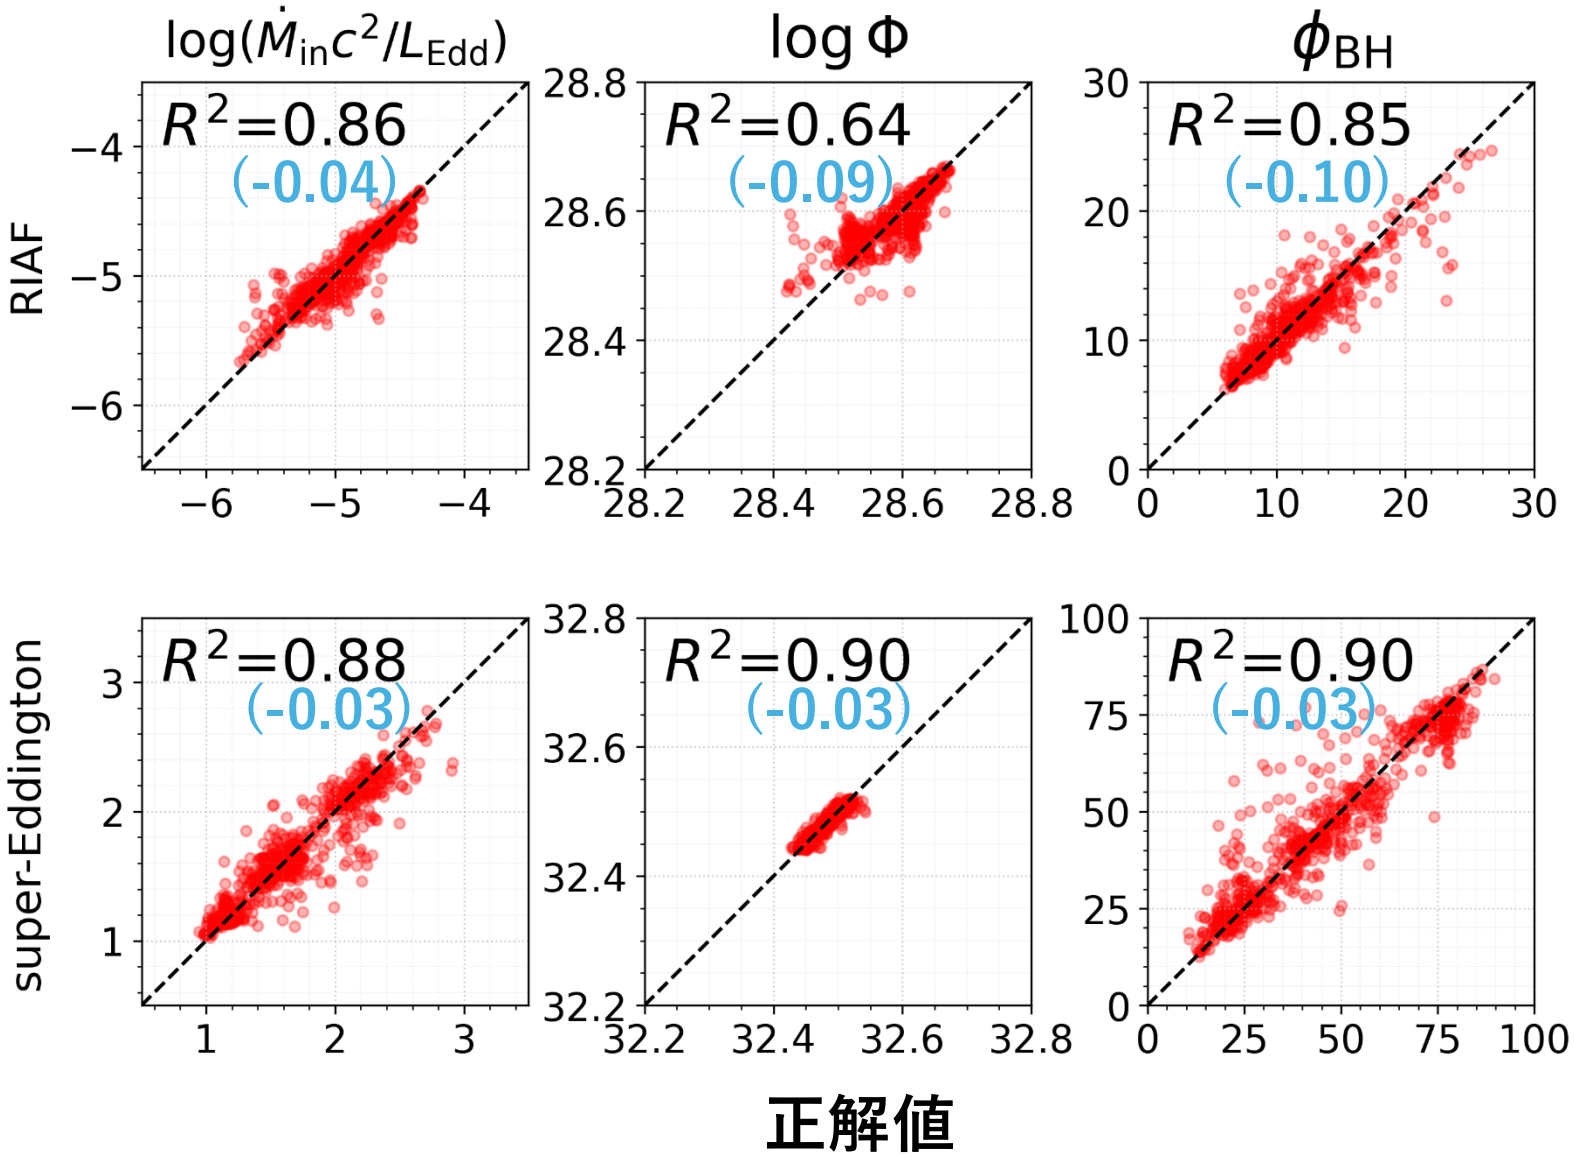

評価指標は決定係数：

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

1に近いほど精度良く
推定できていることを示す

青字は結果①と比較した値

決定係数は0.64~0.90
結果①と比べるとわずかに推定精度が下がっていることがわかる

推定結果③（入力値：~~$L_{\mathrm{rad}}, L_{\mathrm{rad},100t_g}, L_{\mathrm{rad},200t_g}$~~, $L_{\mathrm{kin}}, L_{\mathrm{kin},100t_g}, L_{\mathrm{kin},200t_g}$）

