

## 研究題目

統計モデルの基礎とその応用—Rを利用した解析例

指導教員

今野 良彦

上田 亜衣      小野澤 良子      数馬 早紀      小菅 奈奈

鈴木 菜つ美      樽木 美里      半藤 雅子      六川 咲美

## 発表内容

☆ R

☆ 統計モデル

☆ 新記録の誕生と競技水準の向上

☆ O —157 による集団食中毒

☆ 今後の課題

## ☆R とは

- データを効率的に操作し、保管する機能
- 配列と行列の計算のための演算子セット
- データ解析のための道具の大規模で一貫した集まり
- データ解析のためのグラフィカルな機能と画面または、印刷物へ出力
- 条件分岐、ループ、ユーザー定義の再帰的関数や入出力機能を含む、効果的なプログラミング言語



## ☆統計的な手法

- 記述統計的な手法
- 推測統計的な手法

## ☆統計モデルとは

データの背後に確率的な構造を考え、それを分析するのが推測統計的な手法であり、データの背後に想定される確率的な構造のこと

## 新記録の誕生と競技水準の向上

②

帰無仮説  $H_0$  : 競技の水準に変化がなく、各年の最高記録  
が同じ分布に従う

$k$  年目の最高記録が新記録である場合の確率変数を 1、  
新記録でない場合の確率変数の値を 0 とする。

### 確率変数

$$X_k = \begin{cases} 1、k\text{年目の1年間の最高記録が新記録である} \\ 0、k\text{年目の1年間の最高記録が新記録でない} \end{cases}$$

帰無仮説  $H_0$  の下では  $X_1$  から  $X_k$  は互いに独立で、

$$\Pr\{X_k = 1\} = \frac{1}{k}$$

$$\Pr\{X_k = 0\} = 1 - \frac{1}{k}$$

$n$  年間の新記録の数  $S_n$

$$S_n = X_1 + X_2 + \cdots + X_n$$

とする。

n=4



↓ : 新記録誕生時

1年目：新記録の数 = 1

2年目：新記録の数 = 1

3年目：新記録の数 = 0

4年目：新記録の数 = 2

$X_k = \begin{cases} 1, & k\text{年目の1年間の最高記録が新記録である} \\ 0, & k\text{年目の1年間の最高記録が新記録でない} \end{cases}$

上のグラフをこの確率変数で表すと

$X_1 = 1, X_2 = 1, X_3 = 0, X_4 = 1$  となる.

この4年間の新記録の数： $S_4$ は、次のように計算する.

$$\begin{aligned} S_4 &= X_1 + X_2 + X_3 + X_4 \\ &= 1 + 1 + 0 + 1 \\ &= 3 \end{aligned}$$

グラフから読み取れる新記録の数：4

$S_4$ の値：3

“同じ年に新記録が複数出ても,その一年間の最高記録を,その年の新記録と見ていくので,新記録の数は1つとみなす!!”  
 $S_n$ の確率分布は次のようにして求める.

④

$$p(q, n) = \Pr\{S_n = q\}$$

とおく.

$$\{S_n = q\} = \{S_{n-1} = q-1 \text{ かつ } X_n = 1\} \cup \{S_{n-1} = q \text{ かつ } X_n = 0\} \quad (1.1)$$

