

統計モデリング入門 2015 (f)

Generalized Linear Mixed Model (GLMM)
一般化線形混合モデル

久保拓弥 kubo@ees.hokudai.ac.jp

北大環境科学院の講義 <http://goo.gl/76c4i>

2015-07-27

ファイル更新時刻: 2015-07-28 19:35

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

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

今日のハナシ

- ① GLM では説明できない種子データ
overdispersion data
「ばらつき」が大きすぎる!
overdispersion caused by individual differences
- ② 過分散と個体差
観測されていない個体差がもたらす過分散
- ③ Generalized Linear Mixed Model
一般化線形混合モデル
個体差をあらわすパラメーターを追加
- ④ 一般化線形混合モデルの最尤推定
個体差 v_i を積分して消す尤度方程式
- ⑤ 現実のデータ解析には GLMM が必要
個体差・場所差を考えないといけないから

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7章 一般化線形混合モデル (GLMM)」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

GLM では説明できない種子データ 「ばらつき」が大きすぎる!

1. GLM では説明できない種子データ

overdispersion data
「ばらつき」が大きすぎる!

過分散 (overdispersion) とは何か?

example seed survivorship again, but ...
今日の例題: 種子の生存確率.....前回と同じ?!

(A) 個体 i で観測されたデータ

調査種子数 $N_i = 8$

生存種子数 $y_i = 3$

葉数 $x_i \in \{2, 3, 4, 5, 6\}$

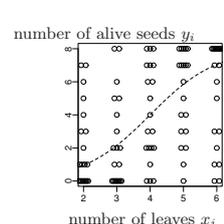
(B) 全 100 個体の x_i と y_i

GLM では説明できない種子データ 「ばらつき」が大きすぎる!

logistic regression as usual?
 “N 個中の y 個” というデータ → ロジスティック回帰?

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: $\beta_1 + \beta_2 x_i$
 link function
 • リンク関数: logit リンク関数



number of alive seeds y_i

number of leaves x_i

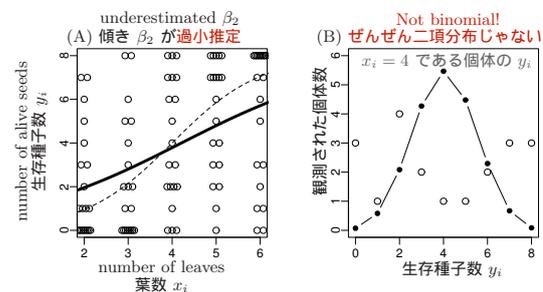
kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 7 / 35

GLM では説明できない種子データ 「ばらつき」が大きすぎる!

GLM doesn't work!
 GLM では説明できないばらつき!

underestimated β_2
 (A) 傾き β_2 が過小推定

Not binomial!
 ぜんぜん二項分布じゃない!
 (B) $x_i = 4$ である個体の y_i



number of alive seeds 生存種子数 y_i

number of leaves 葉数 x_i

観測されたデータの図示

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 8 / 35

過分散と個体差 観測されていない個体差がもたらす過分散

overdispersion caused by individual differences
 2. 過分散と個体差

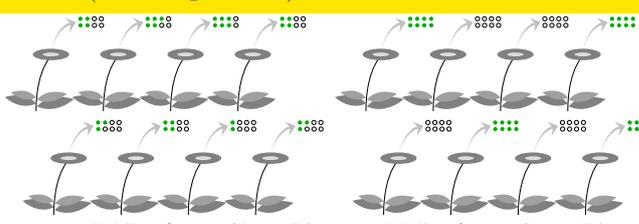
観測されていない個体差がもたらす過分散

unobservable differences
 観測されていない個体差って?

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 9 / 35

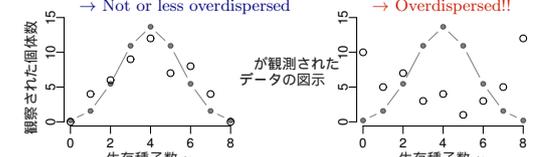
過分散と個体差 観測されていない個体差がもたらす過分散

過分散 (overdispersion) とは何か?



(A) 個体差のばらつきが小さい場合 → Not or less overdispersed

(B) 個体差のばらつきが大きい場合 → Overdispersed!!



