

『データ解析のための統計モデリング入門：
一般化線形モデル・階層ベイズモデル・MCMC』
pp. 67~ 92

4章 GLMのモデル選択 —AICとモデルの予測の良さ—

2014/12/9

担当 日高

4章 GLMのモデル選択 —AICとモデルの予測の良さ—

4.1 データはひとつ, モデルはたくさん

4.2 統計モデルの当てはまりの悪さ: 逸脱度

4.3 モデル選択基準AIC

4.4 AICを説明するためのまた別の例題

4.5 なぜAICでモデル選択をしてよいのか

4.5.1 統計モデルの予測の良さ: 平均対数尤度

4.5.2 最大対数尤度のバイアス補正

4.5.3 ネストしているGLM間のAIC比較

4.6 この章のまとめと参考文献

下準備

R

- ・使用データファイル: Kubo2012 chapter 3

★ディレクトリはchapter 3のみでOK!

一番適しているのはどのモデル？

最大対数尤度 (maximum log likelihood)、
つまり「あてはまりの良さ」をみればよい？

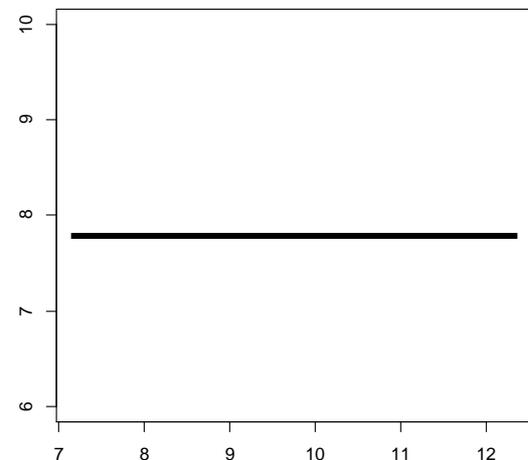
4.1 データはひとつ, モデルはたくさん

(A) 一定モデル(k=1) :

説明変数のない、切片 β_1 だけのモデル
Rでは“null model”とよばれる

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

(第4章 4.2項 参照)



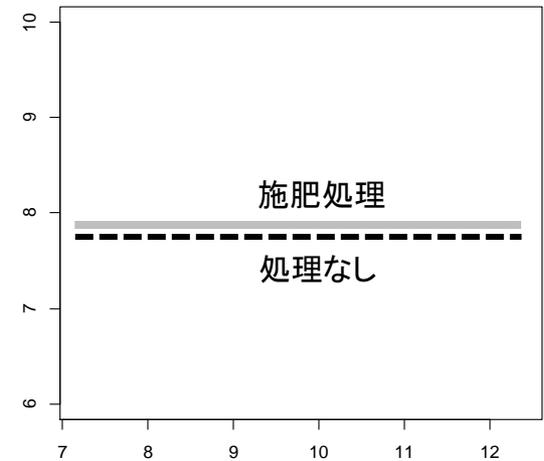
```
> logLik(glm(y ~ 1, data = d, family = poisson))
```

```
'log Lik.' -237.64 (df=1)
```

最大対数尤度

4.1 データはひとつ, モデルはたくさん

(B) fモデル (k=2) :



平均種子数 λ_i が施肥処理 f_i だけに依存するモデル

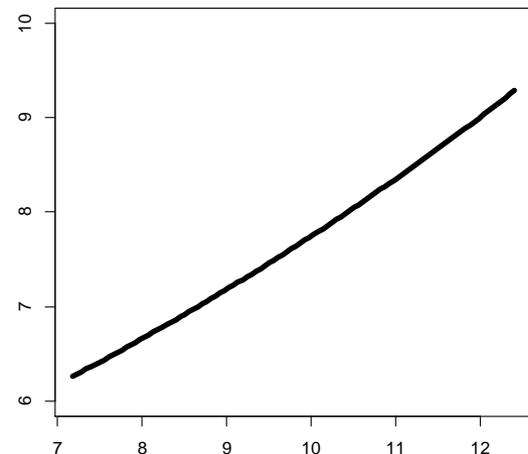
$$\lambda_i = \exp(\beta_1 + \beta_3 f_i)$$

(第3章 3.5項 参照)

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

4.1 データはひとつ, モデルはたくさん

(C) Xモデル ($k=2$) :



平均種子数 λ_i が植物の体サイズ x_i だけに依存するモデル
(第3章 3.4.1項 参照)

