

ハローパワースペクトルとRSD

based on the master thesis

Yosuke Kobayashi

in collaboration with Takahiro Nishimichi & Masahiro Takada

「宇宙論における高次統計: バイスペクトルの理論と観測」 @YITP March 2018


Outline

- ▶ Redshift-space distortion
- ▶ Modeling of the nonlinear clustering in redshift space
- ▶ Dark matter halo - Galaxy
- ▶ Dark Emulator
- ▶ Emulator of the nonlinear redshift-space power spectrum of halos
- ▶ Cosmological information extractable from the nonlinear RSD

Redshift-space distortion

$$z_{\text{obs}} = z + \frac{v_z}{a} \longrightarrow s = \mathbf{x} + \frac{\mathbf{v}(\mathbf{x}) \cdot \hat{\mathbf{z}}}{aH(z)}$$

赤方偏移空間 実空間 銀河の特異速度
での位置座標 での位置座標



© Nishimichi

plain-parallel近似: 視線方向を1つ (eg. z軸) に定める

↓
統計的等方性の破れ

- 密度揺らぎの実空間—赤方偏移空間の対応

$$\delta_D(\mathbf{k}) + \delta^s(\mathbf{k}) = \int d^3x e^{i\mathbf{k} \cdot \mathbf{x}} e^{-ik_z u_z(\mathbf{x})} [1 + \delta(\mathbf{x})]$$

- 赤方偏移空間におけるパワースペクトル

: 波数とz軸との方向余弦

$$\delta_D(\mathbf{k}) + P^s(\mathbf{k}) = \int d^3r e^{i\mathbf{k} \cdot \mathbf{r}} \langle e^{-ik_\mu \Delta u_z} [1 + \delta(\mathbf{x})][1 + \delta(\mathbf{x}')] \rangle$$

Redshift-space distortion

$$z_{\text{obs}} = z + \frac{v_z}{a} \longrightarrow s = \mathbf{x} + \frac{\mathbf{v}(\mathbf{x}) \cdot \hat{\mathbf{z}}}{aH(z)}$$

赤方偏移空間 実空間 銀河の特異速度
での位置座標 での位置座標

plain-parallel近似: 視線方向を1つ (eg. z軸) に定める

↓
統計的等方性の破れ


- 密度揺らぎの実空間—赤方偏移空間の対応

$$\delta_D(\mathbf{k}) + \delta^s(\mathbf{k}) = \int d^3x e^{i\mathbf{k} \cdot \mathbf{x}} e^{-ik_z u_z(\mathbf{x})} [1 + \delta(\mathbf{x})]$$

- 赤方偏移空間におけるパワースペクトル

$$\delta_D(\mathbf{k}) + P^s(\mathbf{k}) = \int d^3r e^{i\mathbf{k} \cdot \mathbf{r}} \langle e^{-ik_\mu \Delta u_z} [1 + \delta(\mathbf{x})][1 + \delta(\mathbf{x}')] \rangle$$

: 波数とz軸との方向余弦



© Nishimichi

Linear Regime: Kaiser's Formula

RSDの線形理論での定式化 (Kaiser, 1987)

$$\delta_D(\mathbf{k}) + P^s(\mathbf{k}) = \int d^3r e^{i\mathbf{k}\cdot\mathbf{r}} \langle e^{-ik\mu\Delta u_z} [1 + \delta(\mathbf{x})][1 + \delta(\mathbf{x}')] \rangle$$



single streaming, 線形近似

$$P^s(k, \mu) = (1 + f\mu^2)^2 P(k)$$

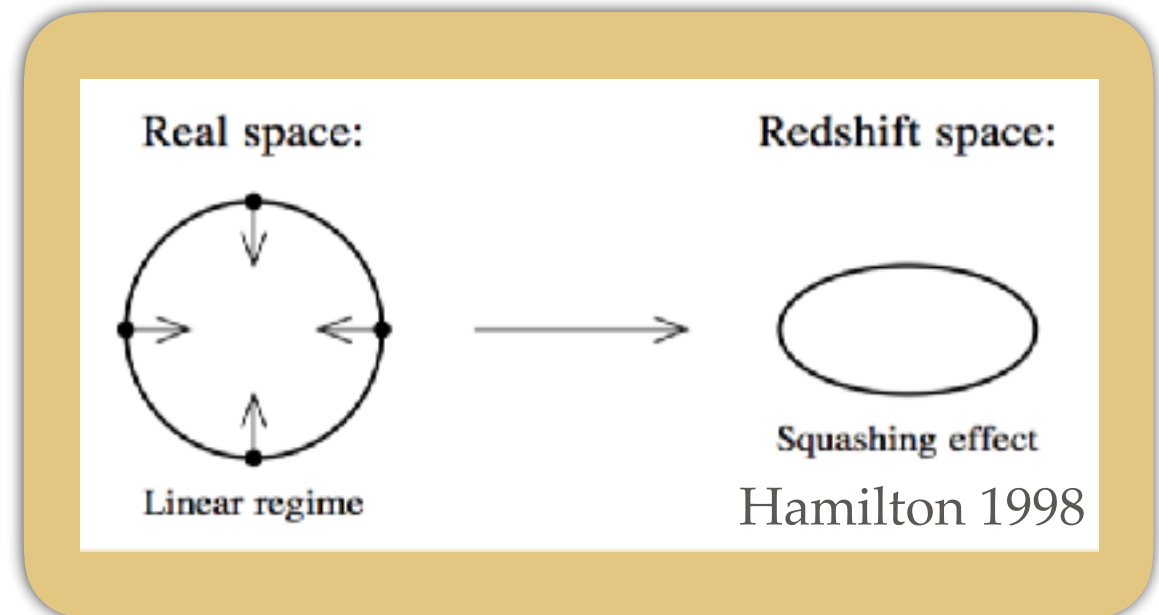
物質が高密度領域に集まる速度成分によって
クラスタリングが増幅される効果

銀河のパワースペクトル

$$P_g^s(k, \mu) = b^2 (1 + \beta\mu^2)^2 P(k)$$

$$P^s(k, \mu) = \sum_{l=0}^{\infty} P_l(k) \mathcal{L}_l(\mu)$$


$$P_l^s(k) = (2l + 1) \int_{-1}^1 \frac{d\mu}{2} P^s(k, \mu) \mathcal{L}_l(\mu)$$



