

統計モデリング入門 2017 (e)

GLM logistic regression
一般化線形モデル: ロジスティック回帰

久保拓弥 kubo@ees.hokudai.ac.jp

靈長研の集中講義 <http://goo.gl/76c4i>

2017-06-21

ファイル更新時刻: 2017-11-07 15:46

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 1 / 47

もくじ

今日のハナシ I

- ① “ N 個のうち y 個が生きてる” タイプのデータ
count data or categorical data with upper bound
上限のあるカウントデータ
logistic regression
- ② ロジスティック回帰 の部品
二項分布 binomial distribution と logit link function
interaction term
- ③ ちょっとだけ 交互作用項 について
complicate terms in linear predictor
線形予測子の中の複雑な項
NEVER $\text{data} \div \text{data}$!
- ④ 何でも「割算」するな!
use GLM with offset term
「脱」割算の offset 項わざ

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 2 / 47

もくじ

今日の内容と「統計モデリング入門」との対応

<http:// goo.g1/Ufq2>

今日はおもに「**第 6 章 GLM の応用範囲をひろげる**」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

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
久保拓弥
岩波書店

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 3 / 47

もくじ

statisticaal models appeared in the class
この授業であつかう統計モデルたち

The development of linear models

```

graph TD
    LM[Linear model] -- "Always normal distribution? That's non-sense!" --> GLM[Generalized Linear Model]
    GLM -- "MLE" --> GLMM[Generalized Linear Mixed Model]
    GLMM -- "Incorporating random effects such as individuality" --> HBM[Hierarchical Bayesian Model]
    HBM -- "Be more flexible" --> GLM
    style GLM fill:#ffffcc
    style GLMM fill:#ffffcc
    style HBM fill:#ffffcc
  
```

Kubo Doctrine: “Learn the evolution of linear-model family, firstly!”

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 4 / 47

もくじ

一般化線形モデルって何だろう?

Generalized Linear Model

一般化線形モデル (GLM)

- ポアソン回帰 (Poisson regression)
- ロジスティック回帰 (logistic regression)
- 直線回帰 (linear regression)
-

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 5 / 47

もくじ

一般化線形モデルを作る

Generalized Linear Model

一般化線形モデル (GLM)

probability distribution

- 確率分布は?
- 線形予測子は?
link function
- リンク関数は?

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 6 / 47

もくじ

how to specify Poisson regression model, a GLM
GLM のひとつであるポアソン回帰モデルを指定する

ポアソン回帰のモデル

probability distribution Poisson distribution
 • 確率分布 : ポアソン分布
 linear predictor
 • 線形予測子: e.g., $\beta_1 + \beta_2 x_i$
 link function log link function
 • リンク関数: 対数リンク関数

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 7 / 47

もくじ

how to specify logistic regression model, a GLM
GLM のひとつである logistic 回帰モデルを指定する

ロジスティック回帰のモデル

probability distribution binomial distribution
 • 確率分布 : 二項分布
 linear predictor
 • 線形予測子: e.g., $\beta_1 + \beta_2 x_i$
 link function
 • リンク関数: logit リンク関数

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 8 / 47

“N 個のうち y 個が生きてる” タイプのデータ 上限のあるカウントデータ

1. “N 個のうち y 個が生きてる” タイプのデータ

count data or categorical data with upper bound
上限のあるカウントデータ

$y_i \in \{0, 1, 2, \dots, 8\}$

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 9 / 47

“N 個のうち y 個が生きてる” タイプのデータ 上限のあるカウントデータ

またいつもの例題? ちょっとちがう

8 個の種子のうち y 個が 発芽可能 だった! というデータ

個体 i
 seeds
 肥料 f_i
 C: 肥料なし
 T: 肥料あり
 生存種子数 $y_i = 3$
 生存種子 (alive) は
 死亡種子 (dead) は
 体サイズ x_i

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 10 / 47

“N 個のうち y 個が生きてる” タイプのデータ 上限のあるカウントデータ

Reading data file

データファイルを読みこむ

data4a.csv は CSV (comma separated value) format file なので, R で読みこむには以下のようにする:

```
> d <- read.csv("data4a.csv")
```

