

赤方偏移空間における ハロークラスタリングのエミュレータ構築

東京大学 理学系研究科物理学専攻 M2

小林洋祐


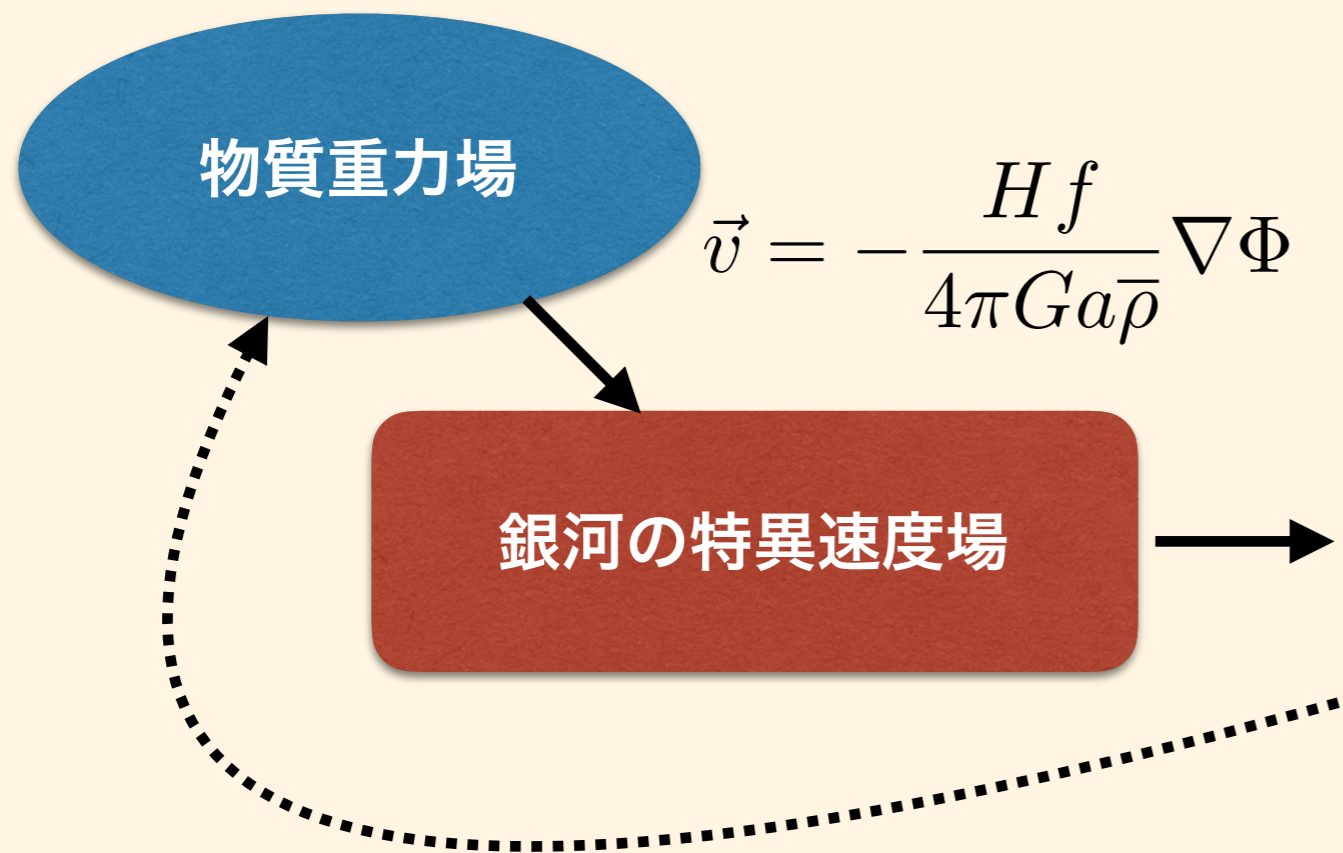
collaborated with
西道啓博 & 高田昌広

in Kavli IPMU

第6回観測的宇宙論ワークショップ@弘前大学

Clustering in Redshift Space

- 銀河分光サーベイで測定される銀河の赤方偏移 = **Hubble膨張** + **特異速度場の視線方向成分**
- 赤方偏移空間・・・視線方向に歪んだ非等方クラスタリング = 赤方偏移歪み



赤方偏移空間のクラスタリングの解析から
重力の情報が得られる

Reid et al. (2014)

Modeling of Clustering in Redshift Space

- 赤方偏移空間クラスタリングの理論モデリングの問題


'Finger-of-God' effect ... 小スケールでのビリアル速度

Galaxy bias ?? ... 銀河形成過程の不定性

- 非線形スケール ($k > 0.2 \text{ h/Mpc}$) で精密な解析的モデルの構築が困難
- N体シミュレーションに基づき、ハローのクラスタリングをモデリング