Constraint from the linear theory

線形理論における μ 依存性からの $f(z)\sigma_8(z)$ の制限

線形理論では $f(z)$ と $\sigma_8(z)$ の縮退を解けない

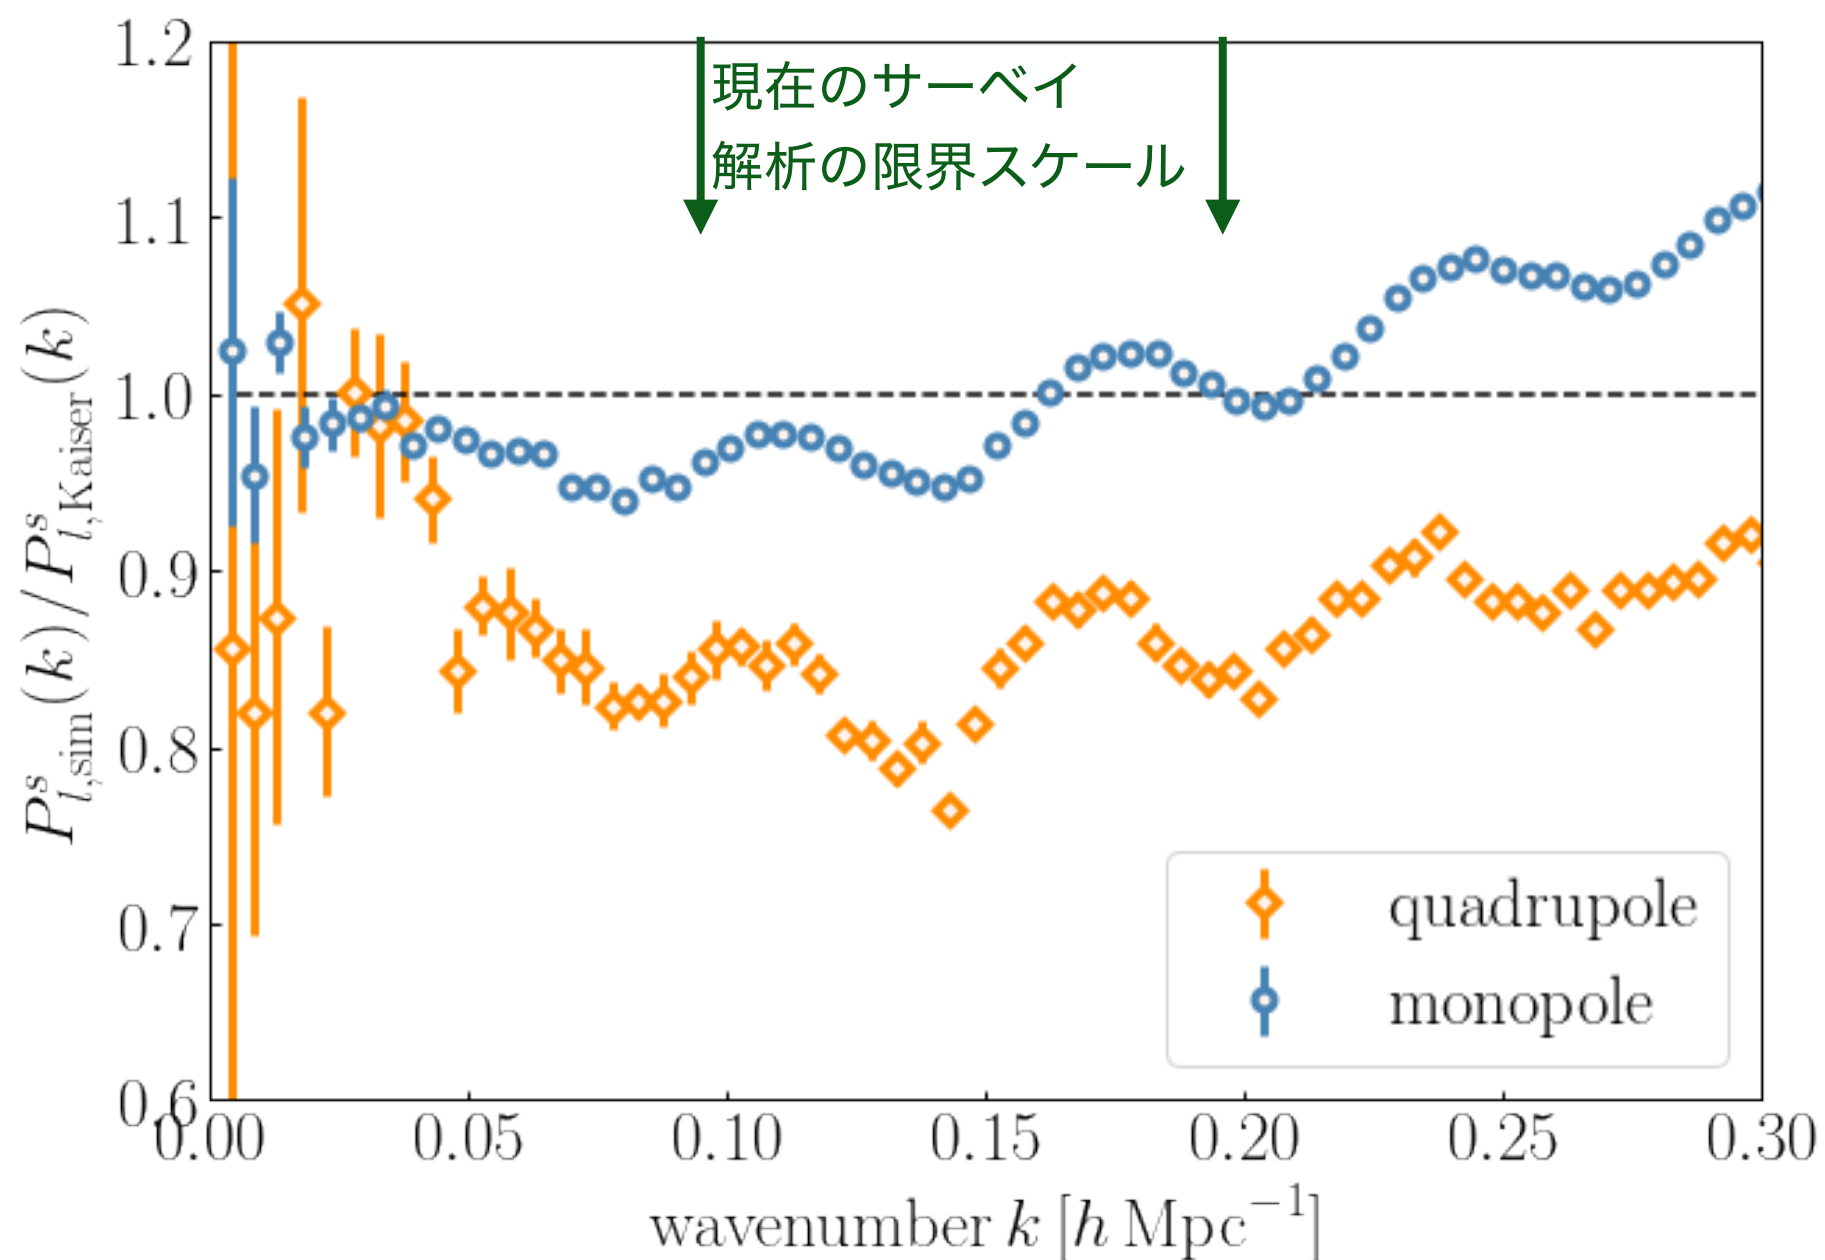


Failure of the linear model

赤方偏移空間でのクラスタリングは比較的大きなスケールで線形理論から逸脱する

(eg. Carlson et al, 2009, Okumura and Jing, 2011)

N体シミュレーションと線形理論との比較



Perturbative Approaches

赤方偏移空間クラスタリングの非線形効果

- real space – redshift space mapping の非線形性
- 物質密度場・速度場の非線形クラスタリング
- ハロースケールにおける物質の random motion
- galaxy bias

解析的模型：

非線形摂動論による模型構築

(eg. Taruya et al., 2010)

$$P^s(\mathbf{k}) = \int d^3r e^{i\mathbf{k}\cdot\mathbf{r}} \left\langle \frac{e^{-ik\mu\Delta u_z} [\delta(\mathbf{x}) + \nabla_z u_z(\mathbf{x})] [\delta(\mathbf{x}') + \nabla_z u_z(\mathbf{x}')] }{\sim \delta^4 \text{ までの Leading term をとる}} \right\rangle$$



$$P^s(\mathbf{k}) \simeq [P_{\delta\delta}(k) + 2\mu^2 P_{\delta\theta}(k) + \mu^4 P_{\theta\theta}(k) + A(\mathbf{k}) + B(\mathbf{k})] \exp(-k^2 \mu^2 \sigma_v^2)$$

streaming motion

(この模型ではフリーパラメータ)

Perturbative Approaches

赤方偏移空間クラスタリングの非線形効果

- real space – redshift space mapping の非線形性
- 物質密度場・速度場の非線形クラスタリング
- ハロースケールにおける物質の random motion
- galaxy bias

解析的模型：

非線形摂動論による模型構築

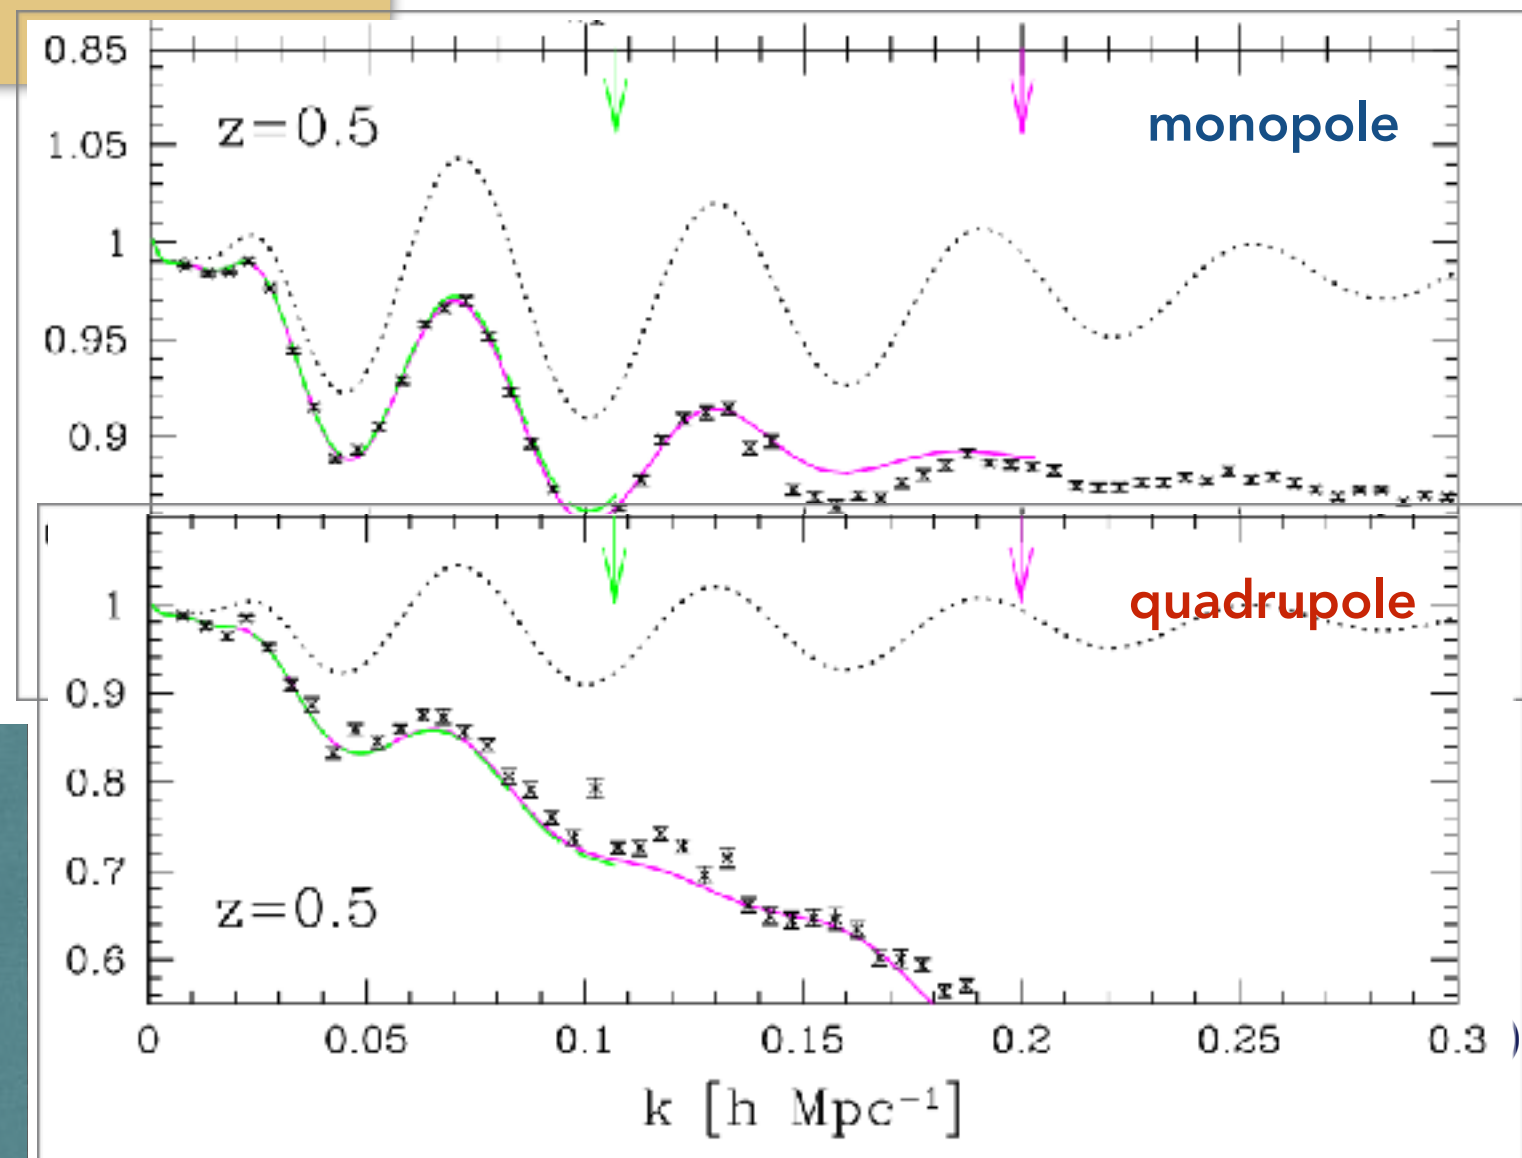
(eg. Taruya et al., 2010)