より,  $n$  年間で  $q$  回新記録を出した確率の関係式

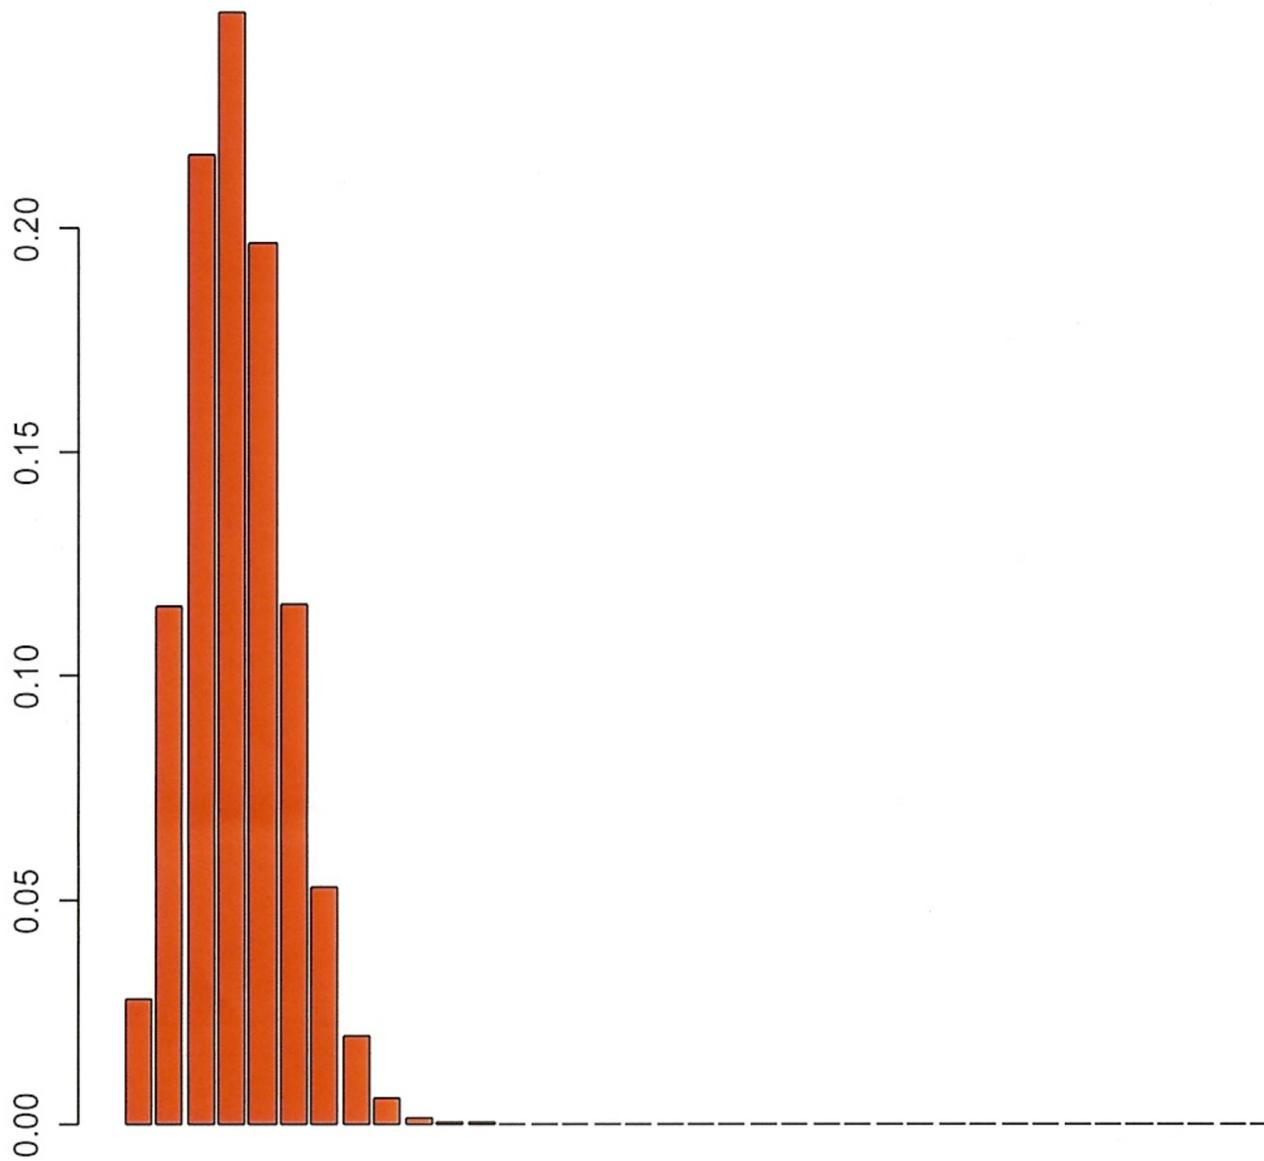
$$p(q, n) = \frac{1}{n} p(q-1, n-1) + \frac{n-1}{n} p(q, n-1)$$
$$q = 1, 2, \dots, n; n = 2, 3, \dots$$