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

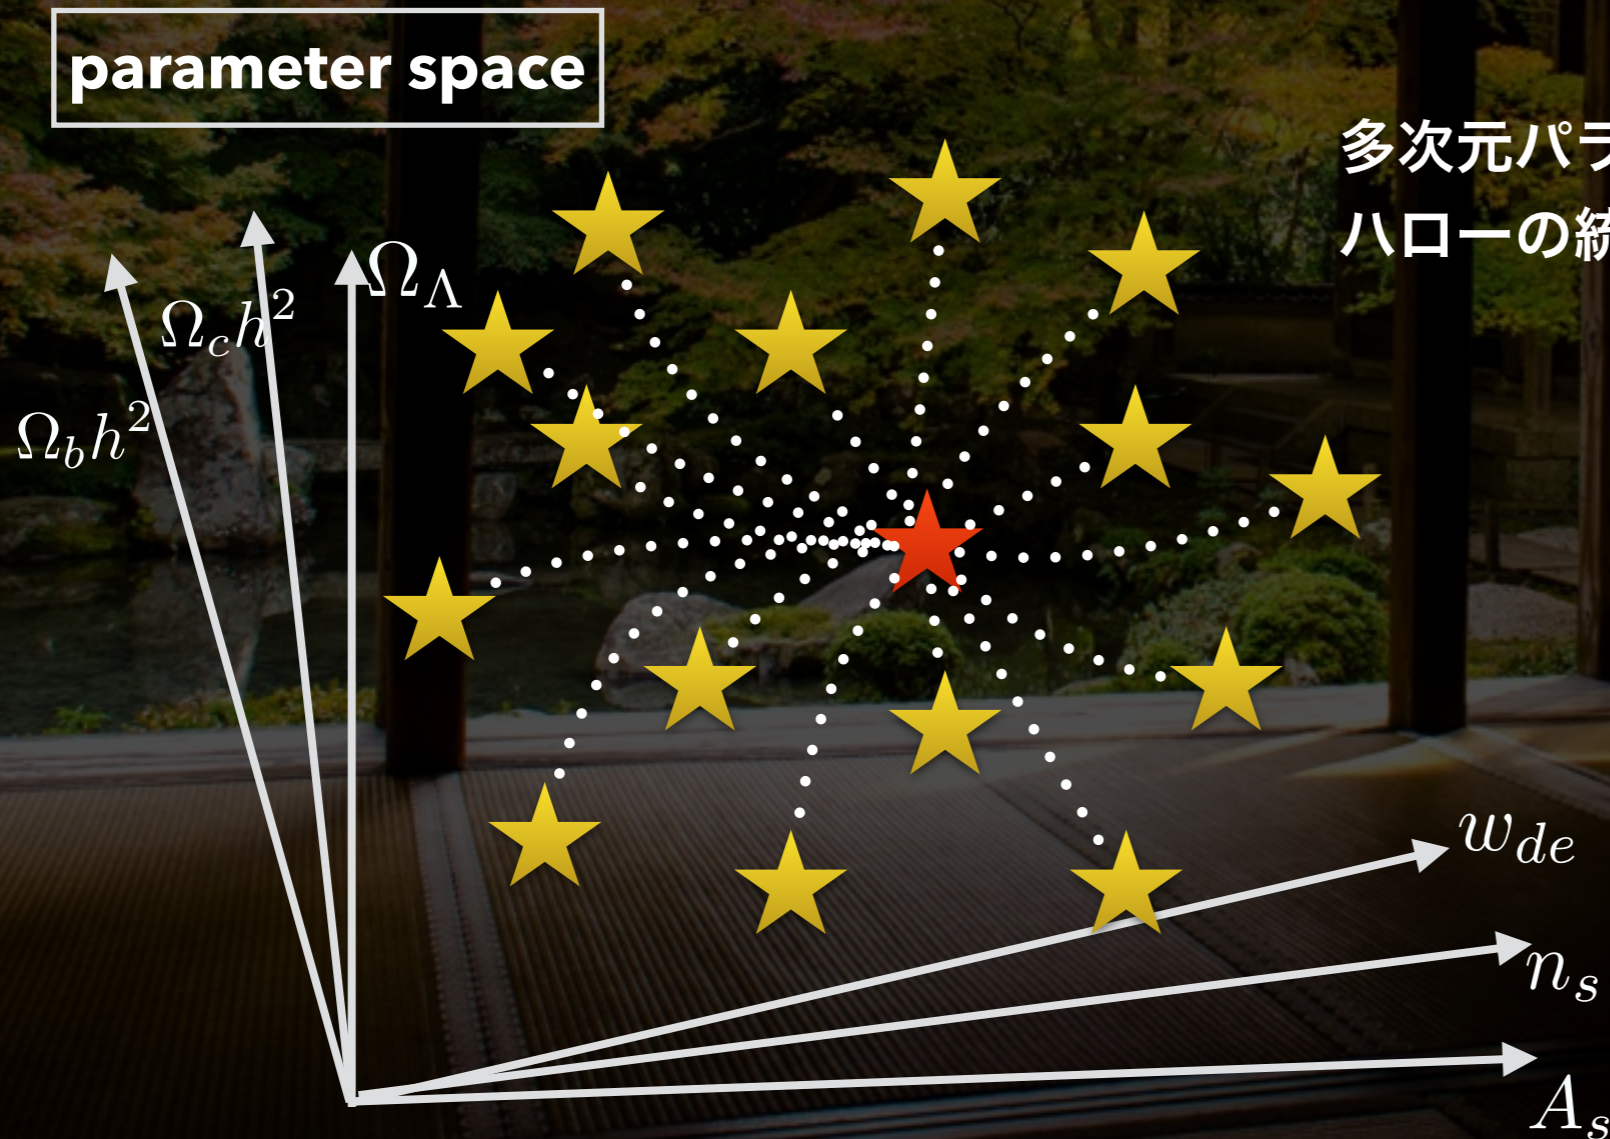
視線方向との角度依存性をLegendre展開、0次と2次のモーメントが主要観測量



Beutler et al. (2014)

Dark Emulator Project

- 東大 Kavli IPMU の西道さん主導
- 構造形成N体シミュレーション+機械学習によるハローの宇宙論統計量の理論模型構築



多次元パラメータ空間上の離散点で計算したハローの統計量を学習、他の点での値を予言





6D 宇宙論パラメータ、赤方偏移、ハロー最小質量に対する依存性をシミュレーションデータから読み取る

Dark Emulator Project

Optimal Sliced Latin Hypercube Design

(S. Ba et al, 2015)

