

統計モデリング入門 2018 (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

北大環境科学院の講義 <http://goo.gl/76c4i>

2018-07-02

ファイル更新時刻: 2018-06-29 14:36

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 1 / 46

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
- ② logistic regression
- ③ ロジスティック回帰の部品
二項分布 binomial distribution と logit link function
- ④ ちょっとだけ interaction term について
線形予測子の中の複雑な項 complicate terms in linear predictor
NEVER $\text{data} \div \text{data}$!
- ⑤ 何でも「割算」するな!
use GLM with offset term
「脱」割算の offset 項わざ

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 2 / 46

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

http:// goo.g1/Ufq2

概要と復習の科学
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
岩波新社

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 3 / 46

もくじ

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

```

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

Hierarchical Bayesian Model
Generalized Linear Mixed Model (GLMM)
Generalized Linear Model (GLM)
Linear model

parameter estimation
MCMC

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 4 / 46

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)
-

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 5 / 46

もくじ

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?
- 線形予測子は?
- リンク関数は?

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 6 / 46

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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 7 / 46

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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 8 / 46

“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

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

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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 9 / 46

“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 ^{alive} 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
 觀察種子数 $N_i = 8$
 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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 10 / 46

“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 R

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://hoshos.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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 11 / 46

“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	

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 12 / 46

“N 回のうち y 回が生きてる” タイプのデータ
上履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?

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 13 / 46

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

logistic regression
2. ロジスティック回帰 の部品

二項分布 binomial distribution & logit link function

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 14 / 46

ロジスティック回帰 の部品 二項分布 binomial distribution & 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 $p(y_i | N, q)$

y_i

q = 0.1 q = 0.3 q = 0.8

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 15 / 46

ロジスティック回帰 の部品 二項分布 binomial distribution & 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

q = $\frac{1}{1+\exp(-z)}$

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 16 / 46

ロジスティック回帰 の部品 二項分布 binomial distribution & 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

$\beta_1 = 2$ $\beta_1 = 0$ $\beta_1 = -3$

$\beta_2 = 4$ $\beta_2 = 2$ $\beta_2 = -1$

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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 17 / 46

ロジスティック回帰 の部品 二項分布 binomial distribution & 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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 18 / 46

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

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
```

kubostat2018e (<http://goo.gl/76c4i1>) 統計モデリング入門 2018 (e) 2018-07-02 19 / 46

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

Fertilization effects
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

kubostat2018e (<http://goo.gl/76c4i1>) 統計モデリング入門 2018 (e) 2018-07-02 20 / 46

ちょっとだけ 交互作用項 について predictor

interaction term

3. 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 complicate terms in linear predictor

ロジスティック回帰を例に

interaction term

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

NEVER $\text{data} \div \text{data}$!

kubostat2018e (<http://goo.gl/76c4i1>) 統計モデリング入門 2018 (e) 2018-07-02 21 / 46

ちょっとだけ 交互作用項 について predictor

interaction terms
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_i 植物の体サイズ x

kubostat2018e (<http://goo.gl/76c4i1>) 統計モデリング入門 2018 (e) 2018-07-02 22 / 46

何でも「割算」するな! 「脱」割算の offset 項わざ

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

NEVER $\text{data} \div \text{data}$!

kubostat2018e (<http://goo.gl/76c4i1>) 統計モデリング入門 2018 (e) 2018-07-02 23 / 46

何でも「割算」するな! 「脱」割算の offset 項わざ

Why you should avoid $\text{data} \div \text{data}$
割算値ひねくるデータ解析はなぜよくないのか?

- **data / data** 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

kubostat2018e (<http://goo.gl/76c4i1>) 統計モデリング入門 2018 (e) 2018-07-02 24 / 46

何でも「割算」するな! 「脱」割算の offset 項わざ
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
 ○ 密度などの指数
 例: 人口密度, specific leaf area (SLA) など
 use offset term!
 対策: **offset 項わざ** — このあと解説!

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

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
 かを知りたい
 light index
 • 明るさ x 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