- σ_v 、バイアスなどのフリーパラメータ
- ハロースケールにおける single streaming の破綻

非線形スケール ($k > 0.2 \text{ h/Mpc}$) で
精密な解析的模型の構築が困難




N体シミュレーションによる模型構築

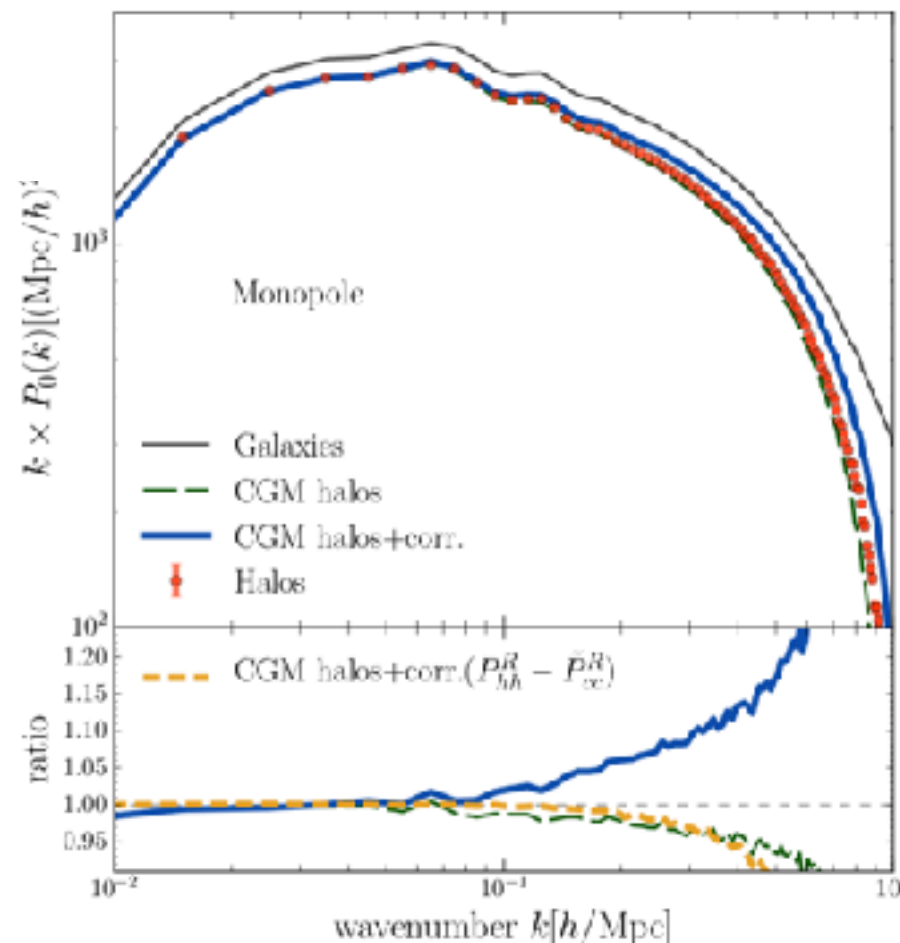


Dark Matter Halo – Galaxy


- 銀河形成の理解の不足
→ 第一原理からの銀河クラスタリングの予言は困難
- 重力進化で生成が可能なダークマターハローのクラスタリングの模型を作って銀河と結びつける
- eg. halo reconstruction (Okumura et al. 2017)



Hikage et al. 2012



Okumura et al. 2017



Dark Emulator (led by Nishimichi-san)

ダークマターハローの統計的性質の宇宙論+赤方偏移+ハロー質量閾値依存性を
N体シミュレーションに基づいてモデル化する

多数のパラメータの値に対するシミュレーションデータを機械学習的な回帰手法で
パラメータ空間上で補間

摂動論によらずにシミュレーションからモデルを作ること、multi-streaming effect,
halo biasを自動的に含んだ模型構築ができ、サーベイデータのもつ非線形領域の
宇宙論情報をより多く抽出できる

将来の銀河分光サーベイのデータ解析に向けた理論模型整備

Dark Emulator

Gadget2 $N = 2048^3$
(Springel, 2005) $L = 2\text{Gpc}/h$


6次元宇宙論パラメータ空間から
Planck 2015を中心に60→57個

約20個ずつが1つの偏りのない
サンプルセット

(Optimal Sliced Latin Hypercube design,
Ba et al, 2015)

$0 \leq z < 1.5$ から21個の赤方偏移

$$\mathbf{p}_{\text{cosmo}} = \{\Omega_b h^2, \Omega_c h^2, \Omega_{de}, \ln[10^{10} A_s], n_s, w\}$$



広い宇宙論パラメータ+赤方偏移のパラメータ空間の
領域の中から偏りなくハローのパワースペクトルを測定

Learning: Gaussian process

本研究で用いた多次元空間の離散データ点の補間

ガウス過程


... 確率変数の集合、そのうちどの有限個をとってもガウス分布

- ・ 入力ベクトルとそれに対する出力値が与えられたデータ

$$\mathbf{x}_n \longrightarrow f(\mathbf{x}_n)$$

- ・ データの出力 $f(\mathbf{x}_n)$ を多変量ガウス分布に従う確率変数と見なす

➡ 出力値の集まり $\{f(\mathbf{x}_n)\}$ が**ガウス過程**になっていると思う



ガウス分布の共分散を指定するcovariance function

$$k(\mathbf{x}, \mathbf{x}' | \boldsymbol{\theta})$$

: ハイパーパラメータ $\boldsymbol{\theta} = \{\theta_0, \theta_1, \dots\}$

でパラメトライズされる入力ベクトルの関数

ガウス過程が学習データを生成する

➡ 尤度関数を最大化するようなハイパーパラメータを求める (= 「学習」)

Gaussian Process for Power Spectrum

input

7次元パラメータベクトル $\{\mathbf{p}_{\text{cosmo}}, z\}$

$$\mathbf{p}_{\text{cosmo}} = \{\Omega_b h^2, \Omega_c h^2, \Omega_{de}, \ln[10^{10} A_s], n_s, w\}$$

cosmology
38

×



redshift
21

parameter range


$0.0211 \leq \Omega_b h^2 \leq 0.0234$	$0.108 \leq \Omega_c h^2 \leq 0.132$
$0.554 \leq \Omega_\Lambda \leq 0.82$	$2.5 \leq \ln(10^{10} A_s) \leq 3.7$
$0.916 \leq n_s \leq 1.012$	$-1.194 \leq w_{de} \leq -0.802$

