

統計モデリング入門 2015 (d)

モデル選択と検定

久保拓弥 kubo@ees.hokudai.ac.jp
北大環境科学院の講義 <http://goo.gl/76c4i>

2015-07-15
ファイル更新時刻: 2015-07-14 16:48

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 1 / 37

もくじ

今日のハナシ I

today's example: seed number data, again

- ① 前回と同じ例題: 種子数データ
植物個体の属性, あるいは実験処理が種子数に影響?
- ② model selection using AIC
AIC を使ったモデル選択
badness of fit
あてはまりの悪さ: deviance
- ③ statistical test
統計学的な検定
and its asymmetry
そして, その非対称性

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 2 / 37

もくじ

今日の内容と「統計モデリング入門」との対応

今日はおもに「第4章 GLMのモデル選択」と「第5章 GLMの尤度比検定と検定の非対称性」の内容を説明します。

- 著者: 久保拓弥
- 出版社: 岩波書店
- 2012-05-18 刊行

<http:// goo.g1/Ufq2>

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 3 / 37

もくじ

パラメーター数は多くても少なくともへん?

(A) パラメーター数 $k=1$
パラメーター少なすぎ?

(B) パラメーター数 $k=7$
パラメーター多すぎ?

What is the “best?” parameter number k ?

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 4 / 37

前回と同じ例題: 種子数データ
植物個体の属性, あるいは実験処理が種子数に影響?

today's example: seed number data, again

1. 前回と同じ例題: 種子数データ
植物個体の属性, あるいは実験処理が種子数に影響?

まずはデータの概要を調べる

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 5 / 37

前回と同じ例題: 種子数データ
植物個体の属性, あるいは実験処理が種子数に影響?

body size x and fertilization f change seed number y ?

個体サイズと実験処理の効果を調べる例題

個体 i

- 応答変数: 種子数 $\{y_i\}$
- 説明変数:
 - body size $\{x_i\}$
 - 施肥処理 $\{f_i\}$

施肥処理 f_i

C: 肥料なし
T: 施肥処理

sample size
標本数

- 無処理 ($f_i = C$): 50 sample ($i \in \{1, 2, \dots, 50\}$)
- 施肥処理 ($f_i = T$): 50 sample ($i \in \{51, 52, \dots, 100\}$)

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 6 / 37

前回と同じ例題: 種子数データ 植物個体の属性、あるいは実験処理が種子数に影響?

a statistical model for this example
この例題のための統計モデル

ポアソン回帰のモデル

probability distribution Poisson distribution

- 確率分布: ポアソン分布
- 線形予測子: $\beta_1 + \beta_2 x_i + \beta_3 f_i$
- リンク関数: 対数リンク関数

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 7 / 37

前回と同じ例題: 種子数データ 植物個体の属性、あるいは実験処理が種子数に影響?

4 candidate models
4つの可能なモデル候補: (A) constant λ

$$\lambda_i = \exp(\beta_1)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ 1, data = d, family = poisson))
'log Lik.' -237.64 (df=1)
```

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 8 / 37

前回と同じ例題: 種子数データ 植物個体の属性、あるいは実験処理が種子数に影響?

4 candidate models
4つの可能なモデル候補: (B) f model

$$\lambda_i = \exp(\beta_1 + \beta_3 f_i)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ f, data = d, family = poisson))
'log Lik.' -237.63 (df=2)
```

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 9 / 37

前回と同じ例題: 種子数データ 植物個体の属性、あるいは実験処理が種子数に影響?