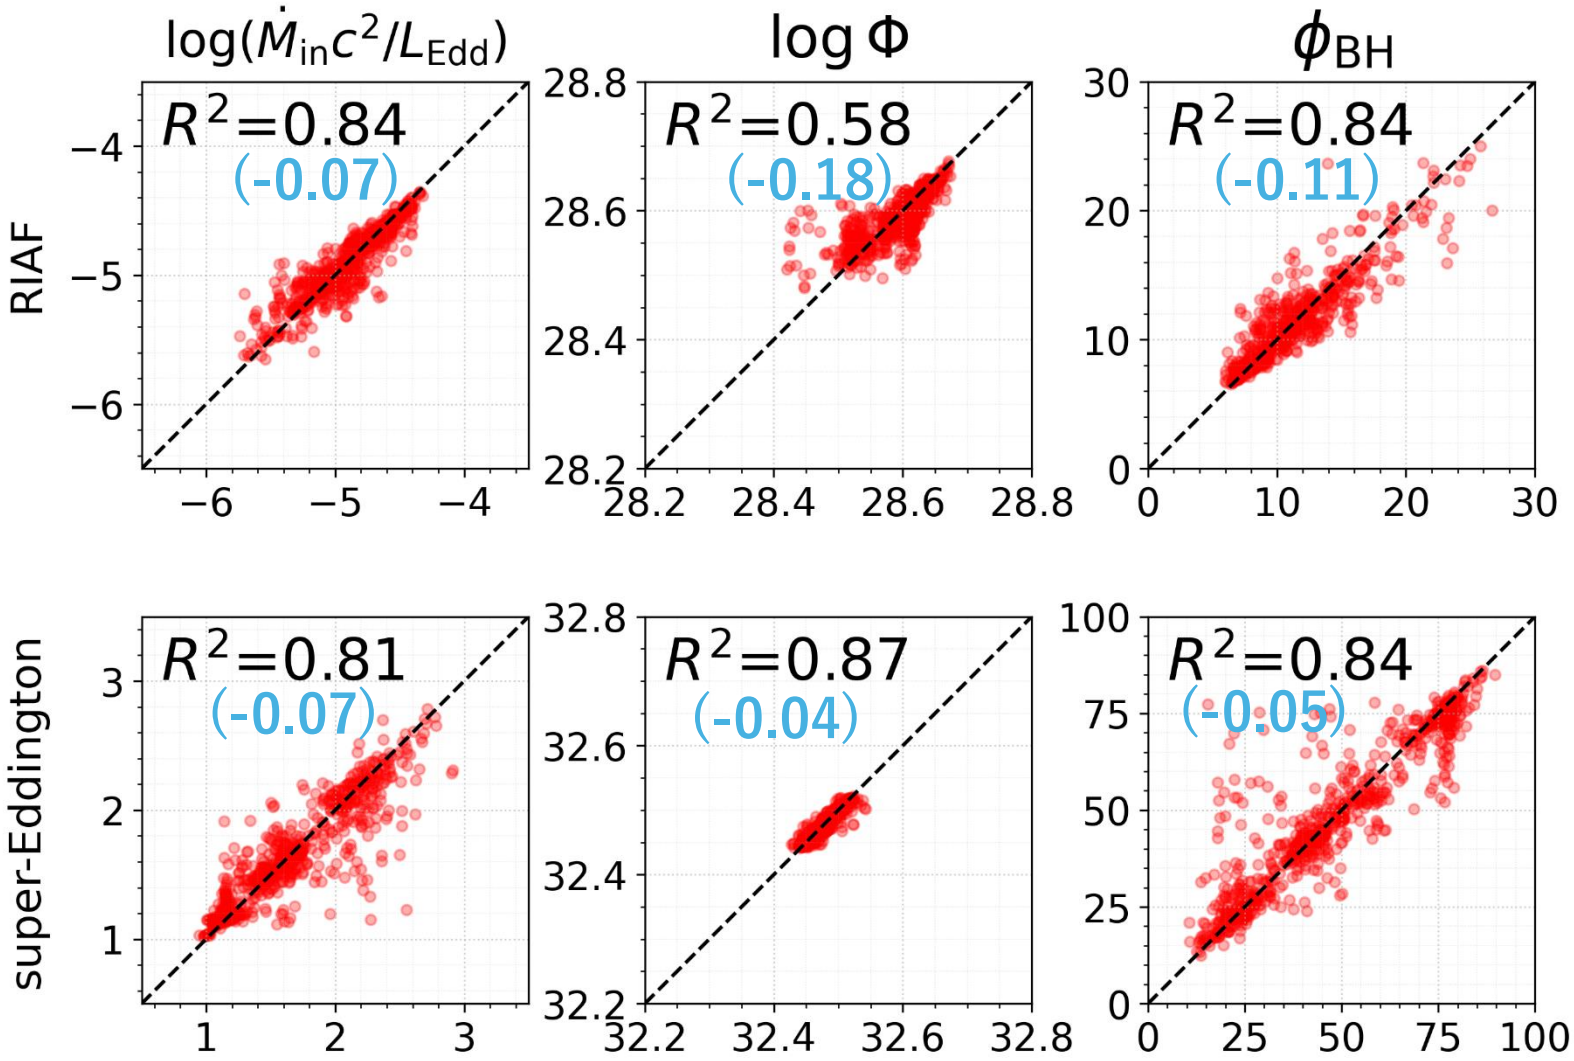

評価指標は決定係数：

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

1に近いほど精度良く
推定できていることを示す

青字は結果①と比較した値

決定係数は0.58~0.87。
結果②と同様、結果①と比べると精度は下がっており、その差は結果②よりも大きい。

入力値に追加する光度の時刻と決定係数の関係

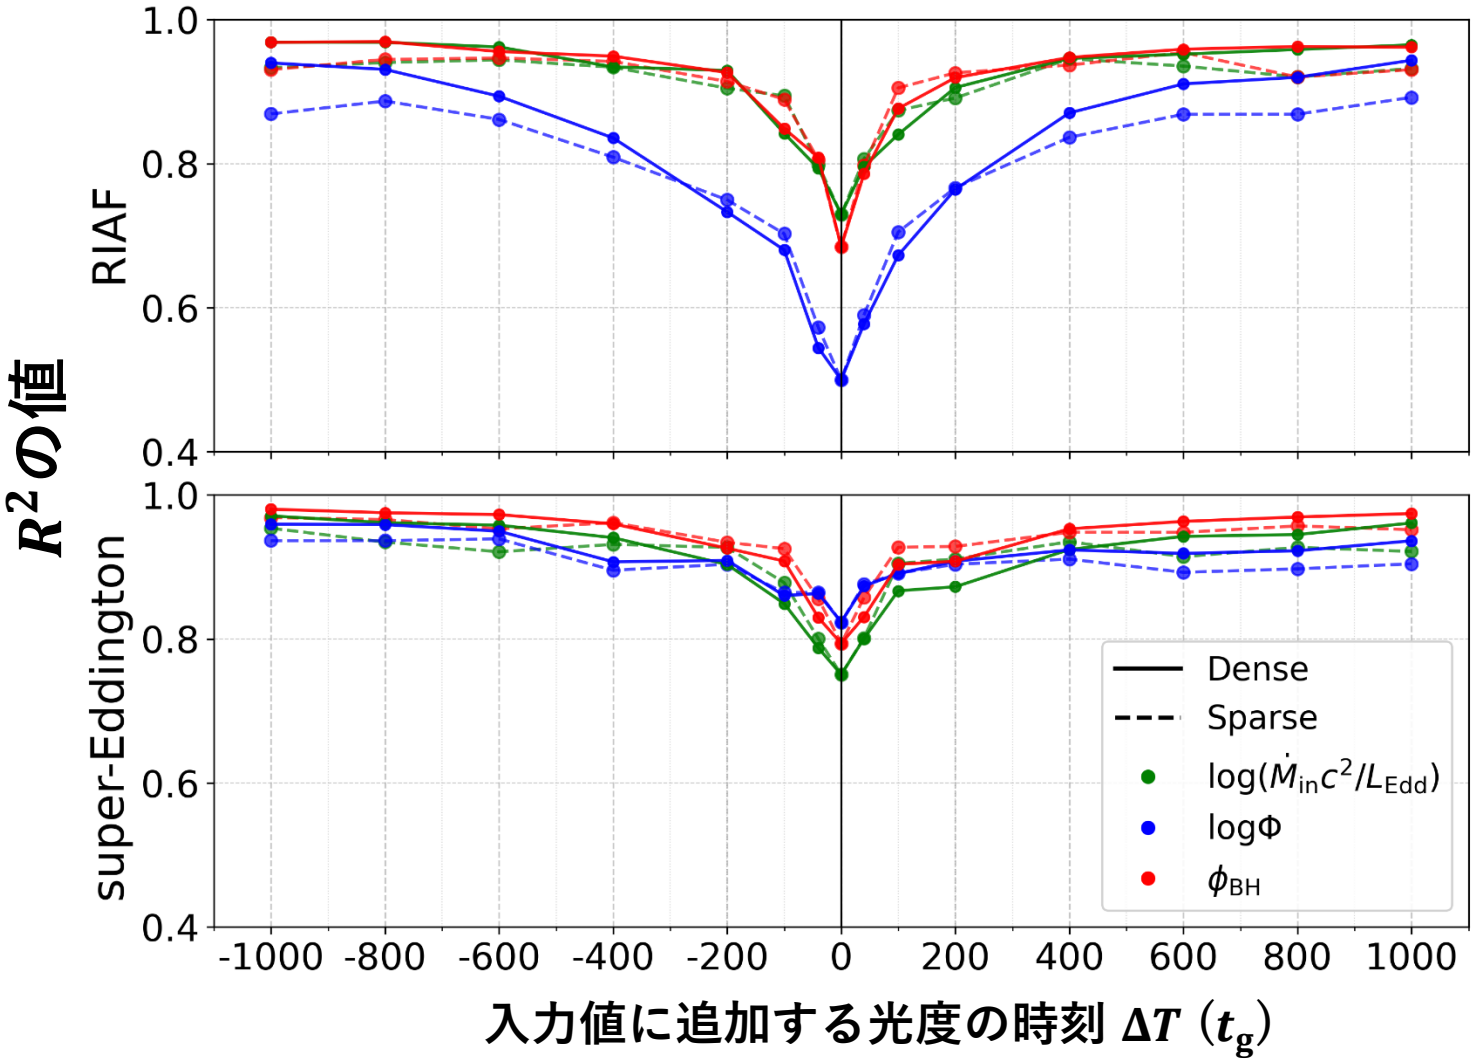

実線：ΔTまでの全ての光度を入力値に追加
破線：ΔTと$\Delta T/2$の光度を入力値に追加

$200t_g$~$400t_g$以上離れた時刻の光度を参照する方が、近い時刻の光度を参照するよりも推定精度が高くなっている

↑運動光度および放射光度が概ね$200t_g$で変化するので、それ以上離れた時刻のデータを参照することで精度が向上していると考えられる

まとめ

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・MADness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

▶ **機械学習を用いたMADnessパラメータなどの推定が可能であることがわかった**

- ✓ **機械学習手法を用いてMADness パラメータなどを推定し、決定係数~0.9を得た**
- ✓ **放射光度と運動光度の両方を入力値として用いることで、予測精度が向上した**
- ✓ **200tgより遠い時刻の光度を参照することが重要であることがわかった**

今後の展望
・多数のパラメータで実施したシミュレーションデータを用いて機械学習モデルを作成する
・見込み角を考慮して光度を計算する
・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