最初の年の最高記録が新記録である確率

$$p(1, 1) = 1$$

36 年間の新記録の確率分布

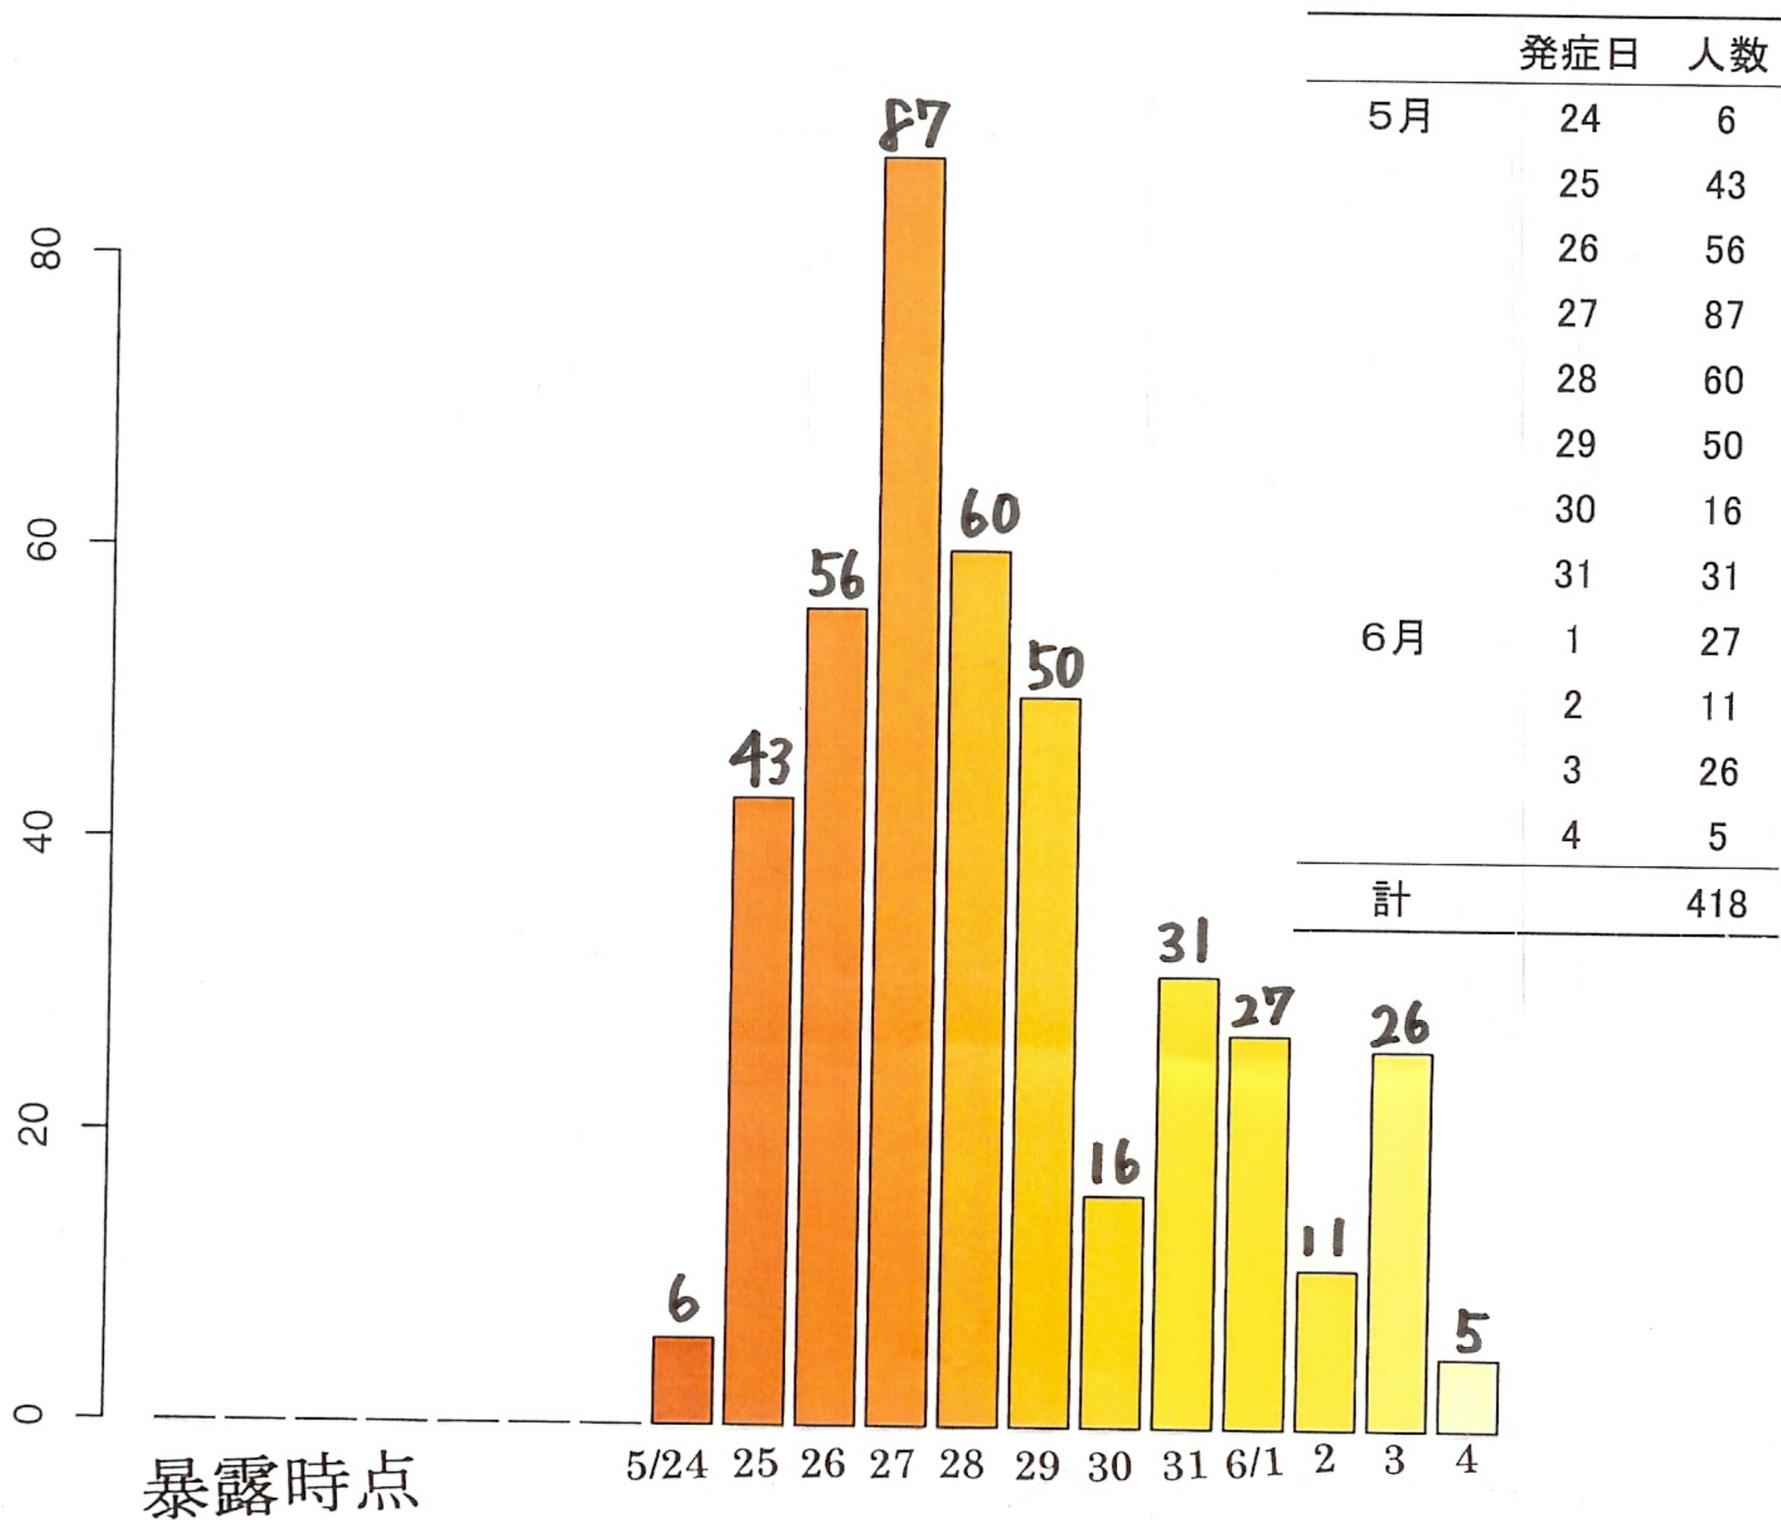
⑤



$S_n$ の値	1	2	3	4	5	6	7	8 以上
確率	0.028	0.115	0.216	0.248	0.197	0.116	0.053	0.027

6

女子1500m世界記録		
結果	データ	$X_k$
4:17.3 03	1967年6月	$X_1=1$
4:15.6 24	1967年10月	
4:12.4 02	1969年7月	$X_3=1$
4:10.7 20	1969年9月	
4:09.6 15	1971年8月	$X_5=1$
4:06.9 18	1972年7月	$X_6=1$
4:06.5 04	1972年9月	
4:05.1 07	1972年9月	
4:01.4 09	1972年9月	
3:56.0 28	1976年6月	$X_{10}=1$
3:55.0 06	1980年7月	$X_{13}=1$
3:52.47 13	1980年8月	
3:50.46 11	1993年9月	$X_{26}=1$



