

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

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

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

NEVER data ÷ data !

④ 何でも「割算」するな!

use GLM with offset term

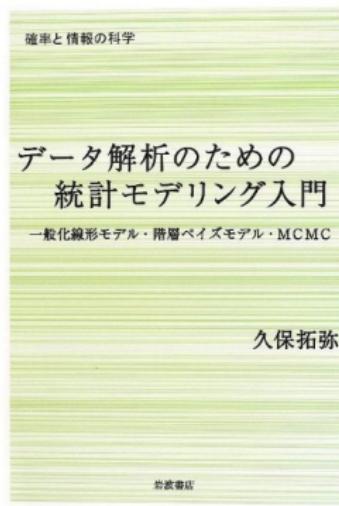
「脱」割算の offset 項わざ

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



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

Be more
flexible

Generalized Linear Mixed Model (GLMM)

MLE

Incorporating
random effects
such as individuality

Generalized Linear Model (GLM)

MSE

Always normal
distribution?
That's non-sense!

Linear model

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

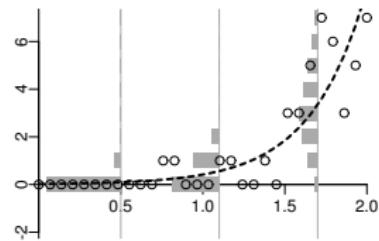
- 確率分布は?
linear predictor
- 線形予測子は?
link function
- リンク関数は?

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



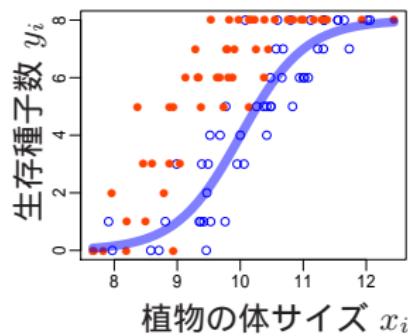
how to specify logistic regression model, a GLM

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

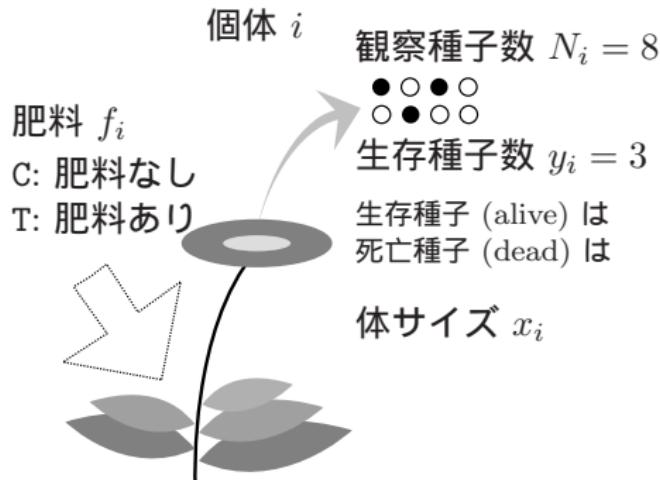
count data or categorical data with upper bound

