# “Dark Matter in Draco and Bootes I: Hints of a Core in an Ultra-Faint Dwarf from Simulation-Based Inference”, Nguyen et al. 2026 (arXiv: 2606.26218)

GAゼミ@20261214 林航平

【アブスト】

機械学習の手法１つであるGraph Neural Posterior Estimation (GraphNPE)を銀河系矮小銀河(Draco, Bootes I)の観測データに適用し、ダークマター密度分布の推定を行った。ダークマター分布、恒星分布、速度非等方性を仮定した分布関数からforward modelを作成し、観測誤差やselection functionも含めて学習させることで、ダークマター密度分布パラメータの事後分布を直接推定する。Mock解析では、視線速度分散のみの解析ではカスプ構造にバイアスされた結果となり、kurtosisを含める重要性を示した。実データの適用では、Dracoはカスプで高い中心密度を持つ結果となった一方で、BootesIはコア構造に近い密度分布が示唆された。

【ゴール】

銀河系矮小銀河のダークマター分布の解明　機械学習を用いた動力学解析

【オリジナリティ】

機械学習を用いた動力学解析

【ロジック】

## GraphNPE（図１）

- 各恒星$\{R_i, v_{\mathrm{los,i}}, \delta v_{\mathrm{los,i}}\}$をnodeとし、近傍の星同士の情報交換を行うことで、銀河全体の運動情報の特徴量を作成する。
- 得られた特徴量から正規化フローを用いてダークマター密度分布パラメータの事後確率$p(\theta|\mathbf{z})$を推定する。

## Forward modeling

- 恒星分布：Plummer, DM分布: Zhao ( $\alpha, \beta, \gamma$ model)
- 速度非等方性：Cuddeford-Osipkov-Merritt (内：$\beta_0$, 外：radially)
- 分布関数：$f(E, L)$（QuasiSphericalCOM by AGAMA）
- 選択関数：削除する星を$f_{\mathrm{drop}} \sim \mathcal{U}(0,0.5)$の割合でランダムに決める。どの部分を削除するかは$(S_{\mathrm{outer}}, S_{\mathrm{inner}}, S_{\mathrm{rand}}) = (0.4, 0.4, 0.2)$の確率で決定。
- 観測誤差：各学習データ生成の際に$\Delta_{\mathrm{max}} \sim \mathcal{U}(5,30)$, $\Delta_{\mathrm{min}} \sim \mathcal{U}(0.01,0.1)$ km/sで誤差の範囲を決めて、Jeffery priorからサンプリング。

## Mock analysis

- 実際の矮小銀河に近い模擬データ$(N_*, r_{\mathrm{half}}, \delta v_{\mathrm{los}}, \mathrm{etc.})$を作成
- GraphNPEと2次Jeans解析で比較
- 2次Jeansはカスプ構造にバイアスされる。GraphNPEはkurtosisも含む解析なので、core構造も再現可能。

## Real data analysis

- **Draco：MMT(Walker+23), DESI(Ding+25), Bool: S⁵(Sandford+26)**データを使用。図２にデータの特徴を示す。
- 図３に実データを用いた解析結果(GraphNPE, 2次Jeans)。GraphNPEの解析では**Dracoはカスプ構造、Boolはコア構造**を示唆する結果。
- 図４＆５に他の論文との比較。BoolはUFDだが、密度が低くコア構造を持つ。→ low-concentration halo?, alternative DM?

【コメント＆感想】

- 学習データが分布関数の形に依存するのでは。
- Kurtosisを扱う場合はcontaminationを影響を慎重に考慮しないといけない。
- Forward modelにSIDMやFDMを組み込むことで、ダークマターモデルパラメータの制限ができないか？