- パラメータ空間から偏りなく効率的にサンプリング
- 最近傍点との距離の総和を最大化するように各パラメータの値を組み合わせる

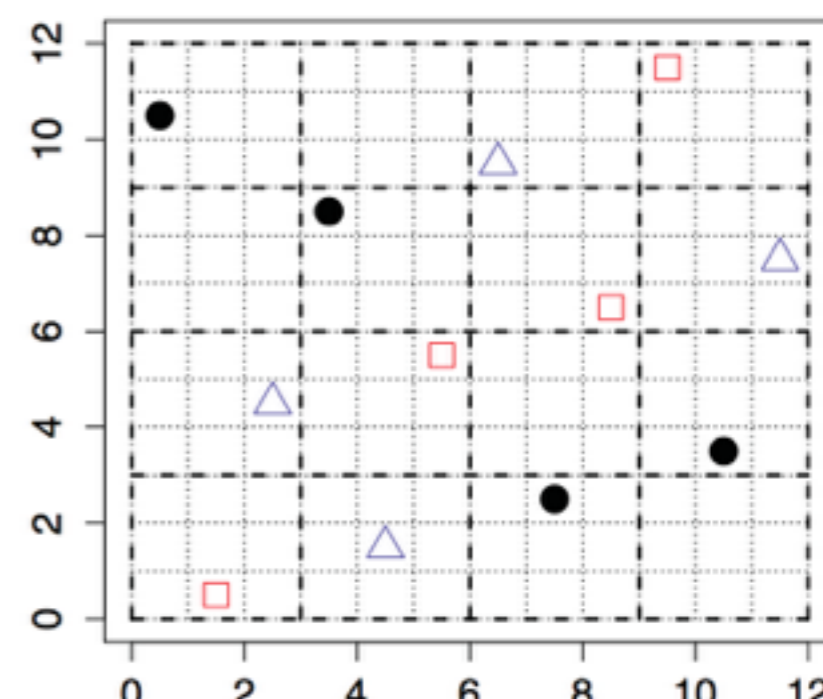





Dark Emulator Project

Optimal Sliced Latin Hypercube Design

(S. Ba et al, 2015)

- パラメータ空間から偏りなく効率的にサンプリング
- 最近傍点との距離の総和を最大化するように各パラメータの値を組み合わせる







Dark Emulator Project

Optimal Sliced Latin Hypercube Design

(S. Ba et al, 2015)

- パラメータ空間から偏りなく効率的にサンプリング
- 最近傍点との距離の総和を最大化するように各パラメータの値を組み合わせる




Halo Power Spectrum Emulator

研究

... a part of "Dark Emulator Project"

- ハローの $P_0(k)$, $P_2(k)$ の
宇宙論パラメータ + 赤方偏移 + ハローの質量閾値
に対する依存性を予言するモデル (エミュレータ) を構築する



宇宙論パラメータを変えても
シミュレーションし直すこと
なくパワースペクトルの理論
値を計算できる

Gaussian Process Regression

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

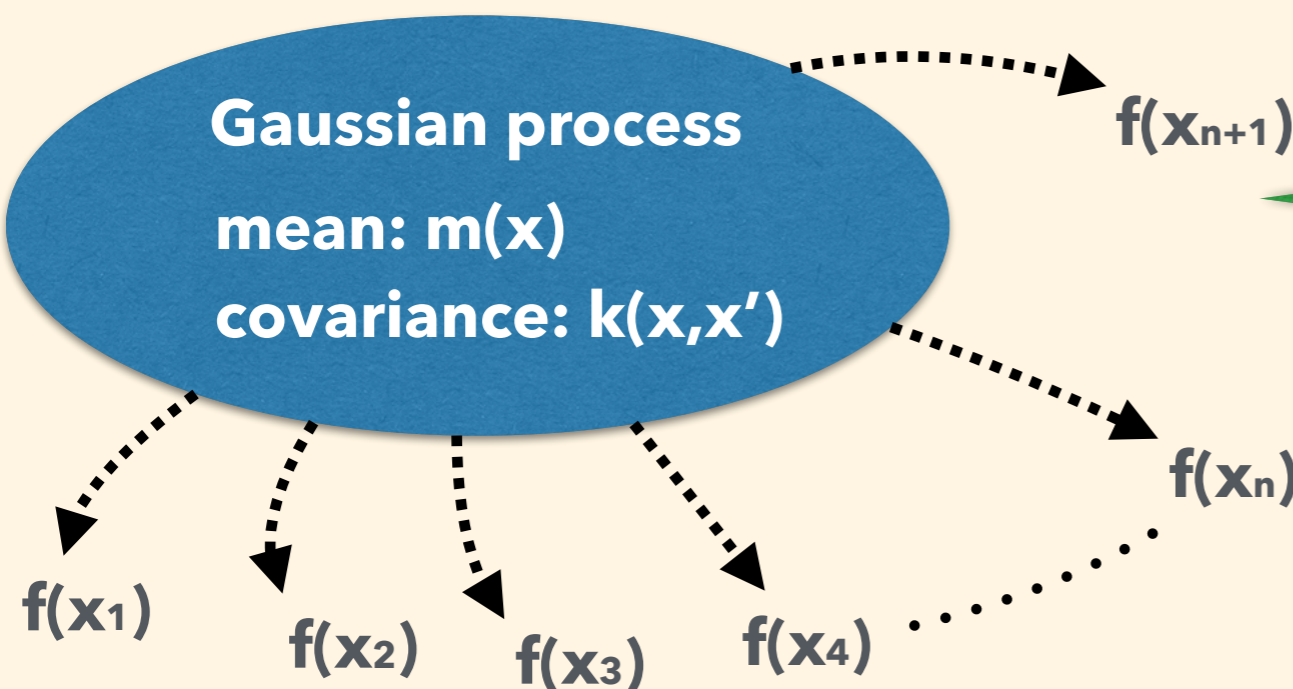
cf. Rasmussen & Williams (2006)

- 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



n個のデータの傾向から
ガウス過程を最適化 (=学習)
n+1個目の値を予測

Gaussian Process for Power Spectrum

input

7D パラメータ (\mathbf{p}_{cosmo}, z)

$$\mathbf{p}_{cosmo} = (\Omega_b h^2, \Omega_c h^2, \Omega_\Lambda, \ln(10^{10} A_s), n_s, w_{de})$$