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

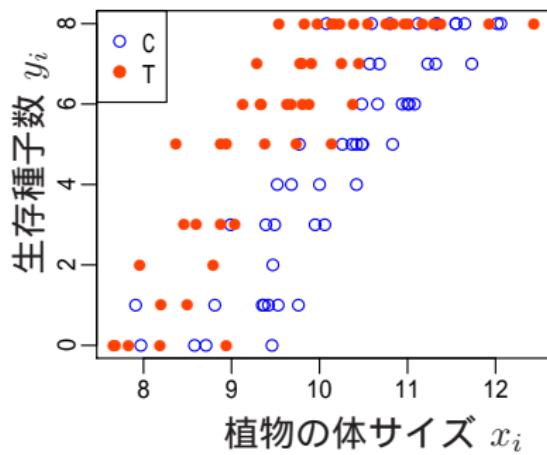
data frame d を調べる

```
> 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

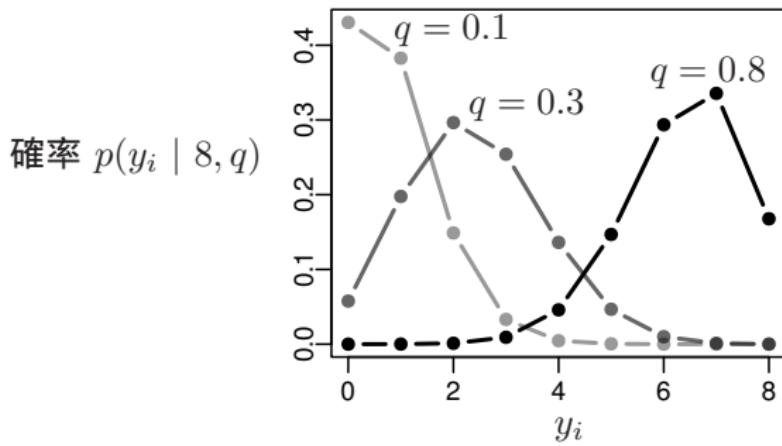
二項分布 binomial distribution と logit link function

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」



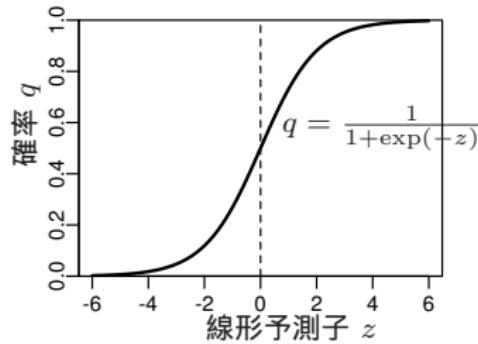
logistic curve

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. $z_i = \beta_1 + \beta_2 x_i$)

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

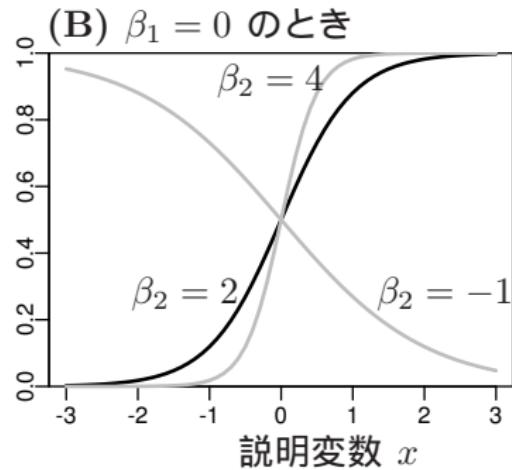
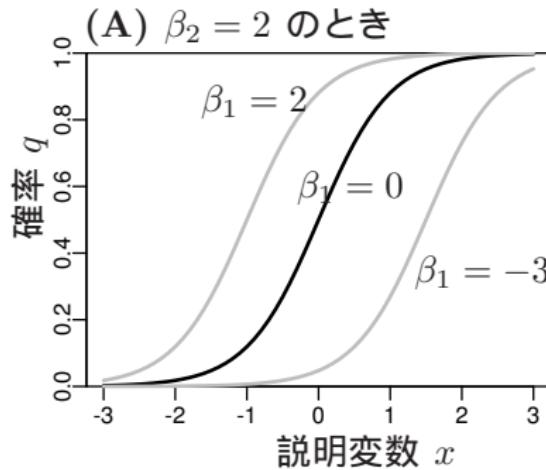
```
> logistic <- function(z) 1 / (1 + exp(-z)) # 関数の定義
> z <- seq(-6, 6, 0.1)
> plot(z, logistic(z), type = "l")
```



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

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

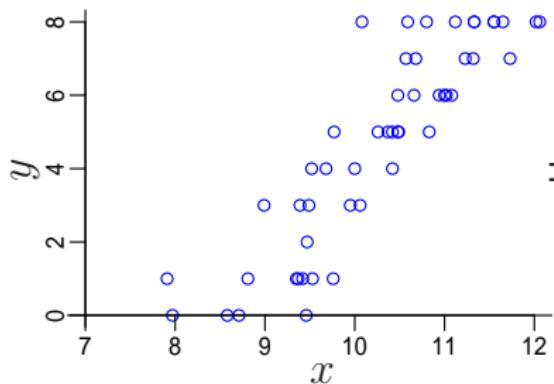
- logit 変換

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

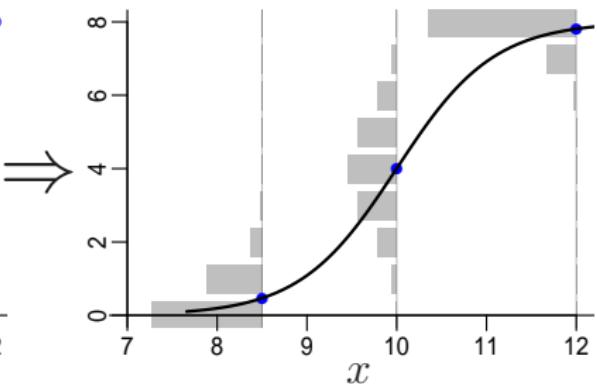
logit は logistic の逆関数 , logistic は logit の逆関数

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)
```