OR

```
> d <- read.csv(  
+ "http://hoshio.ees.hokudai.ac.jp/~kubo/stat/2015/Fig/binomial/data4a.csv")
```

データは d と名付けられた data frame (「表」みたいなもの) に格納される

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 11 / 47

“N 個のうち y 個が生きてる” タイプのデータ 上限のあるカウントデータ

data frame d を調べる

```
> summary(d)
```

	N	y	x	f
Min.	:8	Min. :0.00	Min. : 7.660	C:50
1st Qu.	:8	1st Qu.:3.00	1st Qu.: 9.338	T:50
Median	:8	Median :6.00	Median : 9.965	
Mean	:8	Mean :5.08	Mean : 9.967	
3rd Qu.	:8	3rd Qu.:8.00	3rd Qu.:10.770	
Max.	:8	Max. :8.00	Max. :12.440	

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 12 / 47

“ N 個のうち y 個が生きてる” タイプのデータ
上限のあるカウントデータ

まずはデータを図にしてみる

```
> plot(d$x, d$y, pch = c(21, 19)[d$f])
> legend("topleft", legend = c("C", "T"), pch = c(21, 19))
```

fertilization effective
今回は 施肥処理 がきいている?

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 13 / 47

ロジスティック回帰 の部品 二項分布 binomial distribution と logit link function

logistic regression
2. ロジスティック回帰 の部品

二項分布 binomial distribution と logit link function

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 14 / 47

ロジスティック回帰 の部品 二項分布 binomial distribution と logit link function

binomial distribution
二項分布 : N 回のうち y 回, となる確率

$$p(y | N, q) = \binom{N}{y} q^y (1 - q)^{N-y}$$

$\binom{N}{y}$ は「 N 個の観察種子の中から y 個の生存種子を選びだす場合の数」

確率 $p(y_i | N, q)$

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 15 / 47

ロジスティック回帰 の部品 二項分布 binomial distribution と logit link function

logistic curve
ロジスティック曲線とはこういうもの

ロジスティック関数の関数形 (z_i : 線形予測子, e.g. $z_i = \beta_1 + \beta_2 x_i$)

$$q_i = \text{logistic}(z_i) = \frac{1}{1 + \exp(-z_i)}$$

```
> logistic <- function(z) 1 / (1 + exp(-z)) # 関数の定義
> z <- seq(-6, 6, 0.1)
> plot(z, logistic(z), type = "l")
```

確率 q

線形予測子 z

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 16 / 47

ロジスティック回帰 の部品 二項分布 binomial distribution と logit link function

β_1 and β_2 change logistic curve
パラメーターが変化すると.....

黒い曲線は $\{\beta_1, \beta_2\} = \{0, 2\}$. (A) $\beta_2 = 2$ と固定して β_1 を変化させた場合.
(B) $\beta_1 = 0$ と固定して β_2 を変化させた場合.

(A) $\beta_2 = 2$ のとき

(B) $\beta_1 = 0$ のとき

説明変数 x

確率 q

パラメーター $\{\beta_1, \beta_2\}$ や説明変数 x がどんな値をとっても確率 q は $0 \leq q \leq 1$ となる便利な関数

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 17 / 47

ロジスティック回帰 の部品 二項分布 binomial distribution と logit link function

logit link function

- logistic 関数

$$q = \frac{1}{1 + \exp(-(\beta_1 + \beta_2 x))} = \text{logistic}(\beta_1 + \beta_2 x)$$

- logit 変換

$$\text{logit}(q) = \log \frac{q}{1 - q} = \beta_1 + \beta_2 x$$

logit は logistic の逆関数, logistic は logit の逆関数
logit is the inverse function of logistic function, vice versa

