

機械学習を用いた エディントンテンソルの推定

上野航介(筑波大学)

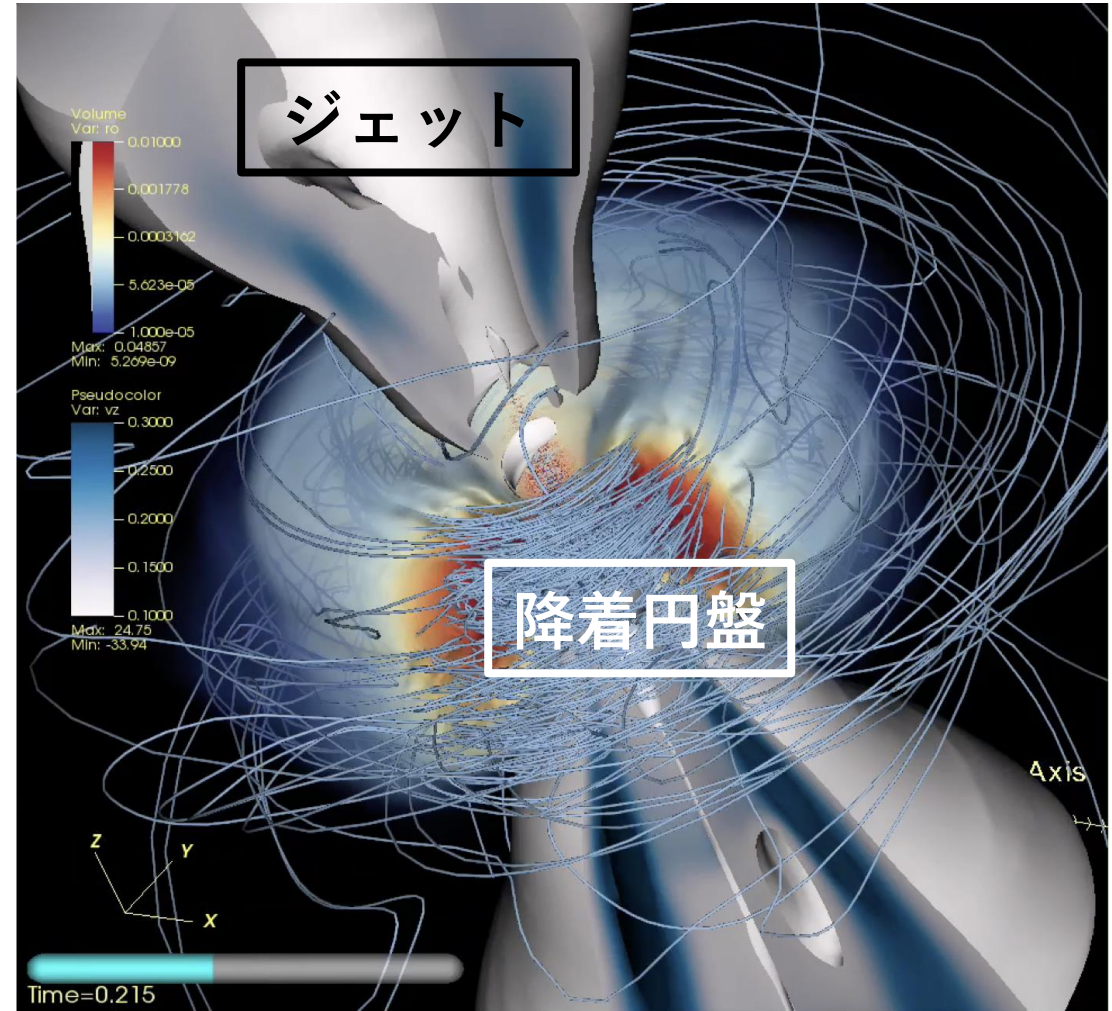
共同研究者

朝比奈雄太(筑波大学), 大須賀健(筑波大学),
矢島秀伸(筑波大学), 福島肇(筑波大学)

研究背景：ブラックホール研究の現状

- ブラックホール降着円盤やジェットの研究では、**一般相対論的輻射磁気流体力学計算（GR-RMHD計算）**が行われている
- 質量降着率が高い降着円盤では強力な輻射場が形成されるため、**輻射場を正確に解く必要がある**

