

統計モデリング入門 2016 (a)

An Introduction to Statistical Modeling

観測されたパターンを説明する統計モデル

久保拓弥 (北海道大・環境科学)

kubo@ees.hokudai.ac.jp

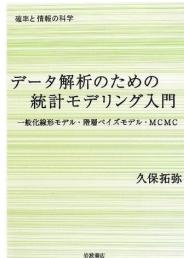


図 3.1 この割頃に登場する菜園植物の第 j 番目の個体。この植物の
体サイズ(個体の大きさ) x_i と肥料をやる施肥処理 f_i が種子数 y_i
にどう影響しているのかを知りたい。

2016-11-15

ngt2016a

1/39

この授業の目的:

「データにあわせて

統計モデルを作る」

…という考え方たに慣れる

「脱」ぶらっくぼっくす統計！

ぶらっくぼっくす統計！？

- 何をやっているのかよくわからないまま統計ソフトウェアにまるなげ
- とにかく $p < 0.05$ …とか “***” なんかが表示されれば「自分は正しい」「好きなように結論してよい」
- なんでも正規分布だ！

2016-11-15

ngt2016a

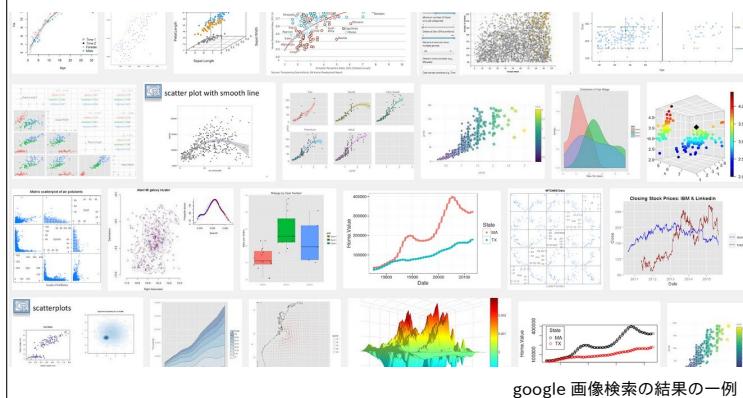
3/39

データ解析で

もっとも重要なことは?

統計モデル?…必ずしもそうではない

データを図示すること!!



作図のないデータ解析はありえない!

2016-11-15

ngt2016a

5/39

じゃ、データ図示の授業やったら?

- うーむ…作図は art?
自分の中では体系化されていない
ダメな作図は指摘できる
よい作図の方針はよくわからない
- 統計モデリングは science
簡単なものから高度なものへステップアップ
何がダメか、比較的明瞭

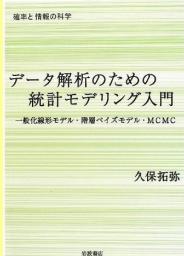
ただし、明日は作図の練習ですよ！

2016-11-15

ngt2016a

6/39

教科書とソフトウェア



この授業は「統計モデリング入門」 にそった内容を説明します

著者: 久保拓弥
出版社: 岩波書店
2012-05-18 刊行
価格 3990 円



<http://goo.gl/Ufq2>

2016-11-15

ngt2016a

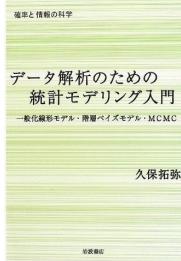
8/39

統計ソフトウェア R

統計学の勉強には良い統計ソフトウェアが必要!

- 無料で入手できる
- 内容が完全に公開されている
- 多くの研究者が使っている
- 作図機能が強力

この教科書でも R を
使って問題を解決する
方法を説明しています

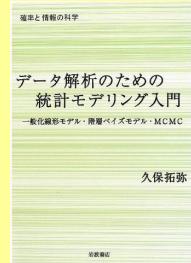


2016-11-15

ngt2016a

9/39

統計モデルとは何か?



「統計モデル」とは何か?

どんな統計解析においても
統計モデルが使用されている

- 観察によってデータ化された現象を説明するために作られる
- 確率分布が基本的な部品であり、これはデータにみられるばらつきを表現する手段である
- データとモデルを対応づける手づきが準備されていて、モデルがデータにどれくらい良くあてはまっているかを定量的に評価できる



2016-11-15

ngt2016a

11/39

「統計モデリング入門」の主張

「何でも正規分布」じゃないでしょ!

線形モデルの発展

推定計算方法
MCMC

階層ベイズモデル

もっと自由な
統計モデリングを!