γ

図 2. 1

O-157:H7 による集団食中毒における発症日別度数分布

$\gamma$  : 一斉に暴露した時点

$x_i, i = 1, \dots, n$  :  $i$  番目の食中毒患者の症状の発生時点

尤度関数は、

$$L(\gamma, \mu, \sigma^2) = \prod_{i=1}^n f(x_i; \gamma, \mu, \sigma^2) \quad (x_i > \gamma)$$

$$= (2\pi\sigma^2)^{-\frac{n}{2}} \prod_{i=1}^n (x_i - \gamma)^{-1} \cdot \exp\left[-\frac{1}{2} \sum_{i=1}^n \left\{ \frac{\log(x_i - \gamma) - \mu}{\sigma} \right\}^2\right]$$

$$l(\gamma, \mu, \sigma^2) = \log L(\gamma, \mu, \sigma^2) \quad \dots (2. 1)$$

対数尤度関数の偏微分を計算した連立方程式

$$\frac{\partial l}{\partial \gamma} = \frac{\partial l}{\partial \mu} = \frac{\partial l}{\partial \sigma^2} = 0 \quad \dots (2. 2)$$

$\gamma$  を所与としたときの、 $\mu$  と  $\sigma^2$  の最尤推定量

$$\hat{\mu}(\gamma) = \frac{1}{n} \sum_{i=1}^n \log(x_i - \gamma) \quad \dots (2. 3)$$

$$\hat{\sigma}^2(\gamma) = \frac{1}{n} \sum_{i=1}^n \{ \log(x_i - \gamma) - \hat{\mu}(\gamma) \}^2 \quad \dots (2. 4)$$

プロフィール対数尤度 :

$$l^{**}(\gamma) = n (\hat{\mu}(\gamma) + \log \hat{\sigma}(\gamma)) - \frac{n}{2} (1 + \log \pi) \quad \dots (2. 5)$$

