

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

京大靈長研の講義 <https://goo.gl/z9yCJY>

2017-11-14

ファイル更新時刻: 2017-11-11 16:02

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 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

今日の内容と「統計モデリング入門」との対応

<http://goo.gl/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




statistical 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

Hierarchical Bayesian Model

parameter
estimation
MCMC



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

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)
-

how to specify GLM

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?

linear predictor

- 線形予測子は?


link function

- リンク関数は?

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 | |




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



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

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

またいつもの例題? ちょっとちがう

seeds
alive
8 個の種子 のうち y 個が 発芽可能 だった! というデータ



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://hosho.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


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	

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?

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

binomial distribution

二項分布 : N 回のうち y 回, となる確率

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

$\binom{N}{y}$ 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」




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")
```



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 .



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

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


logistic regression

MLE for β_1 and β_2

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





```
> glm(cbind(y, N - y) ~ x + f, data = d, family = binomial)
```

```
...
```

```
Coefficients:
```

(Intercept)	x	fT
-19.536	1.952	2.022

統計モデルの予測: 施肥処理によって応答が違う



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

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 ...




in today's example

no interaction effect


この例題データの場合、交互作用はない

 $\wedge\wedge I$ $glm(y \sim x + f, \dots)$ $glm(y \sim x + f + x:f, \dots)$

(A) 交互作用のないモデル



(B) 交互作用のあるモデル



little difference
差がほとんどない

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

ポアソン回帰を強めてみる

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?
- 割算値を使わぬ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

How to avoid data/data?

避けられるわりざん

avoidable 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

- 密度などの指標

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!

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

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




X 大 明るい X 小 暗い

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

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

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


明るさ vs 割算値図の図

```
> plot(d$x, d$y / d$Area)
```



いまいちよくわからない


面積 A vs 個体数 y の図



面積 A とともに区画内の個体数 y が増大するようだ


明るさ x の情報（マルの大きさ）も図に追加

```
> plot(d$Area, d$y, cex = d$x * 2)
```



同じ面積でも明るいほど個体数が多い?

密度が明るさ x に依存する統計モデル



- 区画内の個体数 y の平均は面積 \times 密度
- 密度は明るさ x で変化する

「平均個体数 = 面積 × 密度」モデル

- ある区画 i の応答変数 y_i は平均 λ_i のポアソン分布にしたがうと仮定:

$$y_i \sim \text{Pois}(\lambda_i)$$


- 平均値 λ_i は面積 A_i に比例し、密度は明るさ x_i に依存する

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

つまり $\lambda_i = \exp(\beta_1 + \beta_2 x_i + \log(A_i))$ となるので


$\log(\lambda_i) = \beta_1 + \beta_2 x_i + \log(A_i)$ 線形予測子は右辺のようになる

このとき $\log(A_i)$ を offset 項とよぶ (係数 β がない)



この問題は GLM であつかえる!

- family: poisson, ポアソン分布
- link 関数: "log"
- モデル式 : $y \sim x$
- offset 項の指定 : `log(Area)`
 - 線形予測子 $z = \beta_1 + \beta_2 x + \text{log}(\text{Area})$
 a, b は推定すべきパラメーター
 - 応答変数の平均値を λ とすると $\log(\lambda) = z$
つまり $\lambda = \exp(z) = \exp(\beta_1 + \beta_2 x + \text{log}(\text{Area}))$
 - 応答変数 は平均 λ のポアソン分布に従う:



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

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

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



- solid lines prediction
• 実線 は `glm()` の推定結果にもとづく 予測
- dotted lines “true” model
- 破線 は データ生成時に指定した関係

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



Improve your statistical model and remove data/data values!

統計モデルを工夫してわりざんやめよう

avoidable 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

- 密度などの指標

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!

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)

予習: 階層ベイズモデルで使う 連續確率分布

A preview of continuous probability distributions to construct Hierarchical Bayesian Models

離散確率分布？

discrete probability distributions ?

連續確率分布？


continuous probability
distributions ?

離散確率分布 discrete probability distributions

Poisson distribution



$$p(y | \lambda) = \frac{\lambda^y \exp(-\lambda)}{y!} \quad \text{mean } \lambda \text{ は平均をあらわすパラメーター}$$




Binomial distribution




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

$\binom{N}{y}$ 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」




(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)



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 ($s > 0$)



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