最尤推定法

一般化線形混合モデル

個体差・場所差
といった変量効果
をあつかいたい

最小二乗法

一般化線形モデル

正規分布以外の
確率分布をあつかいたい

線形モデル

2016-11-15

ngt2016a

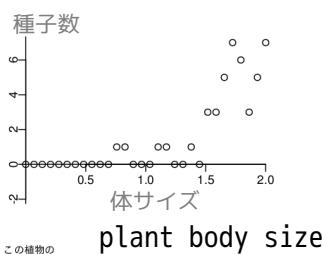
12/39

たとえばこんなデータがあったしましょう

(次の時間の例題)



図 3.1 この例題に登場する架空植物の第 i 番目の個体。この植物の体サイズ(個体の大きさ) x_i と肥料をやる施肥処理 f_i が種子数 y_i にどう影響しているのかを知りたい。



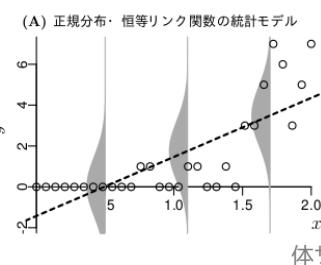
2016-11-15

ngt2016a

13/39

残念なデータ解析

ブラックボックス
統計の典型
統計モデルを
考えていない



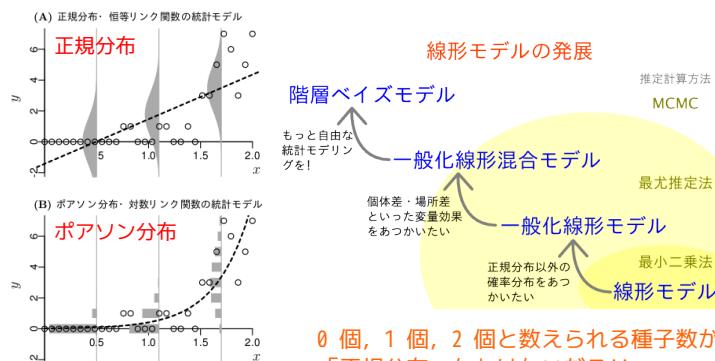
0 個, 1 個, 2 個と数える
種子数が「正規分布」……??

2016-11-15

ngt2016a

14/39

データの値のばらつきをよく見る



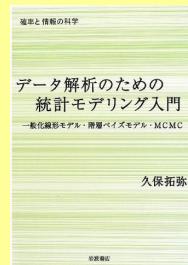
3.9 回帰モデルと確率分布の関係、また別の架空データに対して
GLM をあてはめた例。破線は x とともに変化する平均値、グレイで

2016-11-15

ngt2016a

15/39

誰のための教科書・講義?



あまり勉強しない「理系」院生のための…

「理系」院生の秘密：あまりよく考えない

内容がわからなくてソフトウェアによるなげ

- ブラックボックス統計解析
- とにかく「ゆーい差」さえ出せばよいという発想(「理系」だけにありがちな思考?)

統計モデルを理解する

→ 「脱」ブラックボックス

2016-11-15

ngt2016a

17/39

11/15 の概要

- (a, b) 08:30-10:00 概要, 確率分布と最尤推定
- (c) 10:15-11:45 一般化線形モデルとモデル選択
- (R1) 13:10-14:40 R 実習：データフレーム操作と作図
- (R2) 14:55-16:25 R 実習：GLM あてはめと作図
- (d) 16:40-18:10 検定とロジスティック回帰



11/16 の概要

- (e) 8:30-10:00 階層ベイズモデル
 (f) 10:15-11:45 時間変化データの階層ベイズモデル
 (午後) データ解析相談 (希望する人がいれば)
 場所は?

新潟大集中講義 2016 (b)

確率分布と最尤推定

久保拓弥 kubo@ees.hokudai.ac.jp

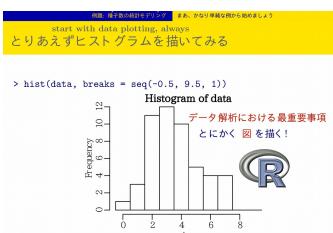
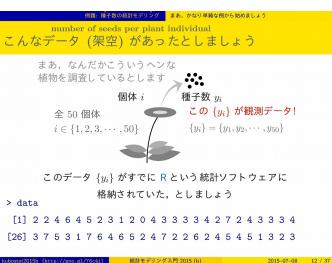
新潟大の講義 <http://goo.gl/aFLHZ>

2016-11-15

ファイル更新時刻: 2016-11-10 15:29

ngt2016b (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 1 / 42

単純化した例題



2016-11-15

ngt2016a

21/39

カウントデータはポアソン分布を使って説明できないかを調べる

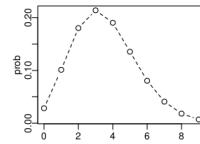


図 4 平均 $\lambda = 3.56$ のポアソン分布。種子数 y とその確率 prob の関係が示されている。図 3 の表を基にしたもの。R の plot() 関数の引数、type = "b" によって「丸」と折れ線による図示し、lty = 2 によって「折れ線は点線で」と指示している。

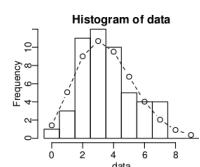
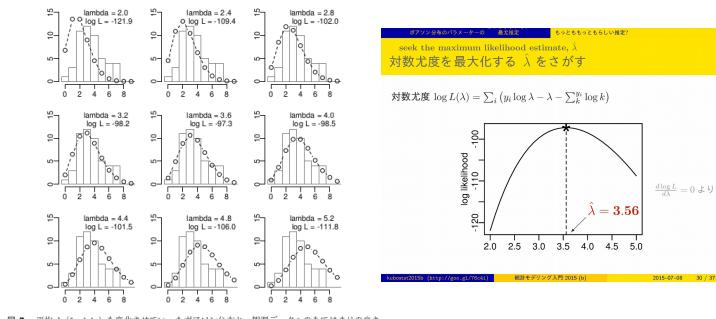