GR-RMHD計算で
再現した降着円盤とジェット
(Takahashi et al. 2018)



研究背景：輻射場を計算する2つの方法

モーメント式

$$\frac{\partial E}{\partial t} + \frac{\partial F^i}{\partial x^i} = \int S d\Omega$$
$$\frac{1}{c^2} \frac{\partial F^j}{\partial t} + \frac{\partial P^{ij}}{\partial x^i} = \int l^i l^j S d\Omega$$



輻射応力テンソルと 輻射エネルギー密度の関係式 (クロージャー関係)

$$P^{ij} = f^{ij} E$$

Variable Eddington Tensor (VET)法 でのエディントンテンソル

$$\frac{1}{c} \frac{\partial I}{\partial t} + l^i \frac{\partial I}{\partial x^i} = S$$
$$f^{ij} = \frac{\int l^i l^j I d\Omega}{\int I d\Omega}$$

M1-closure (M1)法 でのエディントンテンソル

$$f^{ij} = \frac{1 - \chi}{2} \delta^{ij} + \frac{3\chi - 1}{2} l^i l^j$$
$$\chi = \frac{3 + 4|\eta^k|}{5 + 2\sqrt{4 - 3|\eta^k|}}, \quad \eta^k = \frac{F^k}{cE}$$

I : 輻射強度 [$\text{erg s}^{-1} \text{cm}^{-3} \text{sr}^{-1}$]
 E : 輻射エネルギー密度 [erg cm^{-3}]

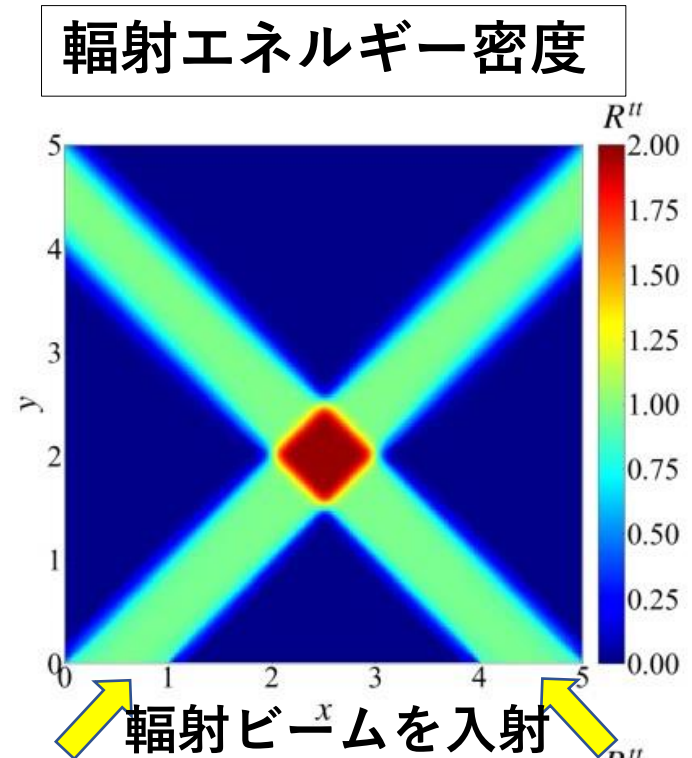
F^i : 輻射流束 [$\text{erg s}^{-1} \text{cm}^{-3}$]
 P^{ij} : 輻射応力テンソル [dyn cm^{-2}]

(González et al. 2007)

研究背景：2つの計算方法の違い


VET法：

- 輻射輸送方程式を解いてエディントンテンソルを計算するため、正確に輻射場を解けるが計算量が多い



M1法：

- 近似的にエディントンテンソルを求めるため、計算量は抑えられるが、光学的に薄い領域や非等方な状況で不正確
(現在の研究ではM1法が多く用いられている)



(Asahina et al. 2020)