4 candidate models
4つの可能なモデル候補: (C) x model

$$\lambda_i = \exp(\beta_1 + \beta_2 x_i)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ x, data = d, family = poisson))
'log Lik.' -235.39 (df=2)
```

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 10 / 37

前回と同じ例題: 種子数データ 植物個体の属性、あるいは実験処理が種子数に影響?

4 candidate models
4つの可能なモデル候補: (D) x + f model

$$\lambda_i = \exp(\beta_1 + \beta_2 x_i + \beta_3 f_i)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ x + f, data = d, family = poisson))
'log Lik.' -235.29 (df=3)
```

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 11 / 37

前回と同じ例題: 種子数データ 植物個体の属性、あるいは実験処理が種子数に影響?

k increases $\rightarrow \log L^*$ increases
パラメーター数が多いとあてはまりが良い

(A) constant λ ($k = 1$) -237.6	(B) f model ($k = 2$) -237.6 fertilization 施肥処理 Control
(C) x model ($k = 2$) -235.4	(D) x + f model ($k = 3$) -235.3 Control fertilization

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 12 / 37

AIC を使ったモデル選択 あてはまりの悪さ : deviance

model selection using AIC
2. AIC を使ったモデル選択

badness of fit
あてはまりの悪さ: deviance

badness of prediction
そして予測の悪さ: AIC

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 13 / 37

AIC を使ったモデル選択 あてはまりの悪さ : deviance
output
R の glm() は deviance を出力

```
> glm(y ~ x + f, data = d, family = poisson)
```

Call: `glm(formula = y ~ x + f, family = poisson, data = d)`

Coefficients:

(Intercept)	x	fT
1.2631	0.0801	-0.0320

Degrees of Freedom: 99 Total (i.e. Null); 97 Residual
Null Deviance: 89.5
Residual Deviance: 84.8 AIC: 477

Residual Deviance? Null Deviance? AIC?

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 14 / 37

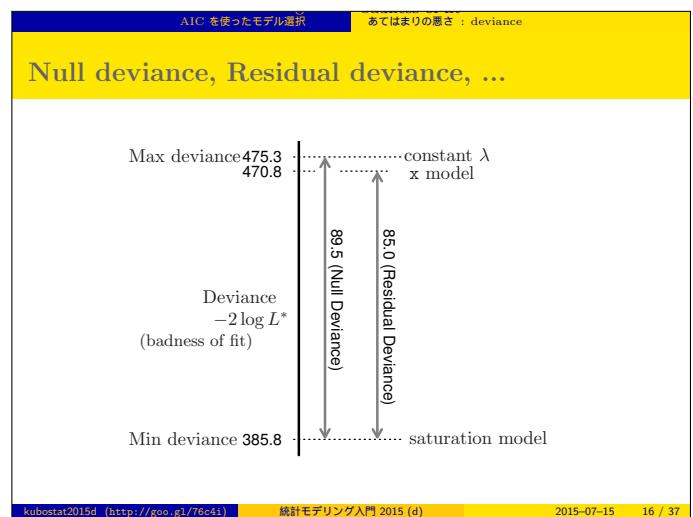
AIC を使ったモデル選択 あてはまりの悪さ : deviance

deviance $D = -2 \times \log L^*$

- Maximum log likelihood $\log L^*$: goodness of fit
- Deviance $D = -2 \log L^*$: badness of fit

model	k	$\log L^*$	Deviance $-2 \log L^*$	Residual deviance
constant λ	1	-237.6	475.3	89.5
f	2	-237.6	475.3	89.5
x	2	-235.4	470.8	85.0
x + f	3	-235.3	470.6	84.8
saturation	100	-192.9	385.8	0.0