図 5 観測データと確率分布の対応をなす。ヒストグラムは図 3 と同じ。それに重ねられていく丸と折線は y 個の種子をもつ個体数の予測。平均 3.56 の図 4 のポアソン分布の確率分布に全個体数 50 をかけて計算される。

さいゆう 最尤推定という考え方を説明します



2016-11-15

ngt2016a

23/39

新潟大集中講義 2016 (c)

一般化線形モデル(ポアソン回帰)とモデル選択

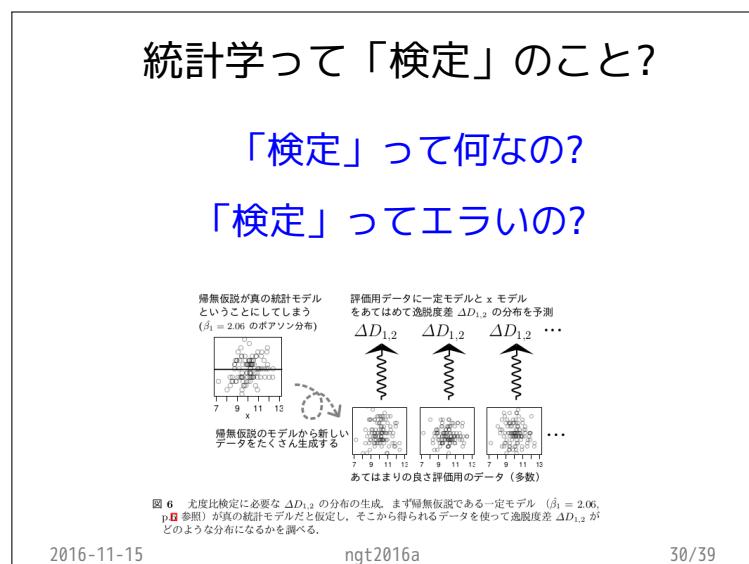
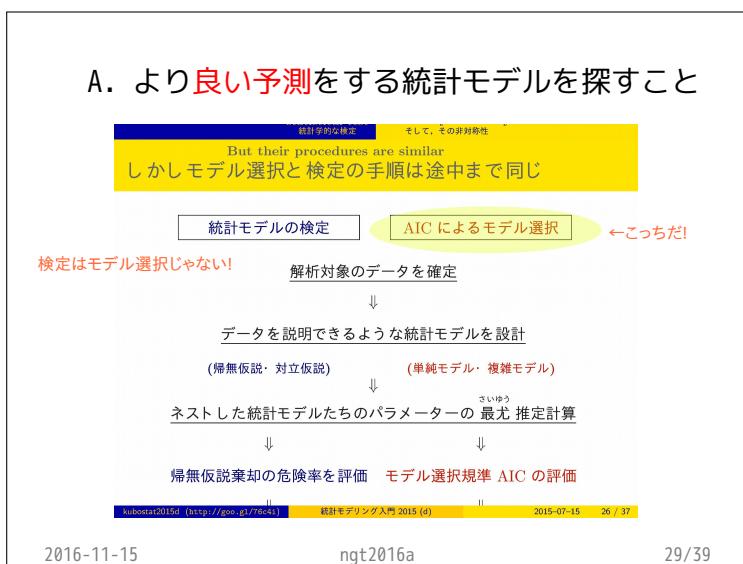
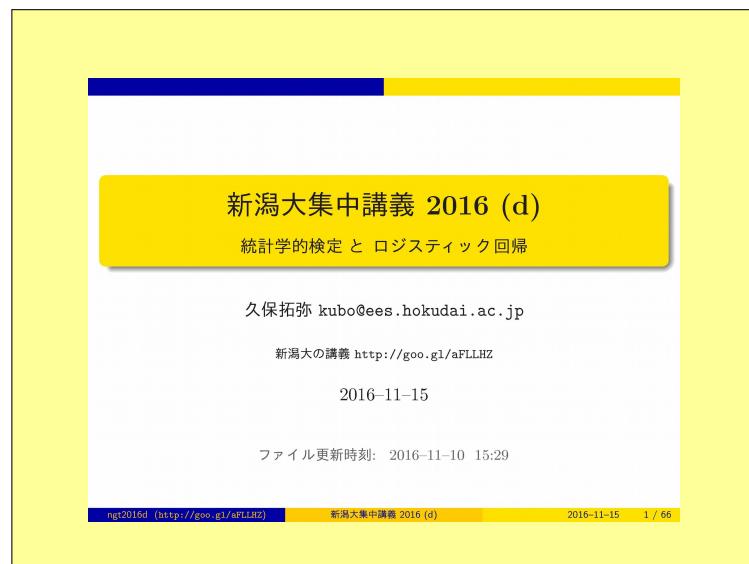
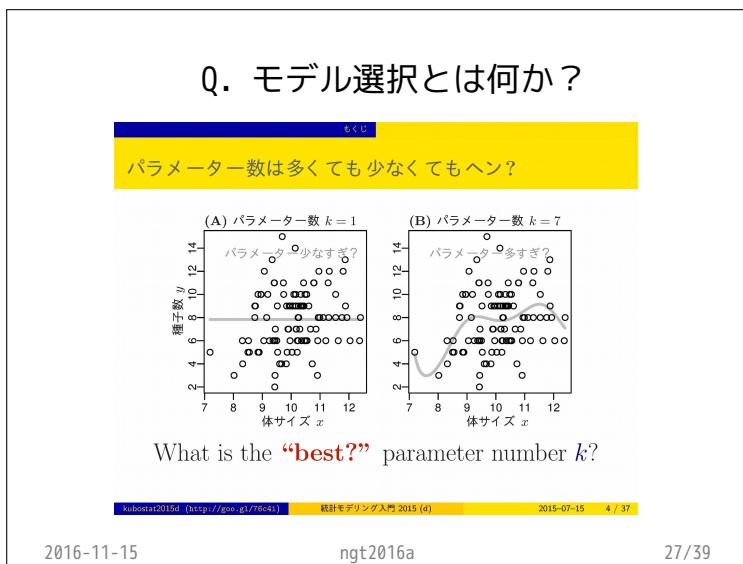
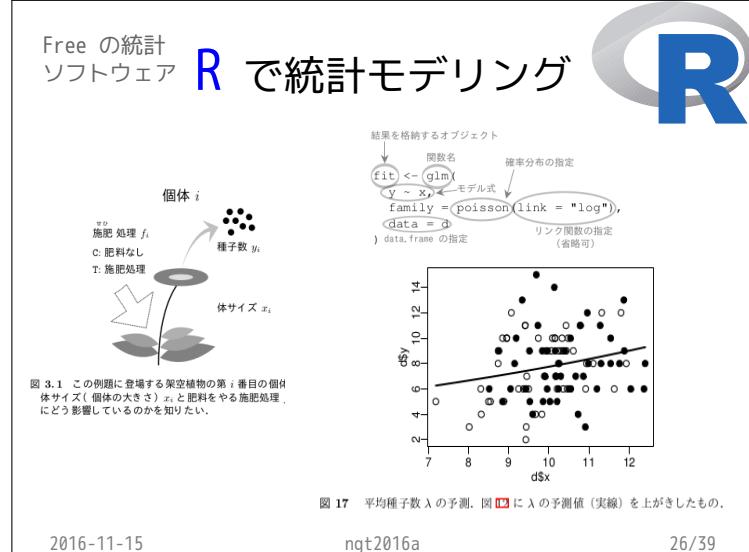
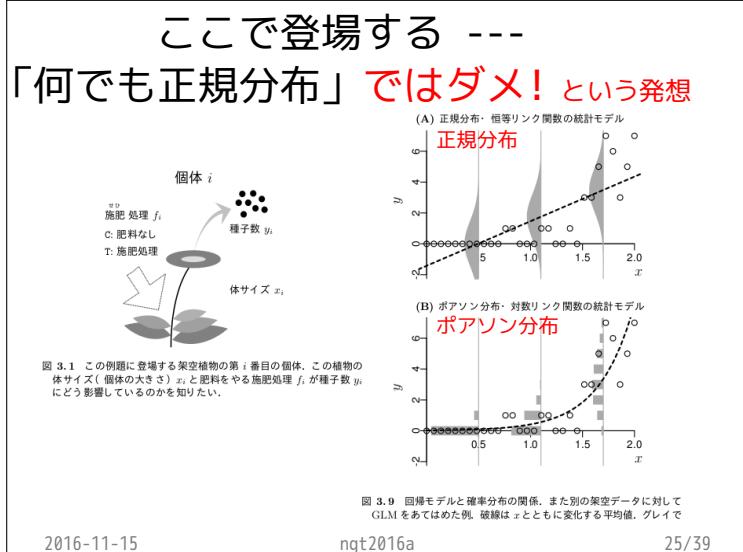
久保拓弥 kubo@ees.hokudai.ac.jp