σ_8

cosmology
60

×

redshift
21

parameter range

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

Gaussian Process for Power Spectrum

input

7D パラメータ (\mathbf{p}_{cosmo}, z)

σ_8

$$\mathbf{p}_{cosmo} = (\Omega_b h^2, \Omega_c h^2, \Omega_\Lambda, \ln(10^{10} A_s), n_s, w_{de})$$

cosmology
60

×

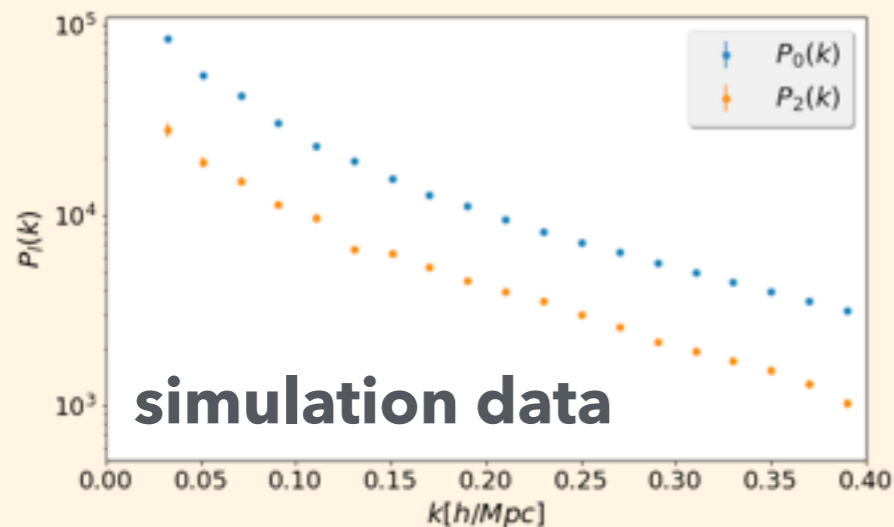
redshift
21

parameter range

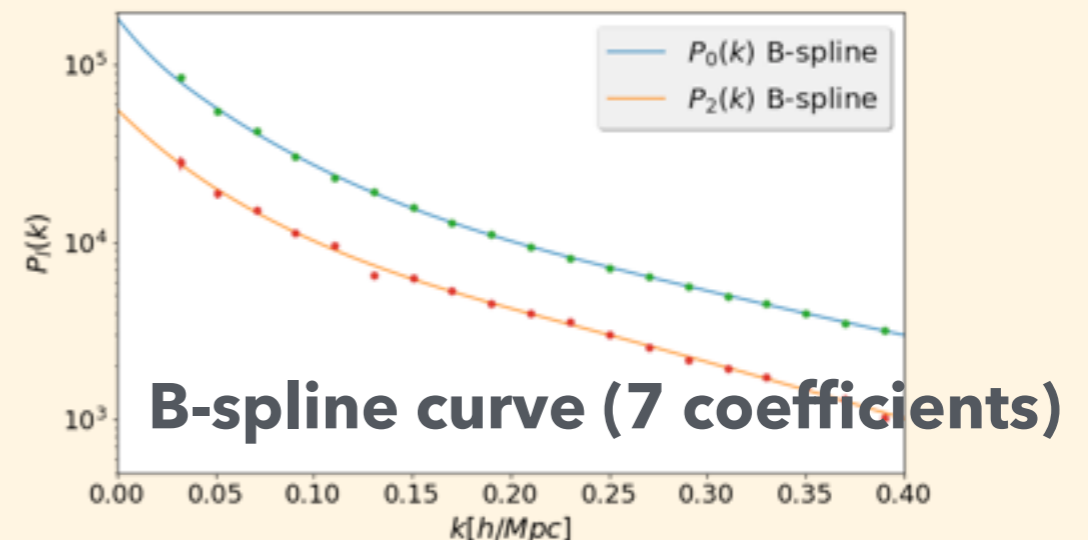
$0.0211 \leq \Omega_b h^2 \leq 0.0234$	$0.108 \leq \Omega_c h^2 \leq 0.132$
$0.554 \leq \Omega_\Lambda \leq 0.82$	$2.5 \leq \ln(10^{10} A_s) \leq 3.7$
$0.916 \leq n_s \leq 1.012$	$-1.194 \leq w_{de} \leq -0.802$

output

$P_0(k), P_2(k)$ を B-spline fit、各係数に対して個別にガウス過程を作って学習



次元削減



Performance of the Emulator

- シミュレーションデータをガウス過程に基づいて学習、Pythonモジュール化
- インスタンスを作ると、学習で得たデータを読み込んで学習済みのガウス過程を構成する
- 宇宙論パラメータと赤方偏移を指定すると、 P_0 , P_2 の値を高速 (~ 1 msec) に出力できる



```
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_1_emu
```

```
In [3]: p0 = P_1_emu(0)
p2 = P_1_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])
```



モジュールのインポート

```
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_1_emu
```

```
In [3]: p0 = P_1_emu(0)
p2 = P_1_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])
```



モジュールのインポート

```
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_1_emu
```

エミュレータクラスの
インスタンス

```
In [3]: p0 = P_1_emu(0)
p2 = P_1_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])
```



モジュールのインポート

```
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_1_emu
```

エミュレータクラスの
インスタンス

```
In [3]: p0 = P_1_emu(0)
p2 = P_1_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)
```

```
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_1_emu
```