観測された個体数

生存種子数 y_i

観測されたデータの図示

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 10 / 35

過分散と個体差 観測されていない個体差がもたらす過分散

ロジスティック回帰やポアソン回帰
 といった GLM では
 全サンプルの均質性を仮定している

GLM does not take into account individual differences

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 11 / 35

過分散と個体差 観測されていない個体差がもたらす過分散

現実のカウントデータは
 ほとんど過分散

Almost all “real” data are overdispersed!

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 12 / 35

一般化線形混合モデル 個体差をあらわすパラメーターを追加

Generalized Linear Mixed Model

3. 一般化線形混合モデル

個体差をあらわすパラメーターを追加

fixed effects random effects
固定効果 と ランダム効果

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 13 / 35

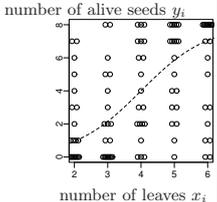
一般化線形混合モデル 個体差をあらわすパラメーターを追加

an improvement of logistic regression model
ロジスティック回帰のモデルを改良する

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: $\beta_1 + \beta_2 x_i + r_i$
- link function
- リンク関数: logit リンク関数



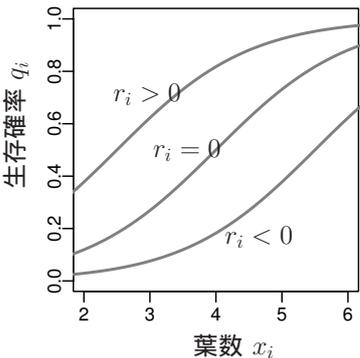
number of alive seeds y_i

number of leaves x_i

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 14 / 35

一般化線形混合モデル 個体差をあらわすパラメーターを追加

個体 i の個体差を r_i としてみよう



生存確率 q_i

葉数 x_i

$r_i > 0$

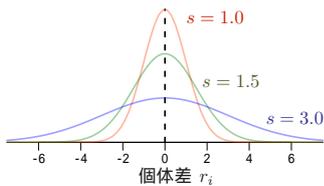
$r_i = 0$

$r_i < 0$

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 15 / 35

一般化線形混合モデル 個体差をあらわすパラメーターを追加

suppose $\{r_i\}$ follow the Gaussian distribution
 $\{r_i\}$ のばらつきは正規分布だと考えてみる



個体差 r_i

$s = 1.0$

$s = 1.5$

$s = 3.0$

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

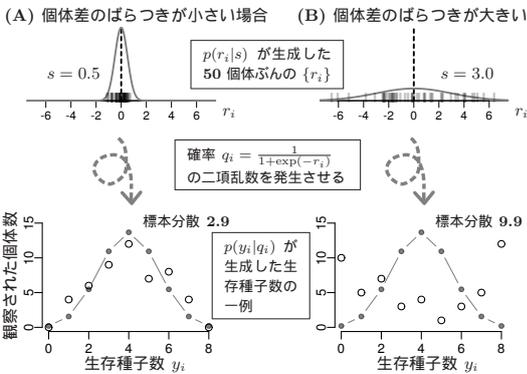
この確率密度 $p(r_i | s)$ は r_i の「出現しやすさ」をあらわしていると解釈すればよいでしょう。 r_i がゼロに近い個体はわりと「ありがち」で、 r_i の絶対値が大きな個体は相対的に「あまりいない」。

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 16 / 35

一般化線形混合モデル 個体差をあらわすパラメーターを追加

個体差 r_i の分布と過分散の関係

(A) 個体差のばらつきが小さい場合 (B) 個体差のばらつきが大きい場合



$s = 0.5$

$s = 3.0$

観察された個体数

生存種子数 y_i

標本分散 2.9

標本分散 9.9

$p(r_i | s)$ が生成した 50 個体ぶん $\{r_i\}$

確率 $q_i = \frac{1}{1 + \exp(-r_i)}$ の二項乱数を発生させる

$p(y_i | q_i)$ が生成した生存種子数の一例

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 17 / 35

一般化線形混合モデル 個体差をあらわすパラメーターを追加

a numerical experiment using random numbers
ちょっと乱数を使った数値実験をしてみましょう

```

> # defining logistic function
> logistic <- function(z) { 1 / (1 + exp(-z)) }
> # random numbers following binomial distribution
> rbinom(100, 8, prob = logistic(0))
> # random numbers following Gaussian distribution
> rnorm(100, mu = 0, sd = 0.5)
> r <- rnorm(100, mu = 0, sd = 0.5)
> # random numbers following ... ?
> rbinom(100, 8, prob = logistic(0 + r))
    
```

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 18 / 35

一般化線形混合モデル 個体差をあらわすパラメーターを追加

fixed effects random effects
固定効果 と ランダム効果

Generalized Linear Mixed Model (GLMM)
linear predictor
で使う Mixed な 線形予測子: $\beta_1 + \beta_2 x_i + r_i$

- fixed effects: $\beta_1 + \beta_2 x_i$
- random effects: $+r_i$

fixed? random? よくわからん.....?