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 15 / 37



AIC を使ったモデル選択 あてはまりの悪さ : deviance
badness of prediction

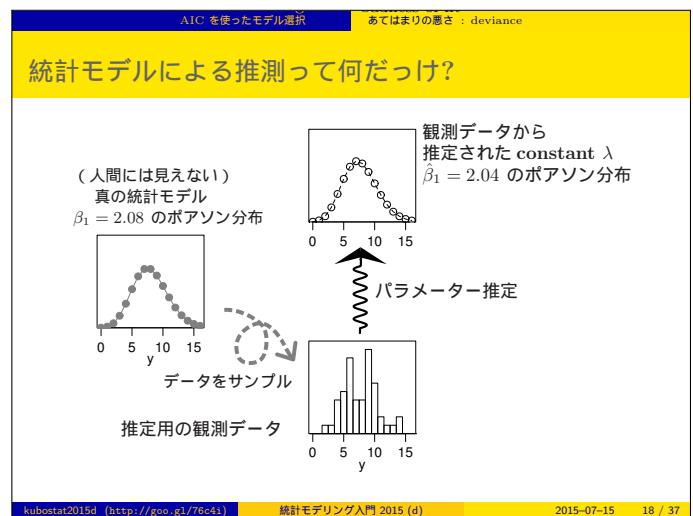
予測の悪さ : $AIC = -2 \log L^* + 2k$

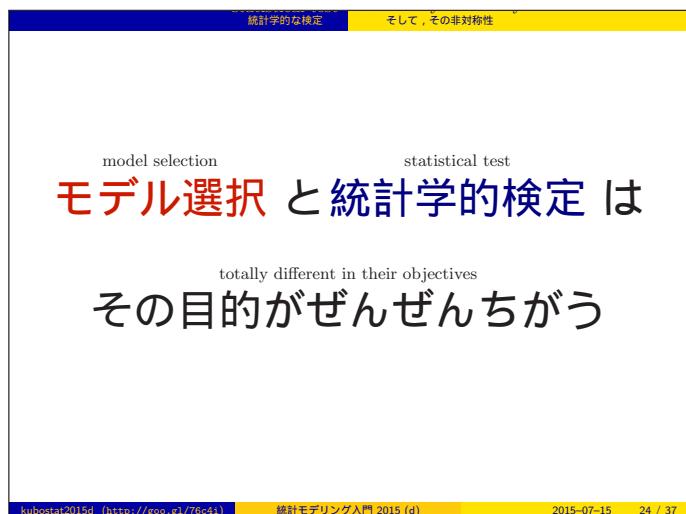