エミュレータクラスの
インスタンス

```
In [3]: p0 = P_1_emu(0)
p2 = P_1_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

- 宇宙論60個を学習用と検証用に分割






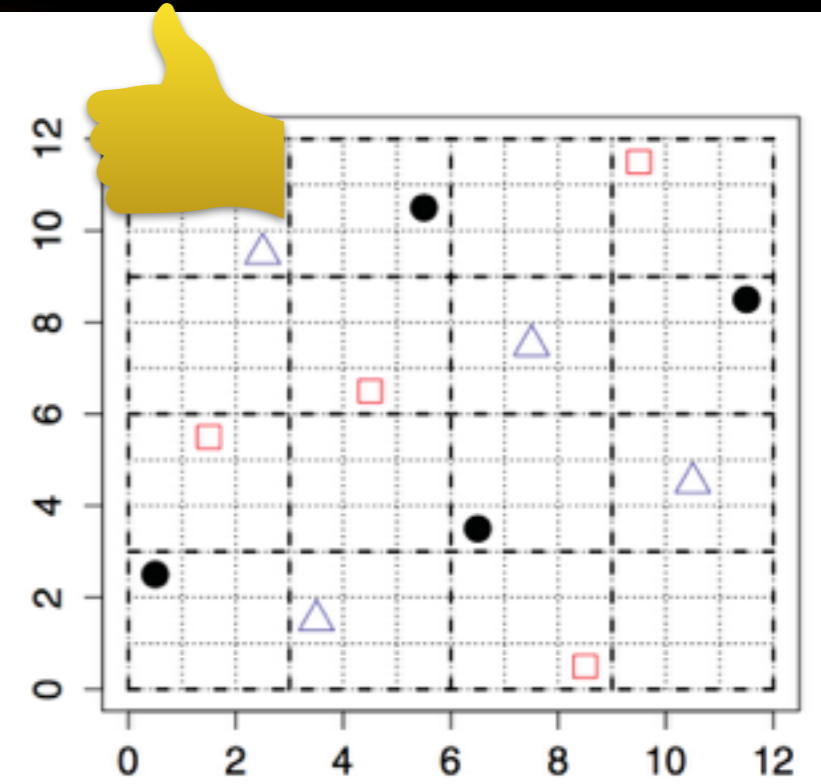
- **Optimal sliced Latin hypercube design** で20個ずつが偏りのないサンプルセット
- 40個の宇宙論を学習したガウス過程が、学習に使っていない20個の宇宙論のパワースペクトルを正しく予言するか？（過学習が起こっていないか？）

Dark Emulator Project

Optimal Sliced Latin Hypercube Design

