

『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』

～読書会～

2章 確率分布と統計モデルの最尤推定



2 確率分布と統計モデルの最尤推定

2.1 例題: 種子数の統計モデリング

2.2 データと確率分布の対応関係をながめる

2.3 ポアソン分布とは何か？

2.4 ポアソン分布のパラメーターの最尤推定

2.4.1 擬似乱数と最尤推定値のばらつき

2.5 統計モデルの要点: 乱数発生・推定・予測

2.5.1 データ解析における推定・予測の役割

2.6 確率分布の選びかた

2.6.1 もっと複雑な確率分布が必要か？

2.7 この章のまとめと参考文献


確率分布 probability distribution

- ・ 統計モデルの本質的な部品
- ・ データにみられるさまざまな「ばらつき」

例題データと確率分布の対応づけ

2.1 例題: 種子数の統計モデリング

個体 i



種子数 y_i

$\left\{ \begin{array}{l} 0, 1, 2, \dots : \text{カウントデータ} \\ \text{非負の整数} \end{array} \right.$

➡ 確率分布を選ぶときの手がかり

2.1 例題: 種子数の統計モデリング

Courier New

```
load("data.RData")
```

```
# ダウンロードしたデータファイルを読み込む
```

```
data
```

```
# 「data」という名前のデータの内容を表示
```

```
length(data)
```

```
# dataにはいくつのデータが含まれるのか
```

2.1 例題: 種子数の統計モデリング


```
summary(data)  
# dataを要約せよ
```

• Min.	最小値	}	四分位数 ↓ 箱ひげ図
• Max.	最大値		
• 1st Qu.	25 %点の値		
• Median	50 %点の値 (標本中央値)		
• 3rd Qu.	75 %点の値		
• Mean	標本平均		

重要なのは、まず様々な方法で図示すること

2.1 例題: 種子数の統計モデリング

`boxplot(data)`




2.1 例題: 種子数の統計モデリング

```
table(data)
```

```
# 度数分布表を得る
```

```
hist(data, breaks = seq(-0.5, 9.5, 1))
```

```
# ヒストグラムを図示
```



2.1 例題: 種子数の統計モデリング

```
var(data)  
# 標本分散を得る
```

標本分散 sample variance
= データのばらつき variability

```
sd(data)  
sqrt(var(data))  
# 標本標準偏差を得る
```

標本標準偏差 sample standard deviation

2.2 データと確率分布の対応関係をながめる

- ・ 0, 1, 2, ... : カウントデータ
- ・ 1個体の種子数の標本平均は3.56個
- ・ 個体ごとの種子数にばらつきあり、
ヒストグラムはひと山分布

➡ **ポアソン分布** (確率分布) が便利
Poisson distribution

2.2 データと確率分布の対応関係をながめる

確率分布

確率変数の値とそれが出現する確率を対応させたもの

確率変数 random variable

ある植物個体 i の種子数 y_i のように、個体ごとにばらつく変数

2.2 データと確率分布の対応関係をながめる


「平均3.56のポアソン分布」 とは？

```
y <- 0:9
prob <- dpois(y, lambda = 3.56)
# 「平均3.56のポアソン分布にしたがって、ある個
# 体の種子数がy個である確率」
```

```
cbind(y, prob)
# 表形式で出力 丸と折れ線
plot(y, prob, type = "b", lty = 2)
# 図形式で出力 破線
```

2.2 データと確率分布の対応関係をながめる

```
hist(data, breaks = seq(-0.5, 9.5, 1))  
# ヒストグラムを図示  
lines(y, 50 * prob, type = "b", lty = 2)  
# 予測値 (prob) を描画
```



観察されたばらつきがポアソン
分布で表現できているみたいだ
なあ

2.3 ポアソン分布とは何か？

ポアソン分布の定義

$$p(y|\lambda) = \frac{\lambda^y \exp(-\lambda)}{y!}$$

平均が λ であるとき、ポアソン分布にしたがう
確率変数が y という値になる確率

平均 λ ：ポアソン分布の唯一のパラメーター

2.3 ポアソン分布とは何か？

ポアソン分布の性質

- ・ $y \in \{0, 1, 2, \dots, \infty\}$ の値をとり、すべての y について和をとると1になる

$$\sum_{y=0}^{\infty} p(y|\lambda) = 1$$

- ・ 確率分布の平均は λ である ($\lambda \geq 0$)
- ・ 分散と平均は等しい： $\lambda = \text{平均} = \text{分散}$