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

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

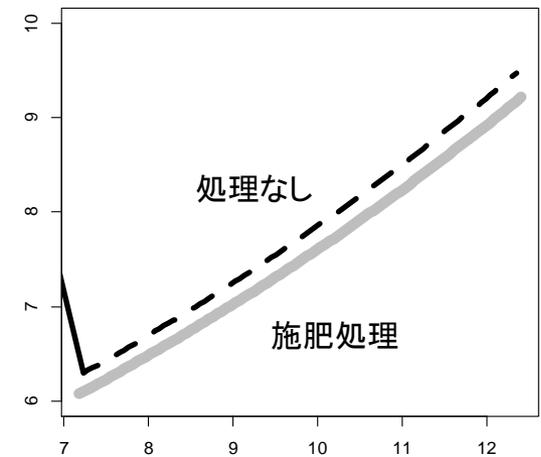
4.1 データはひとつ, モデルはたくさん

(D) X+fモデル (k=3) :

平均種子数 λ_i が

施肥処理 f_i と植物の体サイズ x_i に依存するモデル

$$\lambda_i = \exp(\beta_1 + \beta_2 x_i + \beta_3 f_i) \quad (\text{第3章 3.6項 参照})$$

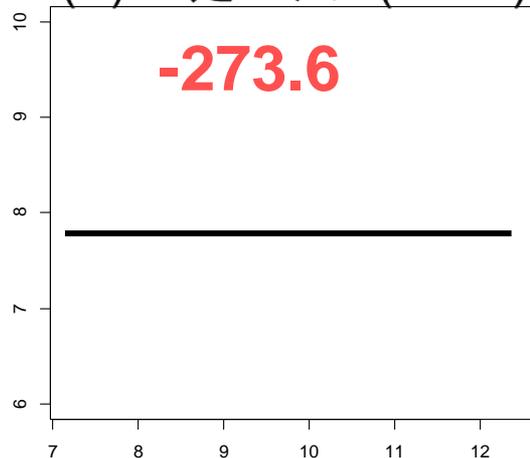


```
> logLik(glm(y ~ x + f, data = d, family = poisson))  
'log Lik.' -235.29 (df=3)
```

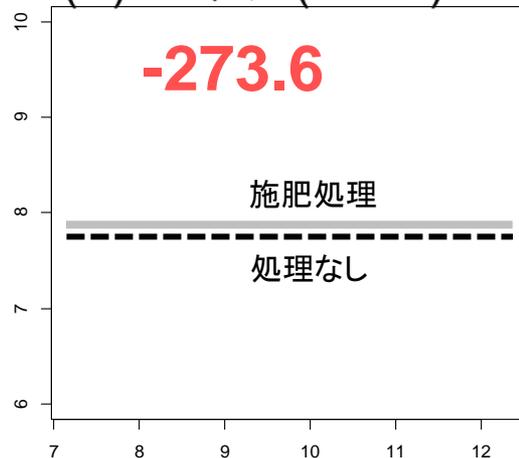
4.1 データはひとつ, モデルはたくさん

パラメーター数が多いとあてはまりが良い

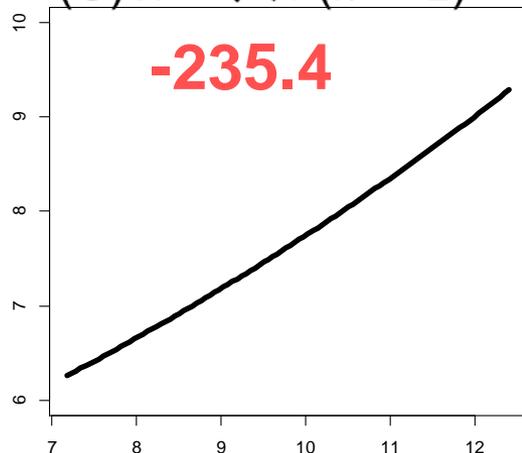
(A) 一定モデル($k = 1$)



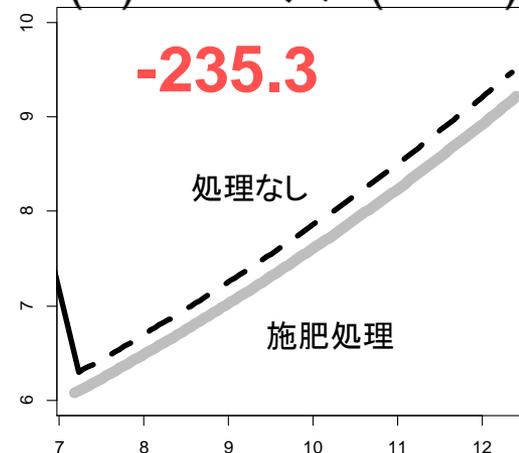
(B) fモデル($k = 2$)



(C) xモデル($k = 2$)



(D) x+fモデル($k = 3$)