Appendix

放射光度の自己相関関数

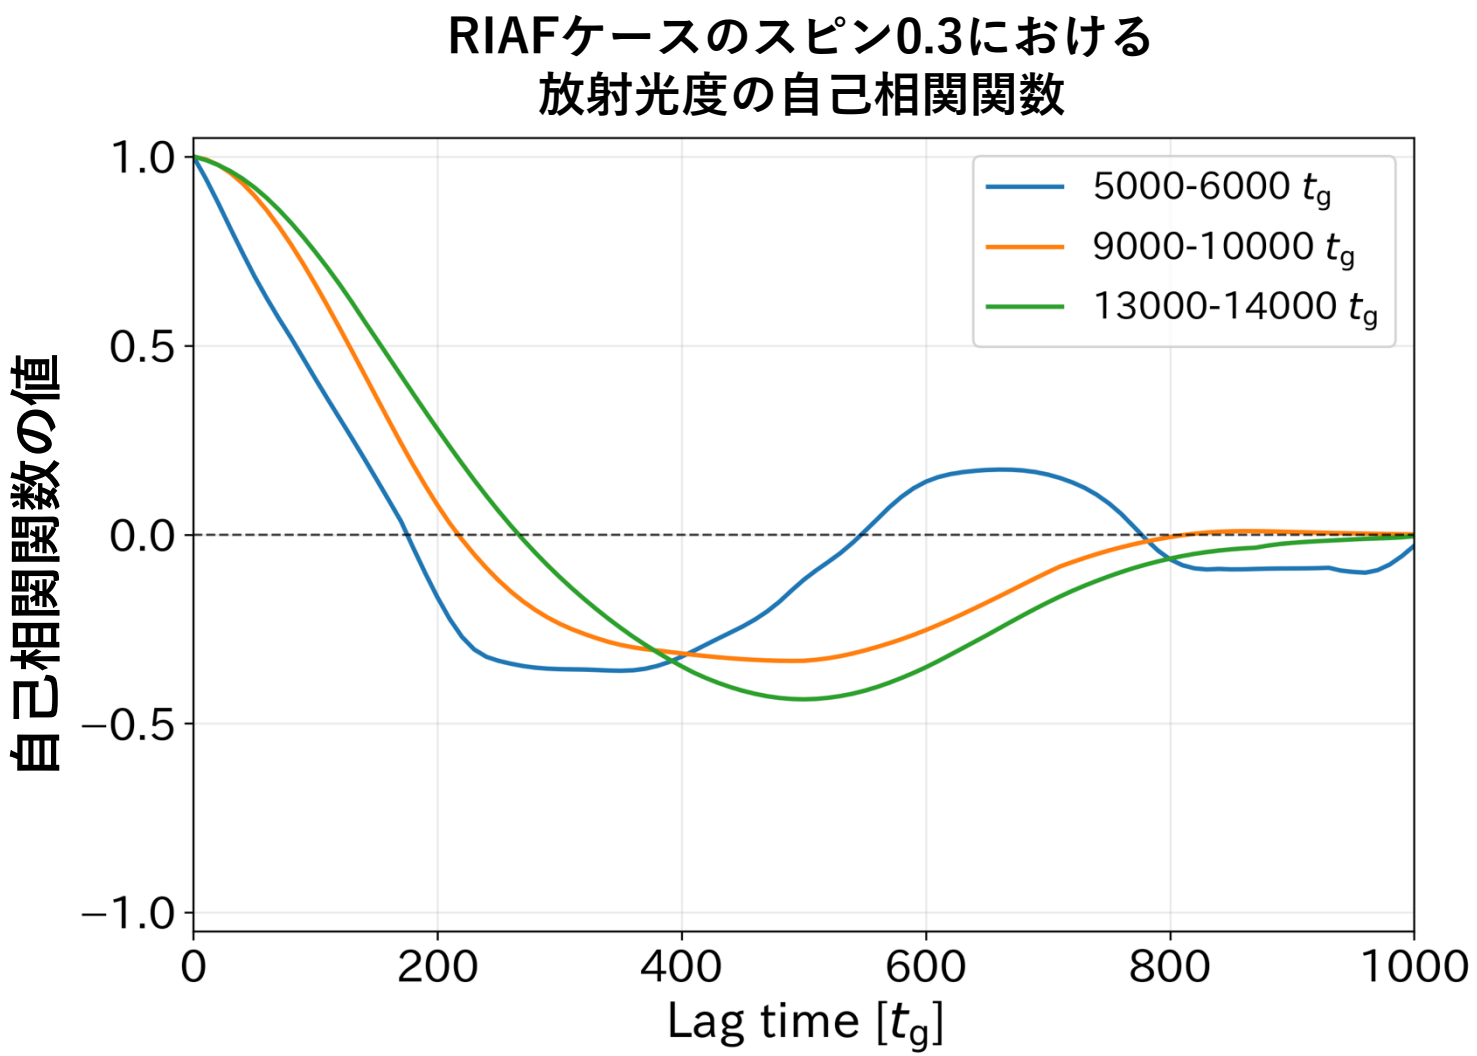

自己相関関数：

$$\mathrm{ACF}(t) = \frac{< (x_i - \bar{x})(x_{i+t} - \bar{x}) >}{< (x_i - \bar{x})^2 >}$$

自己相関関数の値が$200t_g$前後で0になっている。

→ 光度の時間変動のタイムスケールが概ね$200t_g$前後であることを示唆しており、$200t_g$以上離れた時刻の光度を参照すると推定精度が高いことの理由であると推察される。