本研究の目的

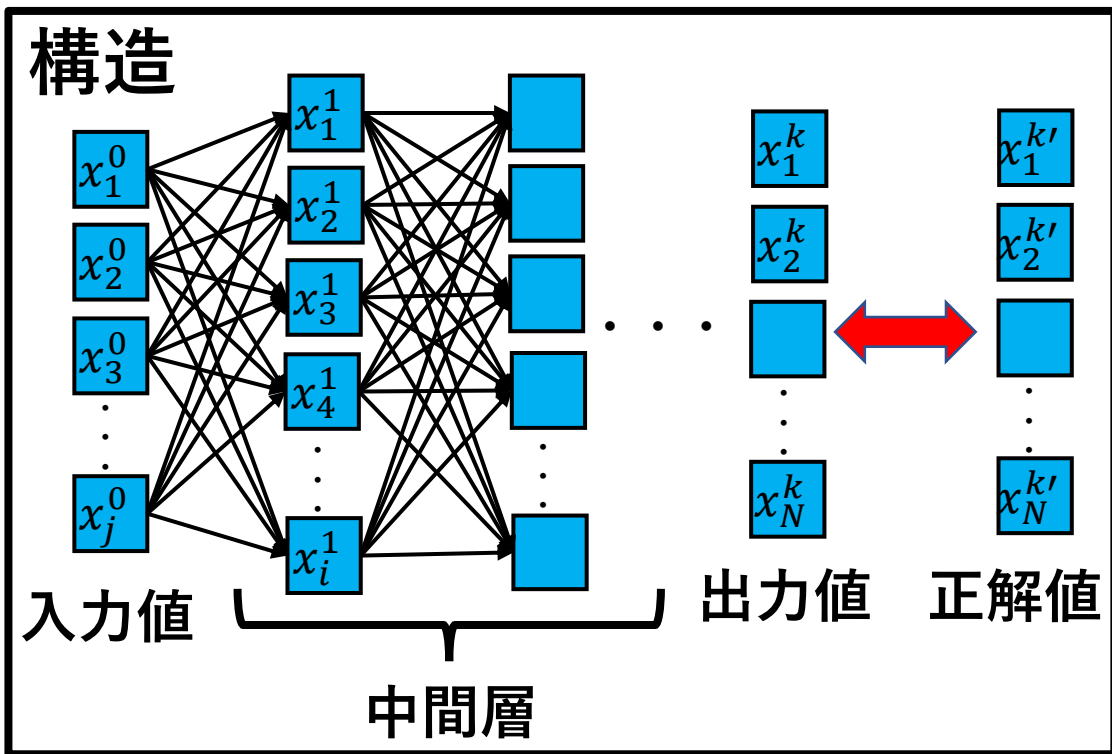
輻射輸送方程式を解かずに、正確なエディントンテンソルを求めることができれば、高精度で高速なGR-RMHD計算が可能になる