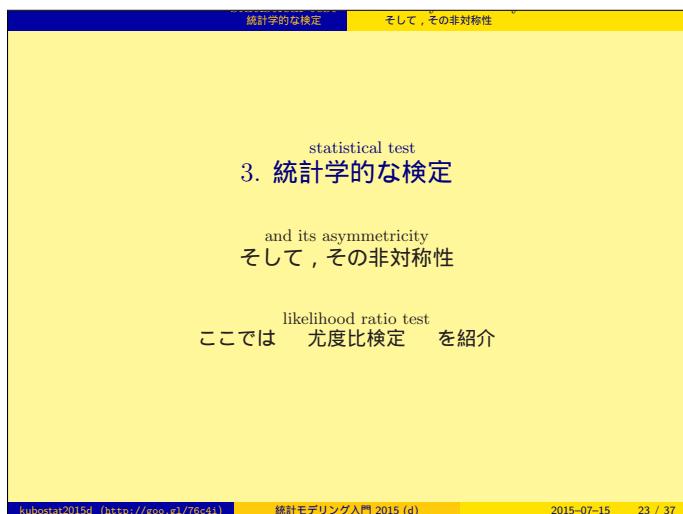
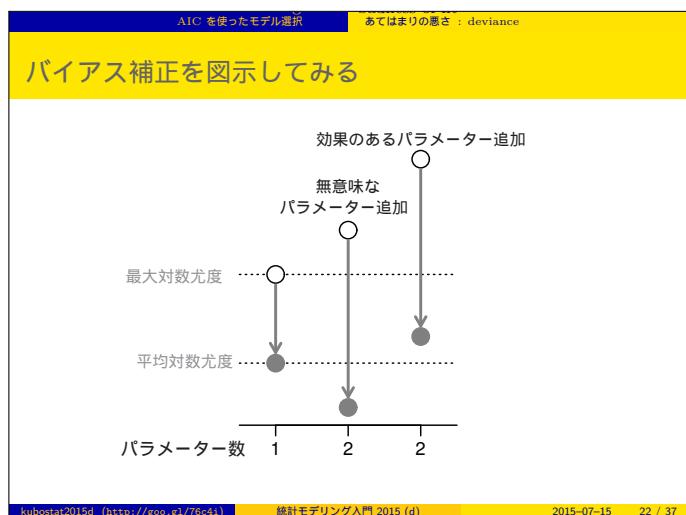
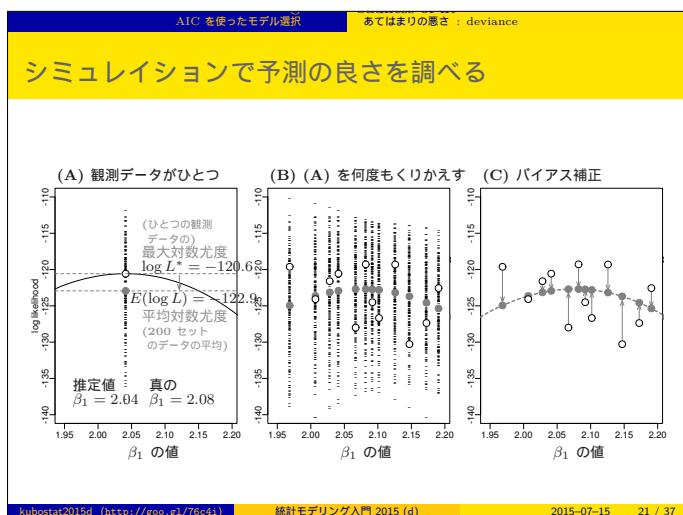
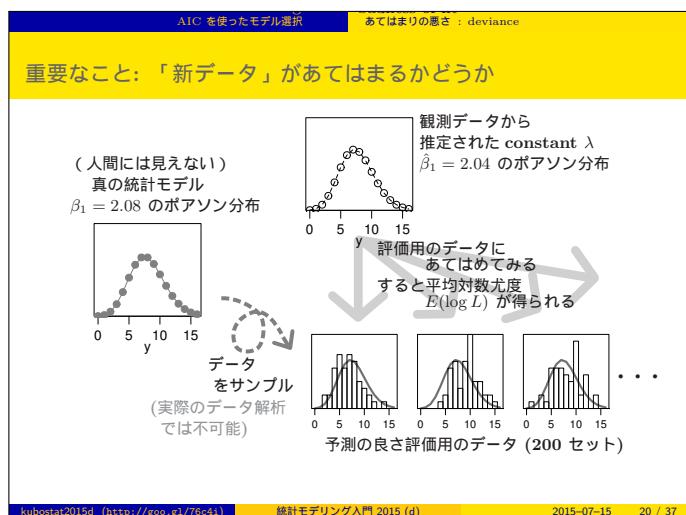
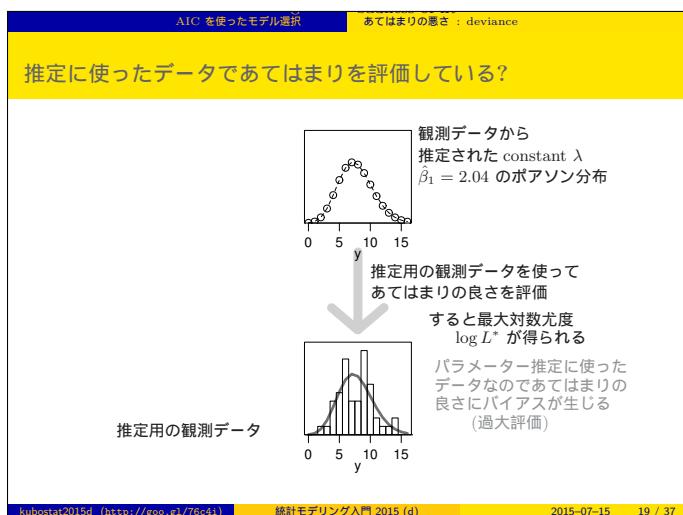
Look for a model of the smallest AIC
AIC 最小のモデルを選ぶ

