

統計モデリング入門 2018 (c)
 Poisson regression, a generalized linear model (GLM)
 一般化線形モデル: ポアソン回帰

久保拓弥 kubo@ees.hokudai.ac.jp

北大環境科学院の講義 <http://goo.gl/76c4i>

2018-06-25

ファイル更新時刻: 2019-07-18 15:59

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 1 / 45

もくじ

agenda
今日のハナシ I

Poisson regression

- ① **ポアソン回帰の統計モデル**
 response variable explanatory variable
 応答変数 y と 説明変数 x
- ② **ポアソン回帰の例題: 架空植物の種子数データ**
 植物個体の属性, あるいは実験処理が種子数に影響?
 how to specify GLM
- ③ **GLMの詳細を指定する**
 probability distribution, linear predictor and link function
 確率分布・線形予測子・リンク関数
- ④ **RでGLMのパラメータを推定**
 how to estimate GLM parameters
 Log-likelihood
 あてはまりの良さは対数尤度関数で評価
- ⑤ **処理をした・しなかった効果も統計モデルに入れる**
 How to incorporate design parameter

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 2 / 45

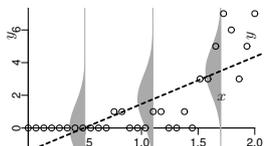
もくじ

agenda
今日のハナシ II

factor type
GLMの因子型説明変数

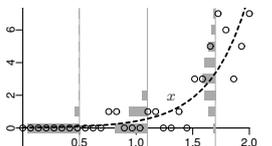
Normal distribution and identity link function

正規分布・恒等リンク関数の統計モデル



Poisson distribution and log link function

ポアソン分布・logリンク関数の統計モデル



kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 3 / 45

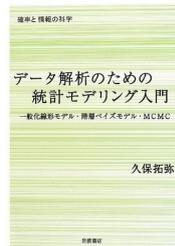
もくじ

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3章 一般化線形モデル (GLM)」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



kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 4 / 45

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)
-

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 5 / 45

もくじ

ポアソン回帰の統計モデル

応答変数 y と 説明変数 x

Poisson regression

1. **ポアソン回帰の統計モデル**

response variable explanatory variable
 応答変数 y と 説明変数 x

一般化線形モデルにとりこんでみる

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 6 / 45

ポアソン回帰の統計モデル 応答変数 y と 説明変数 x

Understand the Evolution of Linear Models!
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

Generalized Linear Mixed Model (GLMM)
Be more flexible

Generalized Linear Model (GLM)
Incorporating random effects such as individuality
Always normal distribution? That's non-sense!

Linear model
MSE

MLE

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 7 / 45

ポアソン回帰の統計モデル 応答変数 y と 説明変数 x

suppose that you have a "count data" set ...
0 個, 1 個, 2 個と数えられるデータ

カウントデータ ($y \in \{0, 1, 2, 3, \dots\}$ なデータ)

response variable y
応答変数
e.g. egg number (たとえば卵数)

explanatory variable x
説明変数
e.g. body size (たとえば体重)

- たとえば x は植物個体の大きさ, y はその個体の花数
- 体サイズが大きくなると花数が増えるように見えるが.....
- この現象を表現する統計モデルは?

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 8 / 45

ポアソン回帰の統計モデル 応答変数 y と 説明変数 x

the normal distribution ... is NOT this one!
正規分布を使った統計モデル ムリがある?

正規分布・恒等リンク関数の統計モデル

response variable y
応答変数

explanatory variable x
説明変数

NO!

とにかくセンシキゃいいんでしょ
傾き「ゆーい」ならいいんでしょ
...という安易な発想のデータ解析

- タテ軸のばらつきは「正規分布」なのか?
- y の値は 0 以上なのに
- 平均値がマイナス?

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 9 / 45

ポアソン回帰の統計モデル 応答変数 y と 説明変数 x

the Poisson distribution approximates data
ポアソン分布を使った統計モデルなら良さそう?!

ポアソン分布・対数リンク関数の統計モデル

response variable y
応答変数

explanatory variable x
説明変数

YES!

- タテ軸に対応する「ばらつき」 fair distribution
- 負の値にならない「平均値」 non-negative mean
- 正規分布を使ってるモデルよりましだね bye-bye, the normal distribution

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 10 / 45

ポアソン回帰の例題: 架空植物の種子数データ 植物個体の属性, あるいは実験処理が種子数に影響?

2. ポアソン回帰の例題: 架空植物の種子数データ

植物個体の属性, あるいは実験処理が種子数に影響?