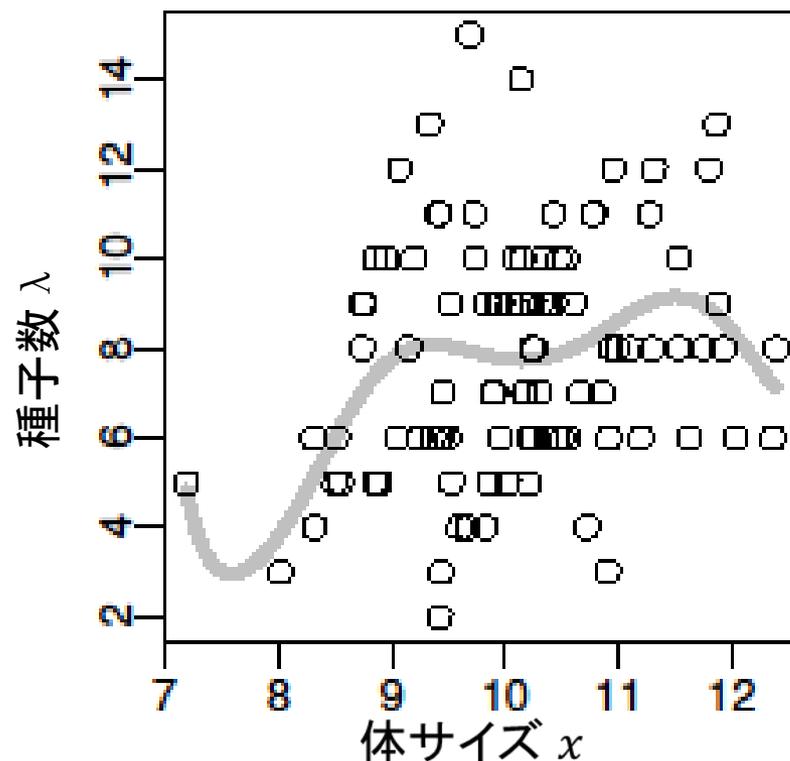


(横軸は個体の体サイズ x_i , 縦軸は平均種子数 λ_i)

4.1 データはひとつ, モデルはたくさん

しかしパラメーター数を増やしすぎると...

パラメーター数 $k = 7$



なんかちがう気がするなあ...

一番適しているのはどのモデル？

最大対数尤度 (maximum log likelihood)、
つまり「あてはまりの良さ」をみればよい？

ほかの指標をみる必要がある！

逸脱度 (deviance)

統計モデルの当てはまりの悪さを表現する指標

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

※今回は対数尤度 $\log L(\{\beta_1\})$ を $\log L$ と省略
最大対数尤度を $\log L^*$ と表記

4.2 統計モデルの当てはまりの悪さ:逸脱度

例えばxモデルでは...

$$\log L^* = -235.4$$

$$\therefore D = -2\log L^* = 470.8$$

しかしRのglm()では...

ここが関係してそう

```
> fit <- glm(y~x, data = d, family = poisson)
```

```
> fit
```

... (中略) ...

```
Null Deviance:    89.51
```

```
Residual Deviance: 84.99
```

```
AIC: 474.8
```

どこにも書かれていない...

さまざまな逸脱度

名前	定義
逸脱度(D)	$-2\log L^*$
最小の逸脱度	フルモデルをあてはめたときのD
残差逸脱度	D-最小のD
最大の逸脱度	NullモデルをあてはめたときのD
Null逸脱度	最大のD-最小のD

($\log L^*$ は最大対数尤度)

※フルモデル: データすべてをパラメータとして使ったモデル
(ここではデータ数100個を使ったモデル)

4.2 統計モデルの当てはまりの悪さ:逸脱度

ちなみに…

RでのフルモデルのDの求め方

```
> sum(log(dpois(d$y,lambda = d$y)))
```

```
[1] -192.8898
```