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 19 / 35

一般化線形混合モデル 個体差をあらわすパラメーターを追加

global parameter と local parameter

Generalized Linear Mixed Model (GLMM)
linear predictor
で使う Mixed な 線形予測子: $\beta_1 + \beta_2 x_i + r_i$

- fixed effects: $\beta_1 + \beta_2 x_i$
 - global parameter — for all individuals
- 全個体のばらつき s も global parameter
- random effects: $+r_i$
 - local parameter — only for individual i

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 20 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

4. 一般化線形混合モデルの最尤推定

個体差 r_i を積分して消す尤度方程式

「積分する」とは分布を混ぜること

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 21 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

個体差 r_i は最尤推定できない

local parameters: $\{r_1, r_2, \dots, r_{100}\}$

全 100 個体に対して, 個体ごとにいちいち r_i の値を最尤推定すると saturation model
飽和モデル の推定になってしまう

```
> d <- read.csv("data.csv")
> head(d)
  N y x id
1 8 0 2 1
2 8 1 2 2
3 8 2 2 3
4 8 4 2 4
5 8 1 2 5
6 8 0 2 6
```

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 22 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

尤度関数の中で r_i を積分してしまえばよい

データ y_i のばらつき — binomial distribution 二項分布
$$p(y_i | \beta_1, \beta_2) = \binom{8}{y_i} q_i^{y_i} (1 - q_i)^{8 - y_i}$$

個体差 r_i のばらつき — Gaussian distribution 正規分布
$$p(r_i | s) = \frac{1}{\sqrt{2\pi s^2}} \exp\left(-\frac{r_i^2}{2s^2}\right)$$

個体 i の likelihood 尤度 — to remove r_i r_i を消す
$$L_i = \int_{-\infty}^{\infty} p(y_i | \beta_1, \beta_2, r_i) p(r_i | s) dr_i$$

likelihood for all data 全データの尤度 — β_1, β_2, s の関数
$$L(\beta_1, \beta_2, s) = \prod_i L_i$$

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 23 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

global parameter と local parameter

Generalized Linear Mixed Model (GLMM)
linear predictor
で使う Mixed な 線形予測子: $\beta_1 + \beta_2 x_i + r_i$

- global parameter は最尤推定できる
 - fixed effects: β_1, β_2
 - 全個体のばらつき: s
- local parameter は最尤推定できない
 - random effects: $\{r_1, r_2, \dots, r_{100}\}$

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 24 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

個体差 r_i について積分する ということは 二項分布と正規分布をまぜ あわせること

Integral of $r_i \rightarrow$ mixture distribution of the
binomial and Gaussian distributions

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 25 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

個体差 r ごとに異なる二項分布 \times 集団内の r の分布重み $p(r | s)$

binomial and Gaussian distributions
二項分布と正規分布のまぜあわせ

積分 集団全体をあらわす混合された分布

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 26 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

個体差 r ごとに異なるポアソン分布 \times 集団内の r の分布重み $p(r | s)$

Poisson and Gaussian distributions
ポアソン分布と正規分布のまぜあわせ

積分 集団全体をあらわす混合された分布

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 27 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

glmmML package を使って GLMM の推定

```
> install.packages("glmmML") # if you don't have glmmML
> library(glmmML)
> glmmML(cbind(y, N - y) ~ x, data = d, family = binomial
+ cluster = id)

> d <- read.csv("data.csv")
> head(d)
  N y x id
1 8 0 2 1
2 8 1 2 2
3 8 2 2 3
4 8 4 2 4
5 8 1 2 5
6 8 0 2 6
```