光度とスピンの相関

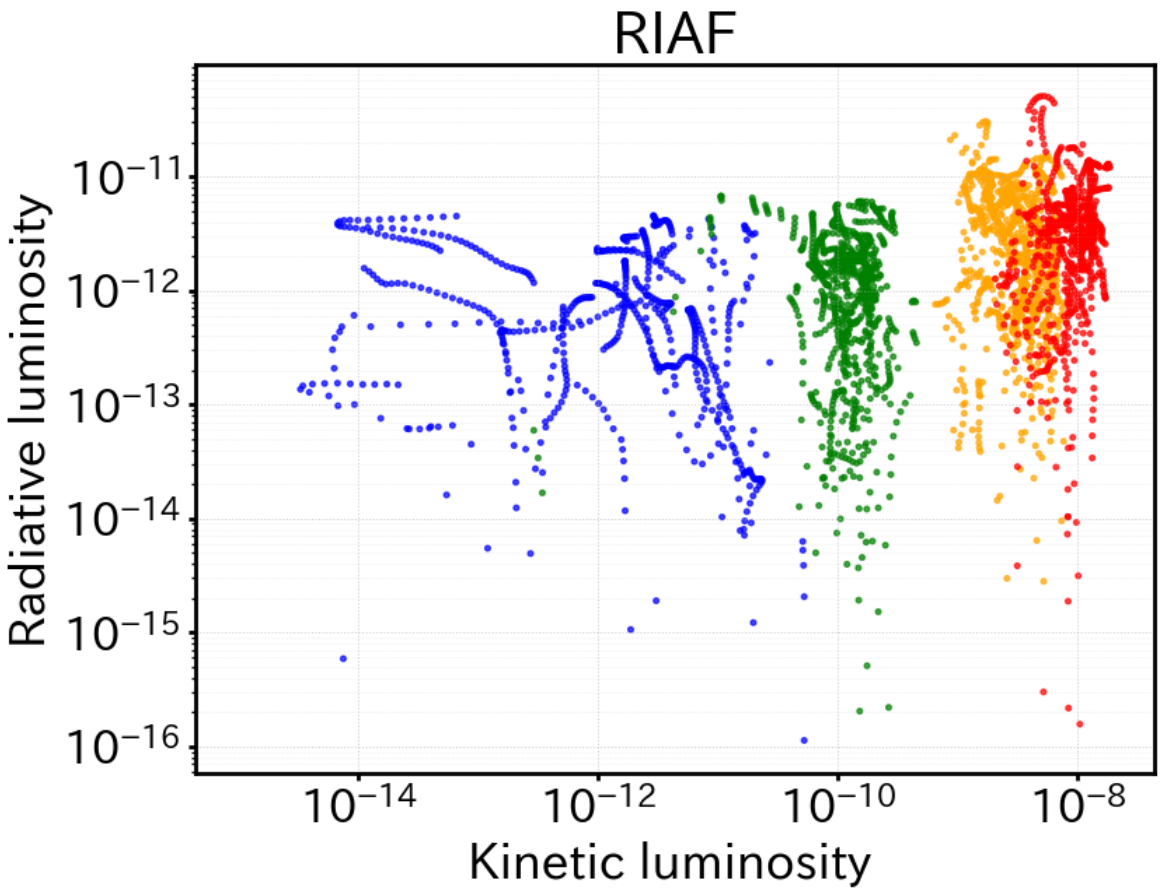

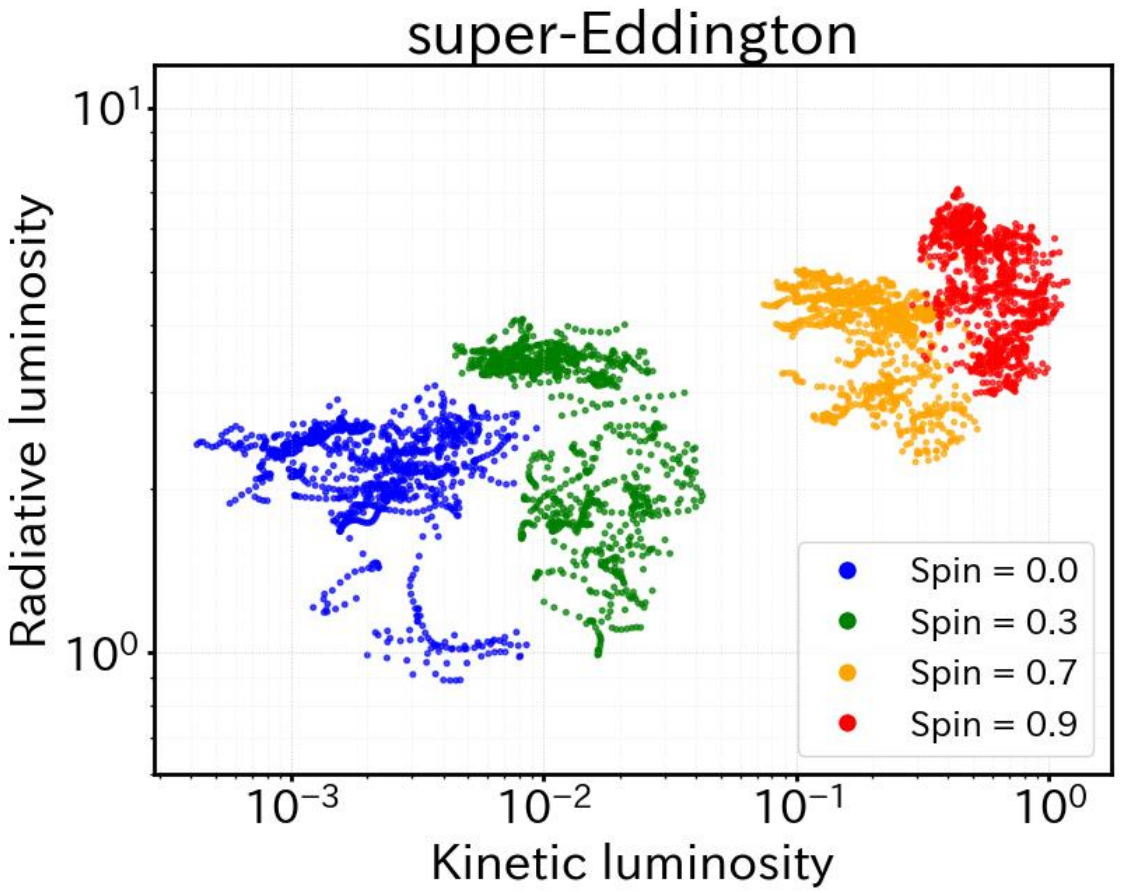

今回のデータセットにおいては、スピンが運動光度に強く依存するため、スピンを目的変数としていない。多くのスピンの値でシミュレーションが実施できた場合はその限りではない。

学習プロセス（スピン推定を例に簡略化）

１本目の決定木の作り方

	教師データ			木ごとに更新される値	
	入力値 (Luminosity)		出力値	初期予測値 (平均値)	残差
	L_{kin}	L_{rad}	スピン a	$\hat{y}_0$	$a-\hat{y}_0$