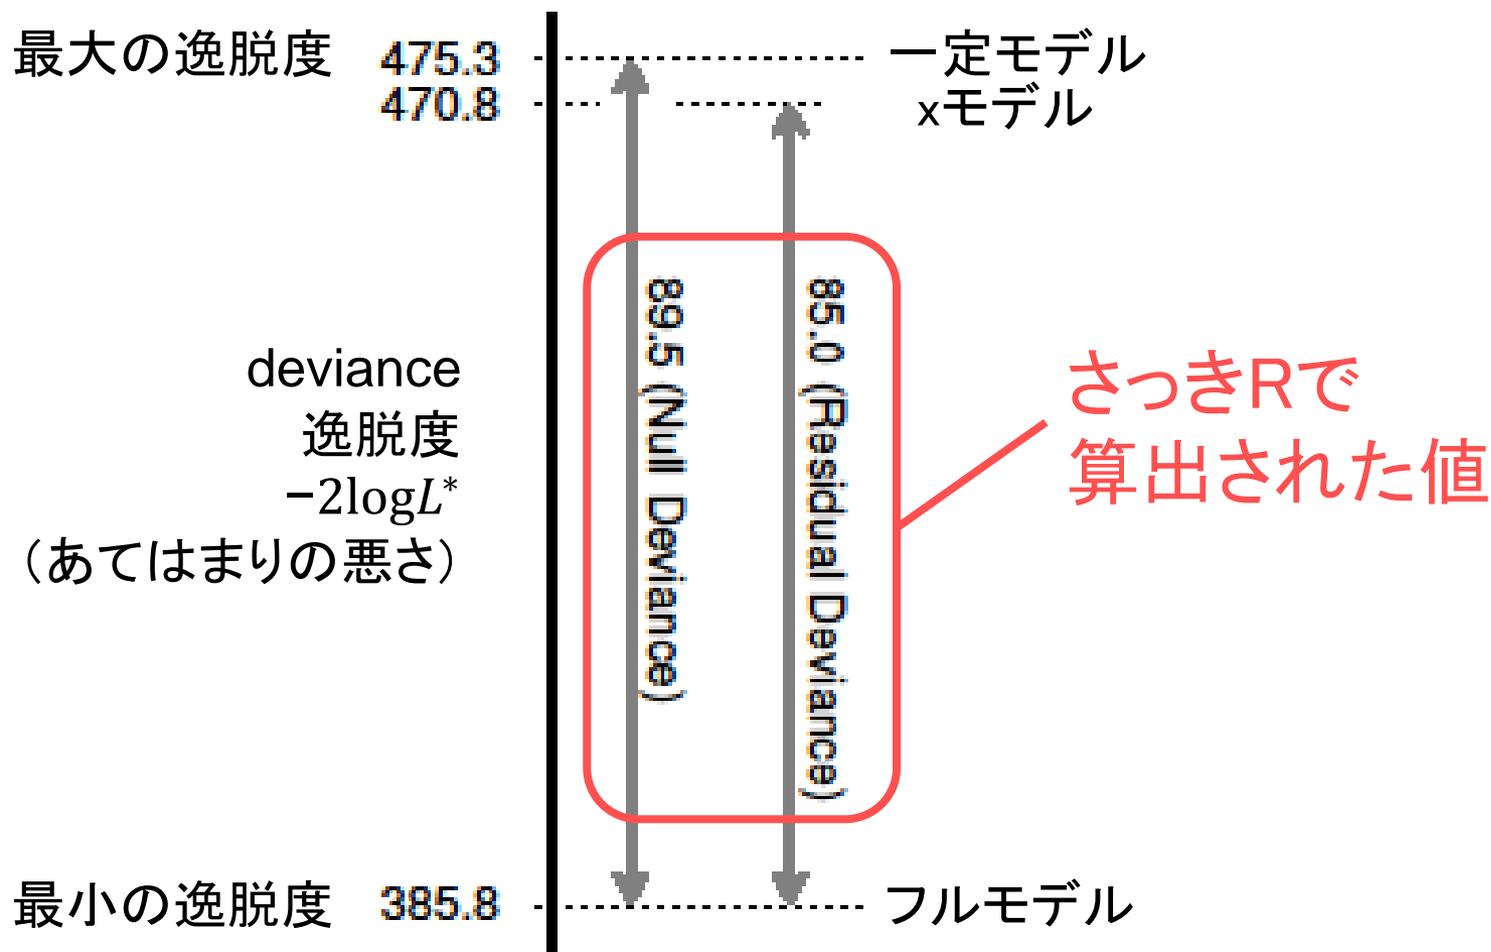
$$\log L^* = -192.9 \text{より}$$

$$D = -2\log L^* = 385.8$$

つまり、このxモデルの残差逸脱度は

$$D - (\text{最小の} D) = 470.8 - 385.8 = 85.0$$

4.2 統計モデルの当てはまりの悪さ: 逸脱度



Null Deviance : 最大逸脱度

Residual Deviance : 残差逸脱度

4.2 統計モデルの当てはまりの悪さ:逸脱度

種子数モデルの最大対数尤度と逸脱度

モデル	k	$\log L^*$	deviance $-2\log L^*$	residual deviance
一定	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	84.5
フル	100	-192.9	385.8	0.0

AIC (Akaike's information criterion)

予測の良さ (goodness of prediction) を重視する指標

AIC

$$= -2\{(\text{最大対数尤度}) - (\text{最尤推定したパラメーター数})\}$$

$$= -2(\log L^* - k)$$

$$= D + 2k$$

AICが一番小さいモデルが良いモデル

種子数モデルの最大対数尤度と逸脱度

モデル	k	$\log L^*$	deviance $-2\log L^*$	residual deviance	AIC
一定	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	84.5	476.6
フル	100	-192.9	385.8	0.0	585.8