新潟大の講義 <http://goo.gl/aFLHZ>

2016-11-15

ファイル更新時刻: 2016-11-10 15:29

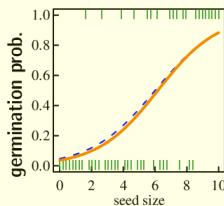
ngt2016c (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 1 / 66



GLM のひとつ、ロジスティック回帰を使おう

データにあわせたより良い統計モデリングを!

おススメできないデータ解析を回避するための注意点



- むやみに 区画わけしない!
- 何でも 割り算するな!
- たくさん 図を描く
- 「観測データを説明する 確率分布は何か?」を考える

コツ: 不自然にデータをこねくりまわさない
データの性質・構造にあったモデリングを!

2012-11-02 k4

(2012-10-26 17:07 修正版)

43 / 44

2016-11-15

ngt2016a

31 / 39

新潟大集中講義 2016 (e)

階層ベイズモデル - 個体差・場所差のモデリング

久保拓弥 kubo@ees.hokudai.ac.jp

新潟大の講義 <http://goo.gl/aFLLHZ>

2016-11-15

ファイル更新時刻: 2016-11-10 15:29

ngt2016e (<http://goo.gl/aFLLHZ>)

新潟大集中講義 2016 (e)

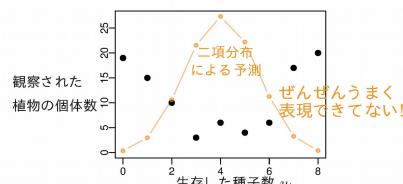
2016-11-15 1 / 82

GLM ではうまく説明できないデータ!?