output

$P_0(k), P_2(k)$ をB-spline fit、7個の係数に対して別々にガウス過程を作る



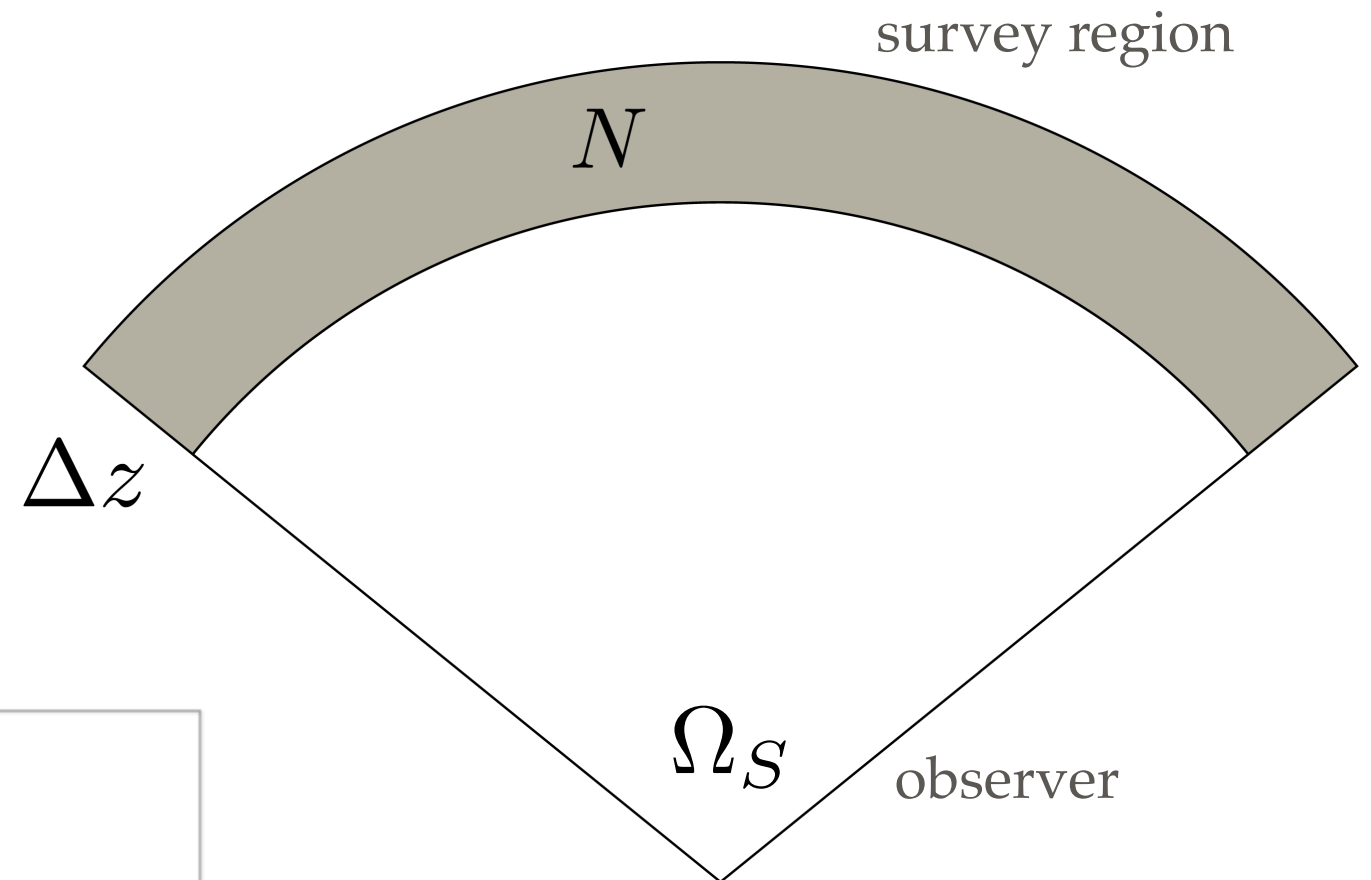
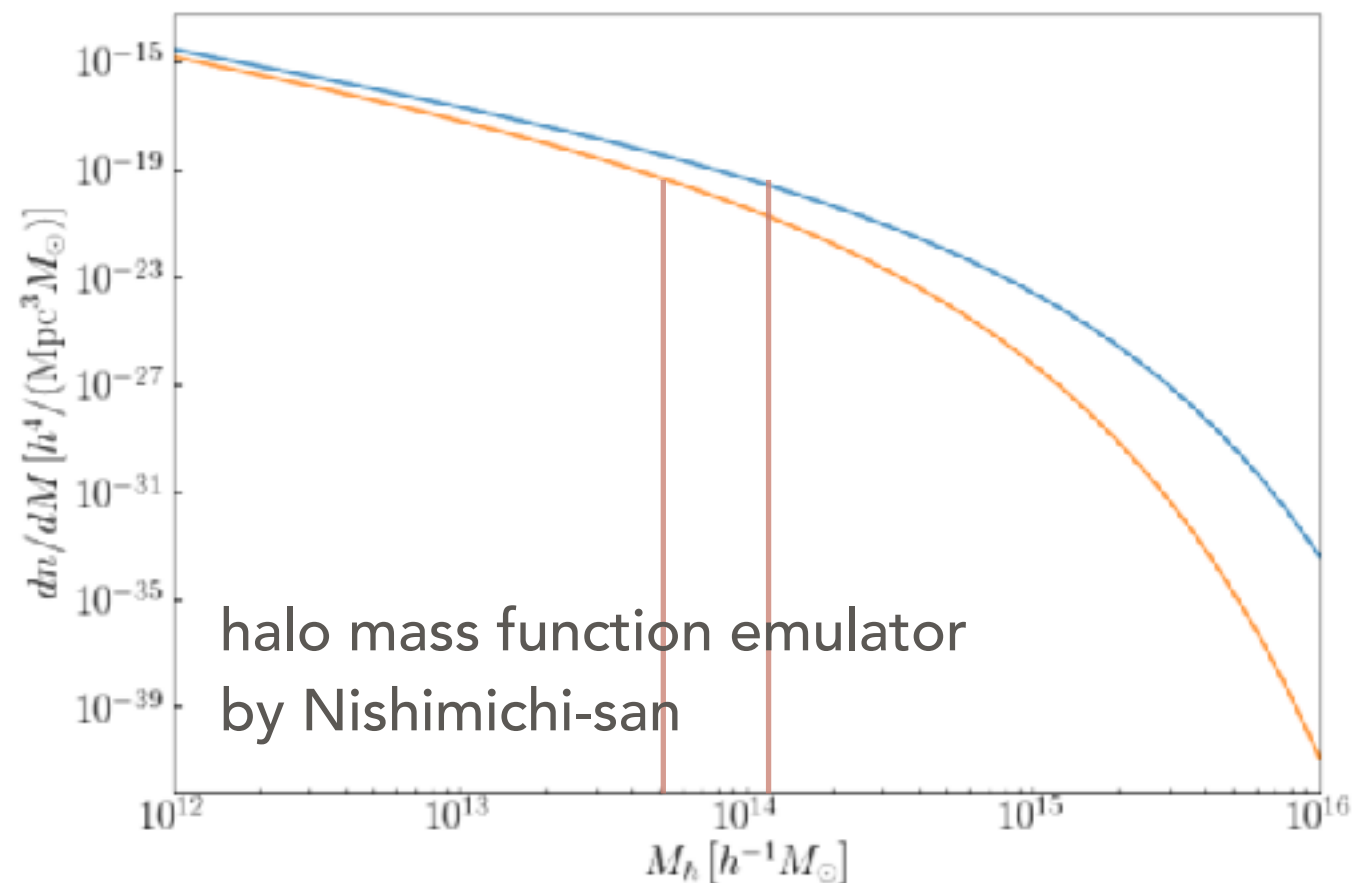
次元削減



Halo Selection

ハロー選択の基準


- 分光サーベイでの直接観測量
 Δz 、 Ω_s 、 N を固定
- Δz 、 Ω_s 、 N を変えない
ように各宇宙論でハローの
質量閾値を決める



Power Spectrum Emulator

構築されたエミュレータ

ハローの赤方偏移空間におけるパワースペクトルのmonopoleおよびquadrupoleの
宇宙論+赤方偏移依存性を高速に予言するモデル





```
In [1]: %pylab inline
import sys
sys.path.append('/Users/yosuke.kobayashi/rsd/Emulator/halo_power/python')
```

Populating the interactive namespace from numpy and matplotlib

```
In [2]: from halo_power import P_l_emu
```

```
In [3]: p0 = P_l_emu(0)
p2 = P_l_emu(2)
```

```
In [4]: cparam = np.array([0.02225,0.1198,0.6844,3.094,0.9645,-1])
z = 0.57
k = [0.05,0.10,0.15,0.20,0.25,0.30,0.35,0.40]
```

```
In [5]: p0(cparam, z, k)
```

```
Out[5]: array([[ 24595.28342627,  11148.09694812,   6124.10909976,   3888.46305176,
                2721.4822656 ,   2006.58288423,   1526.55430547,   1192.15457141])
```

```
In [6]: p2(cparam, z, k)
```

```
Out[6]: array([[ 13429.65726745,   5826.04804862,   3179.51523164,   2015.38609347,
                1387.91107644,   991.09468541,   722.59774346,   531.04596224])
```

```
In [1]: %pylab inline
import sys
sys.path.append('/Users/yosuke.kobayashi/rsd/Emulator/halo_power/python')

Populating the interactive namespace from numpy and matplotlib
```

モジュールのインポート

```
In [2]: from halo_power import P_l_emu
```

エミュレータクラスの
インスタンス

```
In [3]: p0 = P_l_emu(0)
p2 = P_l_emu(2)
```

```
In [4]: cparam = np.array([0.02225,0.1198,0.6844,3.094,0.9645,-1])
z = 0.57
k = [0.05,0.10,0.15,0.20,0.25,0.30,0.35,0.40]
```

宇宙論パラメータ、z、k

```
In [5]: p0(cparam, z, k)
```

```
Out[5]: array([ 24595.28342627, 11148.09694812, 6124.10909976, 3888.46305176,
                2721.4822656 , 2006.58288423, 1526.55430547, 1192.15457141])
```

```
In [6]: p2(cparam, z, k)
```