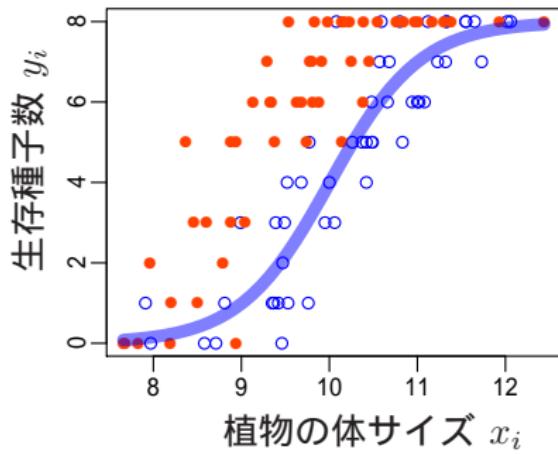
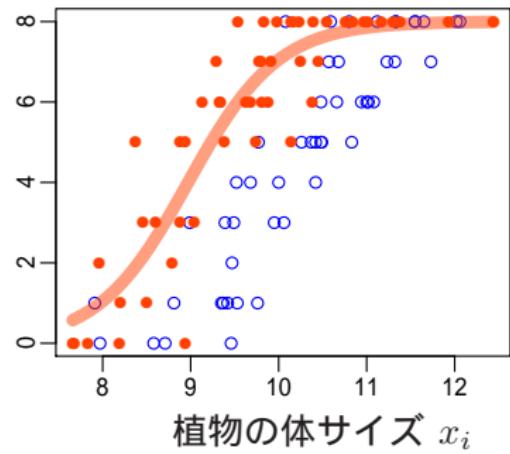
```
...
```

```
Coefficients:
```

(Intercept)	x	fT
-19.536	1.952	2.022

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 ($f_i = T$)

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

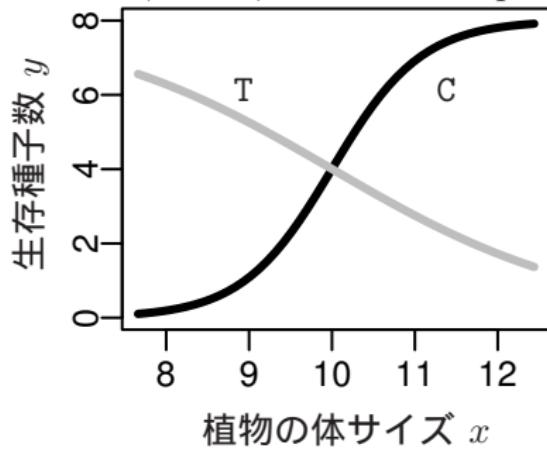
ロジスティック回帰を例に

interaction 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 ...



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

Why you should avoid data ÷ 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 ...