xモデルが最も良いモデルと推定された！

一番適しているのはどのモデル？

AIC、すなわち「予測の良さ」をみればよい

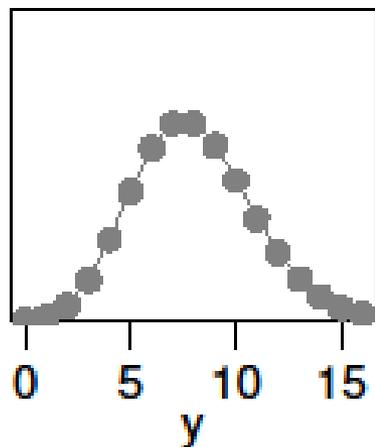
なぜそういいきれる？

- ・AICで選ばれたモデルは何が「良いのか」
- ・ $AIC = -2(\log L^* - k)$ となるのはなぜか

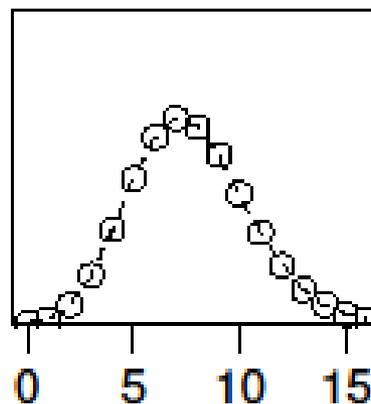
4.5 なぜAICでモデル選択してよいのか？

統計モデルのパラメーターの最尤推定の流れ

(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

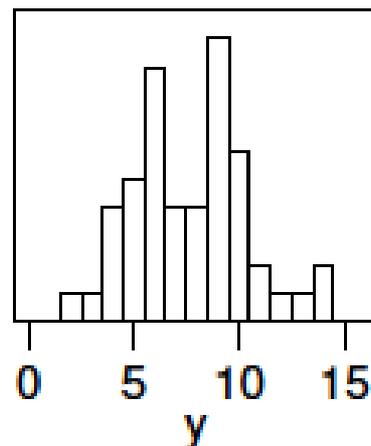


データをサンプリング



観測データから
推定された一定モデル
 $\beta_1 = 2.04$ のポアソン分布

パラメーター推定

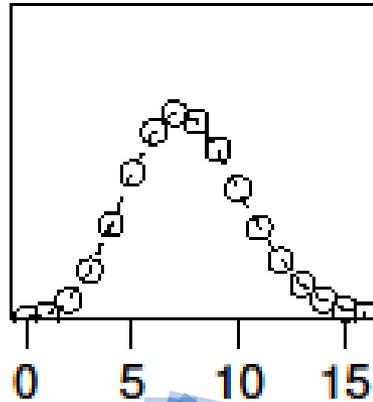
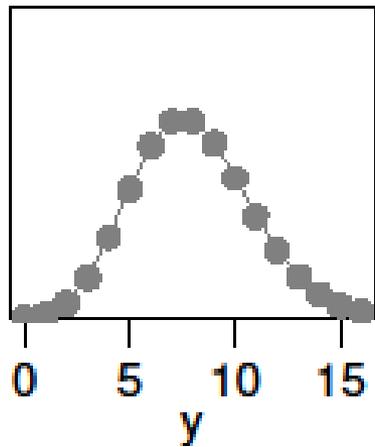


推定用の観測データ

4.5 なぜAICでモデル選択してよいのか？

(人間には見えない)
真の統計モデル

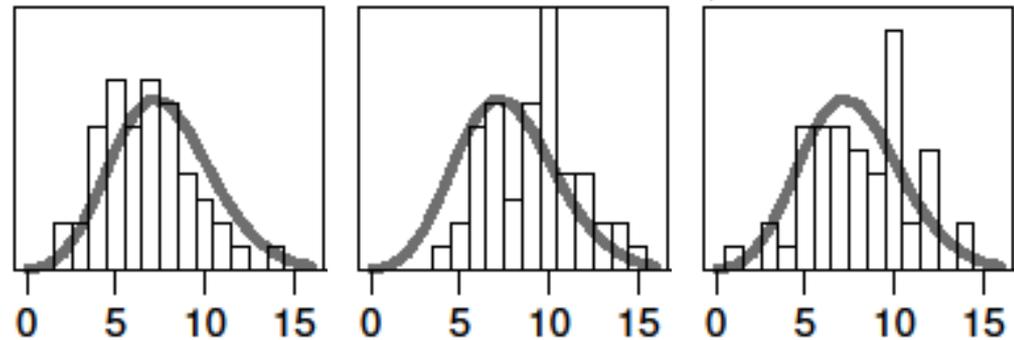
$\beta_1 = 2.08$ のポアソン分布



観測データから
推定された一定モデル
 $\beta_1 = 2.04$ のポアソン分布

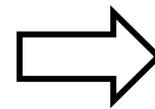
評価用のデータにあてはめると
平均対数尤度 $E(\log L)$ が得られる

データを
サンプリング
(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)

200個の対数尤度の平均



平均対数尤度
 $E(\log L)$

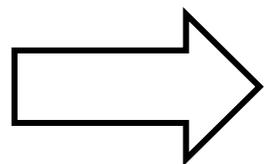
...