P0, P2 を出力 (~1 msec)

```
Out[6]: array([ 13429.65726745, 5826.04804862, 3179.51523164, 2015.38609347,
                1387.91107644, 991.09468541, 722.59774346, 531.04596224])
```

Validation of the Emulator

検証データの宇宙論19個それぞれについて

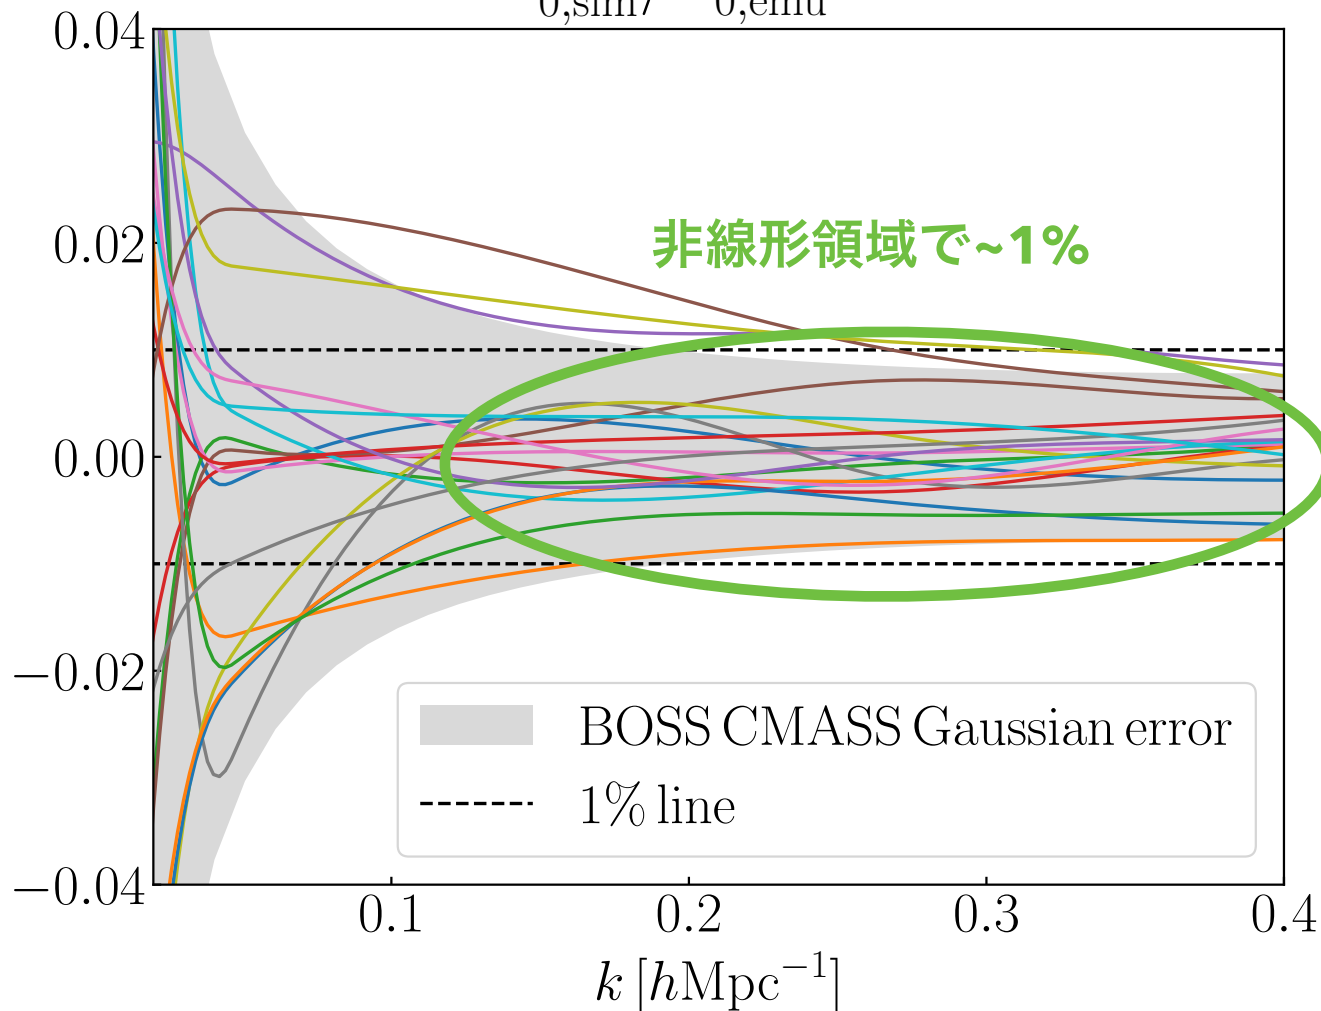
シミュレーションデータ(+ B-spline fit)

38宇宙論を学習して作ったエミュレータによる予言

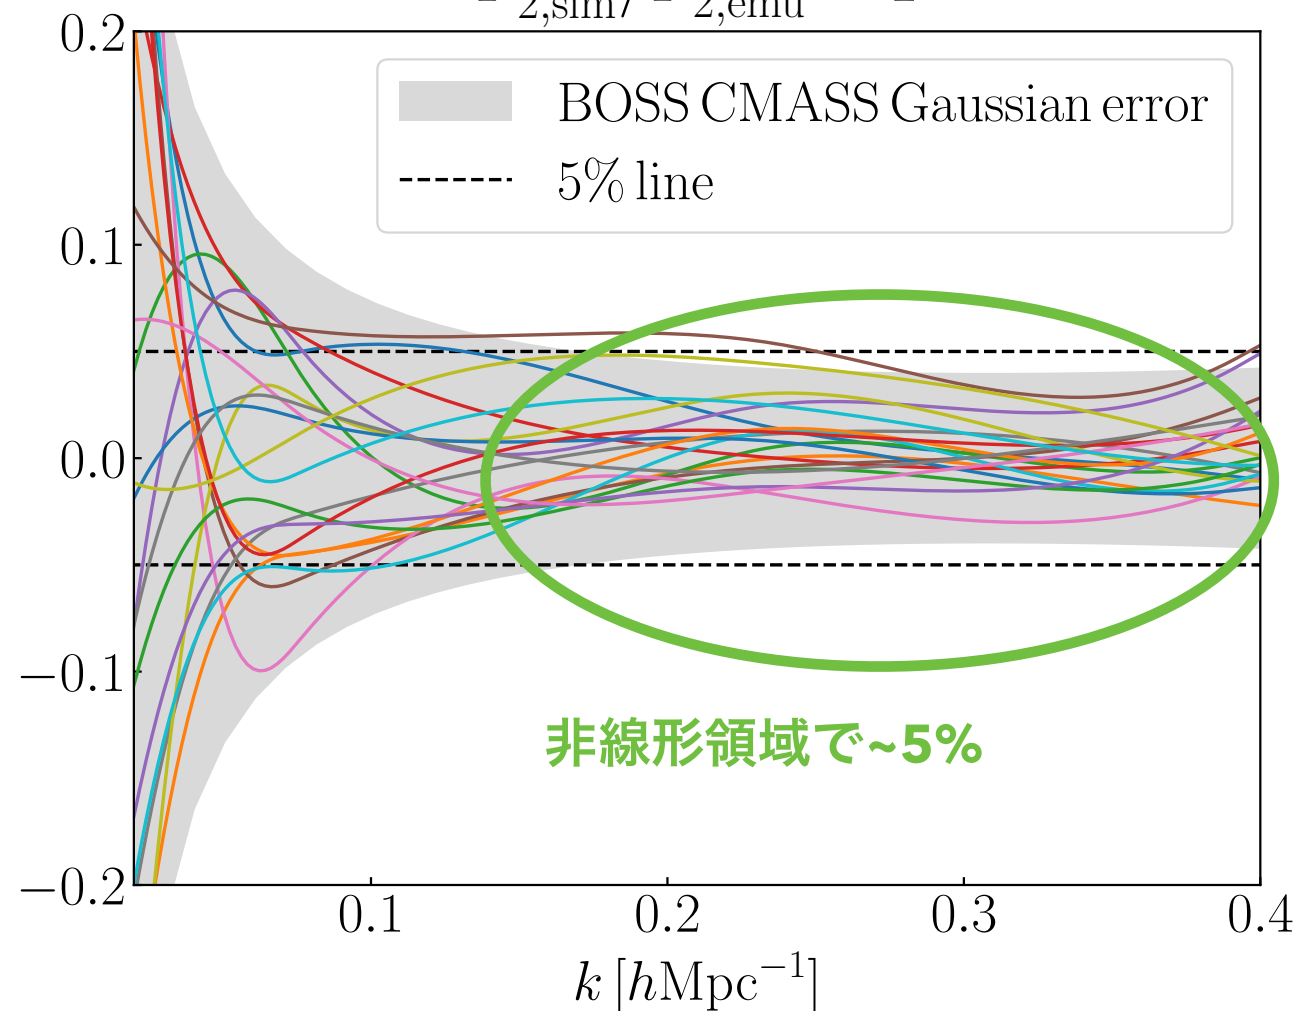
- 1

$$n_{\text{fid}} = 10^{-3} [h^3 \text{Mpc}^{-3}] \quad V = 2 [\text{Gpch}]^3$$

$$P_{0,\text{sim}}^s / P_{0,\text{emu}}^s - 1$$



$$P_{2,\text{sim}}^s / P_{2,\text{emu}}^s - 1$$



Cosmological Information in the Nonlinear RSD

$P_2(k)$ (非等方成分のLeading order)