機械学習を用いてエディントンテンソルを求めることで、VET法より高速に、M1法より正確にGR-RMHD計算を行うことを目指す

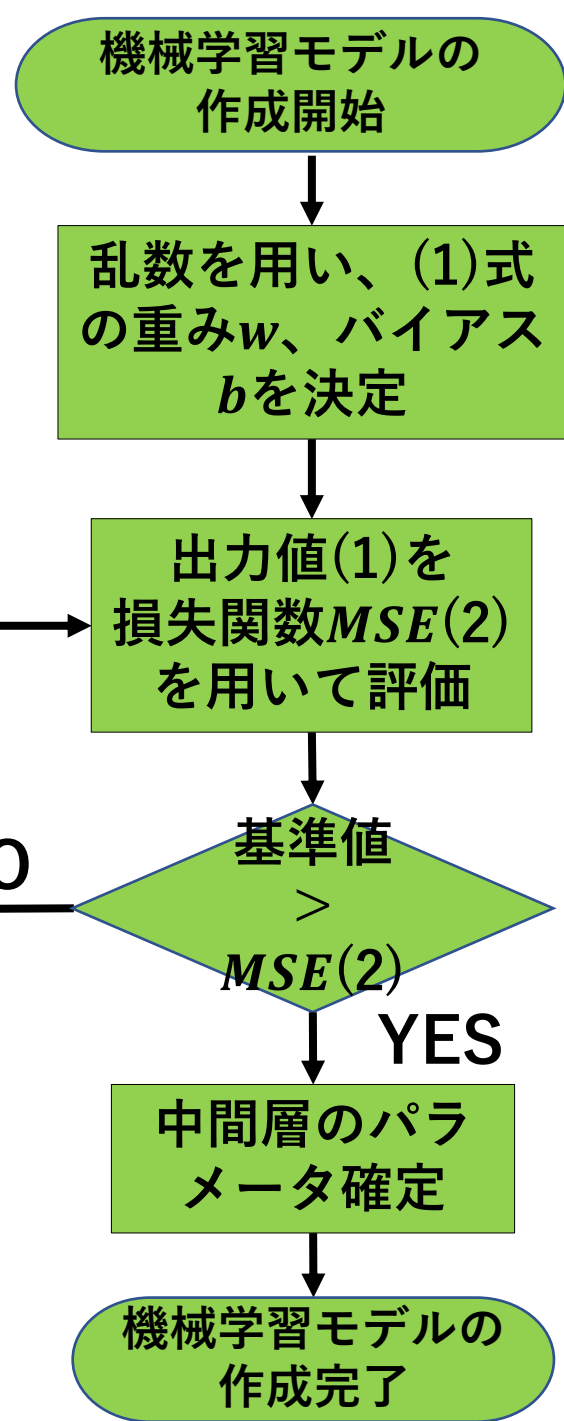
本講演では、ブラックホール降着円盤の時間発展を機械学習モデルに基づきGR-RMHD計算し、各計算方法を比較することにより、本計算方法の有用性を示す

方法：本研究で用いる教師あり学習

・・・データ間の最適な関数関係を導く機械学習手法



x : 入力値or出力値
 x' : 正解値
 w : 重み(パラメータ)
 b : バイアス(パラメータ)
 g : 活性化関数
 MSE : 損失関数



重みw、バイアスb
を更新

$$x_i^n = g \left(\sum_j w_{ij}^n x_j^{n-1} + b_i^n \right) \quad \dots(1)$$

$$MSE = \frac{1}{N} \sum_{l=1}^N (x_l^k - x_l^{k'})^2 \quad \dots(2)$$

方法：計算方法




■VET法に基づく二次元軸対称GR-RMHD計算

『INAZUMA (Asahina et al. 2020)』

- ブラックホール質量： $M = 10M_{\text{sun}}$
- スピンパラメータ： $a^* = 0$
- 回転平衡トーラスの最大密度： $\rho_0 = 0.01 \text{ g/cm}^3$
- グリッド数： $(N_r, N_\theta, N_\phi) = (300, 300, 1)$
- 計算領域： $r = [r_H, 1000r_g]$ 、 $\theta = [0, \pi]$