GLMM は階層ベイズモデルの一種。事前分布はどう選ぶかが重要

また別の観測データ: 二項分布だめだめ!

100 個体の植物の合計 800 種子中 403 個の生存が見られたので、平均生存確率は 0.50 と推定されたが……



さっきの例題と同じようなデータなのに?
(「統計モデリング入門」第 10 章の最初の例題)

第 6 回と同じような例題を、こんどはベイズモデルを使ってモデリングします

なぜ階層ベイズモデルまで勉強するの?

個体差・店舗差・地区

差・空間相関・時間相関

などめんどうな「細かい

差異」をあつかわないと

いけない

そういう難しい状況では……

- 「差異」の階層ベイズモデル化
- そのパラメーターの事後分布を MCMC 法を使って推定するのが無難

2016-11-15

ngt2016a

35 / 39

GLM を階層ベイズモデル化して対処

GLMM は階層ベイズモデルの一種。事前分布はどう選ぶかが重要

なぜ「階層」ベイズモデルと呼ばれるのか?

超事前分布 → 事前分布という階層があるから

データ 8 個中の $y[i]$ 個の種子が生存

σ は hyper parameter

二項分布 生存確率 $q[i]$

植物の個体差

全体の平均 a

個体差のばらつき

無情報事前分布

σ は s と思ってください

事前分布 $r[i]$

無情報事前分布 (超事前分布)

矢印は手順ではなく、依存関係をあらわしている

kubostat2015e (<http://goo.gl/76c441>)

統計モデリング入門 2015 (e)

2015-07-29

56 / 87

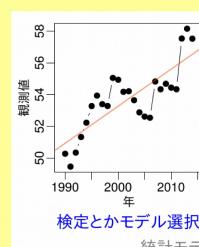
2016-11-15

ngt2016a

34 / 39

(f) 階層ベイズモデル - 時間変化の統計モデリング

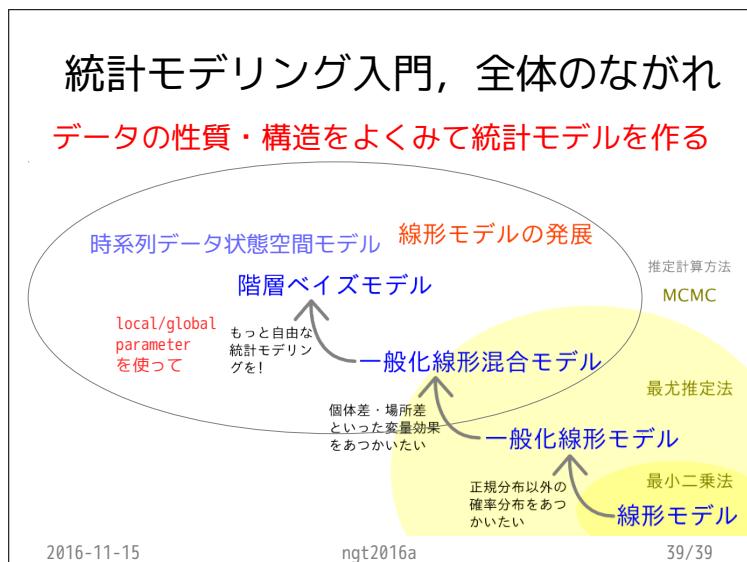
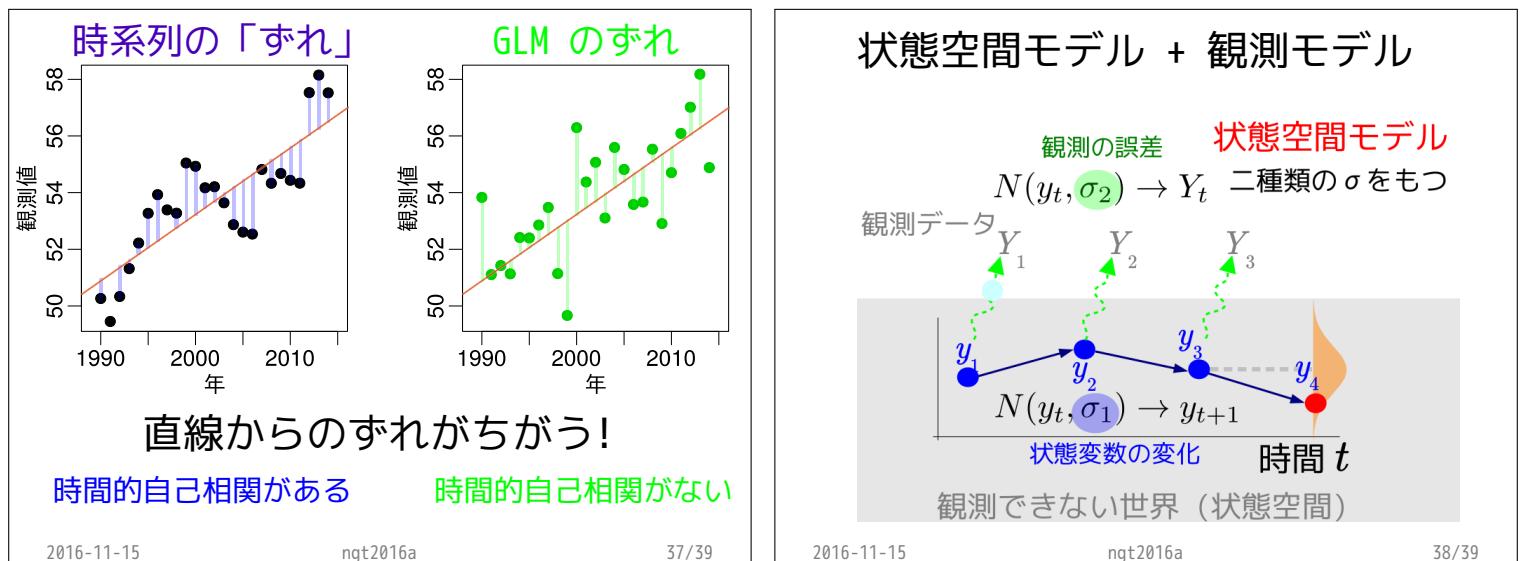
(危 1) 時系列データを GLM で