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 18 / 47

ロジスティック回帰 の部屋 二項分布 binomial distribution と logit link function

R でロジスティック回帰 — β_1 と β_2 の最尤推定

(A) 例題データの一部 ($f_i = C$) (B) 推定されるモデル

```

logistic regression          MLE for  $\beta_1$  and  $\beta_2$ 
R でロジスティック回帰 —  $\beta_1$  と  $\beta_2$  の最尤推定

(A) 例題データの一部 ( $f_i = C$ )      (B) 推定されるモデル
  
```

```

> glm(cbind(y, N - y) ~ x + f, data = d, family = binomial)
...
Coefficients:
(Intercept)           x           fT
-19.536        1.952       2.022
  
```

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 19 / 47

ロジスティック回帰 の部屋 二項分布 binomial distribution と logit link function

統計モデルの予測: 施肥処理によって応答が違う

(A) 施肥処理なし ($f_i = C$) (B) 施肥処理あり ($f_i = T$)

生存種子数 y_i 植物の体サイズ x_i

生存種子数 y_i 植物の体サイズ x_i

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 20 / 47

ちょっとだけ 交互作用項 について 線形予測子の中の複雑な項

interaction term

3. ちょっとだけ 交互作用項 について

complicate terms in linear predictor
線形予測子の中の複雑な項

ロジスティック回帰を例に

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 21 / 47

ちょっとだけ 交互作用項 について 線形予測子の中の複雑な項

交互作用項とは何か?

$$\text{logit}(q) = \log \frac{q}{1-q} = \beta_1 + \beta_2 x + \beta_3 f + \beta_4 x f$$

... in case that $\beta_4 < 0$, sometimes it predicts ...

生存種子数 y 植物の体サイズ x

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 22 / 47

ちょっとだけ 交互作用項 について 線形予測子の中の複雑な項

in today's example no interaction effect
この例題データの場合, 交互作用はない

~~I $\text{glm}(y \sim x + f, \dots)$ $\text{glm}(y \sim x + f + x:f, \dots)$

(A) 交互作用のないモデル (B) 交互作用のあるモデル

生存種子数 y 植物の体サイズ x

生存種子数 y 植物の体サイズ x

little difference
差がほとんどない

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 23 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

NEVER data \div data!

4. 何でも「割算」するな!

use GLM with offset term
「脱」割算の offset 項わざ

ポアソン回帰を強めてみる

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 24 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

割算値ひねくるデータ解析はなぜよくないのか?

- 観測値 / 観測値 がどんな確率分布にしたがうのか見とおしが悪く、さらに説明要因との対応づけが難しくなる
- 情報が失われる: 「10 打数 3 安打」と「200 打数 60 安打」, 「どちらも 3 割バッター」と言ってよいのか?
- 割算値を使わないほうが見とおしのよい, 合理的なデータ解析ができる (今回の授業の主題)
- したがって割算値を使ったデータ解析は不利な点ばかり, そんなことをする必要性はどこにもない

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 25 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

避けられるわりざん

- 避けられる割算値
 - probability
 - 確率

例: N 個のうち y 個にある事象が発生する確率
use statistical model with binomial distribution
対策: ロジスティック回帰など二項分布モデルで
- indices such as densities
 - 密度などの指数

例: 人口密度, specific leaf area (SLA) など
use offset term! described later
対策: offset 項わざ — このあと解説!

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 26 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

unfortunately, sometimes fractions appear ... 避けにくいわりざん

hard to avoid ...

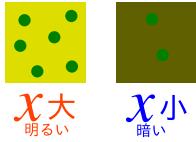
- 避けにくい割算値
 - outputs from some measuring machines
 - 測定機器が内部で割算した値を出力する場合
 - sometimes we have no choice but plot data/data values ...
 - 割算値で作図せざるをえない場合があるかも

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 27 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

example population densities in research plots offset 項の 例題 : 調査区画内の個体密度

light intensity index
何か架空の植物個体の密度が「明るさ」 x に応じてどう変わる
かを知りたい
light index
• 明るさ は $\{0.1, 0.2, \dots, 1.0\}$ の 10 段階で観測した

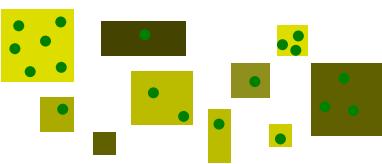


これだけなら単純に `glm(..., family = poisson)` とすればよいのだが

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 28 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

What? Differences in plot size?! 「場所によって調査区の面積を変えました」?!