model	k	$\log L^*$	Deviance $-2 \log L^*$	Residual deviance	AIC
constant λ	1	-237.6	475.3	89.5	477.3
f	2	-237.6	475.3	89.5	479.3
x	2	-235.4	470.8	85.0	474.8
x + f	3	-235.3	470.6	84.8	476.6
saturation	100	-192.9	385.8	0.0	585.8

AIC: A (or Akaike) information criterion

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 17 / 37



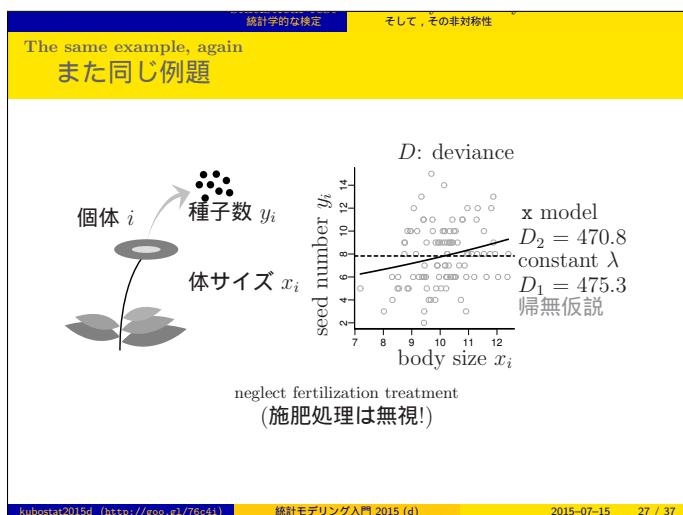
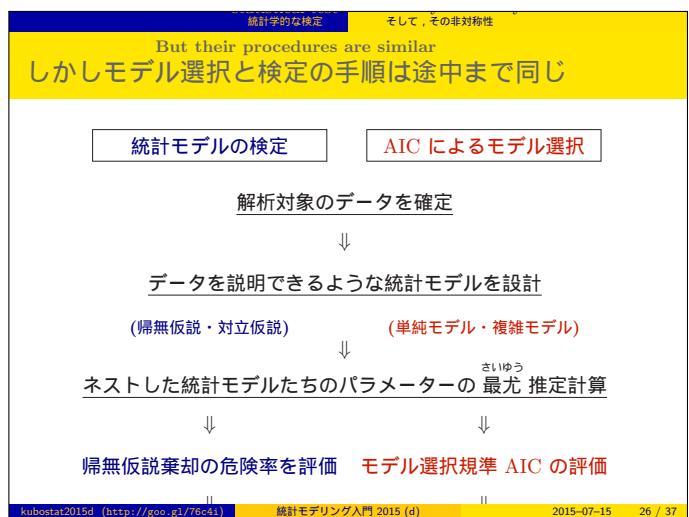


統計学的な検定 そして、その非対称性

Objective
目的?
model selection
モデル選択:
Look for a model of better prediction
よい予測をするモデルの探索

statistical test rejection of null hypothesis
統計学的検定: 帰無仮説の排除
described later
(あとで説明)

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 25 / 37



統計学的な検定 そして、その非対称性

test statistics
検定統計量 $\Delta D_{1,2}$

difference in deviance $\Delta D_{1,2} = D_1 - D_2 = 4.51 \approx 4.5$
likelihood ratio? — $\log \frac{L_1^*}{L_2^*} = \log L_1^* - \log L_2^*$

model	k	$\log L^*$	Deviance $-2 \log L^*$
constant λ	1	-237.6	$D_1 = 475.3$
x	2	-235.4	$D_2 = 470.8$

null hypothesis **帰無仮説**
alternative hypothesis **対立仮説**

asymmetry in test Null hypothesis is junk
検定の非対称性: 帰無仮説はゴミあつかい
... yet we are focusing only on null hypothesis
.....にもかかわらず、帰無仮説だけをしつこく調べる