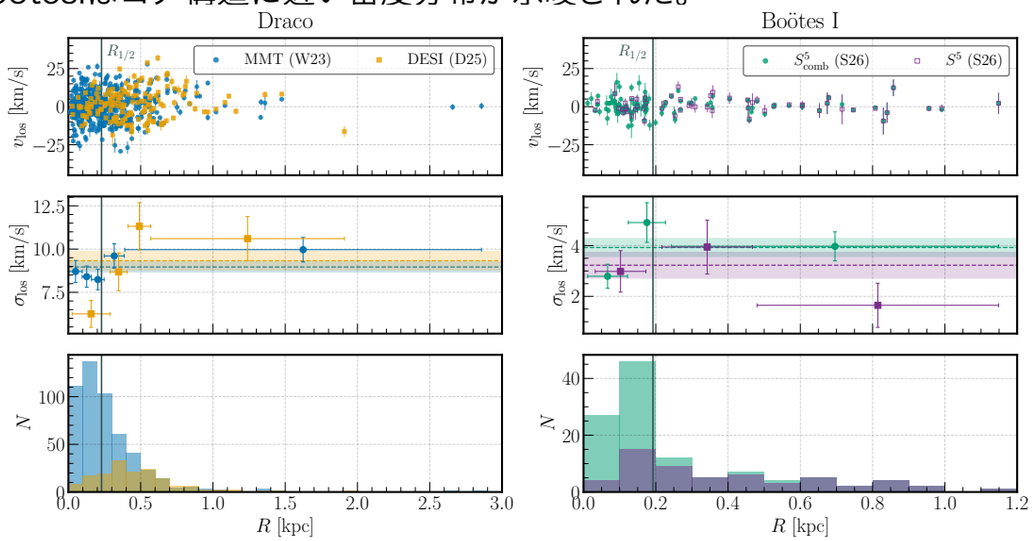



図２

Draco DESI　　Boötes I $S^5_{\mathrm{comb}}$

図３

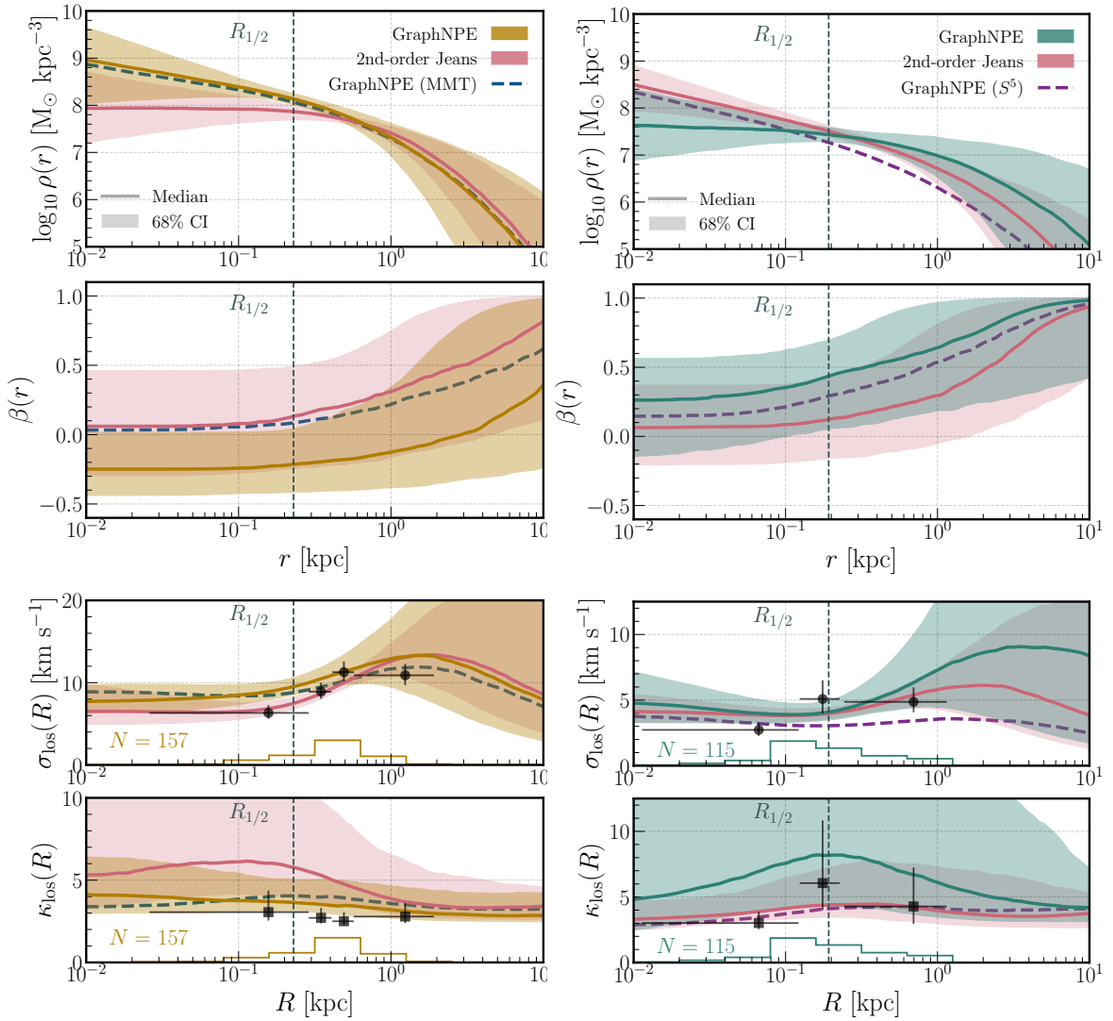


図4