- 明るさ x と面積 A を同時に考慮する必要あり
- ただし「密度 = 個体数 / 面積」といった割算値解析はやらない!
- `glm()` の offset 項わざでうまく対処できる
- ともあれその前に観測データを図にしてみる

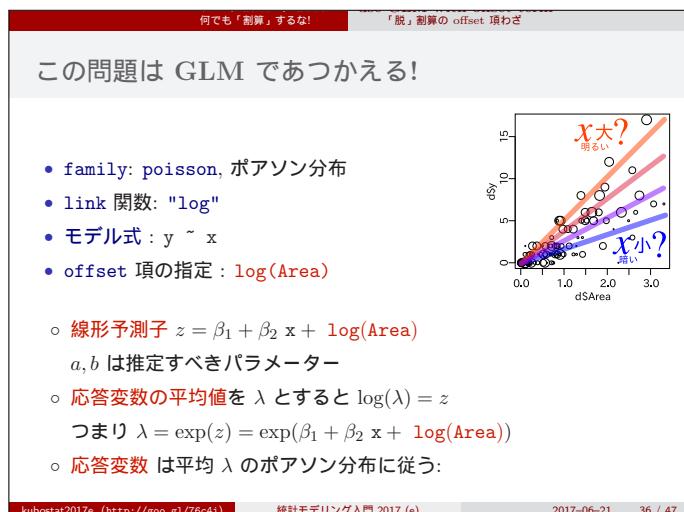
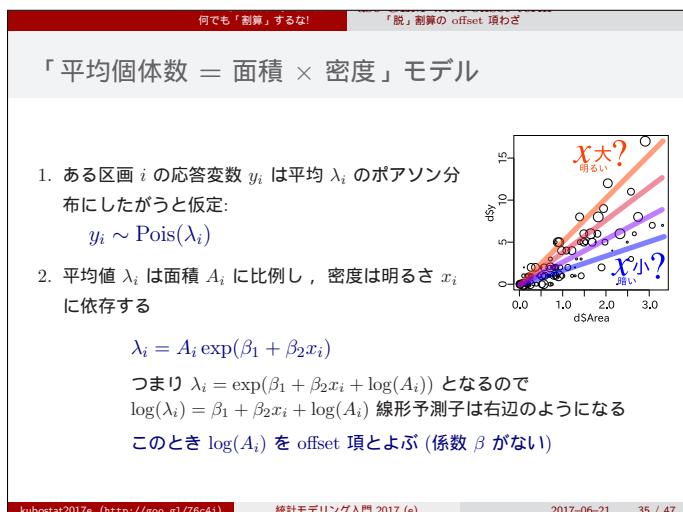
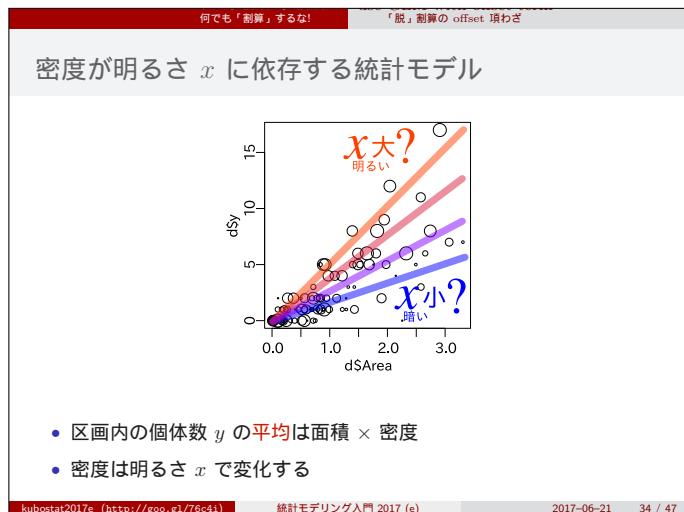
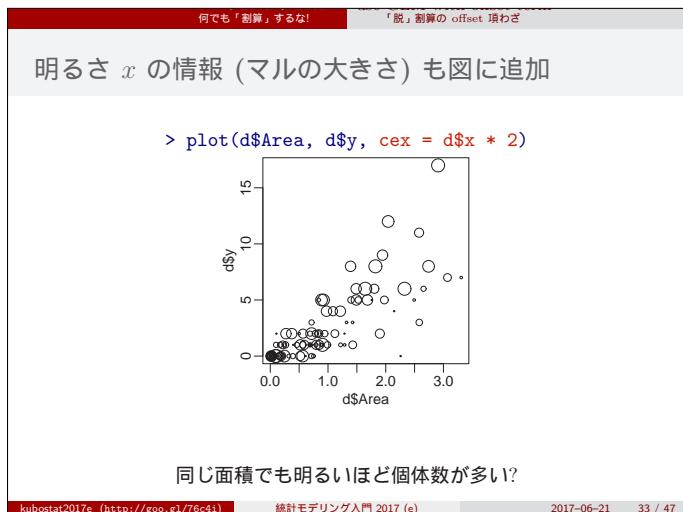
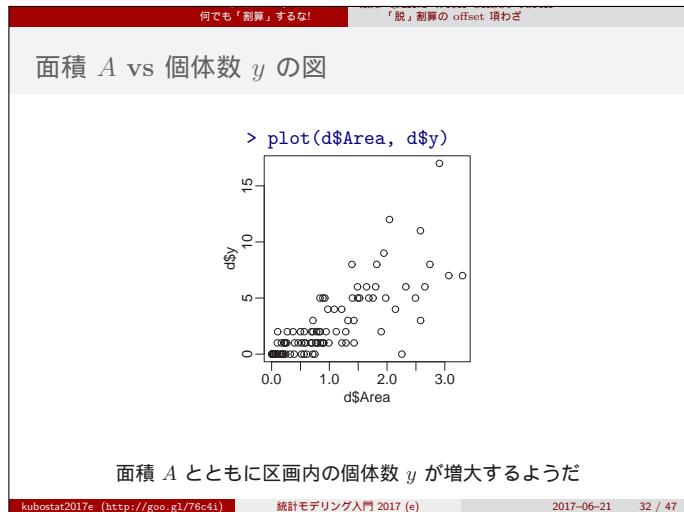
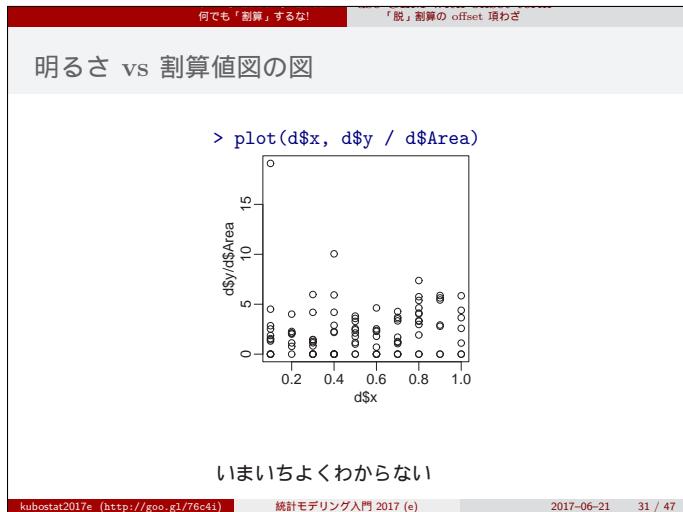
kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 29 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

light index number of plants R の data.frame: 面積 Area, 明るさ x, 個体数 y

```
> load("d2.RData")
> head(d, 8) # 先頭 8 行の表示
   Area   x   y
1  0.017249 0.5 0
2  1.217732 0.3 1
3  0.208422 0.4 0
4  2.256265 0.1 0
5  0.794061 0.7 1
6  0.396763 0.1 1
7  1.428059 0.6 1
8  0.791420 0.3 1
```