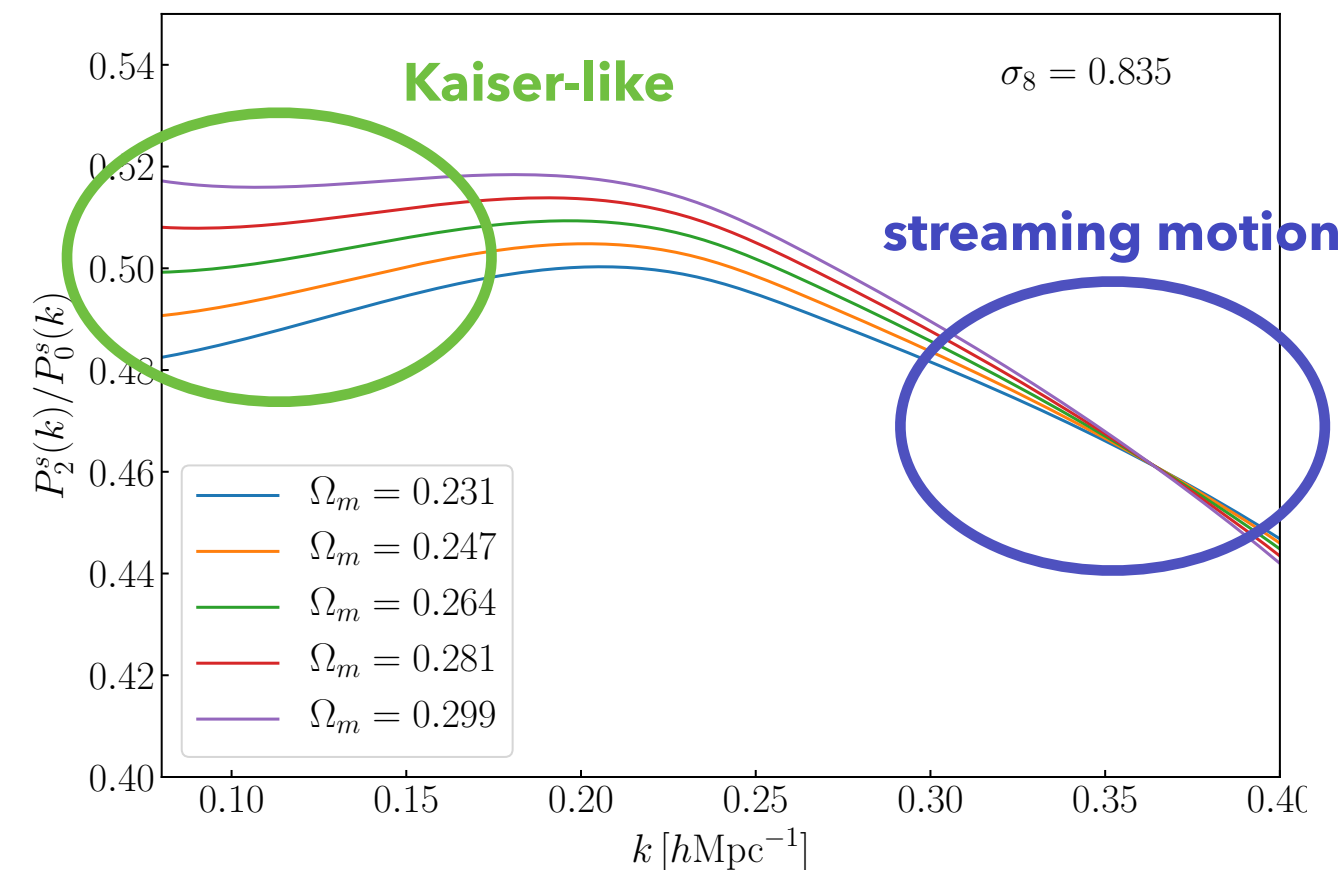
$P_0(k)$ (等方成分)

- 線形理論ではスケール不変

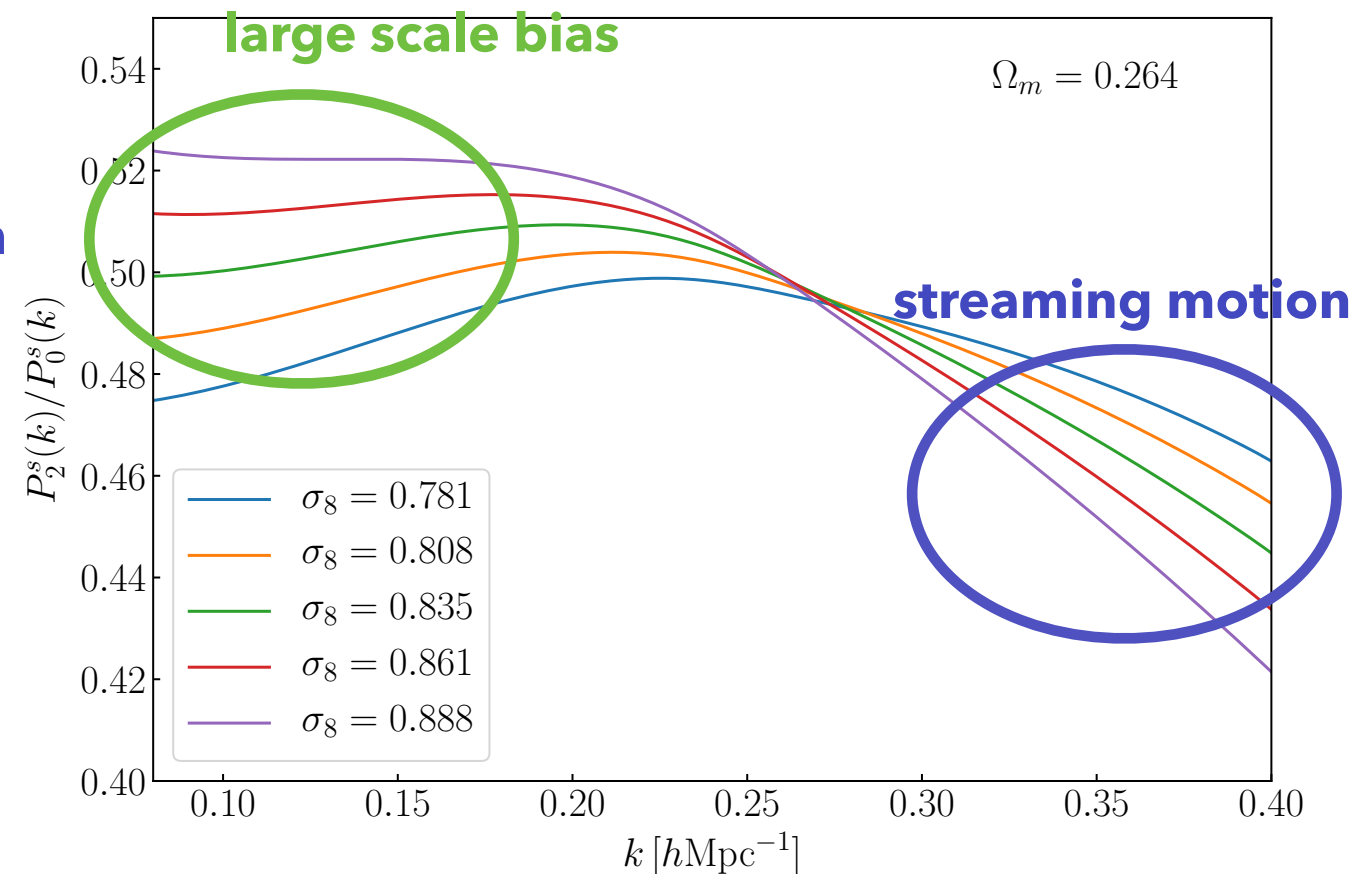
$$\frac{P_2^s(k)}{P_0^s(k)} \xrightarrow{k \rightarrow 0} \frac{\frac{4}{3}\beta + \frac{4}{7}\beta^2}{1 + \frac{2}{3}\beta + \frac{1}{5}\beta^2}$$

$$\beta = f/b$$

Ω_m dependence




σ_8 dependence



- 非線形RSDの宇宙論情報の豊富さを直接的に表現


Scale dependence of the Nonlinear RSD

- エミュレータが予言する $k^3 P_0^s(k)$ のスケール毎の $\Omega_m - \sigma_8$ 依存性
- ★はPlanck 2015
- $z = 0.57, n_{\text{fid}} = 10^{-3} [\text{h/Mpc}]^3$




Scale dependence of the Nonlinear RSD

- エミュレータが予言する $k^3 P_0^s(k)$ のスケール毎の $\Omega_m - \sigma_8$ 依存性
- ★はPlanck 2015
- $z = 0.57, n_{\text{fid}} = 10^{-3} [\text{h}/\text{Mpc}]^3$




Scale dependence of the Nonlinear RSD

- エミュレータが予言する $k^3 P_0^s(k)$ のスケール毎の $\Omega_m - \sigma_8$ 依存性
- ★はPlanck 2015
- $z = 0.57, n_{\text{fid}} = 10^{-3} [\text{h/Mpc}]^3$