Data_1	4	5	-0.3	0.05	-0.4
Data_2	4	4	-0.2	0.05	-0.4
Data_3	7	8	-0.1	0.05	-0.15
Data_4	7	9	0.1	0.05	0.05
Data_5	2	6	0.2	0.05	0.2
Data_6	3	3	0.4	0.05	0.55
Data_7	1	4	0.4	0.05	0.45

残差をもとに
予測値を決定

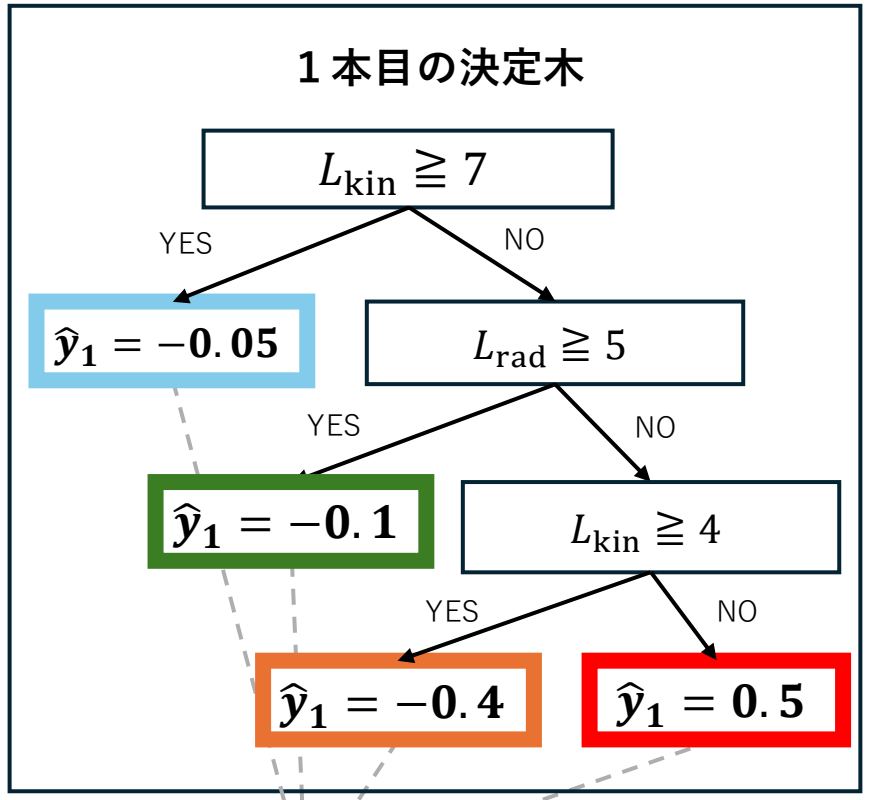

1本目の木の予測値 $\hat{y}_1$ =(リーフ内の残差の平均値)