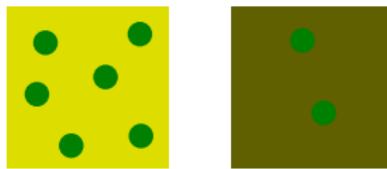
- 割算値で作図せざるをえない場合があるかも

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



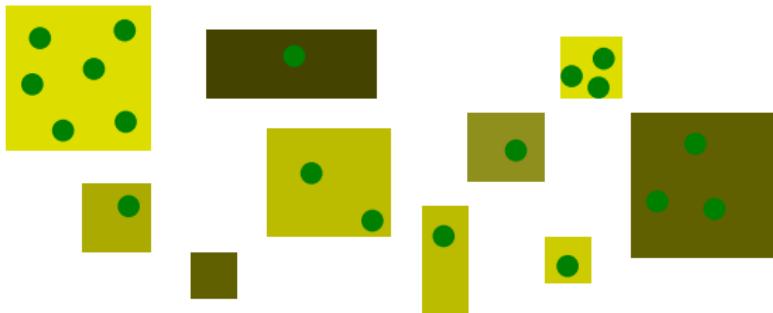
X 大
明るい

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
```

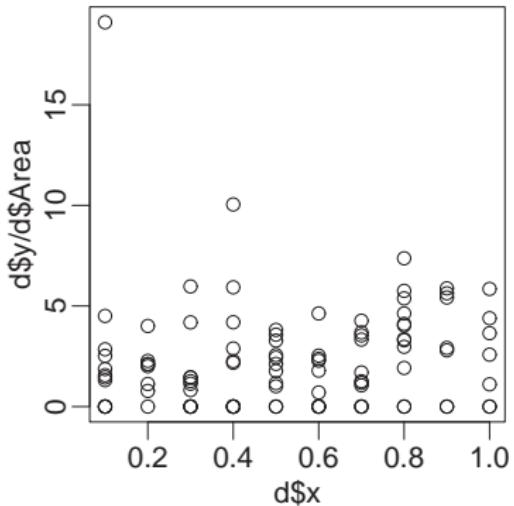
light index

quotient or synthetic variable

明るさ vs

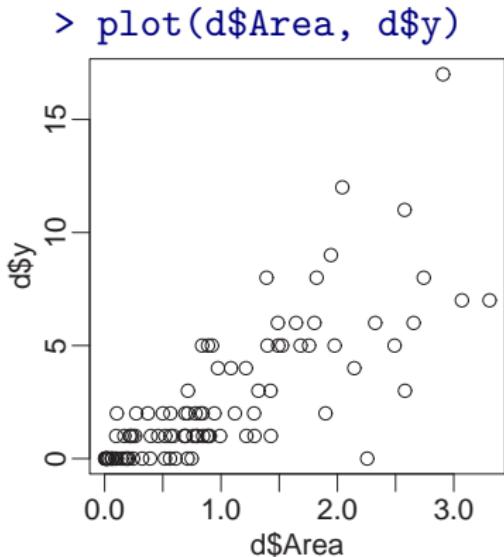
割算値 の図

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



いまいちよくわからない

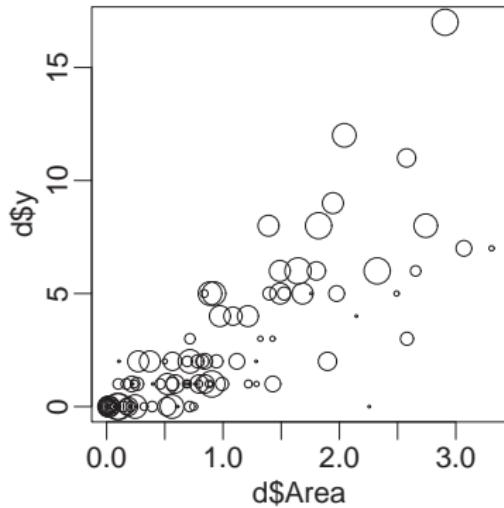
面積 A vs 個体数 y の図



面積 A とともに区画内の個体数 y が増大するようだ

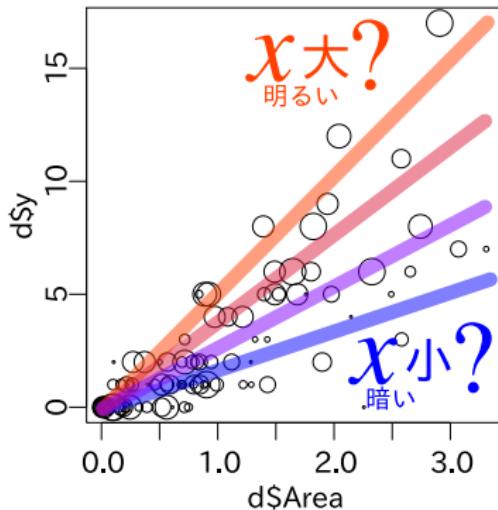
明るさ x の情報（マルの大きさ）も図に追加

```
> 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:

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

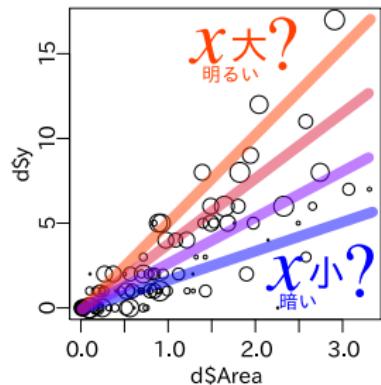
- 平均値 λ_i は面積 A_i に比例し、密度は明るさ x_i に依存する

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

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

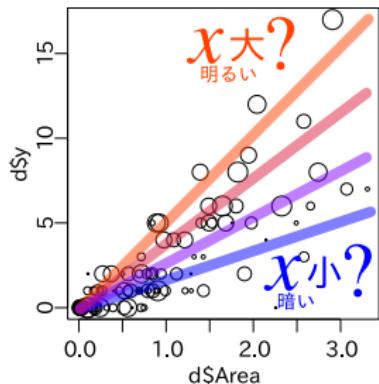
このとき $\log(A_i)$ を offset 項とよぶ (係数 β がない)



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 $z = \beta_1 + \beta_2 x + \text{log(Area)}$
 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 $\lambda = \exp(z) = \exp(\beta_1 + \beta_2 x + \text{log(Area)})$
- 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))
```

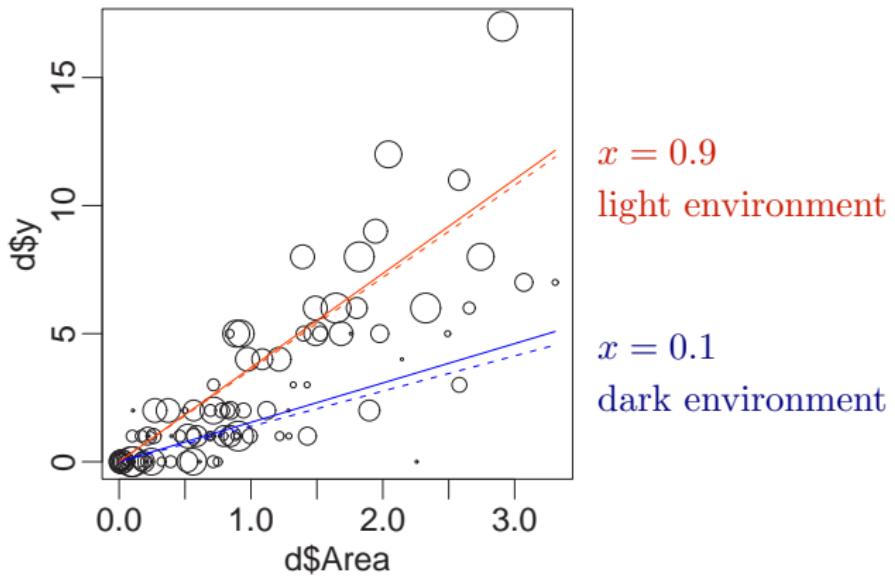
(... 略 ...)

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

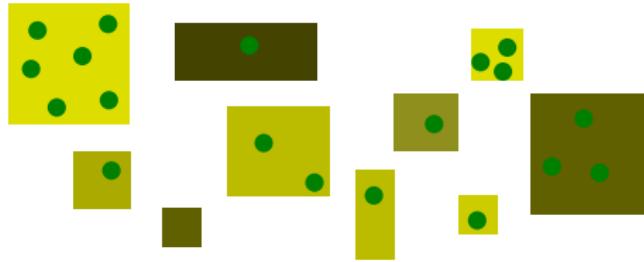
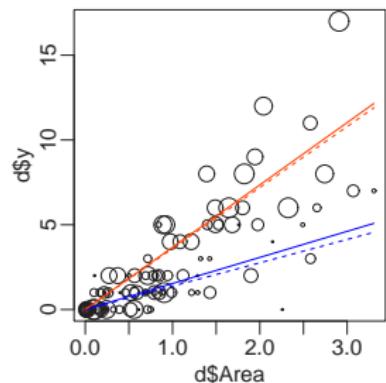
推定結果にもとづく予測を図にしてみる