Scale dependence of the Nonlinear RSD

- エミュレータが予言する $k^3 P_0^s(k)$ のスケール毎の $\Omega_m - \sigma_8$ 依存性
- ★はPlanck 2015
- $z = 0.57, n_{\text{fid}} = 10^{-3} [\text{h}/\text{Mpc}]^3$




Scale dependence of the Nonlinear RSD

- エミュレータが予言する $k^3 P_2^s(k)$ のスケール毎の $\Omega_m - \sigma_8$ 依存性
- ★はPlanck 2015
- $z = 0.57, n_{\text{fid}} = 10^{-3} [\text{h}/\text{Mpc}]^3$




Scale dependence of the Nonlinear RSD

- エミュレータが予言する $k^3 P_2^s(k)$ のスケール毎の $\Omega_m - \sigma_8$ 依存性
- ★はPlanck 2015
- $z = 0.57, n_{\text{fid}} = 10^{-3} [\text{h}/\text{Mpc}]^3$




Scale dependence of the Nonlinear RSD

- エミュレータが予言する $k^3 P_2^s(k)$ のスケール毎の $\Omega_m - \sigma_8$ 依存性
- ★はPlanck 2015
- $z = 0.57, n_{\text{fid}} = 10^{-3} [\text{h}/\text{Mpc}]^3$



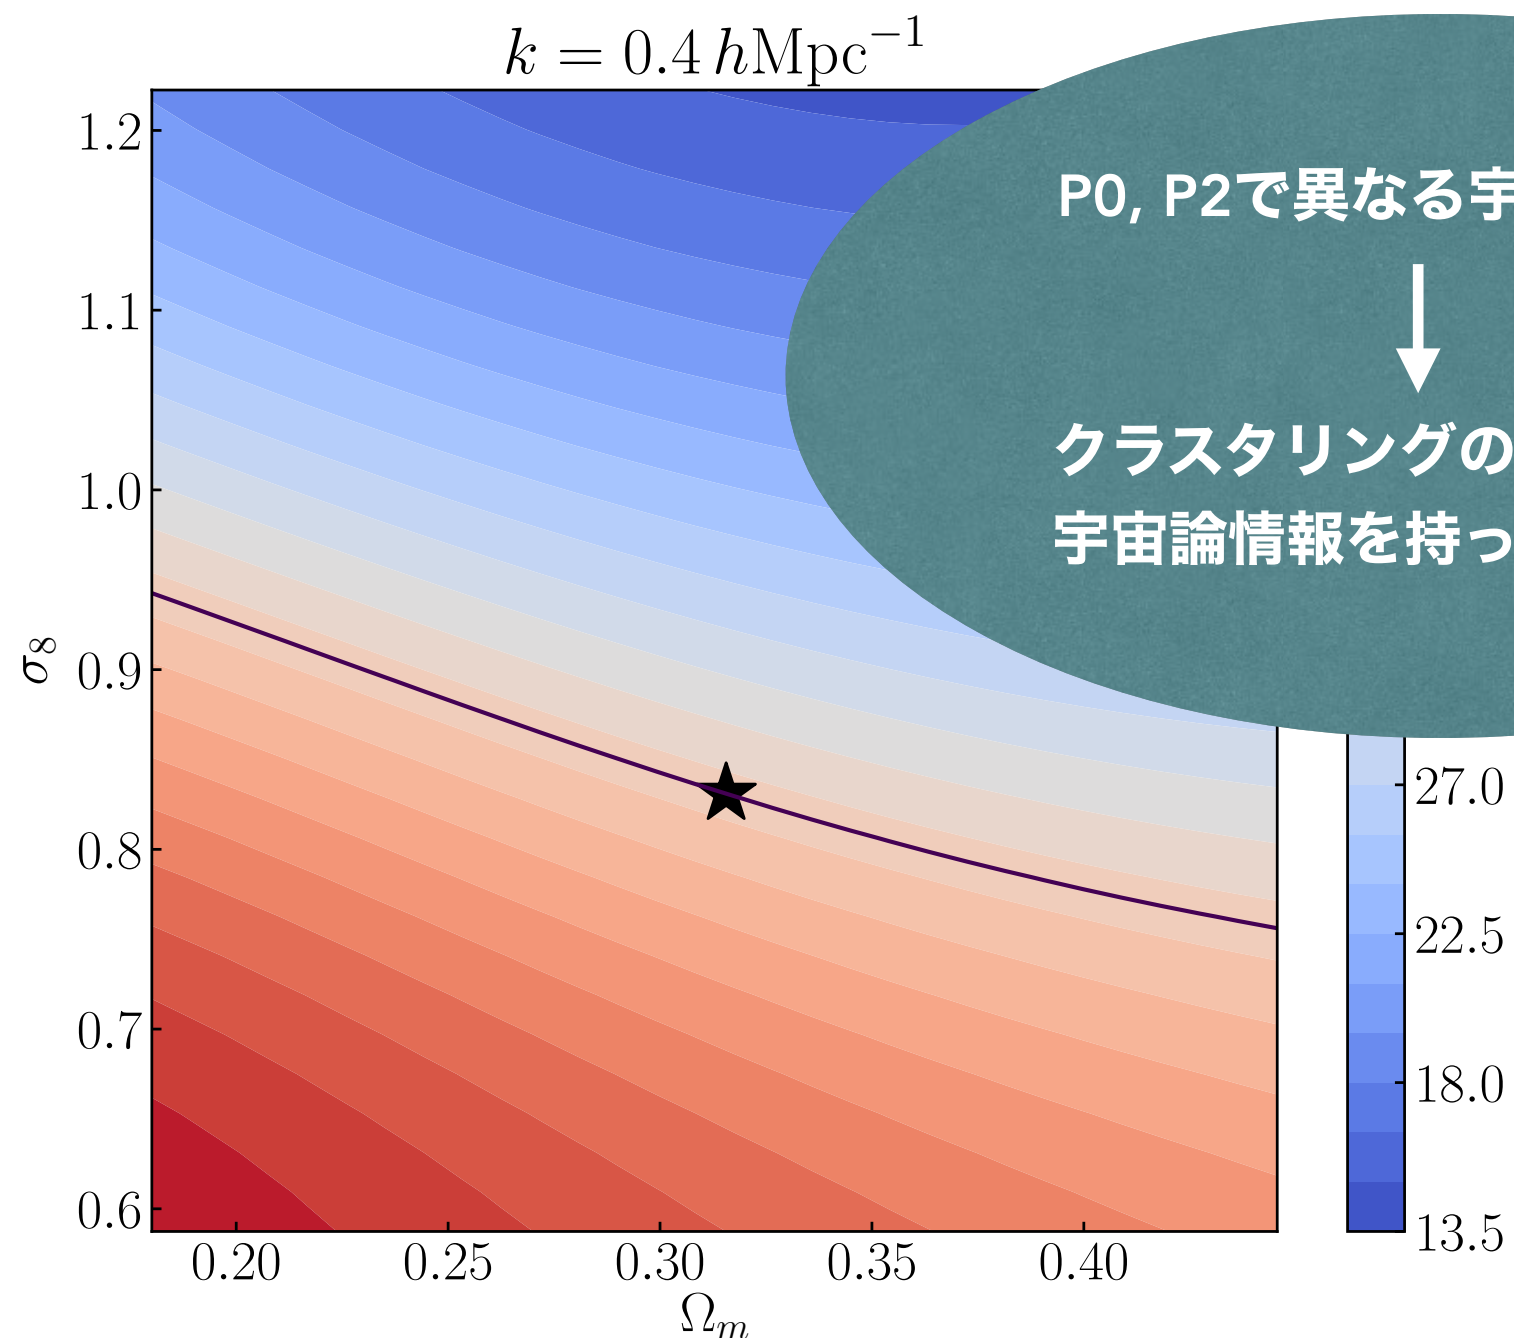
Scale dependence of the Nonlinear RSD

- エミュレータが予言する $k^3 P_2^s(k)$ のスケール毎の $\Omega_m - \sigma_8$ 依存性
- ★はPlanck 2015
- $z = 0.57, n_{\text{fid}} = 10^{-3} [\text{h/Mpc}]^3$




Scale dependence of the Nonlinear RSD

- エミュレータが予言する $k^3 P_2^s(k)$ のスケール毎の $\Omega_m - \sigma_8$ 依存性
- ★はPlanck 2015
- $z = 0.57, n_{\text{fid}} = 10^{-3} [\text{h}/\text{Mpc}]^3$




Fisher Forecasts

- $k_{\min} = 0.02 h\text{Mpc}^{-1}$, $k_{\max} = \{0.1, 0.2, 0.3\} h\text{Mpc}^{-1}$ でP0を用いてFisher解析
- $V = 2[\text{Gpch}]^3 \sim \text{BOSS CMASS}$
- **非線形性**の情報で宇宙論パラメータの縮退が緩和




Fisher Forecasts

- $k_{\min} = 0.02 h\text{Mpc}^{-1}$, $k_{\max} = \{0.1, 0.2, 0.3\} h\text{Mpc}^{-1}$ でP0を用いてFisher解析
- $V = 2[\text{Gpch}]^3 \sim \text{BOSS CMASS}$
- **非線形性**の情報で宇宙論パラメータの縮退が緩和