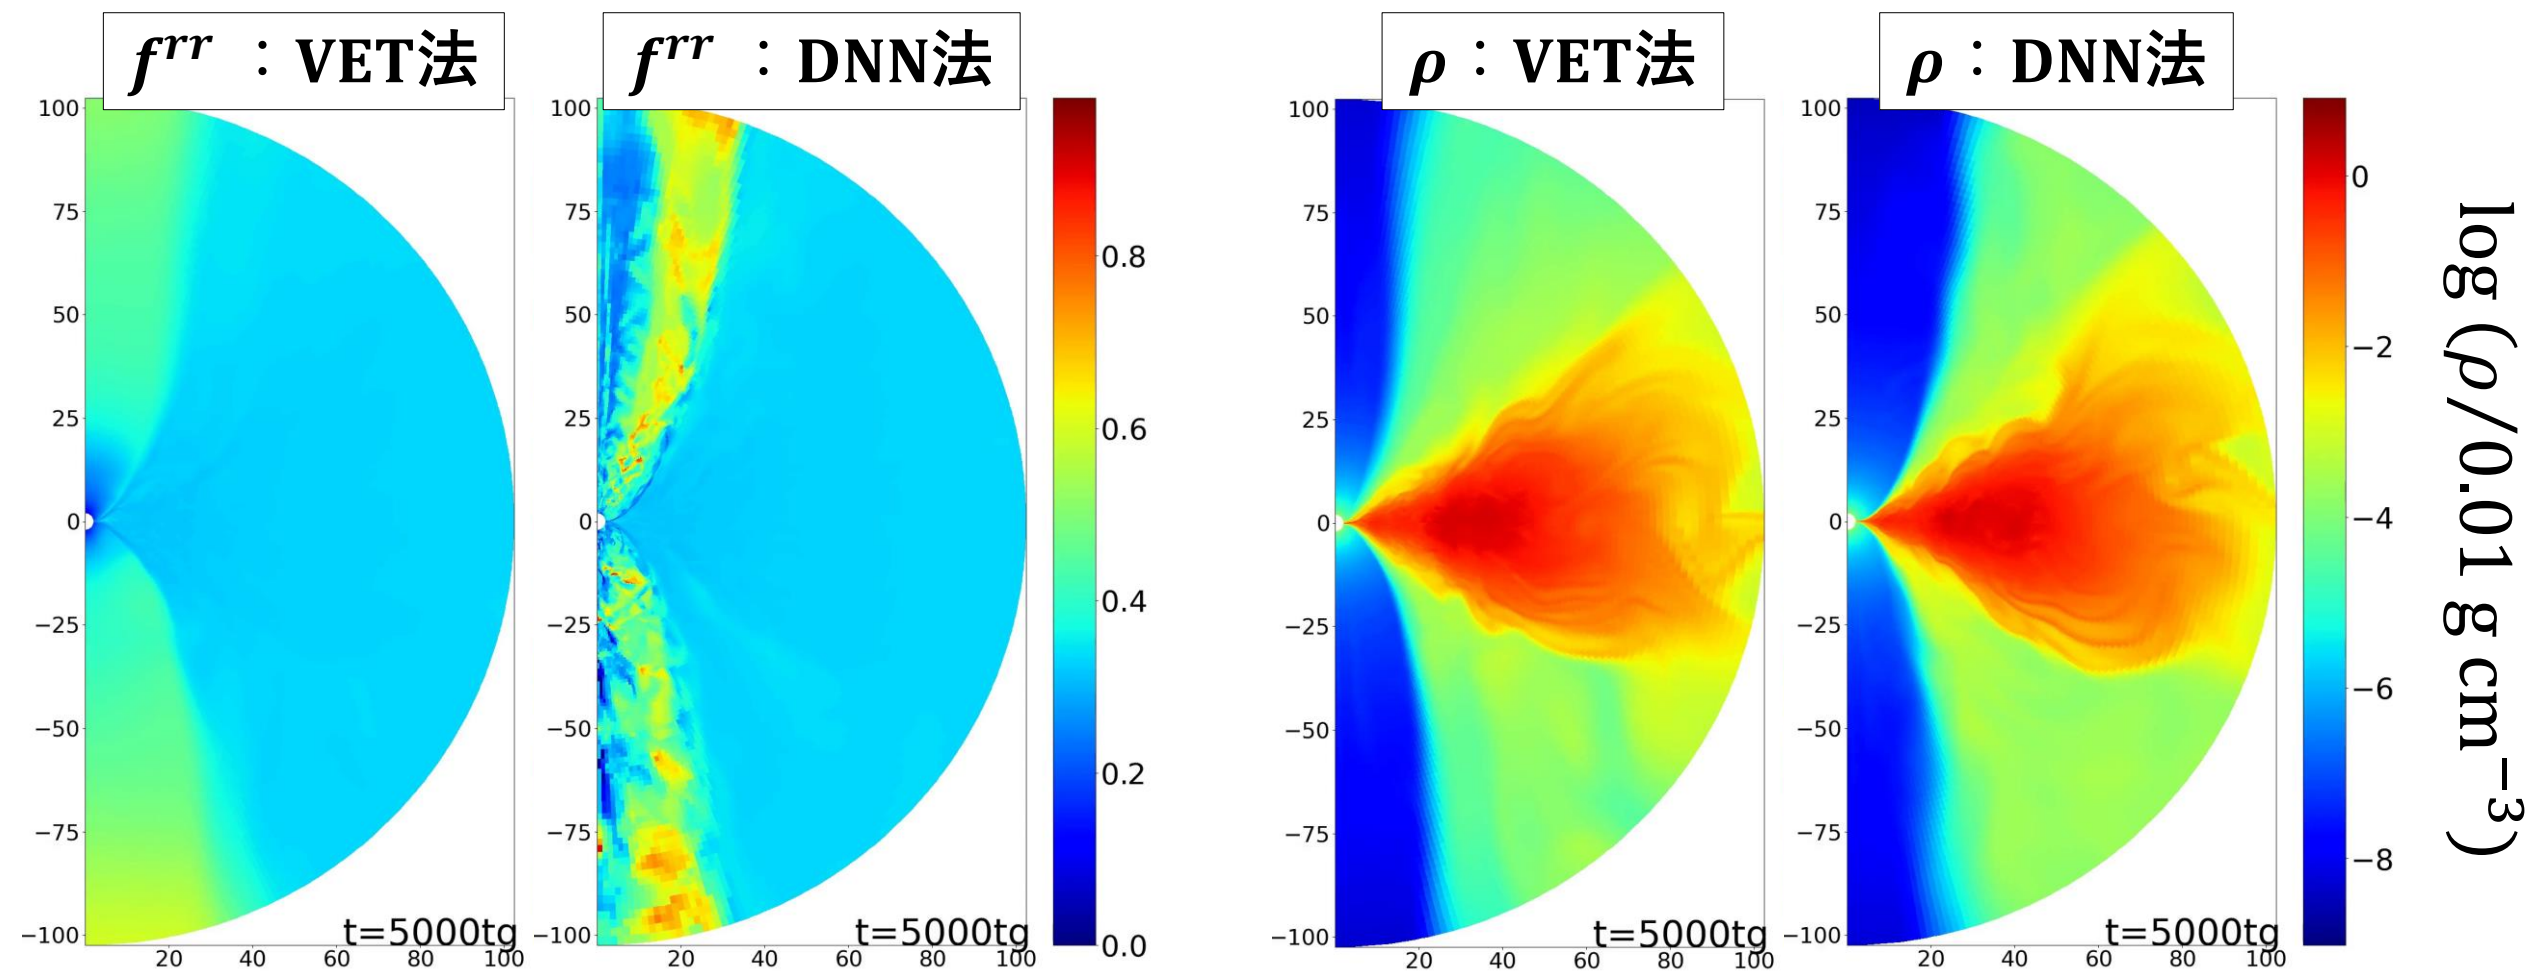
■機械学習モデルに基づくGR-RMHD計算 (Deep Neural Network (DNN) 法)