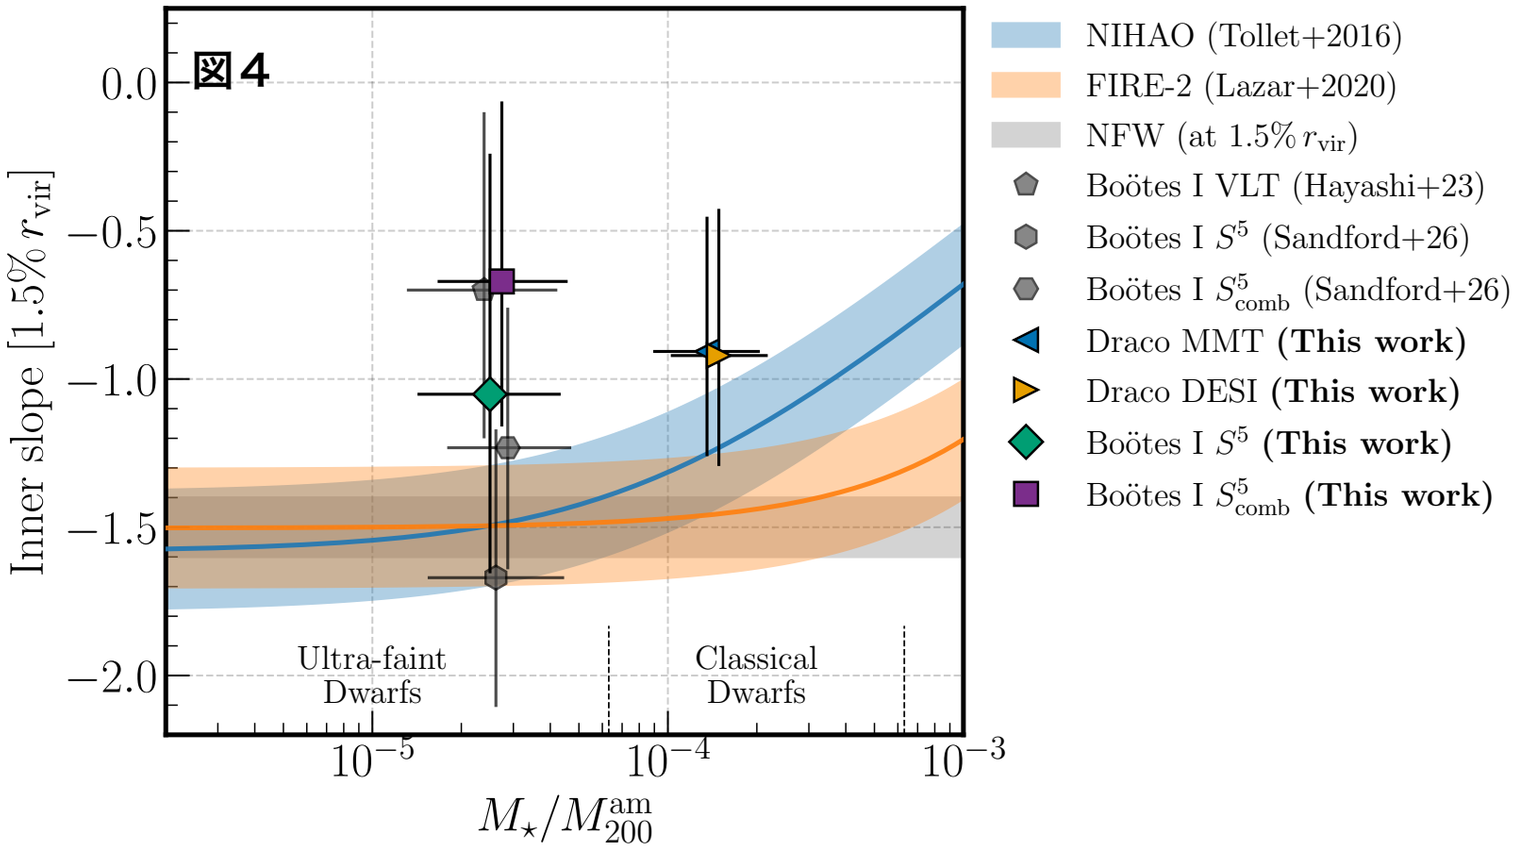



図5

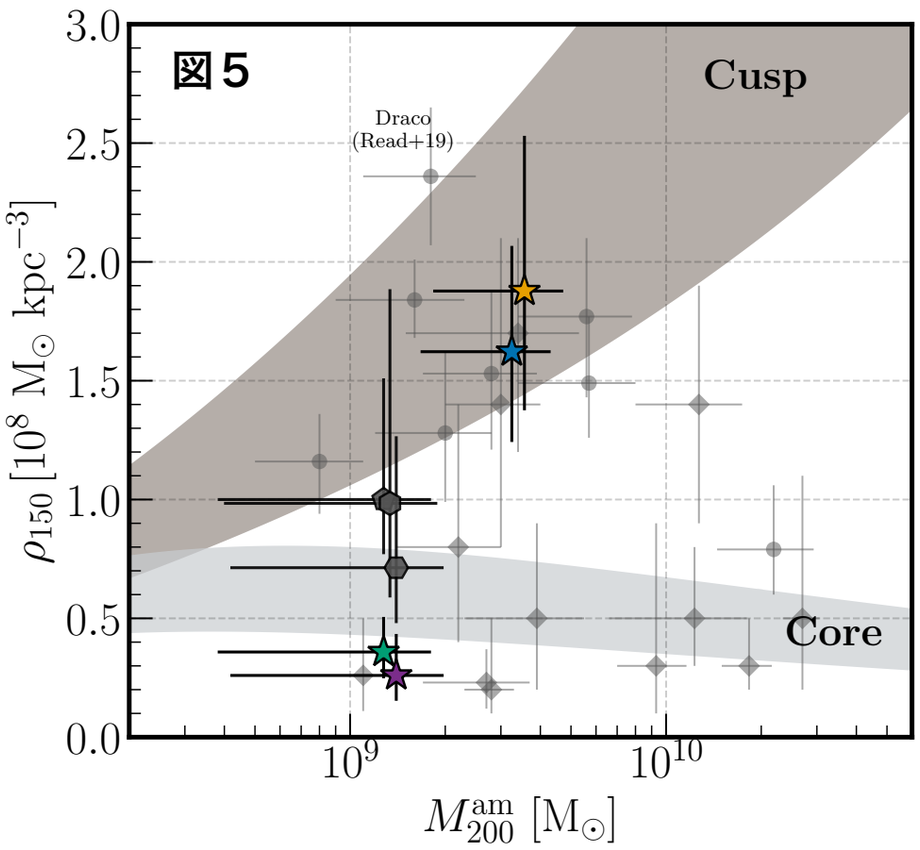