(S. Ba et al, 2015)

- パラメータ空間から偏りなく効率的にサンプリング
- 最近傍点との距離の総和を最大化するように各パラメータの値を組み合わせる



Validation of the Emulator

- 検証用の20宇宙論それぞれについて

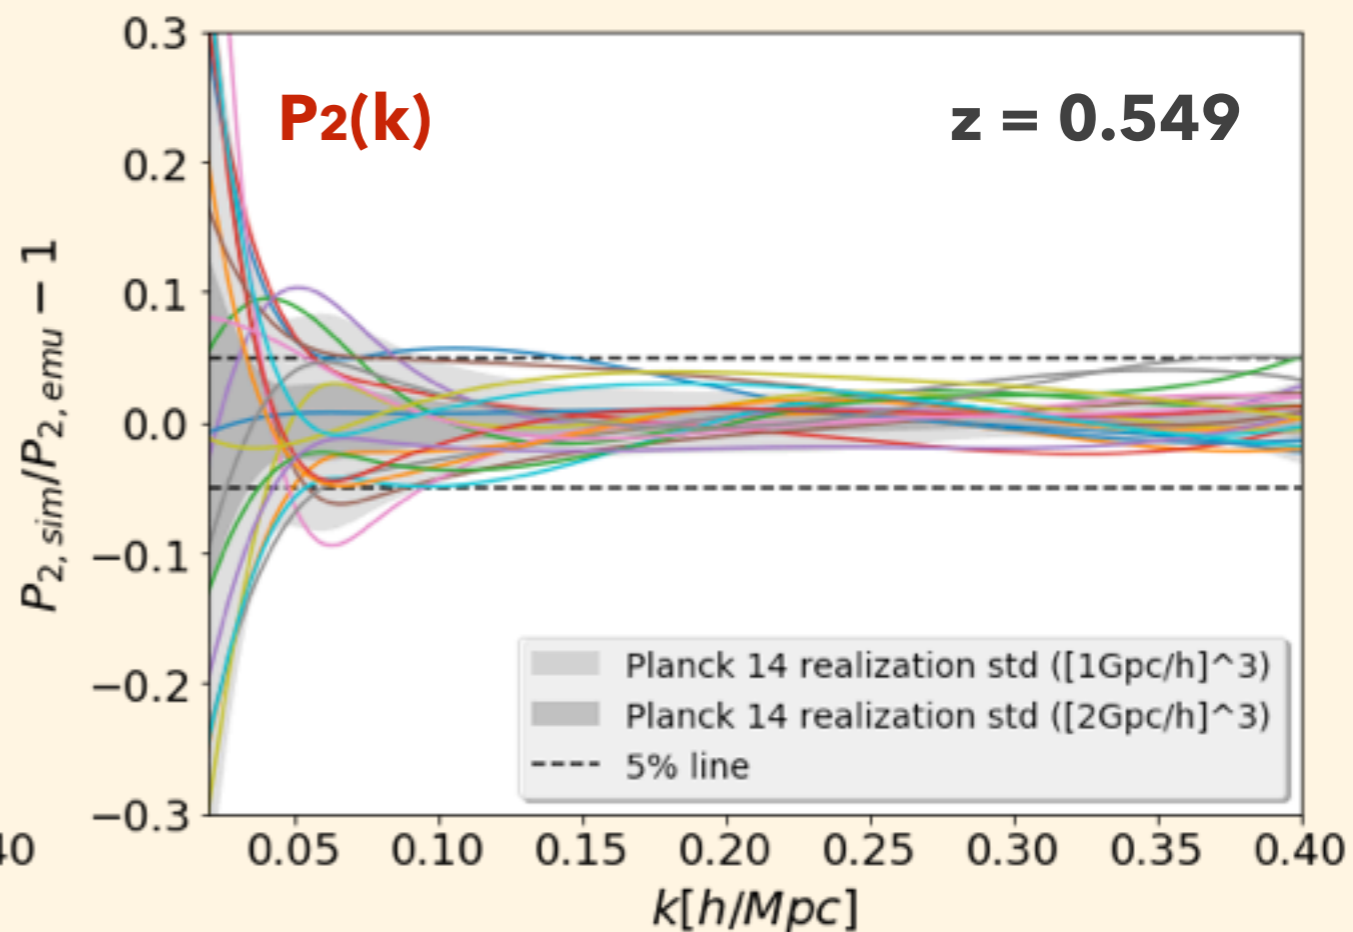

シミュレーションデータ(+ B-spline fit)

40宇宙論を学習して作ったエミュレータによる予言

- 1

を計算した結果

$$n_{\text{halo}} = 10^{-3} [h/\text{Mpc}]^3 \sim \text{WFIRST galaxy number density}$$



Validation of the Emulator

- 検証用の20宇宙論それぞれについて

