

統計モデリング入門 2017 (d)

model selection and statistical test
モデル選択と検定

久保拓弥 kubo@ees.hokudai.ac.jp

霊長研の集中講義 <http://goo.gl/76c4i>

2017-06-19

ファイル更新時刻: 2017-11-07 15:46

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 1 / 44

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?
- 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
- statistical test
- ③ 統計学的な検定
and its asymmetricity
そして, その非対称性
- model selection statistical test
- ④ モデル選択 と 統計学的な検定
misunderstanding
のさまざまな 誤解

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 2 / 44

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。

<http://goo.gl/Ufq2>

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



kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 3 / 44

もくじ

number of parameters パラメーター数 は多くても少なくてもヘン?

(A) パラメーター数 $k = 1$

(B) パラメーター数 $k = 7$

What is the “best?” parameter number k ?

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 4 / 44

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

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 5 / 44

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?

パラメーター数 k は多くても少なくてもヘン?

(A) パラメーター数 $k = 1$

(B) パラメーター数 $k = 7$

“良いモデル” とはなにか? k も重要なのか?

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 6 / 44

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

response variable seed number
 • 応答変数: 種子数 $\{y_i\}$

explanatory variable
 • 説明変数: body size
 • 体サイズ $\{x_i\}$
 fertilization
 • 施肥処理 $\{f_i\}$

sample size
 標本数
 control
 • 無処理 ($f_i = C$): 50 sample ($i \in \{1, 2, \dots, 50\}$)
 fertilization
 • 施肥処理 ($f_i = T$): 50 sample ($i \in \{51, 52, \dots, 100\}$)

個体 i
 種子数 y_i
 体サイズ x_i
 施肥処理 f_i
 C: 肥料なし
 T: 施肥処理

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 7 / 44

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

probability distribution Poisson distribution
 • 確率分布: **ポアソン分布**

linear predictor
 • 線形予測子: $\beta_1 + \beta_2 x_i + \beta_3 f_i$

link function log link function
 • リンク関数: **対数リンク関数**

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 8 / 44

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)
```

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 9 / 44

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)
```

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 10 / 44

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)
```

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 11 / 44

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)
```

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 12 / 44

前回と同じ例題: 種子数データ 植物個体の異性, 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 ($k = 1$)

(B) f model ($k = 2$)

(C) x model ($k = 2$)

(D) x + f model ($k = 3$)

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 13 / 44

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

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 14 / 44

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?

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 15 / 44

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 |

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 16 / 44

AIC を使ったモデル選択 あてはまりの悪さ: deviance

Null deviance, Residual deviance, ...

Max deviance 475.3
 470.8
 Deviance $-2 \log L^*$
 (badness of fit)
 Min deviance 385.8

constant λ
 x model
 89.5 (Null Deviance)
 85.0 (Residual Deviance)
 saturation model

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 17 / 44

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

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 18 / 44

AIC を使ったモデル選択 あてはまりの悪さ : deviance

統計モデルによる推測 (estimation) って何だっけ?

(人間には見えない) 真の統計モデル $\beta_1 = 2.08$ のポアソン分布

観測データから推定された constant λ $\hat{\beta}_1 = 2.04$ のポアソン分布

parameter estimation
パラメーター推定

データをサンプル
推定用の観測データ

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 19 / 44

AIC を使ったモデル選択 あてはまりの悪さ : deviance

Is it OK? Goodness of fit is evaluated by using the SAME data set ... 推定に使ったデータであてはまりを評価している?

観測データから推定された constant λ $\hat{\beta}_1 = 2.04$ のポアソン分布

推定用の観測データを使ってあてはまりの良さを評価すると最大対数尤度 $\log L^*$ が得られる

パラメーター推定に使ったデータなのであてはまりの良さにバイアスが生じる (過大評価) **biased "goodness of fit"!**

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 20 / 44

AIC を使ったモデル選択 あてはまりの悪さ : deviance

重要なこと: 新データがあてはまるかどうか

(人間には見えない) 真の統計モデル $\beta_1 = 2.08$ のポアソン分布

観測データから推定された constant λ $\hat{\beta}_1 = 2.04$ のポアソン分布

データをサンプル (実際のデータ解析では不可能)

予測の良さ評価用のデータ (200 セット)

評価用のデータにあてはめてみる
すると平均対数尤度 $E(\log L)$ が得られる

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 21 / 44

AIC を使ったモデル選択 あてはまりの悪さ : deviance

シミュレーションで予測の良さを調べる

(A) 観測データがひとつ (B) (A) を何度もくりかえす (C) バイアス補正

log likelihood

(ひとつの観測データの) 最大対数尤度 $\log L^* = -120.0$

平均対数尤度 (200 セットのデータの平均) $E(\log L) = -122.9$

推定値 $\hat{\beta}_1 = 2.04$ 真の $\beta_1 = 2.08$

β_1 の値

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 22 / 44

AIC を使ったモデル選択 あてはまりの悪さ : deviance

バイアス補正を図示してみる

効果のあるパラメーター追加

無意味なパラメーター追加

最大対数尤度

平均対数尤度

パラメーター数 1 2 2

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 23 / 44

統計学的な検定 そして、その非対称性

statistical test 3. 統計学的な検定

and its asymmetry
そして、その非対称性

likelihood ratio test
ここでは 尤度比検定 を紹介

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 24 / 44

統計学的な検定 そして、その非対称性

Although their procedures are similar ... they are totally different!
モデル選択と検定の手順は途中まで同じ