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 28 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

estimates
GLMM の推定値: $\hat{\beta}_1, \hat{\beta}_2, \hat{s}$

```
> glmmML(cbind(y, N - y) ~ x, data = d, family = binomial,
+ cluster = id)
...(snip)...
```

	coef	se(coef)	z	Pr(> z)
(Intercept)	-4.13	0.906	-4.56	5.1e-06
x	0.99	0.214	4.62	3.8e-06

Scale parameter in mixing distribution: 2.49 gaussian
Std. Error: 0.309

Residual deviance: 264 on 97 degrees of freedom AIC: 270

$\hat{\beta}_1 = -4.13, \hat{\beta}_2 = 0.99, \hat{s} = 2.49$

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 29 / 35

一般化線形混合モデルの最尤推定 個体差 r_i を積分して消す尤度方程式

prediction
推定された GLMM を使った 予測

(A) 葉数と生存種子数の関係 (B) 葉数 $x = 4$ での種子数分布

生存種子数 y_i 葉数 x_i 種子数 y 個体数

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 30 / 35

現実のデータ解析には GLMM が必要 個体差・場所差を考えないといけないから

5. 現実のデータ解析には GLMM が必要

個体差・場所差を考えないといけないから

反復・擬似反復に注意しよう

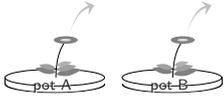
kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 31 / 35

現実のデータ解析には GLMM が必要 個体差・場所差を考えないといけないから

differences both in plants and pots

個体差 + 場所差の GLMM I

(A) 個体・植木鉢が反復

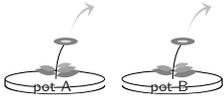


個体差も植木鉢差も推定できない

$$\text{logit}q_i = \beta_1 + \beta_2 x_i \text{ (GLM)}$$

q_i : 種子の生存確率

(B) 個体は擬似反復, 植木鉢は反復



個体差は推定できる 植木鉢差は推定できない

$$\text{logit}q_i = \beta_1 + \beta_2 x_i + r_i$$

より正確にいうと (A) (B) は個体差と植木鉢差の区別がつかない

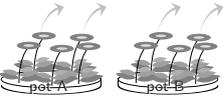
kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 32 / 35

現実のデータ解析には GLMM が必要 個体差・場所差を考えないといけないから

differences both in plants and pots

個体差 + 場所差の GLMM II

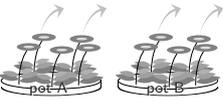
(C) 個体は反復, 植木鉢は擬似反復



個体差は推定できない 植木鉢差は推定できる

$$\text{logit}q_i = \beta_1 + \beta_2 x_i + r_j$$

(D) 個体・植木鉢が擬似反復



個体差も植木鉢差も推定できる

$$\text{logit}q_i = \beta_1 + \beta_2 x_i + r_i + r_j$$

複雑なモデルほど最尤推定は困難, しかも多くのデータが必要

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 33 / 35

現実のデータ解析には GLMM が必要 個体差・場所差を考えないといけないから

summary

GLMM まとめ

- 現実のデータ解析では個体差・場所差の効果を統計モデルに組みこまなければならない
- これらは歴史的には random effects とよばれてきた
- 実際のところは — 統計モデルには global parameter と local parameter があると考えればよい
- GLMM では global parameter を最尤推定する — local parameter は積分して消す
- local parameter が増えると (e.g. 個体差 + 場所差) パラメーター推定がたいへんになる — ということで

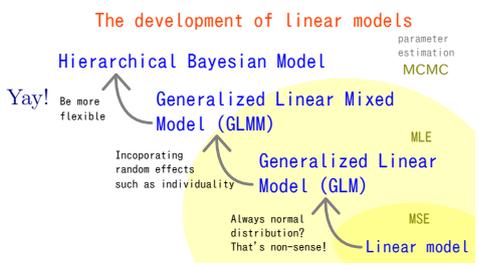
kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 34 / 35

現実のデータ解析には GLMM が必要 個体差・場所差を考えないといけないから

次回予告

The next topic

The development of linear models



Yay! Be more flexible

parameter estimation MCMC

MLE

MSE

Always normal distribution? That's non-sense!

Linear model

Generalized Linear Model (GLM)

Generalized Linear Mixed Model (GLMM)

Hierarchical Bayesian Model

階層ベイズモデル

Hierarchical Bayesian Model (HBM)

kubostat2015f (http://goo.gl/76c4i) 統計モデリング入門 2015 (f) 2015-07-27 35 / 35