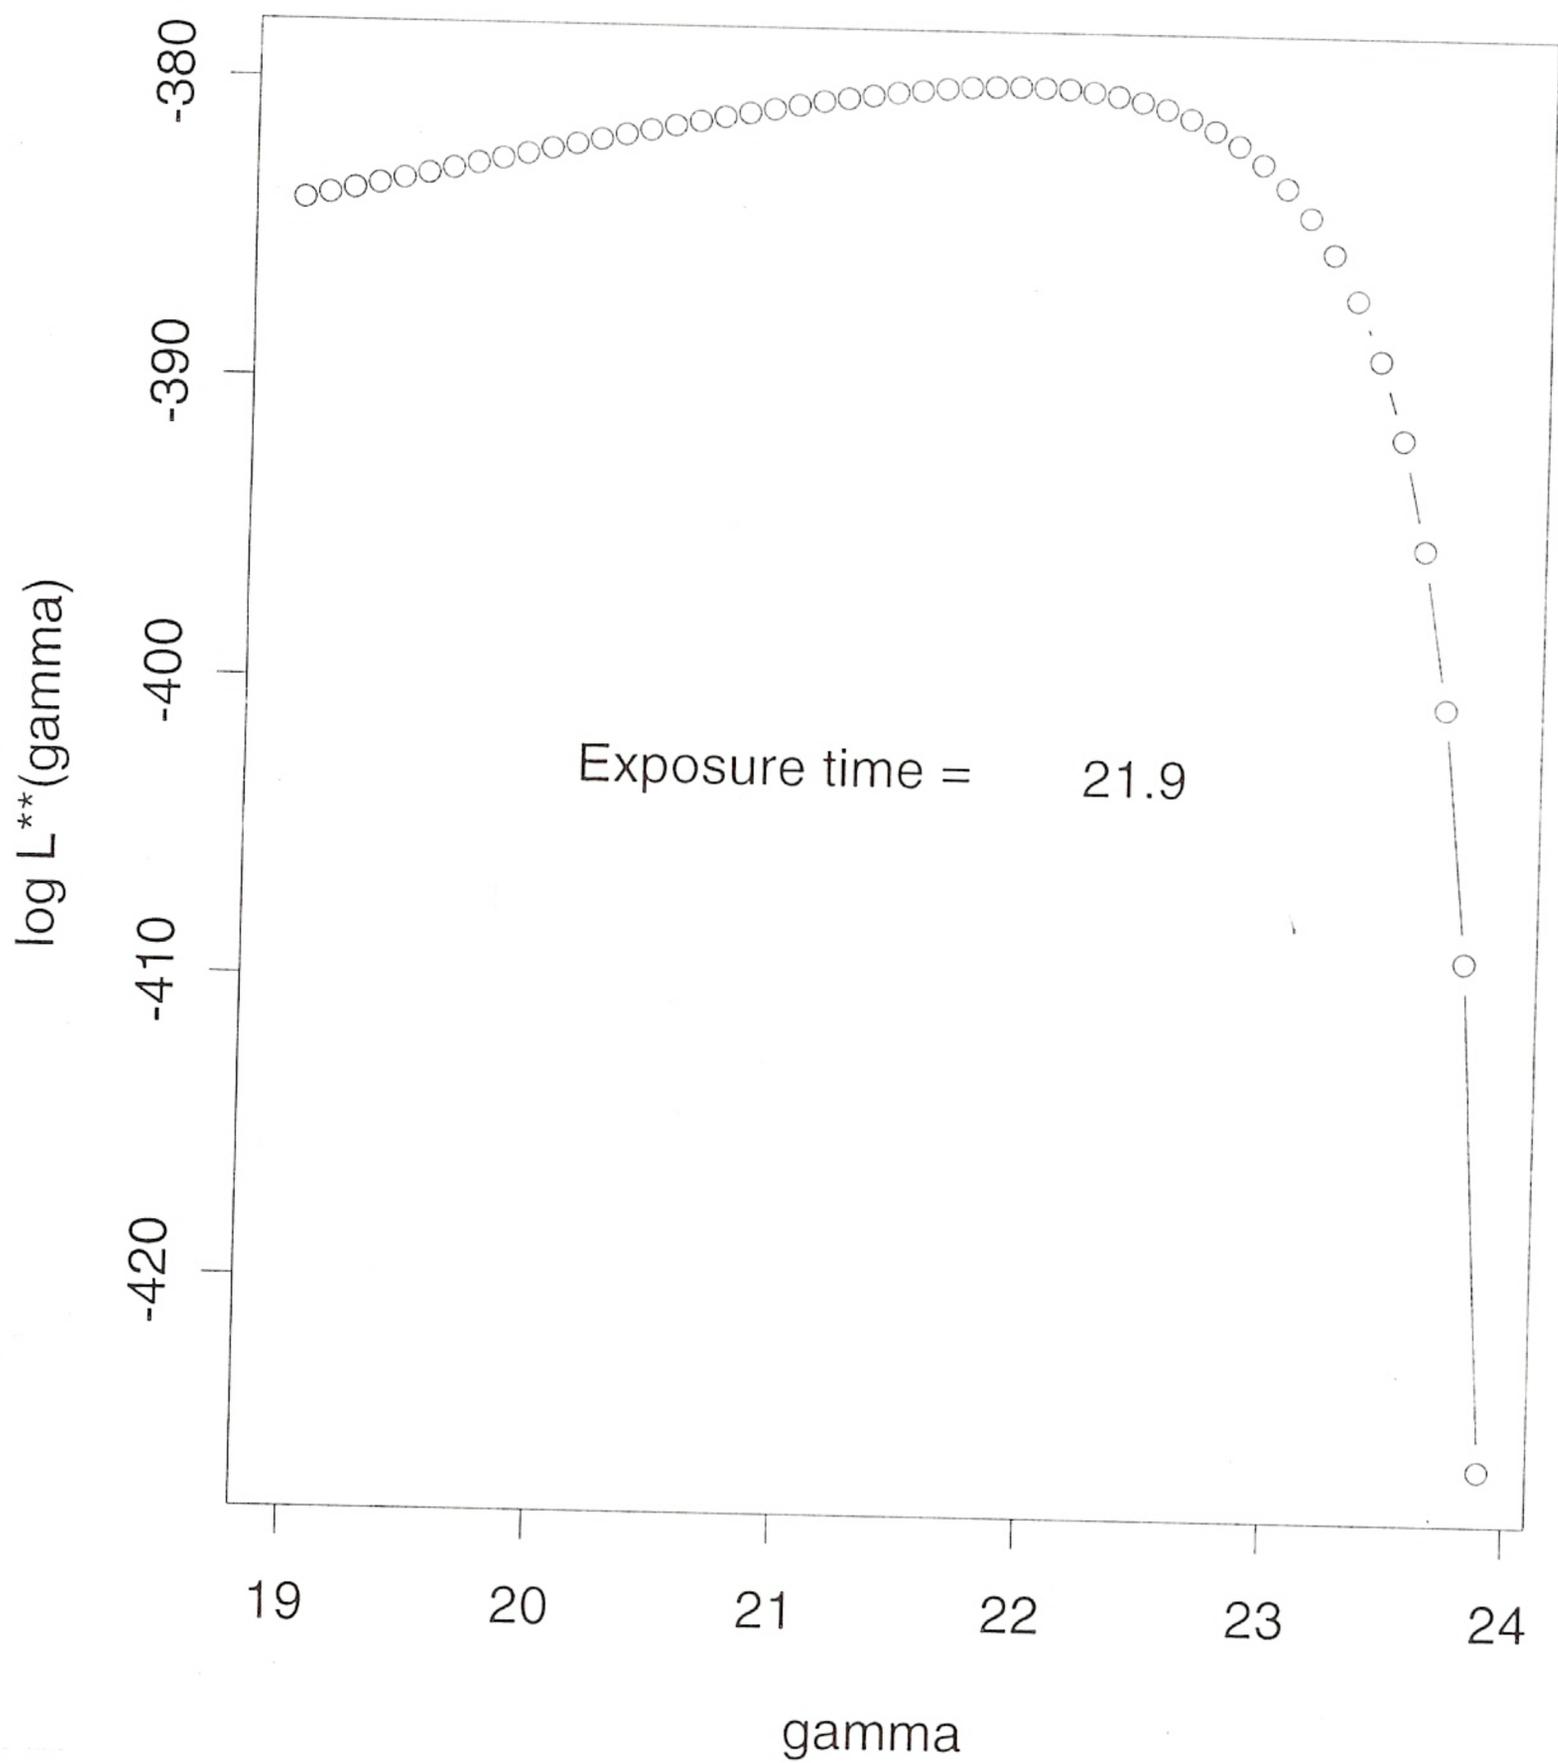


図 2. 2

数値列  $\gamma = \frac{j}{10}$  ( $j = 190, 191, \dots, 239$ ) における図 2. 1 のデータの  
プロフィール対数尤度  $l^{**}(\gamma)$  と推定値