Modeling number of seeds of plants using GLM

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 11 / 45

ポアソン回帰の例題: 架空植物の種子数データ 植物個体の属性, あるいは実験処理が種子数に影響?

body size x and fertilization f change seed number y ?
個体サイズと実験処理の効果を調べる例題

response variable seed number
応答変数 : 種子数 $\{y_i\}$

explanatory variable
body size
体サイズ $\{x_i\}$
fertilization
施肥処理 $\{f_i\}$

individual i
せいひ 施肥処理 f_i
C: 肥料なし
T: 施肥処理

種子数 y_i

体サイズ x_i
施肥処理する前に測定したもの

sample size
標本数

- control
無処理 ($f_i = C$): 50 sample ($i \in \{1, 2, \dots, 50\}$)
- treated
施肥処理 ($f_i = T$): 50 sample ($i \in \{51, 52, \dots, 100\}$)

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 12 / 45

ポアソン回帰の例題: 架空植物の種子数データ 植物個体の異性,あるいは実験処理が種子数に影響?

施肥処理 f した・しないの箱ひげ図 (box-whisker plot)

```
> plot(d$f, d$y) # note that d$f is factor type!
```

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 19 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

how to specify GLM

3. GLM の詳細を指定する

probability distribution, linear predictor and link function
確率分布・線形予測子・リンク関数

ポアソン回帰では log link 関数を使うのが便利

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 20 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

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?

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 21 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

how to specify linear model (LM as a GLM)

GLM のひとつである直線回帰モデルを指定する

直線回帰のモデル

probability distribution Gaussian distribution

- 確率分布: 正規分布

linear predictor

- 線形予測子: e.g., $\beta_1 + \beta_2 x_i$

link function identity link function

- リンク関数: 恒等リンク関数

直線の式: (切片) + (傾き) $\times x_i$

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 22 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

線形モデルの予測子, predictor of linear model

- 応答変数 (response variable)
- 説明変数 (explanatory variable)
- 係数 (coefficient)
- 線形予測子 (linear predictor):

$$\begin{aligned} (\text{応答変数}) = & \text{定数 (切片, intercept)} \\ & + (\text{係数 1}) \times (\text{説明変数 1}) \\ & + (\text{係数 2}) \times (\text{説明変数 2}) \\ & + (\text{係数 3}) \times (\text{説明変数 3}) \\ & + \dots \end{aligned}$$

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 23 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

how to specify Poisson regression model as 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

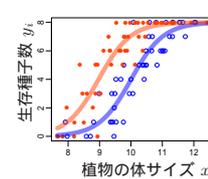
kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 24 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

how to specify logistic regression model as 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

- 確率分布: **二項分布**
- 線形予測子: e.g., $\beta_1 + \beta_2 x_i$
- リンク関数: **logit リンク関数**



生存種子数 y_i

植物の体サイズ x_i

probability distribution binomial distribution
linear predictor
link function

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 25 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

R で一般化線形モデル (GLM) の推定を.....

	probability distribution 確率分布	random number generation 乱数発生	GLM fitting GLM あてはめ
(離散)	ベルヌーイ分布	rbinom()	glm(family = binomial)
	二項分布	rbinom()	glm(family = binomial)
	ポアソン分布	rpois()	glm(family = poisson)
	負の二項分布	rnbinom()	glm.nb() in library(MASS)
(連続)	ガンマ分布	rgamma()	glm(family = gamma)
	正規分布	rnorm()	glm(family = gaussian)

- glm() で使える確率分布は上記以外にもある
- GLM は直線回帰・重回帰・分散分析・ポアソン回帰・ロジスティック回帰その他の「よせあつめ」と考えてもよいかも

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 26 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

さて、種子数の例題にもどって...

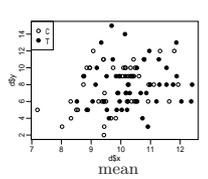
seed number y_i follows the Poisson distribution
種子数 y_i は平均 λ_i のポアソン分布にしたがうと
しましょう

$$p(y_i | \lambda_i) = \frac{\lambda_i^{y_i} \exp(-\lambda_i)}{y_i!}$$

個体 i の平均 λ_i を以下のようにおいてみたらどうだろう.....?