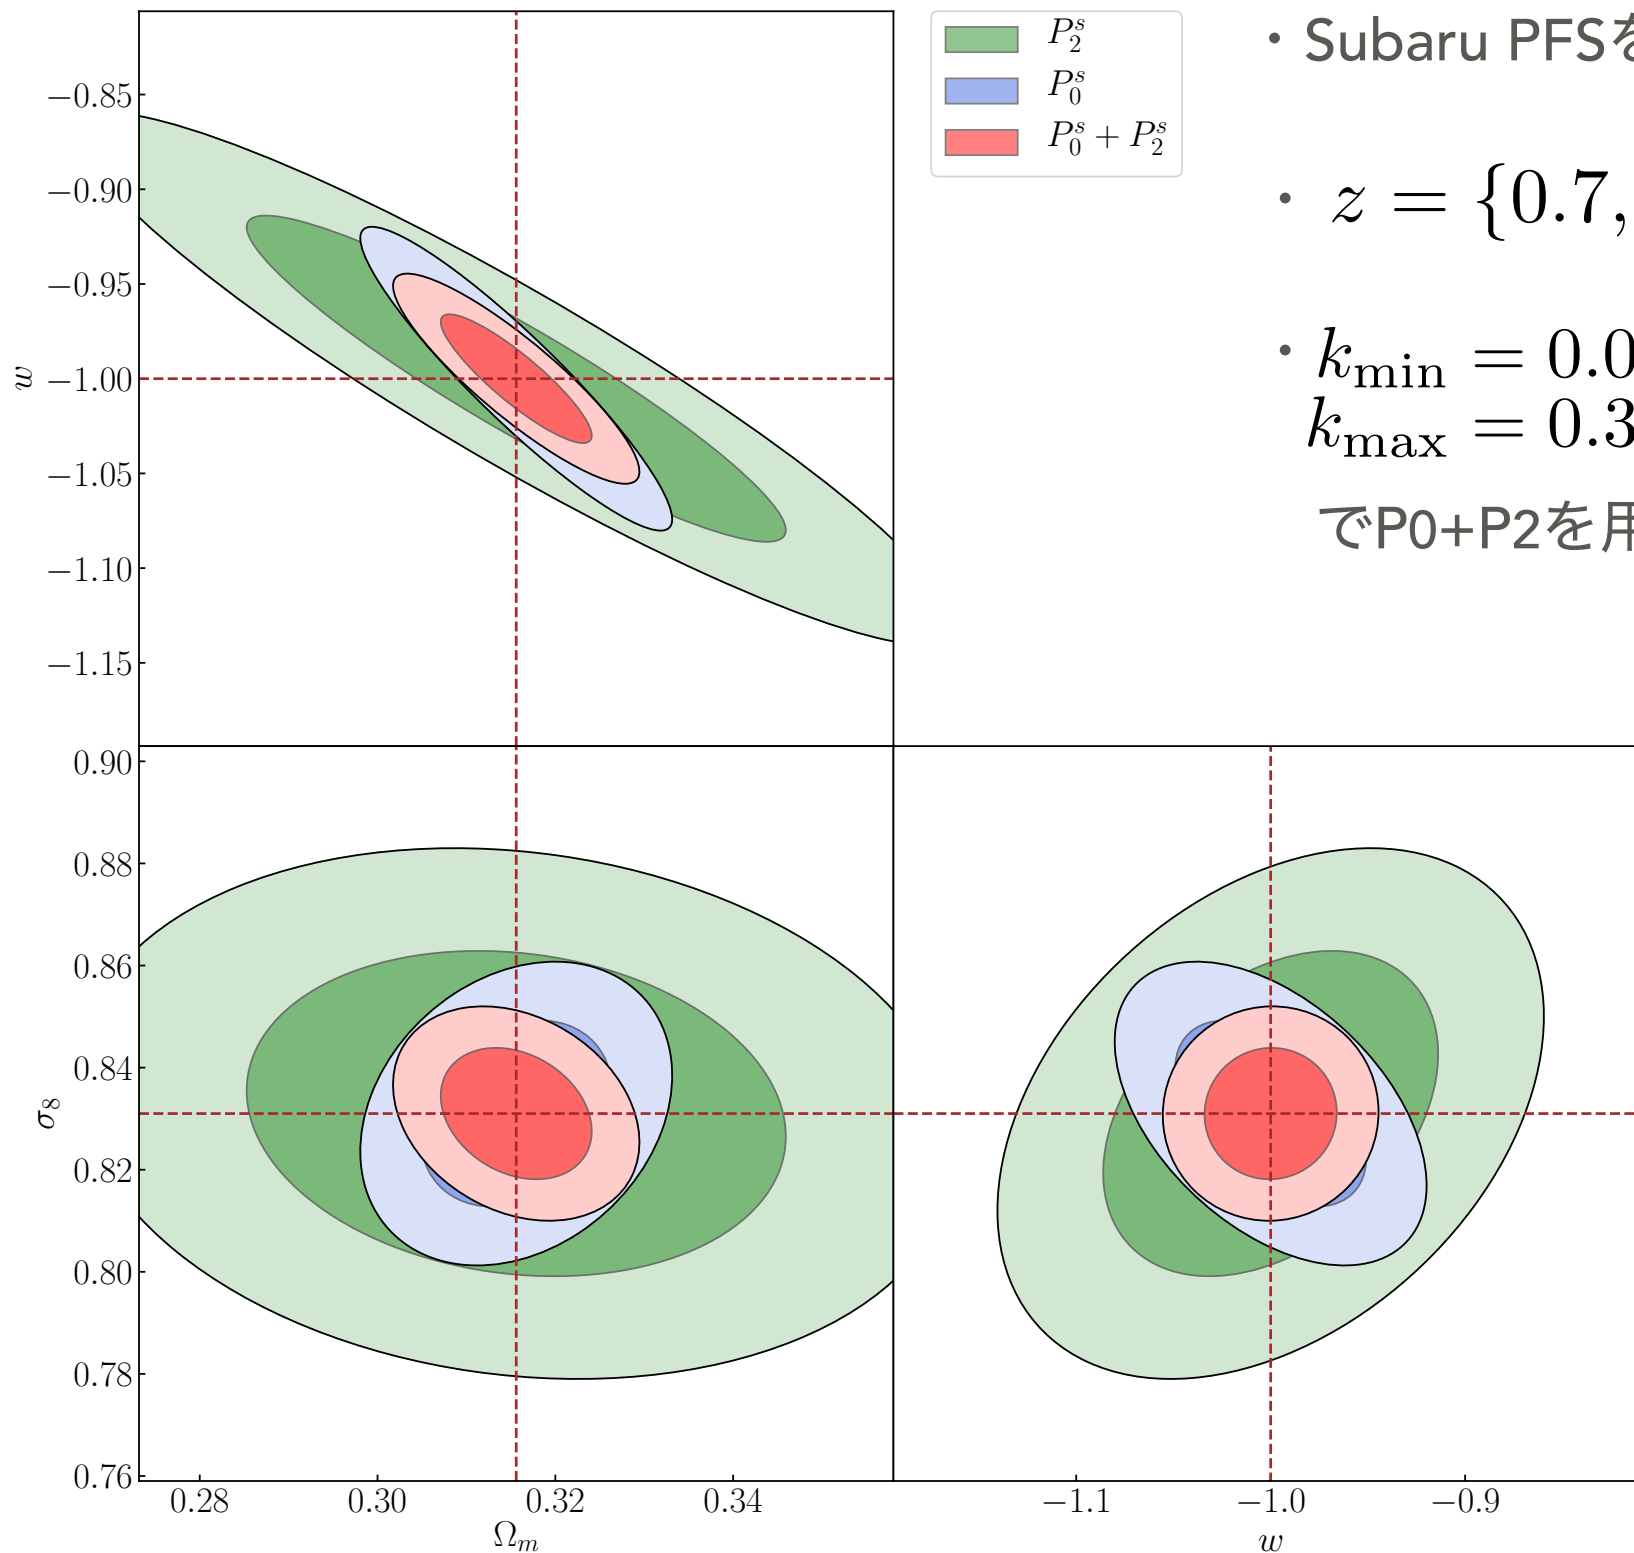


Fisher Forecasts

- $k_{\min} = 0.02 h\text{Mpc}^{-1}$, $k_{\max} = \{0.1, 0.2, 0.3\} h\text{Mpc}^{-1}$ でP0+P2を用いてFisher解析
- $V = 2[\text{Gpch}]^3 \sim \text{BOSS CMASS}$
- **非線形性**の情報で宇宙論パラメータの縮退が緩和



Fisher Forecasts: Subaru PFS



• Subaru PFSを想定したFisher forecast

• $z = \{0.7, 0.9, 1.1, 1.3\}$ の4つのredshift bin

• $k_{\min} = 0.02 h\text{Mpc}^{-1}$
 $k_{\max} = 0.3 h\text{Mpc}^{-1}$

でP0+P2を用いてFisher解析

非等方性+非線形性で
宇宙論パラメータの
縮退が緩和することを
確認

Conclusion

- シミュレーション+ガウス過程で
 $k = 0.05 - 0.40 \text{ h/Mpc}$ において、ハローのmonopoleを~1%、quadrupoleを~5%
で高速に予言できるエミュレータが構成された
- 非線形monopole+quadrupoleにより、宇宙論パラメータの縮退が
効果的に解けることを確認：非線形性の持つ情報の豊富さ
- Subaru PFS など広視野・高精度銀河分光サーベイ
のもたらすクラスタリング情報の効果的な活用に寄与すると期待

Future Works

- 実際の観測データをエミュレータを用いて解析 (BOSS DR12など)
→ Halo reconstruction (Okumura et al., 2017) などとの併用による宇宙論情報の抽出
- 追加シミュレーションによるエミュレータの予言精度の向上
→ P4, Bispectrum ??