「ゆーいな傾き」をねつぞうする原因

傾きの検定やめて
AIC モデル選択
しても同様になる

検定とかモデル選択とかそういう問題ではない
統計モデルがおかしい?



新潟大集中講義 2016 (b)
確率分布と最尤推定

久保拓弥 kubo@ees.hokudai.ac.jp
新潟大の講義 <http://goo.gl/aFLLHZ>
2016-11-15
ファイル更新時刻: 2016-11-10 17:15

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 1 / 42

もくじ

今日のハナシ I

- ① 例題: 種子数の統計モデリング
まあ,かなり単純な例から始めましょう
- ② データと確率分布の対応
probability distribution, the core of statistical model
- ③ ポアソン分布のパラメーターの 最尤推定
さいこうすいてい
もっとももっともらしい推定?
- ④ 統計モデルの要点
乱数発生・推定・予測

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 2 / 42

前半のながれ

統計モデリング授業前半の 主題は 「線形モデルを発展させる」 こと

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 3 / 42

前半のながれ

この授業であつかう統計モデルたち

The diagram illustrates the progression of statistical models:

- 線形モデル** (Linear Model) at the bottom, with "最小二乗法" (Least Squares Method) associated with it.
- 一般化線形モデル (GLM)** (Generalized Linear Model) is built upon the linear model, with "正規分布以外の確率分布をあつかいたい" (Want to use probability distributions other than normal) as a motivation.
- 一般化線形混合モデル (GLMM)** (Generalized Linear Mixed Model) is built upon GLM, with "個体差・場所差といった変量効果をあつかいたい" (Want to handle individual differences and spatial effects) as a motivation.
- 階層ベイズモデル (HBM)** (Hierarchical Bayesian Model) is built upon GLMM, with "もっと自由な統計モデリングを!" (Want more flexible statistical modeling) as a motivation.
- 線形モデルの発展** (Development of Linear Models) is labeled at the top right.
- 推定計算方法** (Estimation methods) include **MCMC** and **最尤推定法** (Maximum Likelihood Estimation).

データの特徴にあわせて線形モデルを改良・発展させる

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 4 / 42

前半のながれ

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)

応答変数 y 説明変数 x

説明変数 x	応答変数 y
0.0	0
0.0	1
0.0	2
0.0	3
0.0	4
0.0	5
0.5	0
0.5	1
0.5	2
1.0	0
1.0	1
1.0	2
1.0	3
1.0	4
1.0	5
1.5	0
1.5	1
1.5	2
1.5	3
1.5	4
1.5	5
2.0	0
2.0	1
2.0	2

説明変数

- 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?

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 5 / 42

前半のながれ

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

応答変数 y 説明変数 x

NO!

とにかくセンひきやいいんじょ傾き「ゆーい」ならいいんじょ...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?

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 6 / 42

前半のながれ

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

- タテ軸に対応する「ばらつき」
- 負の値にならない「平均値」
- 正規分布を使ってるモデルよりましたね

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 7 / 42

前半のながれ

データの性質をよくみる 確率分布という部品を選ぶ 「ぶらっくぼっくす」にしない!

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 8 / 42

前半のながれ

今日の内容と「統計モデリング入門」との対応

今日はおもに「**第2章 確率分布と統計モデルの最尤推定**」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>

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 9 / 42

前半のながれ

例題: 種子数の統計モデリング まあ, かなり単純な例から始めましょう

2. 例題: 種子数の統計モデリング

まあ, かなり単純な例から始めましょう

R でデータをあつかいつつ

ngt2016b (<http://goo.g1/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 10 / 42

例題: 種子数の統計モデリング まあ, かなり単純な例から始めましょう

この授業では架空植物の架空データをあつかう

理由: よけいなことは考えなくてすむので

現実のデータはどれも授業で使うには難しすぎる.....

ngt2016b (<http://goo.g1/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 11 / 42

例題: 種子数の統計モデリング まあ, かなり単純な例から始めましょう

こんなデータ(架空)があったとしましょう

まあ, なんだかこういうへんな植物を調査しているとします

個体 i

全 50 個体

$i \in \{1, 2, 3, \dots, 50\}$

種子数 y_i

この $\{y_i\}$ が観測データ!