学習プロセス（スピン推定を例に簡略化）

２本目の決定木の作り方

	教師データ			木ごとに更新される値	
	入力値 (Luminosity)		出力値	1本目の木の予測値	残差
	L_{kin}	L_{rad}	スピン a	$\hat{y}_1$	$a-\hat{y}_1$
Data_1	3	5	-0.3	-0.1	-0.2
Data_2	2	4	-0.2	-0.4	0.2
Data_3	5	8	-0.1	-0.05	-0.05
Data_4	5	9	0.1	-0.05	0.15
Data_5	4	6	0.2	-0.1	0.3
Data_6	6	3	0.4	0.5	-0.1
Data_7	7	4	0.4	0.5	-0.1

残差をもとに決定木を作成

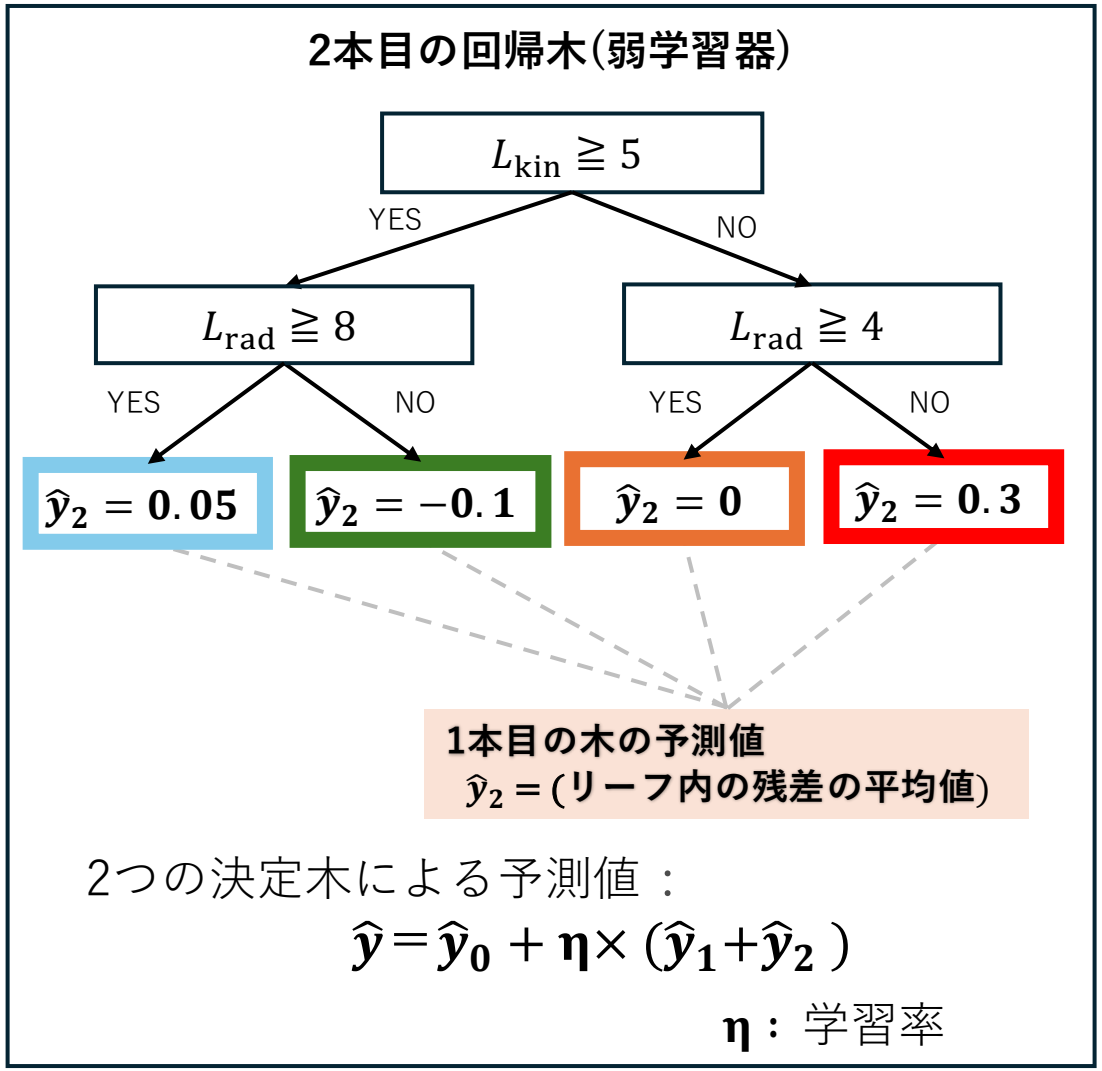

2つの決定木による予測値：

$$\hat{y} = \hat{y}_0 + \eta \times (\hat{y}_1 + \hat{y}_2)$$

η：学習率