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 28 / 37

統計学的な検定 そして、その非対称性

objective null hypothesis rejection
検定の目的: **帰無仮説** の棄却

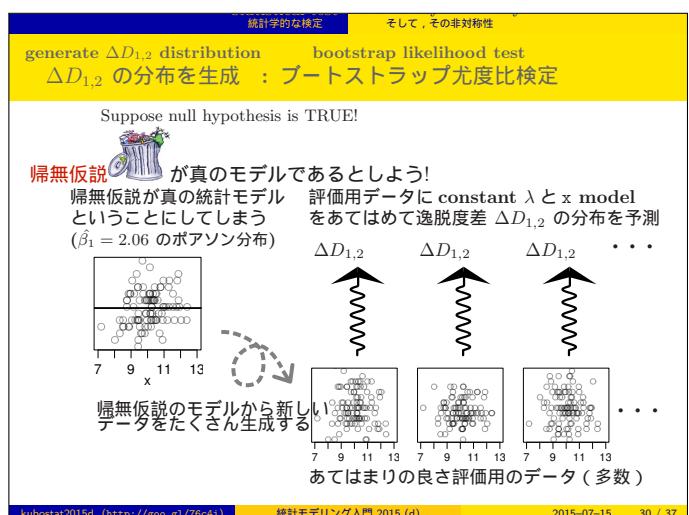
observed
観察された逸脱度差 $\Delta D_{1,2} = 4.5$ は.....
帰無仮説は 「めったにない差」 「よくある差」
(帰無仮説を棄却) (棄却できない)
眞のモデルである 第一種の過誤 (問題なし)
眞のモデルではない (問題なし) 第二種の過誤

significant (Reject) not significant (Not reject)

TRUE Type I error (no problem)
NOT true (no problem) Type II error

asymmetry in test evaluating only Type-I error
検定の非対称性: 第一種の過誤だけに注目

kubostat2015d (<http://goo.gl/76c4i>) 統計モデリング入門 2015 (d) 2015-07-15 29 / 37



統計学的な検定 そして, その非対称性

How to generate $\Delta D_{1,2}$ under is TRUE?

```
> d$y.rnd <- rpois(100, lambda = mean(d$y))
> fit1 <- glm(y.rnd ~ 1, data = d, family = poisson)
> fit2 <- glm(y.rnd ~ x, data = d, family = poisson)
> fit1$deviance - fit2$deviance
```

generation of random numbers virtual data

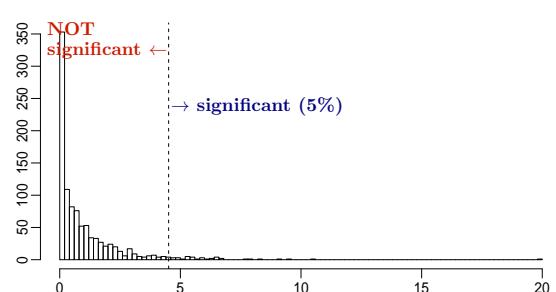
- `rpois()` による ポアソン乱数の生成 (架空データ)
- fitting GLM to the virtual data
- 架空データを使って `glm()` あてはめ

kubostat2015d (<http://goo.gl/76c4i1>) 統計モデリング入門 2015 (d) 2015-07-15 31 / 37

統計学的な検定 そして, その非対称性

You must define “rejection region” in advance
あらかじめ棄却域を決めておく

say, 5%?
たとえば 5%とか?