- 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

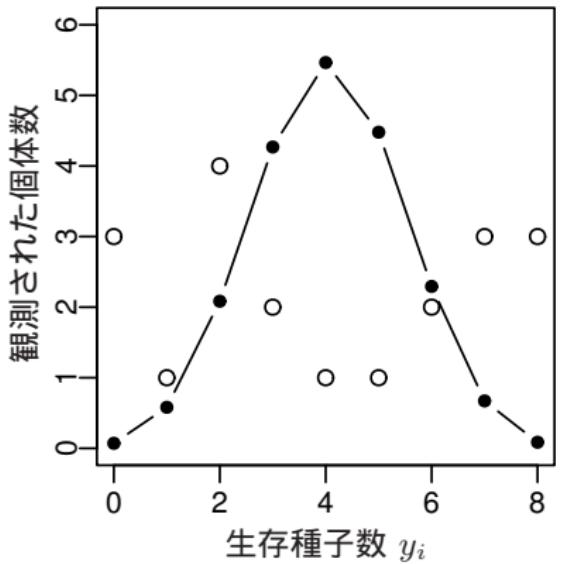
use offset term! Improve your statistical model!

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？

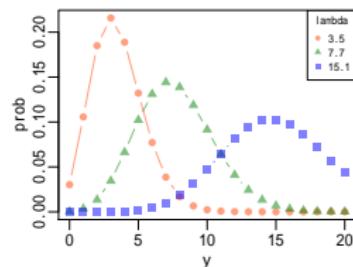
continuous probability
distributions ?

離散確率分布 discrete probability distributions

Poisson distribution



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

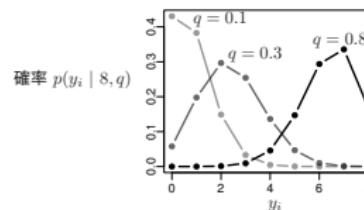


Binomial distribution



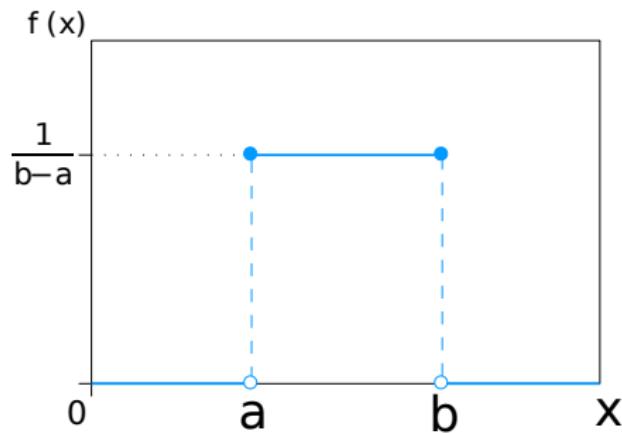
$$p(y | N, q) = \binom{N}{y} q^y (1 - q)^{N-y}$$

$\binom{N}{y}$ 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」



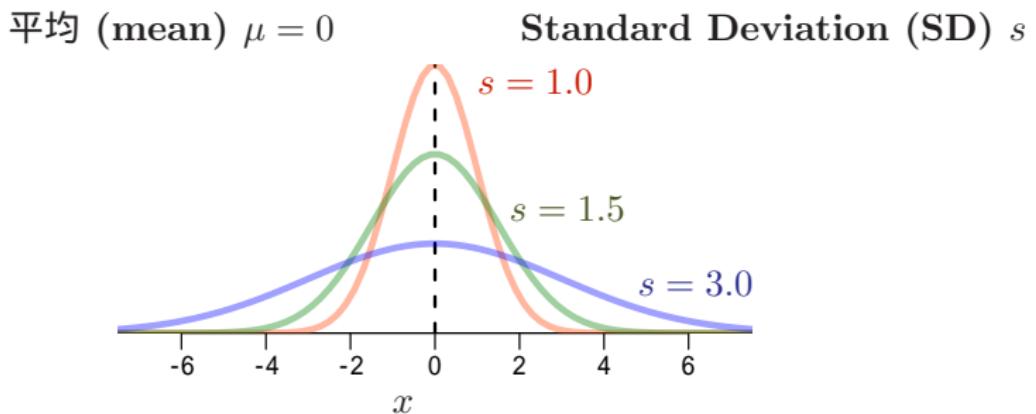
(連続) 一様分布 – 階層ベイズモデルの重要な部品

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 ($s > 0$)



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