$\{y_i\} = \{y_1, y_2, \dots, y_{50}\}$

このデータ $\{y_i\}$ がすでに R という統計ソフトウェアに格納されていた, としましょう

```
> data
[1] 2 2 4 6 4 5 2 3 1 2 0 4 3 3 3 3 4 2 7 2 4 3 3 3 4
[26] 3 7 5 3 1 7 6 4 6 5 2 4 7 2 2 6 2 4 5 4 5 1 3 2 3
```

ngt2016b (<http://goo.g1/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 12 / 42

例題：種子数の統計モデリング　まあ，かなり単純な例から始めましょう

これ使いましょう：統計ソフトウェア R

<http://www.r-project.org/>

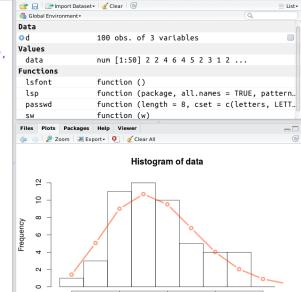


- いろいろな OS で使える free software
- 使いたい機能が充実している
- 作図機能も強力
- S 言語によるプログラミング可能
- Rstudio <http://www.rstudio.com/>

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 13 / 42

例題：種子数の統計モデリング　まあ，かなり単純な例から始めましょう

RStudio



Console > load('F:/芋/distribution/data.RData')
> data
> hist(data)
Min. 1st Qu. Median Mean 3rd Qu. Max.
0.00 2.00 3.00 3.56 4.75 7.00
> lines(0:9, 58 - dpois(0:9, lambda = 3.56), type = 'b', col = '#ff408080', lwd = 4)

File Edit Code View Plots Session Build Debug Tools Help

Environment History Import Dataset Clear Data Editor Environment Data d 180 obs. of 3 variables Values data num [1:50] 2 2 4 6 4 5 2 3 1 2 ... Functions lsfont function () lsp function (package, all.names = TRUE, pattern, passwd function (length = 8, cset = c(letters, LETTERS), ...) sw function (...) File Plots Packages Help Viewer Zoom Export Clear All Histogram of data

Frequency

http://www.rstudio.com/ ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 14 / 42

例題：種子数の統計モデリング　まあ，かなり単純な例から始めましょう

R でデータの様子をながめる



の table() 関数を使って種子数の頻度を調べる

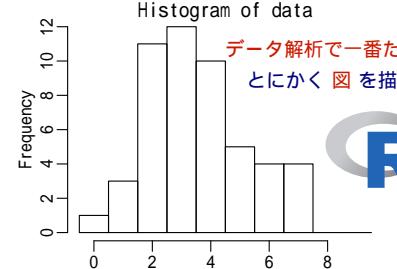
```
> table(data)
 0 1 2 3 4 5 6 7
 1 3 11 12 10 5 4 4
```

(種子数 5 は 5 個体，種子数 6 は 4 個体

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 15 / 42

例題：種子数の統計モデリング　まあ，かなり単純な例から始めましょう

とりあえずヒストグラムを描いてみる



```
> hist(data, breaks = seq(-0.5, 9.5, 1))
Histogram of data
```

データ解析で一番たいせつなことにかく 図を描く!

Frequency

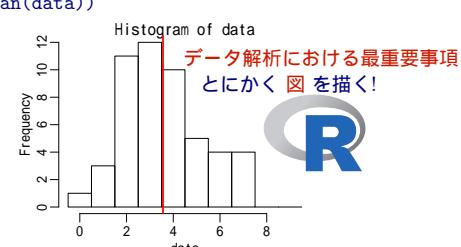
data

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 16 / 42

例題：種子数の統計モデリング　まあ，かなり単純な例から始めましょう

How to evaluate mean value using R?

```
> mean(data)
[1] 3.56
> abline(v = mean(data))
```



データ解析における最重要事項とにかく 図を描く!

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 17 / 42

例題：種子数の統計モデリング　まあ，かなり単純な例から始めましょう

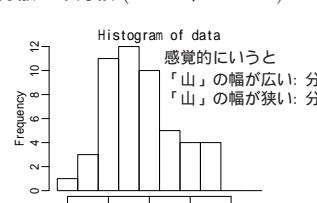
「ばらつき」の統計量

あるデータの ばらつき をあらわす標本統計量の例: 標本分散

```
> var(data)
[1] 2.9861
```

標本標準偏差 とは標本分散の平方根 ($SD = \sqrt{\text{variance}}$)

```
> sd(data)
[1] 1.7280
> sqrt(var(data))
[1] 1.7280
```