2.3 ポアソン分布とは何か？

ばらつき = 誤差 error

個体ごとの種子数が同一の確率分布にしたがっている場合でも、なんらかの理由で個体ごとに異なる種子数になっている

調査している人の間違い（測定誤差）ではない

2.4 ポアソン分布のパラメーターの最尤推定

最尤推定 maximum likelihood estimation

尤度（あてはまりの良さ）を最大にする
ようなパラメーターの値を探す

尤度

ある λ の値を決めたときに、すべての個体 i
についての $p(y_i|\lambda)$ の積

$$L(\lambda) = \prod_i p(y_i|\lambda) = \frac{\lambda^{y_i} \exp(-\lambda)}{y_i!}$$

$$\log L(\lambda) = \sum_i \left(y_i \log \lambda - \lambda - \sum_k^{y_i} \log k \right)$$

2.4 ポアソン分布のパラメーターの最尤推定

対数尤度関数を使ってパラメータを最尤推定する


```
logL <- function(m) sum(dpois(data, m,  
log = TRUE))
```

```
lambda <- seq(2, 5, 0.1)
```

```
plot(lambda, sapply(lambda, logL),  
type = "l")
```

対数尤度と λ の関係を図示

2.4 ポアソン分布のパラメーターの最尤推定



対数尤度関数が最大値で関数の傾きがゼロになる λ を探せばよい

2.4 ポアソン分布のパラメーターの最尤推定

対数尤度関数

$$\log L(\lambda) = \sum_i \left(y_i \log \lambda - \lambda - \sum_k^{y_i} \log k \right)$$

パラメーター λ で偏微分すると、

$$\frac{\partial \log L(\lambda)}{\partial \lambda} = \sum_i \left\{ \frac{y_i}{\lambda} - 1 \right\} = \frac{1}{\lambda} \sum_i y_i - 50$$

これがゼロである場合、

$$\hat{\lambda} = \frac{1}{50} \sum_i y_i = \frac{\text{全部の } y_i \text{ の和}}{\text{データ数}} = \text{データの標本平均} = 3.56$$

2.4 ポアソン分布のパラメーターの最尤推定

最尤推定量 maximum likelihood estimator


対数尤度あるいは尤度が最大になる $\hat{\lambda}$

最尤推定値 maximum likelihood estimate

具体的な y_i の値を使って評価された

$$\hat{\lambda} = 3.56$$

2.5 統計モデルの要点：乱数発生・推定・予測



2.5 統計モデルの要点：乱数発生・推定・予測

統計モデルを使った予測

- ・次に得られる応答変数の平均だけを示す
- ・次に得られるデータの予測区間も示す

時系列構造のあるデータ ➡ 将来予測

空間構造のあるデータ ➡ 欠測データの補間

2.5 統計モデルの要点：乱数発生・推定・予測

予測の良さ goodness of prediction

推定されたモデルが新しく得られたデータ
にどれくらい良くあてはまるか

2.6 確率分布の選びかた

「この現象がどのような確率分布で説明されそうか」

- ・ 説明したい量は離散か連続か？
- ・ 説明したい量の範囲は？
- ・ 説明したい量の標本分散と標本平均の関係は？

2.6 確率分布の選びかた

確率分布の種類

- **ポアソン分布 poisson distribution**
データが離散値、ゼロ以上で上限なし、平均 $\approx$ 分散
- **二項分布 binomial distribution**
データが離散値、ゼロ以上で有限の範囲、分散は平均の関数
- **正規分布 normal distribution**
データが連続値、範囲が $[-\infty, +\infty]$ 、分散は平均とは無関係に決まる
- **ガンマ分布 gamma distribution**
データが連続値、範囲が $[0, +\infty]$ 、分散は平均の関数
- **一様分布 uniform distribution**
データが連続かつ有限

2.7 この章のまとめと参考文献

「ブラックボックスな統計解析」から脱するために、まず、「この統計モデリングでは、このような理由でこの確率分布を使いました」と他人にきちんと説明できるようになってください。