- 教師データ： $t = 0, 1000, 2000, 3000, 4000, 5000t_g$
 $r = [0, 100]r_g$ の6枚のsnapshot
- 入力値： $\frac{F^i}{E}, \rho, p, u^i$
- 出力値： f^{ij}
- 中間層：4層64ノード
- 初期条件：教師データと同様



$r \leq 100r_g$
のプロット

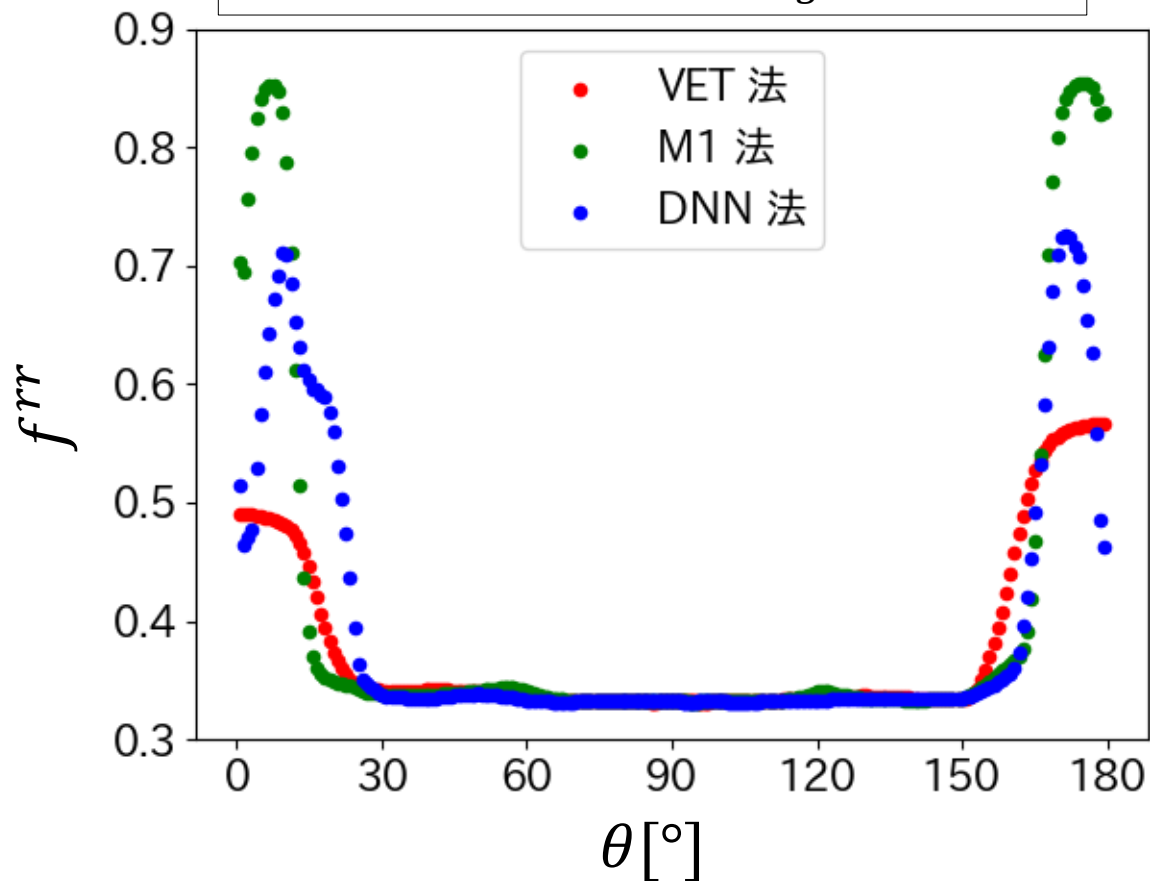
結果：ブラックホール降着円盤の時間発展計算



$r \leq 100r_g$ のプロット


結果：各計算方法での準定常状態の f^{rr}

各計算方法での f^{rr} の準定常状態の
時間平均 ($100r_g$)



- 左の図は準定常状態 ($t = 3500t_g \sim 5000t_g$) の時間平均
- DNN法は、円盤領域 ($\theta = 30^\circ \sim 150^\circ$) でM1法と同様に正確な値 ($f^{rr} \sim \frac{1}{3}$) を計算できる
- DNN法の回転軸付近 ($\theta = \sim 30^\circ, 150^\circ \sim$) での値 ($f^{rr} \sim 0.7$) は、M1法の値 ($f^{rr} \sim 0.85$) と比較して、VET法の値 ($f^{rr} \sim 0.5$) に近く正確である

結果：各計算方法での質量降着率



- 左の図は質量降着率の時間発展を表している
- 質量噴出率は3つの計算とも同様の時間発展を遂げる
- 質量降着率は3つの計算とも同程度

$$\dot{M}_{in} = -2\pi(2r_g)^2 \int_0^\pi \rho \min(0, u^r) \sin \theta d\theta$$

	VET法	M1法	DNN法
精度	良い	回転軸付近で悪い	M1法より良い
計算時間	長い (220時間)	短い (32時間)	短い (80時間)

まとめと今後の課題

まとめ

- VET法に基づいたGR-RMHD計算によって得られたブラックホール降着円盤データを用いて機械学習モデルを作成し、機械学習モデルに基づいたGR-RMHD計算を行った
- 機械学習モデルに基づいた計算はM1法より正確にVET法より高速に計算できることが確認できた

今後の課題

- 回転軸付近の精度向上や計算速度の向上
- 他の物理量を用いてさらに定量的な比較
- 初期条件の異なる計算への適用限界の調査