4.5 なぜAICでモデル選択してよいのか？

平均対数尤度 $E(\log L)$ は
統計モデルの良さの指標として適当！

しかしながら現実のデータ解析では

真の統計モデルが不明

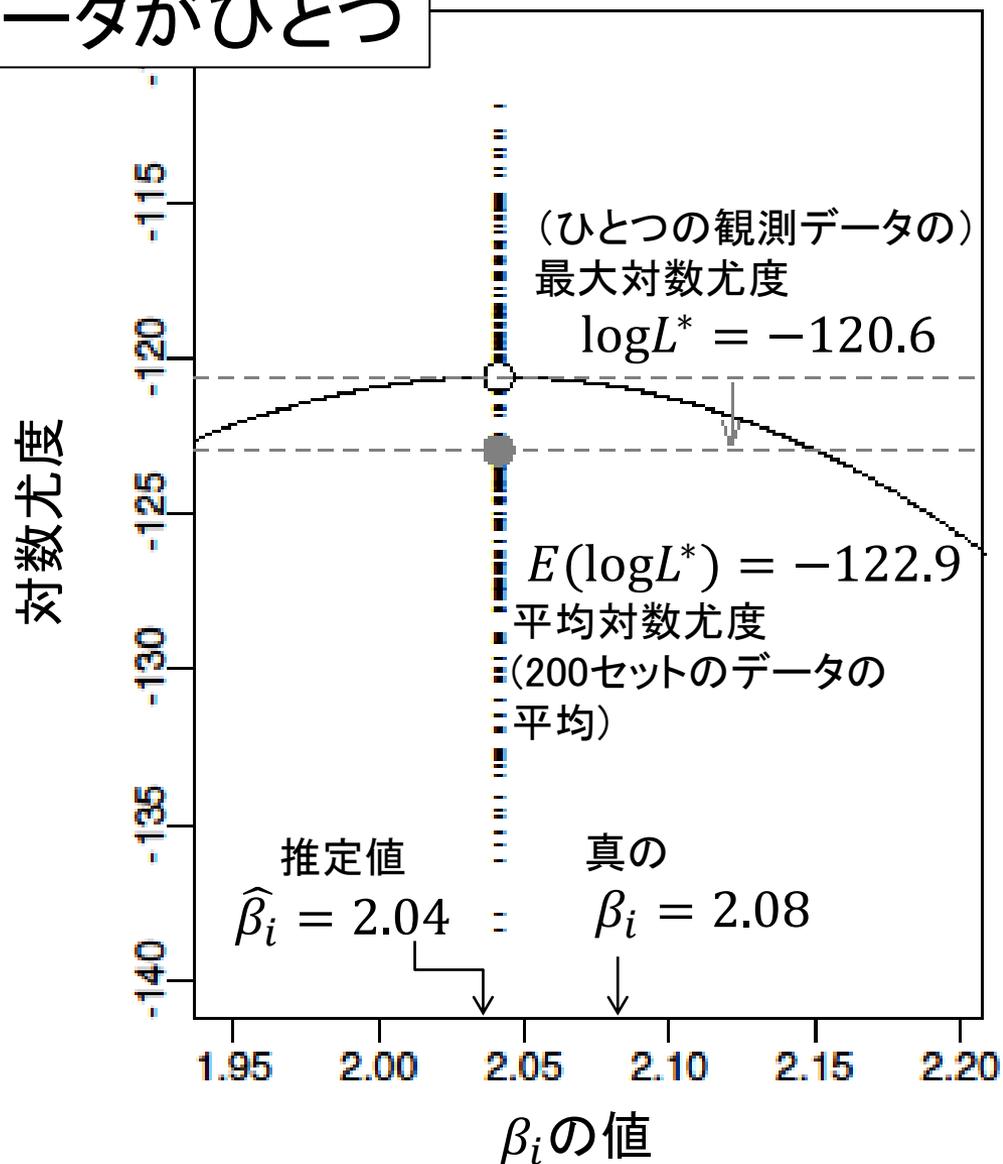


平均対数尤度もわからない…

なにか工夫が必要

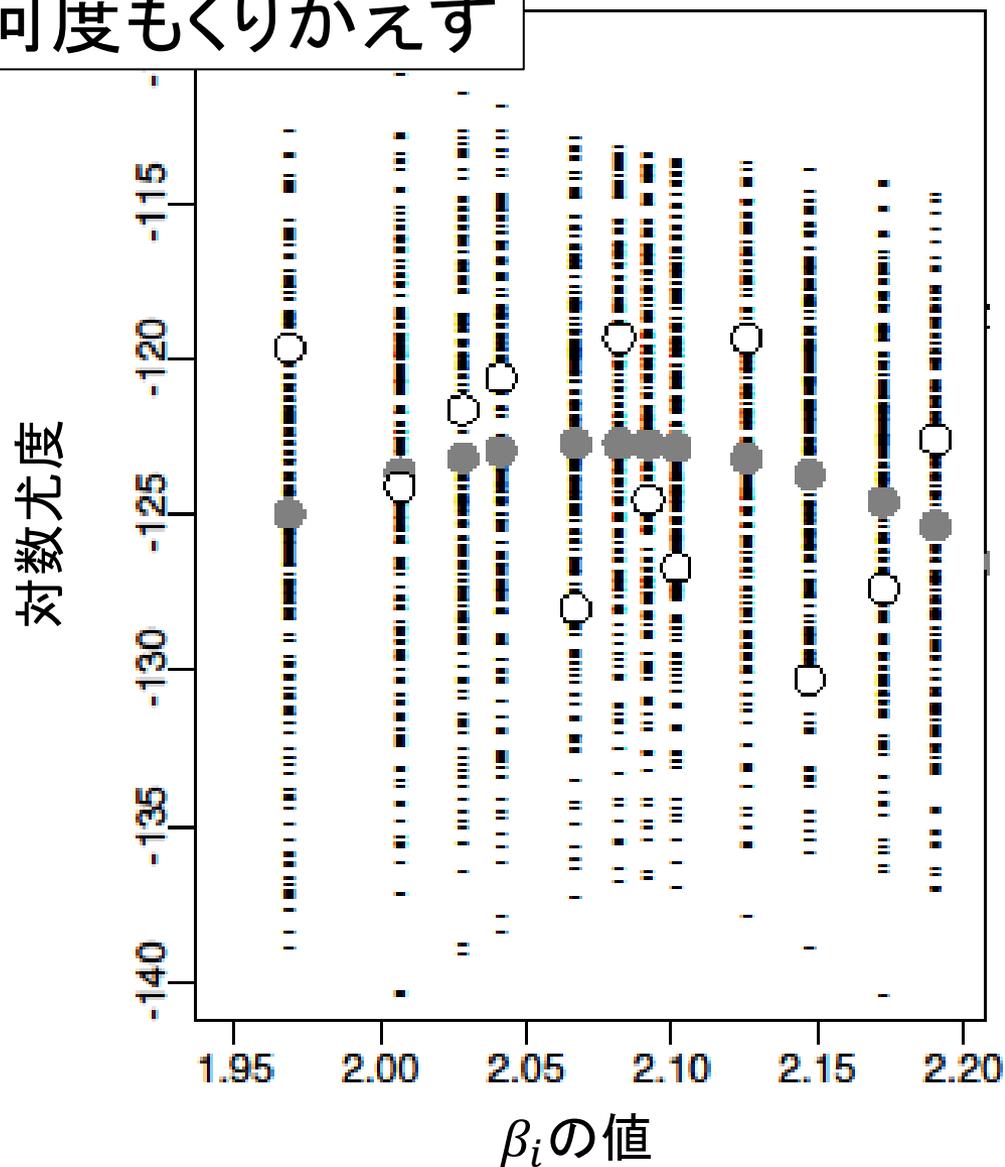
4.5 なぜAICでモデル選択してよいのか？

(A) 観測データがひとつ



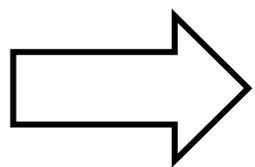
4.5 なぜAICでモデル選択してよいのか？

(B)(A)を何度もくりかえす



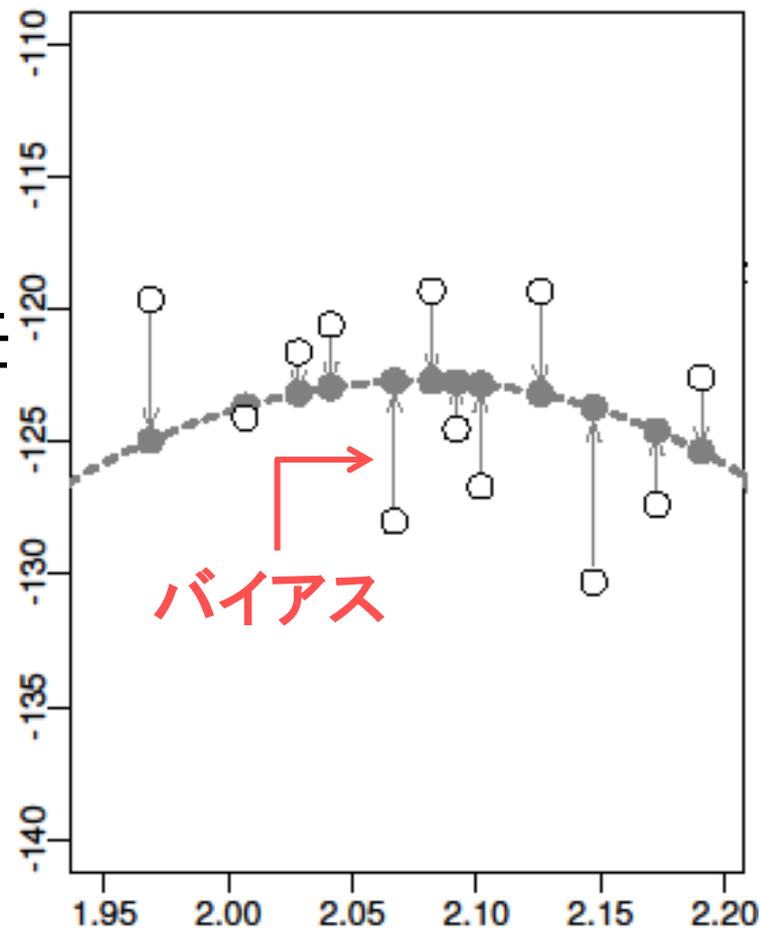
4.5 なぜAICでモデル選択してよいのか？