統計モデルの検定
AICによるモデル選択

解析対象のデータを確定

↓

データを説明できるような統計モデルを設計

(帰無仮説・対立仮説) ↓ (単純モデル・複雑モデル)

↓

ネストした統計モデルたちのパラメーターの最尤推定計算

↓

帰無仮説棄却の危険率を評価

↓

帰無仮説棄却の可否を判断

モデル選択規準 AIC の評価

↓

予測の良いモデルを選ぶ

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 25 / 44

統計学的な検定 そして、その非対称性

model selection statistical test

モデル選択 と 統計学的検定 は

totally different in their objectives

その目的がぜんぜんちがう

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 26 / 44

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

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 27 / 44

統計学的な検定 (Neyman-Pearson framework)

statistical test



Null hypothesis
帰無仮説
 $glm(y \sim 1)$
is better!

どうでもいい
... 興味ない...

VS



Alternative hypothesis
対立仮説
 $glm(y \sim x)$
is better!

重要! これを
主張したい!

非対称性 asymmetry?

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 28 / 44

統計学的な検定 (Neyman-Pearson framework)

statistical test



Null hypothesis
帰無仮説
 $glm(y \sim 1)$
is better!

VS



Alternative hypothesis
対立仮説
 $glm(y \sim x)$
is better!

test! ↓

(if ...) reject 棄却 ----- ► support 支持

非対称性 asymmetry?

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 29 / 44

統計学的な検定 (Neyman-Pearson framework)

statistical test



Null hypothesis
帰無仮説
 $glm(y \sim 1)$
is better!

VS



Alternative hypothesis
対立仮説
 $glm(y \sim x)$
is better!

test! ↓

(if ...) NOT reject ----- ► Say Nothing!?

非対称性 asymmetry?

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 30 / 44

統計学的な検定 そして、その非対称性

また同じ例題 The same example, again

個体 i

種子数 y_i

体サイズ x_i

D : deviance

neglect fertilization treatment (施肥処理は無視!)

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 31 / 44

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

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 32 / 44

統計学的な検定 そして、その非対称性

How to make null model 帰無仮説のつくりかた

Null hypothesis is included in Alt hypothesis
対立仮説の中に帰無仮説がある
 this is a "nested" model (ネストした関係)

- カウントデータ $\{y_i\}$ は平均である λ_i のポアソン分布に従う alternative hypothesis
- 対立仮説** の一例: $\log \lambda_i = \beta_1 + \beta_2 x_i$
- null hypothesis
 • ネストした **帰無仮説**: $\log \lambda_i = \beta_1$ (切片だけのモデル)

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 33 / 44

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

observerd 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」 (帰無仮説を棄却) | 「よくある差」 (棄却できない) |
| 真のモデルである | 第一種の過誤 (問題なし) | (問題なし) |
| 真のモデルではない | (問題なし) | 第二種の過誤 |

| | | |
|-----------------------|---------------------|------------------------------|
| is ... (Reject) | significant | not significant (Not reject) |
| TRUE (no problem) | Type I error | (no problem) |
| NOT true (no problem) | (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

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 34 / 44

統計学的な検定 そして、その非対称性

generate $\Delta D_{1,2}$ distribution bootstrap likelihood test $\Delta D_{1,2}$ の分布を生成: ブートストラップ尤度比検定

Suppose null hypothesis is TRUE!

帰無仮説が真のモデルであるとして!
 帰無仮説が真の統計モデルということにしてしまう ($\beta_1 = 2.06$ のポアソン分布)

評価用データに constant λ と x model をあてはめて逸脱度差 $\Delta D_{1,2}$ の分布を予測

帰無仮説のモデルから新しいデータをたくさん生成する

あてはまりの良さ評価用のデータ (多数)

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 35 / 44

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

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2017-06-19 36 / 44

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?

3500
2500
1500
500
0

0 5 10 15

NOT significant ←
→ significant (5%)

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 37 / 44

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))
}
    
```

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 38 / 44

統計学的な検定 そして、その非対称性

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

3500
2500
1500
500
0

0 5 10 15

observed $\Delta D_{1,2}$
観察された逸脱度差

$\Delta D_{1,2} = 4.5$

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

(R code is in the next page)

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 39 / 44

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.

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 40 / 44

統計学的な検定 そして、その非対称性

null hypothesis 帰無仮説

In this case, **帰無仮説** is rejected

alternative hypothesis 対立仮説

So we can state that **対立仮説** can be accepted.
x model is better than constant λ .

D: deviance

seed number y_i

body size x_i

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

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 41 / 44

統計学的な検定 そして、その非対称性

In case that $P > 0.05$...?

You can conclude **NOTHING!**

何も結論できない

You can NOT state that constant λ (Null hypothesis) 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 stat-test
検定の非対称性 : 帰無仮説 はけっして受容されない

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 42 / 44

モデル選択 と 統計学的な検定 のさまざまな 誤解

model selection statistical test
4. モデル選択 と 統計学的な検定

misunderstanding
のさまざまな 誤解

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 43 / 44

モデル選択 と 統計学的な検定 のさまざまな 誤解

とりあえず FAQ モデル選択

<http://hosho.ees.hokudai.ac.jp/~kubo/ce/FaqModelSelection.html>

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2017-06-19 44 / 44