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

- β_1 と β_2 は 係数 (パラメーター)
- x_i は個体 i の体サイズ, f_i はとりあえず無視



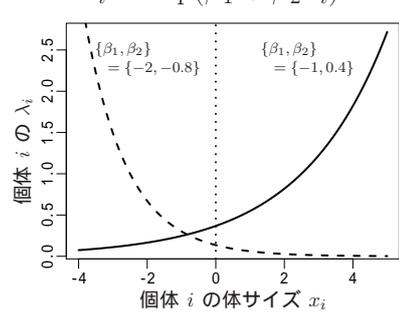
mean

coefficient parameter
body size no f_i , for simplicity

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 27 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

exponential function
指数関数ってなんだっけ?

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


個体 i の λ_i

個体 i の体サイズ x_i

$\{\beta_1, \beta_2\} = \{-2, -0.8\}$

$\{\beta_1, \beta_2\} = \{-1, 0.4\}$

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 28 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

GLM のリンク関数と線形予測子 ← (直線の式)

個体 i の平均 λ_i

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

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

log link function linear predictor

log link function linear predictor

log(平均) = 線形予測子

log リンク関数とよばれる理由は、上のようにになっているから

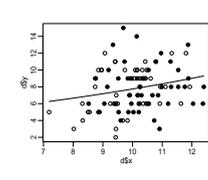
kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 29 / 45

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

a statistical model for this example
この例題のための統計モデル

ポアソン回帰のモデル

- 確率分布: **ポアソン分布**
- 線形予測子: $\beta_1 + \beta_2 x_i$
- リンク関数: **対数リンク関数**



probability distribution Poisson distribution
linear predictor
link function log link function

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 30 / 45

GLM のパラメーターを推定 あてはまりの良さは 対数尤度関数で評価

how to estimate GLM parameters

4. Rで GLM のパラメーターを推定

Log-likelihood
あてはまりの良さは 対数尤度関数で評価

numerical estimation with R
推定計算はコンピューターにおまかせ

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 31 / 45

GLM のパラメーターを推定 あてはまりの良さは 対数尤度関数で評価

function
glm() 関数 の指定

```
> d
  y   x f
1  6 8.31 C
2  6 9.44 C
3  6 9.50 C
... (中略) ...
99 7 10.86 T
100 9 9.97 T
```

Is that all?
これだけ!

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

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 32 / 45

GLM のパラメーターを推定 あてはまりの良さは 対数尤度関数で評価

glm() 関数の指定の意味

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

結果を格納するオブジェクト: fit
関数名: glm
モデル式: y ~ x
確率分布の指定: poisson
リンク関数の指定 (省略可): link = "log"
data.frame の指定: data = d

- モデル式 (線形予測子 z): どの説明変数を使うか?
- link 関数: z と応答変数 (y) 平均値 の関係は?
- family: どの確率分布を使うか?

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 33 / 45

GLM のパラメーターを推定 あてはまりの良さは 対数尤度関数で評価

glm() 関数の出力

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

```
all: glm(formula = y ~ x, family = poisson, data = d)
```

Coefficients:
(Intercept) x
 1.2917 0.0757

Degrees of Freedom: 99 Total (i.e. Null); 98 Residual
Null Deviance: 89.5
Residual Deviance: 85 AIC: 475

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 34 / 45

GLM のパラメーターを推定 あてはまりの良さは 対数尤度関数で評価

glm() 関数のくわしい出力

```
> summary(fit)
```

```
Call:
glm(formula = y ~ x, family = poisson, data = d)
```

Deviance Residuals:
Min 1Q Median 3Q Max
-2.368 -0.735 -0.177 0.699 2.376

Coefficients:
 Estimate Std. Error z value Pr(>|z|)
(Intercept) 1.2917 0.3637 3.55 0.00038
x 0.0757 0.0356 2.13 0.03358

..... (以下, 省略)

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 35 / 45

GLM のパラメーターを推定 あてはまりの良さは 対数尤度関数で評価

推定値と標準誤差のイメージ (かなりいいかげんな説明)

- 確率 p は ゼロからの距離 をあらわしている
- p がゼロに近いほど 推定値 $\hat{\beta}$ はゼロから離れている
- p が 0.5 に近いほど 推定値 $\hat{\beta}$ はゼロに近い

(注: 頻度主義的な信頼区間の正しい解釈はもっとめんどくさい)

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 36 / 45

GLM のパラメーターを指定 あてはまりの良さは 対数尤度関数で評価

model prediction
モデルの予測

```
> fit <- glm(y ~ x, data = d, family = poisson)
...
Coefficients:
(Intercept)          x
      1.2917         0.0757
```

```
> plot(d$x, d$y, pch = c(21, 19)[d$f]) # data
> xp <- seq(min(d$x), max(d$x), length = 100)
> lines(xp, exp(1.2917 + 0.0757 * xp))
```

the figure shows the relationship
ここでは観測データと予測の関係
between model prediction and data
を見ているだけ、なのだが