NOT significant ←
→ significant (5%)

kubostat2015d (<http://goo.gl/76c4i1>) 統計モデリング入門 2015 (d) 2015-07-15 32 / 37

統計学的な検定 そして, その非対称性

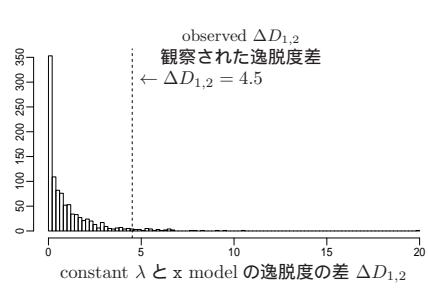
A random $\Delta D_{1,2}$ generator in R

```
get.dd <- function(d) # データの生成と逸脱度差の評価
{
  n.sample <- nrow(d) # データ数
  y.mean <- mean(d$y) # 標本平均
  d$y.rnd <- rpois(n.sample, lambda = y.mean)
  fit1 <- glm(y.rnd ~ 1, data = d, family = poisson)
  fit2 <- glm(y.rnd ~ x, data = d, family = poisson)
  fit1$deviance - fit2$deviance # 逸脱度の差を返す
}
pb <- function(d, n.bootstrap)
{
  replicate(n.bootstrap, get.dd(d))
}
```

kubostat2015d (<http://goo.gl/76c4i1>) 統計モデリング入門 2015 (d) 2015-07-15 33 / 37

統計学的な検定 そして, その非対称性

Generated distribution of $\Delta D_{1,2} = D_1 - D_2$



observed $\Delta D_{1,2}$
観察された逸脱度差
← $\Delta D_{1,2} = 4.5$

constant λ & x model の逸脱度の差 $\Delta D_{1,2}$

(R code is in the next page)

kubostat2015d (<http://goo.gl/76c4i1>) 統計モデリング入門 2015 (d) 2015-07-15 34 / 37

統計学的な検定 そして, その非対称性

Probability{ $\Delta D_{1,2} \geq 4.5$ } = $\frac{38}{1000} = 0.038$

```
> source("pb.R") # reading "pb.R" text file
> dd12 <- pb(d, n.bootstrap = 1000)
> hist(dd12, 100) # to plot histogram
> abline(v = 4.5, lty = 2)
> sum(dd12 >= 4.5)
[1] 38
```

so-called “P-value” is 0.038.

kubostat2015d (<http://goo.gl/76c4i1>) 統計モデリング入門 2015 (d) 2015-07-15 35 / 37

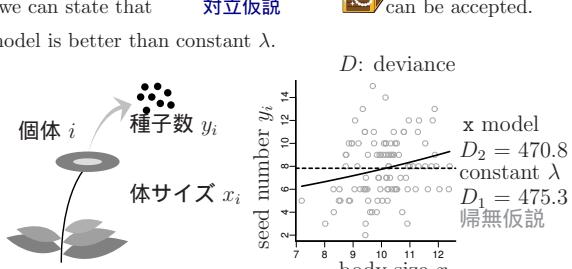
統計学的な検定 そして, その非対称性

null hypothesis  is rejected

alternative hypothesis  So we can state that **対立仮説**  can be accepted.

x model is better than constant λ .

D : deviance



個体 i
種子数 y_i
体サイズ x_i

D : deviance

constant λ
 $D_2 = 470.8$
 $D_1 = 475.3$
帰無仮説

body size x_i

kubostat2015d (<http://goo.gl/76c4i1>) 統計モデリング入門 2015 (d) 2015-07-15 36 / 37

統計学的な検定

そして、その非対称性

In case that $P > 0.05 \dots ?$

No conclusion
何も結論できない……

You can NOT state that constant λ is better
 λ 一定のモデルが良いとは言えない

Null hypothesis is never accepted

asymmetry in test

検定の非対称性 : 帰無仮説



はけっして受容されない