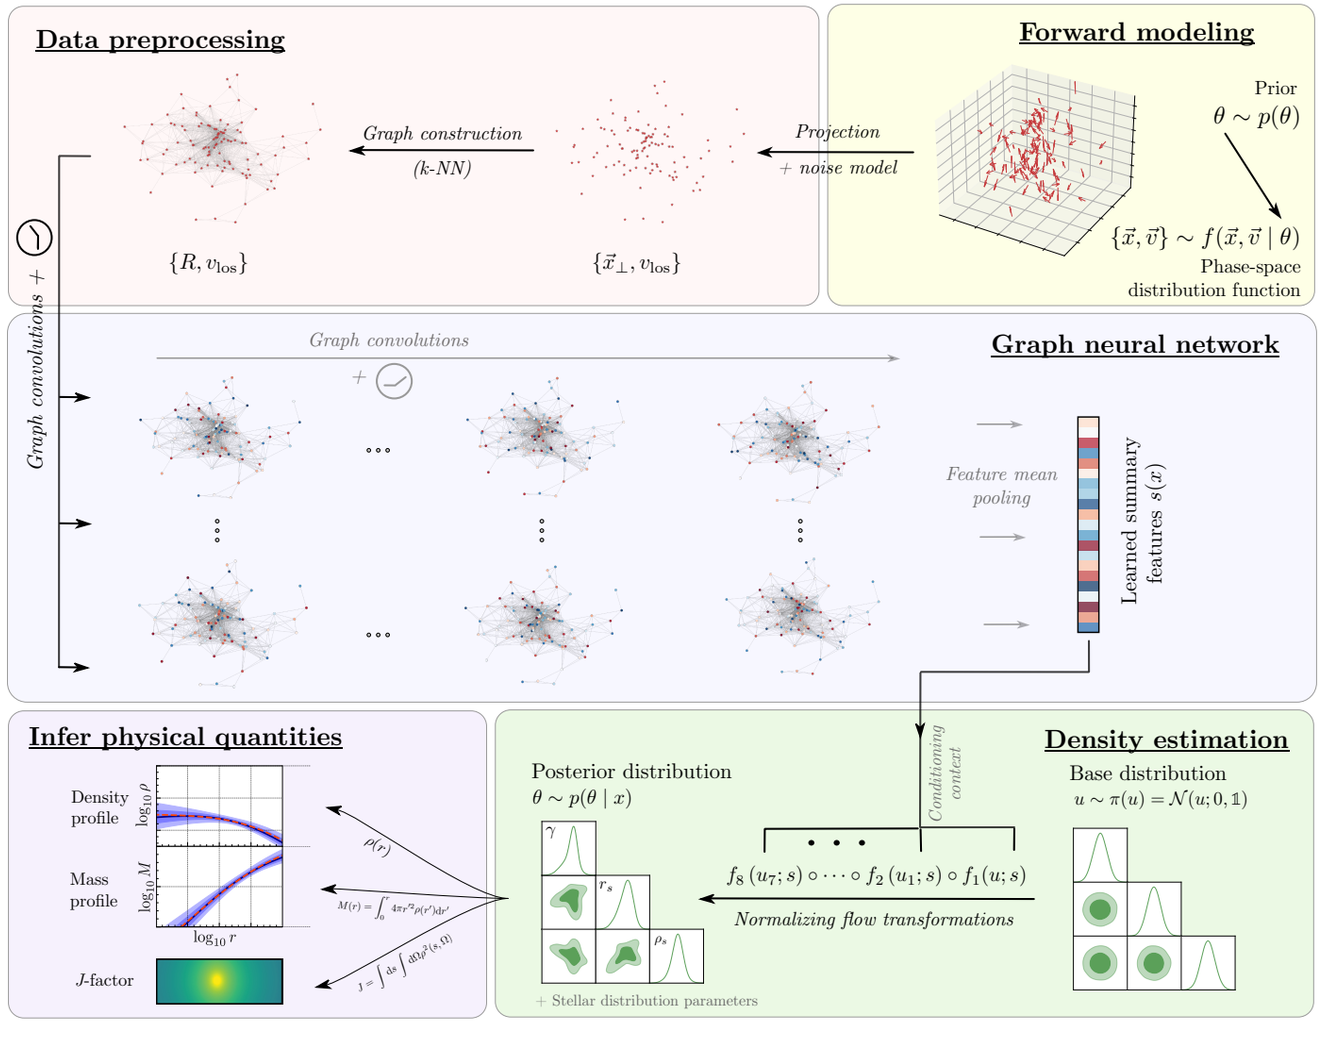



図1




Nguyen et al. (2023)