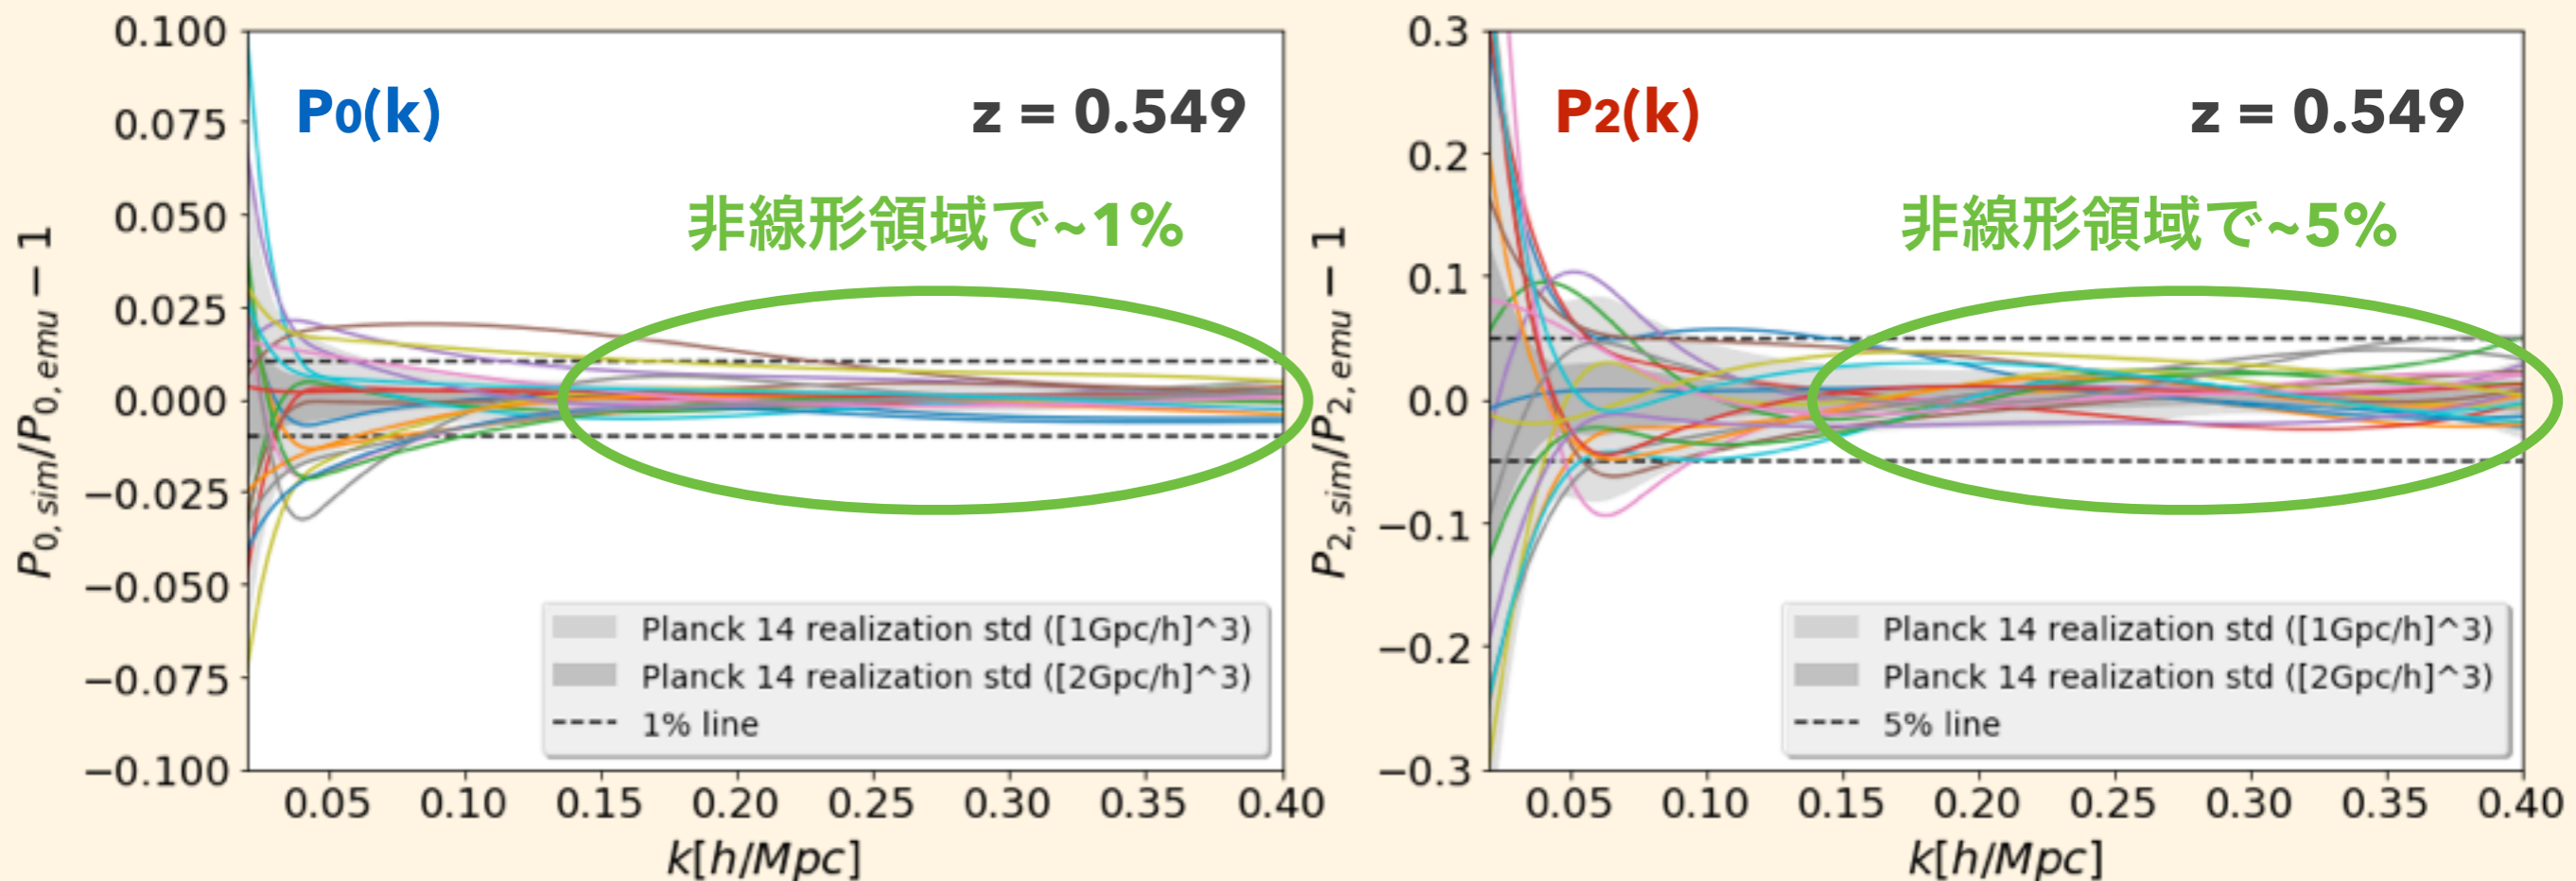
シミュレーションデータ(+ B-spline fit)

40宇宙論を学習して作ったエミュレータによる予言

- 1

を計算した結果

$$n_{\text{halo}} = 10^{-3} [h/\text{Mpc}]^3 \sim \text{WFIRST galaxy number density}$$



Validation of the Emulator

- 検証用の20宇宙論それぞれについて

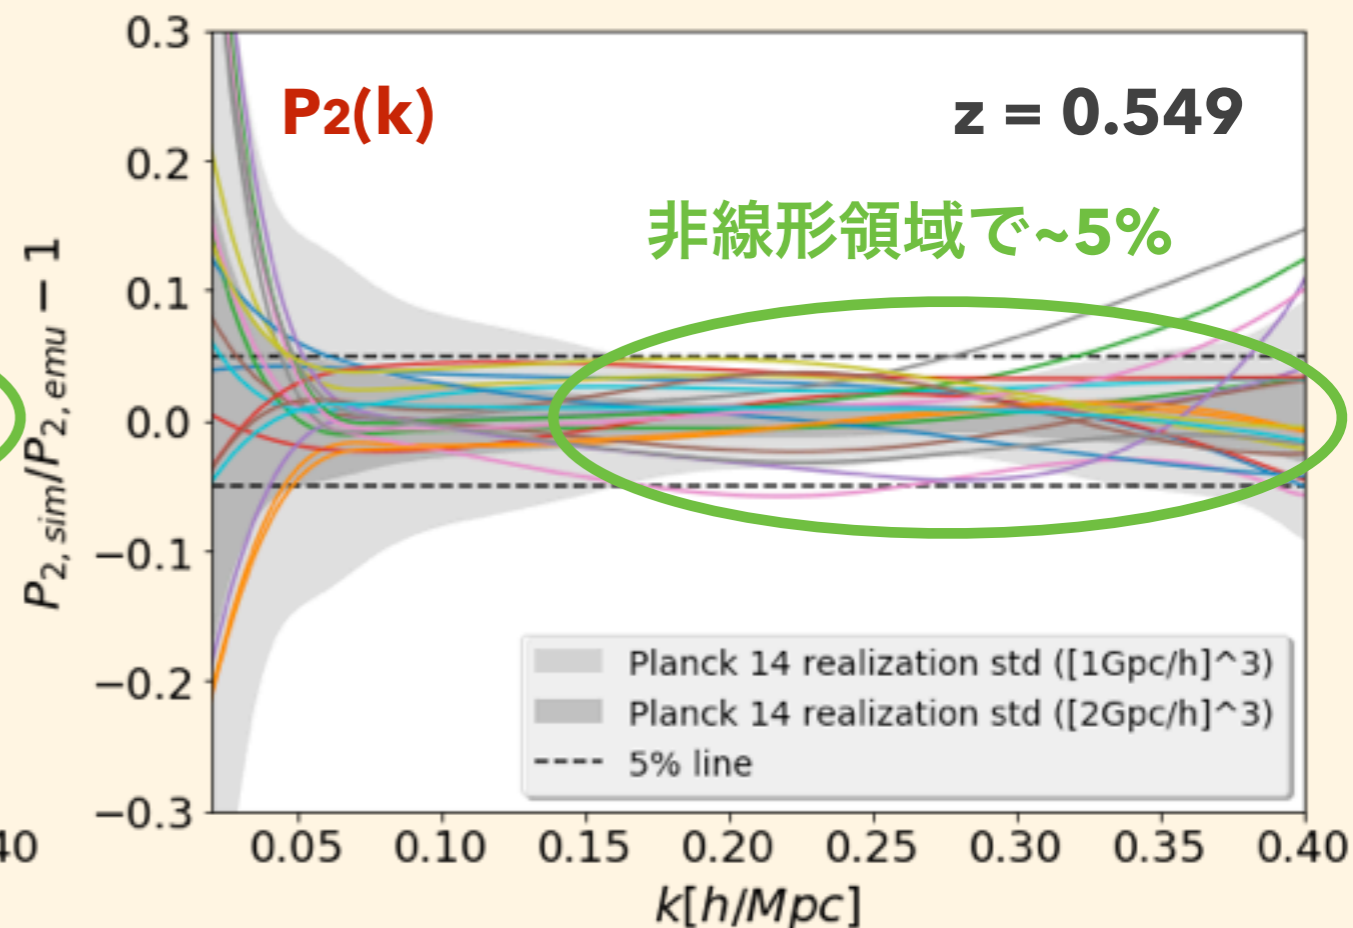
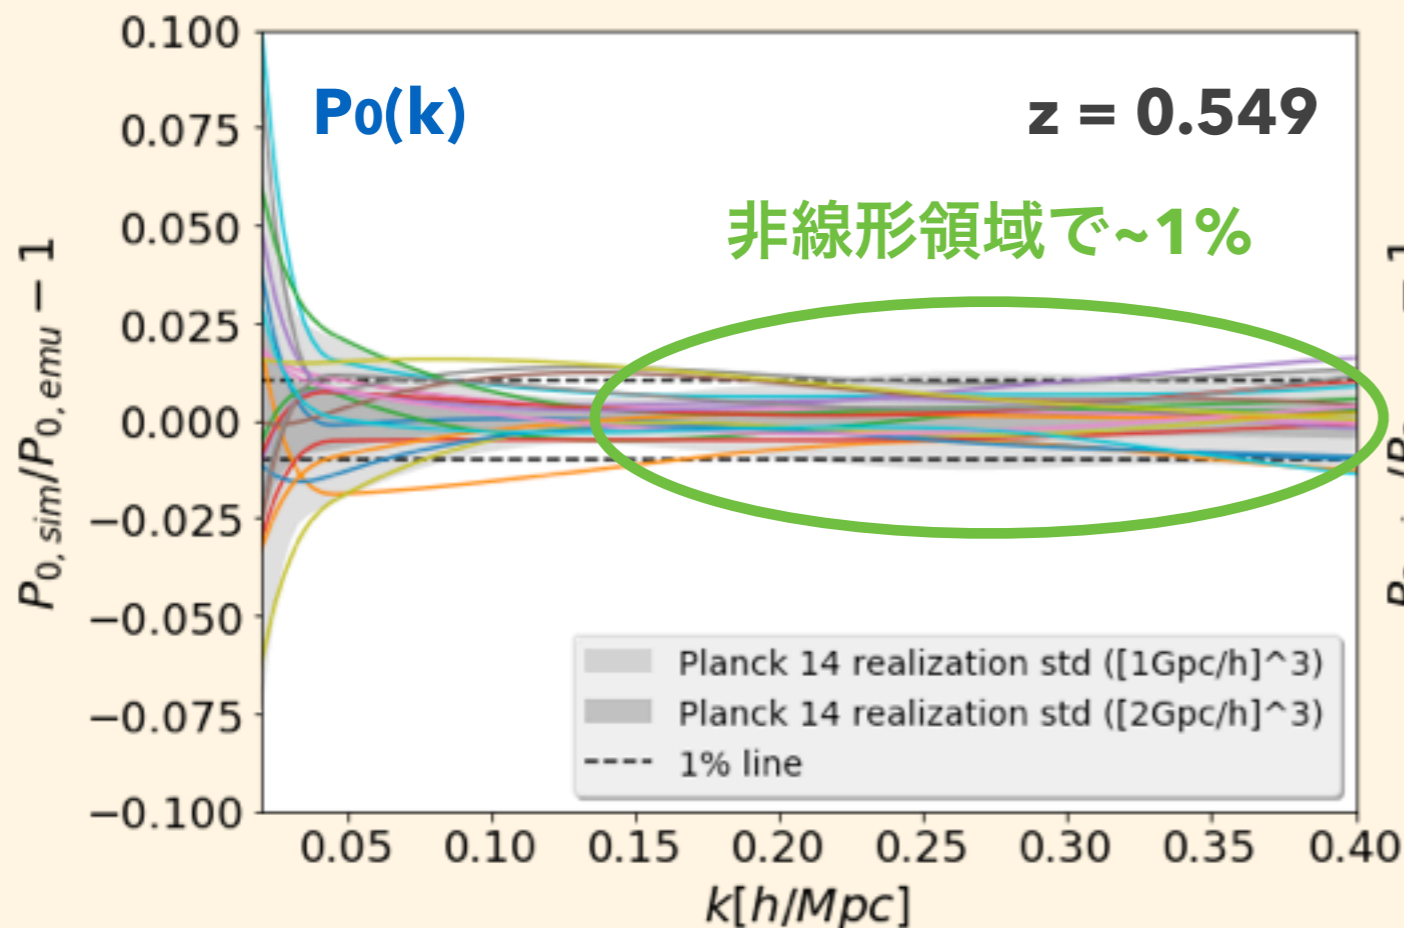
シミュレーションデータ(+ B-spline fit)

40宇宙論を学習して作ったエミュレータによる予言

- 1

を計算した結果

$$n_{\text{halo}} = 10^{-4} [h/\text{Mpc}]^3 \sim \text{BOSS galaxy number density}$$



Conclusion & Future Work

- B-spline fit + ガウス過程で、赤方偏移空間におけるハローのパワースペクトルの P_0, P_2 をそれぞれ1%, 5%程度で予言できた
- $k \sim 0.4 \text{ h/Mpc}$ までの非線形スケールで高精度予言
- シミュレーションの追加による統計の増加で精度向上が期待

Future Work

- ハローの質量閾値に対する依存性の実装
- エミュレータを用いた Fisher forecast

数～数十ミリ秒単位での出力？