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

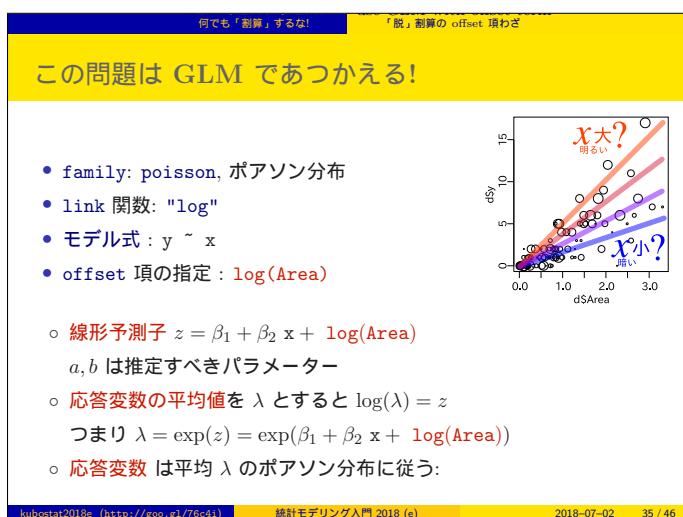
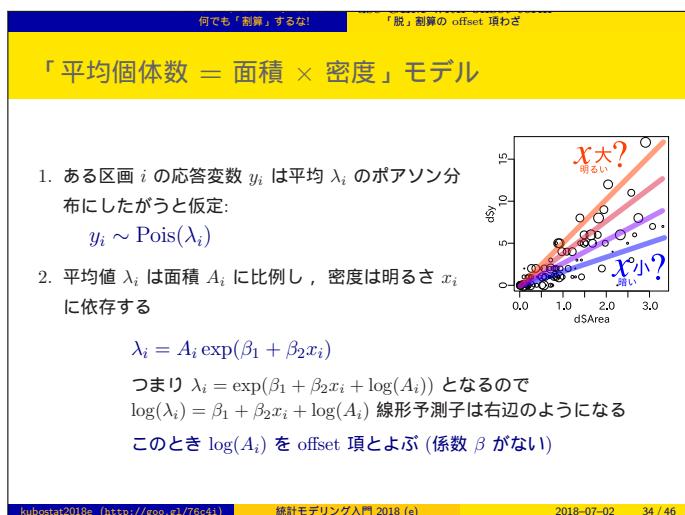
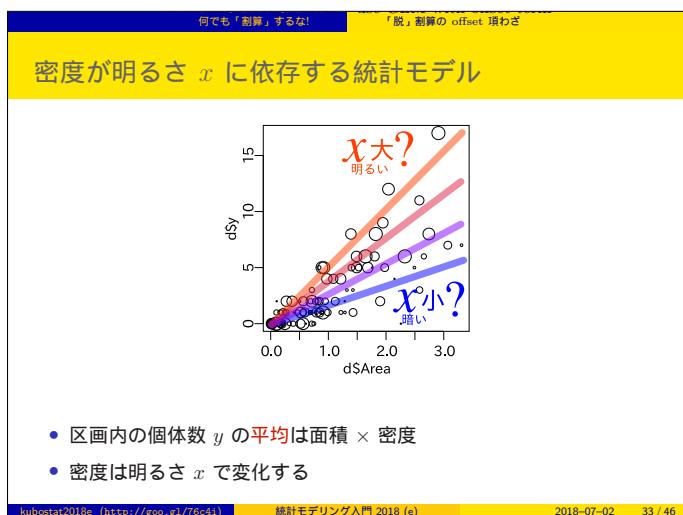
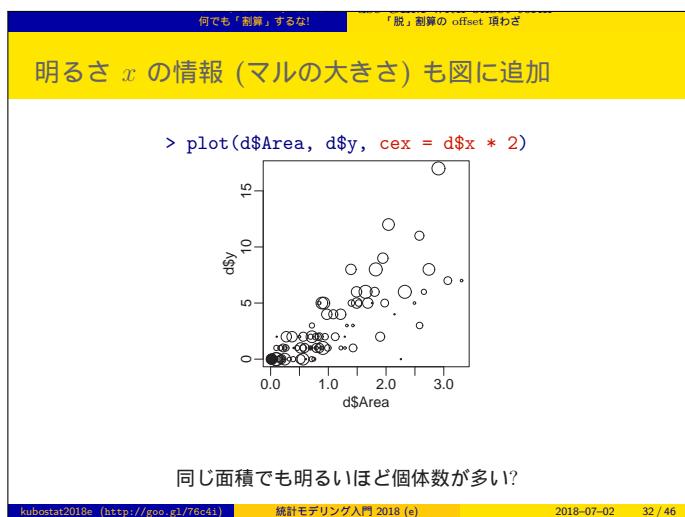
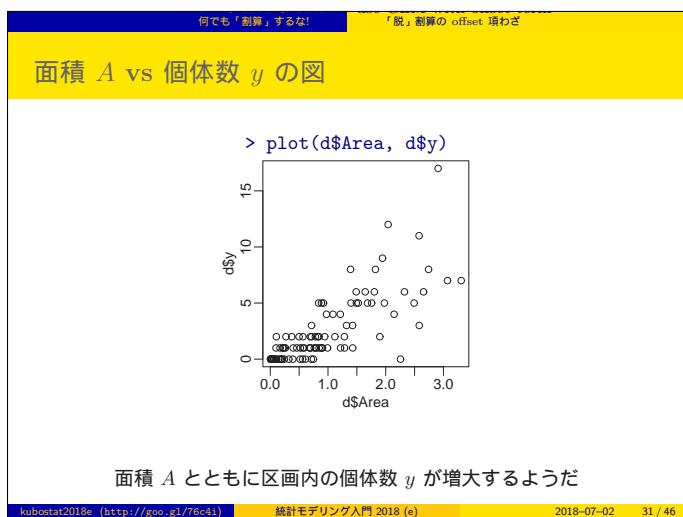
何でも「割算」するな! 「脱」割算の offset 項わざ
R の data.frame: 面積 Area, 明るさ x, 個体数 y
light index number of plants

```
> 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
```

何でも「割算」するな! 「脱」割算の offset 項わざ
light index quotient or synthetic variable
明るさ vs 割算値 の図

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

いまいちよくわからない



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
```

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 37 / 46

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

- 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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 38 / 46

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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 39 / 46

何でも「割算」するな! 「脱」割算の offset 項わざ

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

- 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

- 密度などの指数
 - 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! Improve your statistical model!
対策: offset 項わざ — 統計モデリングの工夫!

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 40 / 46

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)

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 41 / 46

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

kubostat2018e (<http://goo.gl/76c4i>) 統計モデリング入門 2018 (e) 2018-07-02 42 / 46

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 ?

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

<p>Poisson distribution</p> <p>データの離散性のため probability distribution, the core of statistical model λ changes the shape of distribution ポアソン分布の λ を変えてみる</p> <p>$p(y \lambda) = \frac{\lambda^y \exp(-\lambda)}{y!}$</p>	<p>Binomial distribution</p> <p>二項分布 二項確率分布 二項分布の確率 : N 回のうち y 回となる確率</p> <p>$p(y N, q) = \binom{N}{y} q^y (1-q)^{N-y}$</p>
---	--

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)

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

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