最大対数尤度と平均対数尤度の差



バイアス

$$b = \log L^* - E(\log L)$$

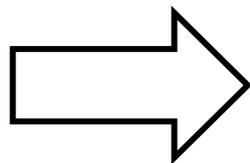


4.5 なぜAICでモデル選択してよいのか？

この式を変形すると $E(\log L) = \log L^* - b$

すなわち…

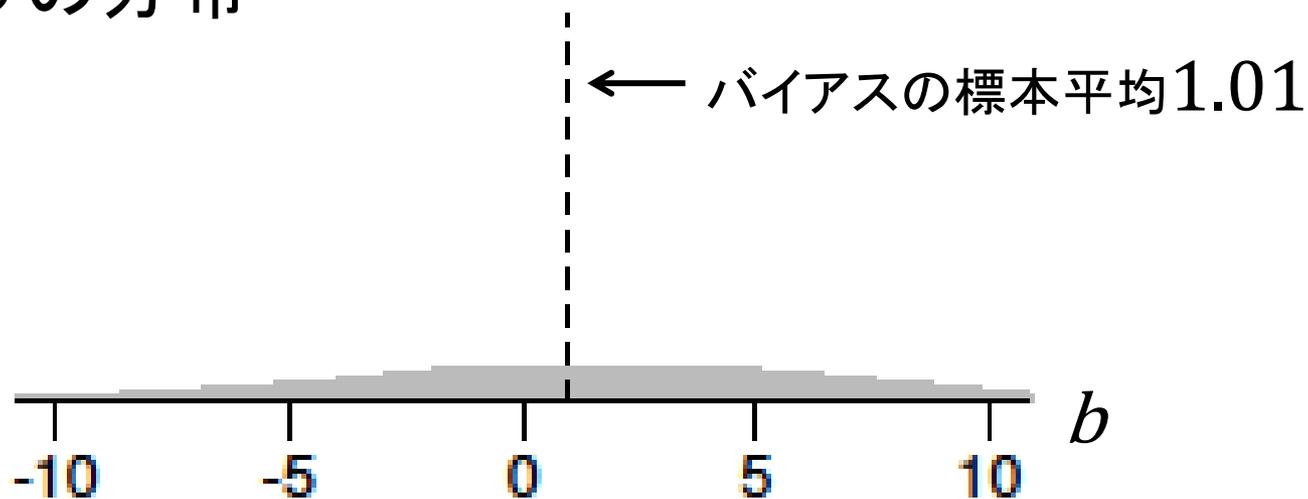
平均的な b と最大対数尤度 $\log L^*$ の値がわかれば
平均対数尤度 $E(\log L)$ の推定値が得られるはず



バイアス補正

4.5 なぜAICでモデル選択してよいのか？

バイアス b の分布



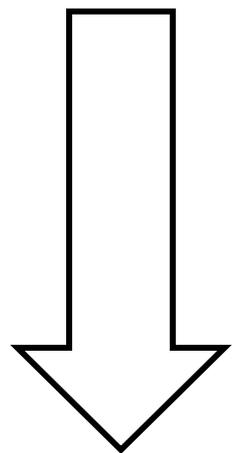
- ・平均バイアスがおおよそ1くらい

$$\therefore E(\log L) = \log L^* - 1$$

4.5 なぜAICでモデル選択してよいのか？

パラメーター数 k のモデルの平均対数尤度は

$$E(\log L) = \log L^* - k \quad \text{といわれている}$$



※一定モデルでは $k = 1$ なので

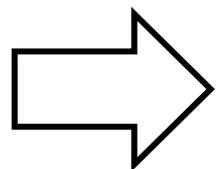
$$E(\log L) = \log L^* - 1$$

これに -2 をかけたものが**AIC**！

$$\text{AIC} = -2 \times (\log L^* - k)$$

一番適しているのはどのモデル？

AIC、すなわち「予測の良さ」をみればよい



- ・AICは平均対数尤度の推定値
(バイアス補正によって評価)
- ・モデルの複雑さを考慮している