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 30 / 47



何でも「割算」するな! 「脱」割算の offset 項わざ

glm() 関数の指定

```

    fit <- glm(
      y ~ x,
      family = poission(link = "log"),
      data = d,
      offset = log(Area)
    )
  
```

結果を格納するオブジェクト
関数名
モデル式
確率分布の指定
リンク関数の指定（省略可）
offset の指定

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 37 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

R の glm() 関数による推定結果

```

> fit <- glm(y ~ x, family = poisson(link = "log"), data = d,
  offset = log(Area))
> print(summary(fit))

Call:
glm(formula = y ~ x, family = poisson(link = "log"), data = d,
  offset = log(Area))

(... 略...)

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept) 0.321     0.160   2.01    0.044
x           1.090     0.227   4.80  1.6e-06
  
```

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 38 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

Plotting the model prediction based on estimation 推定結果にもとづく予測を図にしてみる

$x = 0.9$
light environment
 $x = 0.1$
dark environment

- solid lines prediction
- dotted lines “true” model
- 破線はデータ生成時に指定した関係

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 39 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

まとめ: glm() の offset 項わざで「脱」割算

- 平均値が面積などに比例する場合は、この面積などを offset 項として指定する
- 平均 = 面積 × 密度、というモデルの密度を $\exp(\text{線形予測子})$ として定式化する

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 40 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

統計モデルを工夫してわりざんやめよう

- available data/data values
- 避けられる割算値
 - probability
 - 確率
- 例: N 個のうち y 個にある事象が発生する確率
- use statistical model with binomial distribution
対策: ロジスティック回帰など二項分布モデルで
- indices such as densities
- 密度などの指數
 - 例: 人口密度, specific leaf area (SLA) など
- use offset term! Improve your statistical model!
対策: offset 項わざ — 統計モデリングの工夫!

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 41 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

次回予告 The next topic

種子数分布

N 個のうち y 個
という形式のデータ
なのに
二項分布ではまったく
説明できない?

階層ベイズモデル
Hierarchical Bayesian Model (HBM)

kubostat2017e (http://goo.gl/76c4i) 統計モデリング入門 2017 (e) 2017-06-21 42 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

予習: 階層ベイズモデルで使う 連続確率分布

A preview of continuous probability distributions to construct Hierarchical Bayesian Models

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 43 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

離散確率分布 ?

discrete probability distributions ?

連続確率分布 ?

continuous probability distributions ?

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 44 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

離散確率分布 discrete probability distributions

Poisson distribution	Binomial distribution
----------------------	-----------------------

λ changes the shape of distribution ポアソン分布の λ を変えてみる

lambda distribution, the core of statistical model

lambda is average to allways/(ラメーター)

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

binomial distribution ビンomial 分布 : N 回のうち y 回, となる確率

(N choose y) は「N 個の観察種子の中から y 個の生存種子を選び出す場合の数」

確率 p(yi | N, q) = $\binom{N}{yi} q^{yi} (1-q)^{N-yi}$

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 45 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

(連続) 一様分布 – 階層ベイズモデルの重要な部品

Uniform distribution (continuous) – an important “device” for HBM

parameter: min (a) and max (b)

f(x)

1/(b-a)

a, b

x

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 46 / 47

何でも「割算」するな! 「脱」割算の offset 項わざ

正規分布あるいはガウス分布 – 階層ベイズモデルの重要な部品

the normal or Gaussian distribution – an important “device” for HBM

parameter: mean (μ) and SD ($s > 0$)

平均 (mean) $\mu = 0$	Standard Deviation (SD) s
---------------------	-----------------------------

$s = 1.0$

$s = 1.5$

$s = 3.0$

$$p(x | s) = \frac{1}{\sqrt{2\pi}s^2} \exp\left(-\frac{x^2}{2s^2}\right)$$

kubostat2017e (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (e) 2017-06-21 47 / 47