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 37 / 45

処理をした・しなかった 効果も統計モデルに入れる GLM の 因子型説明変数

How to incorporate design parameter

5. 処理をした・しなかった 効果も統計モデルに入れる

factor type
GLM の 因子型説明変数

numerical factor
数量型 + 因子型 という組み合わせで

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 38 / 45

処理をした・しなかった 効果も統計モデルに入れる GLM の 因子型説明変数

incorporate the fertilization effects in GLM
肥料の効果 f_i もいれましょう

seed number y_i follows the Poisson distribution
種子数 y_i は平均 λ_i のポアソン分布にしたがうと
しましょう

$$p(y_i | \lambda_i) = \frac{\lambda_i^{y_i} \exp(-\lambda_i)}{y_i!}$$

個体 i の平均 λ_i を次のようにする

$$\lambda_i = \exp(\beta_1 + \beta_2 x_i + \beta_3 d_i)$$

fertilization effects coefficient
 β_3 は 施肥処理の効果 の 係数
dummy variable

- f_i の ダミー変数

$$d_i = \begin{cases} 0 & (f_i = C \text{ の場合}) \\ 1 & (f_i = T \text{ の場合}) \end{cases}$$

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 39 / 45

処理をした・しなかった 効果も統計モデルに入れる GLM の 因子型説明変数

output
 $\text{glm}(y \sim x + f, \dots)$ の出力

```
> summary(glm(y ~ x + f, data = d, family = poisson))
... (略) ...
```

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	1.2631	0.3696	3.42	0.00063
x	0.0801	0.0370	2.16	0.03062
fT	-0.0320	0.0744	-0.43	0.66703

..... (以下, 省略)

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 40 / 45

処理をした・しなかった 効果も統計モデルに入れる GLM の 因子型説明変数

model prediction
 $x + f$ モデルの予測

```
> plot(d$x, d$y, pch = c(21, 19)[d$f]) # data
> xp <- seq(min(d$x), max(d$x), length = 100)
> lines(xp, exp(1.2631 + 0.0801 * xp), col = "blue", lwd = 3) # C
> lines(xp, exp(1.2631 + 0.0801 * xp - 0.032), col = "red", lwd = 3) # T
```

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 41 / 45

処理をした・しなかった 効果も統計モデルに入れる GLM の 因子型説明変数

multiple explanatory variables
複数の説明変数をいれた場合の統計モデル

- $f_i = C: \lambda_i = \exp(1.26 + 0.0801x_i)$
- $f_i = T: \lambda_i = \exp(1.26 + 0.0801x_i - 0.032)$
 $= \exp(1.26 + 0.0801x_i) \times \exp(-0.032)$

平均種子数 λ_i

施肥効果である $\exp(-0.032)$ は
かけ算できくことに注意!

body size x_i

kubostat2018c (http://goo.gl/76c4i) 統計モデリング入門 2018 (c) 2018-06-25 42 / 45

処理をした・しなかった 効果も統計モデルに入れる GLM の 因子型説明変数

model interpretation depends on link function
リンク関数が違うとモデルの解釈が異なる

log link function
(A) 対数リンク関数
 $\lambda = \exp(\beta_1 + \beta_2 x + \dots)$

multiplicative
相乗的

identity link function
(B) 恒等リンク関数
 $\lambda = \beta_1 + \beta_2 x + \dots$

additive
相加的

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 43 / 45

処理をした・しなかった 効果も統計モデルに入れる GLM の 因子型説明変数

probability distribution link function
GLM: 適切な 確率分布 とリンク関数 を選ぶ

正規分布・恒等リンク関数の統計モデル

ポアソン分布・log リンク関数の統計モデル

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 44 / 45

処理をした・しなかった 効果も統計モデルに入れる GLM の 因子型説明変数

Understand the Evolution of Linear Models!
この授業であつかう統計モデルたち

The development of linear models

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 45 / 45

処理をした・しなかった 効果も統計モデルに入れる GLM の 因子型説明変数

次回予告
The next topic

(A) $k = 1$

Too simple?

(B) $k = 7$

Too complex?

モデル選択と統計学的検定
Model selection and statistical test

kubostat2018c (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (c) 2018-06-25 46 / 45