感覚的にいうと「山」の幅が広い: 分散が大きい「山」の幅が狭い: 分散が小さい

Frequency

data

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 18 / 42

データと確率分布の対応 probability distribution, the core of statistical model

3. データと確率分布の対応

probability distribution, the core of statistical model

確率分布は統計モデルの重要な部品

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 19 / 42

データと確率分布の対応 probability distribution, the core of statistical model

Empirical VS Theoretical Distributions

統計モデルの部品である 確率分布 には
“データそのまま”な 経験分布 (cf. サイコロ) と
数式で定義される理論的な分布 がある

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 20 / 42

データと確率分布の対応 probability distribution, the core of statistical model

“データそのまま”な経験分布

```
> data.table <- table(factor(data, levels = 0:10))
> cbind(y = data.table, prob = data.table / 50)
```

y	prob
0	0.02
1	0.06
2	0.22
3	0.24
4	0.20
5	0.10
6	0.08
7	0.08
8	0.00
9	0.00
10	0.00

- 確率分布とは 発生する事象 と 発生する確率 の対応づけ
- “たまたま手もとにある”データから “発生確率”を決める確率分布が 経験分布

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 21 / 42

データと確率分布の対応 probability distribution, the core of statistical model

なるほど経験分布は“直感的”かもしれないが……

- データが変わると確率分布が変わる?
- 種子数 $y = \{0, 1, 2, \dots\}$ となる確率が、個々におたがい無関係に決まる?
- パラメーターは $\{p_0, p_1, p_2, \dots, p_{99}, p_{100}, \dots\}$ 無限個ある?

道具として使うには、ちょっと不便かもしれない……

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 22 / 42

データと確率分布の対応 probability distribution, the core of statistical model

なにか理論的に導出された確率分布のほうが便利ではないか?

- 少数のパラメーターで分布の“カタチ”が決まる
- “なめらかに”確率が変化する
- いろいろと数理的な道具が準備されている(パラメーター推定方法など)

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 23 / 42

データと確率分布の対応 probability distribution, the core of statistical model

確率分布(ポアソン分布)を数式で決めてしまう

種子数が y である確率は以下のように決まる、と考えている

$$p(y | \lambda) = \frac{\lambda^y \exp(-\lambda)}{y!}$$

- $y!$ は y の階乗で、たとえば $4!$ は $1 \times 2 \times 3 \times 4$ をあらわしています。
- $\exp(-\lambda) = e^{-\lambda}$ のこと ($e = 2.718\dots$)
- ここではなぜポアソン分布の確率計算が上のようになるのかは説明しません—まあ、こういうもんだと考えて先に進みましょう

ngt2016b (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 24 / 42

データと確率分布の対応 probability distribution, the core of statistical model

数式で決められたポアソン分布?

とりあえず R で作図してみる

```
> y <- 0:9 # これは種子数（確率変数）
> prob <- dpois(y, lambda = 3.56) # ポアソン分布の確率の計算
> plot(y, prob, type = "b", lty = 2) # cbind で「表」作り
> cbind(y, prob)
y      prob
1 0 0.02843882
2 1 0.10124222
3 2 0.18021114
4 3 0.21385056
5 4 0.19032700
6 5 0.13551282
7 6 0.08040427
8 7 0.04089132
9 8 0.01819664
10 9 0.00719778
```

平均 (λ) が 3.56 である
Poisson distribution

ngt2016b (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (b) 2016-11-15 25 / 42

データと確率分布の対応 probability distribution, the core of statistical model

データとポアソン分布を重ね合わせる

Histogram of data

```
> hist(data, seq(-0.5, 8.5, 0.5)) # まずヒストグラムを描く
> lines(y, prob, type = "b", lty = 2) # その「上」に折れ線を描く
```

ngt2016b (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (b) 2016-11-15 26 / 42

データと確率分布の対応 probability distribution, the core of statistical model

パラメーター λ はポアソン分布の平均

λ はポアソン分布の唯一のパラメーター

```
> # cbind で「表」作り
> cbind(y, prob)
y      prob
1 0 0.02843882
2 1 0.10124222
3 2 0.18021114
4 3 0.21385056
5 4 0.19032700
6 5 0.13551282
7 6 0.08040427
8 7 0.04089132
9 8 0.01819664
10 9 0.00719778
```

- 平均 λ はポアソン分布の唯一のパラメーター
- 確率分布の平均は λ である ($\lambda \geq 0$)
- 分散と平均は等しい: $\lambda = \text{平均} = \text{分散}$
- $y \in \{0, 1, 2, \dots, \infty\}$ の値をとり、すべての y について和をとると 1 になる

$$\sum_{y=0}^{\infty} p(y | \lambda) = 1$$

ngt2016b (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (b) 2016-11-15 27 / 42

データと確率分布の対応 probability distribution, the core of statistical model

どういう場合にポアソン分布を使う?

統計モデルの部品としてポアソン分布が選んだ理由:

- データに含まれている値 y_i が $\{0, 1, 2, \dots\}$ といった非負の整数である（カウントデータである）
- y_i に下限（ゼロ）はあるみたいだけど上限はよくわからない
- この観測データでは平均と分散がだいたい等しい
 - このだいたい等しいがあやしいのだけど、まあ気にしないことにしましょう

ngt2016b (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (b) 2016-11-15 28 / 42

データと確率分布の対応 probability distribution, the core of statistical model

ポアソン分布の λ を変えてみる

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

lambda	3.5	7.7	15.1
●	●	▲	■

ngt2016b (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (b) 2016-11-15 29 / 42

ポアソン分布のパラメーターの 最尤推定 もっともっともらしい推定?

さいゆうすいてい

4. ポアソン分布のパラメーターの 最尤推定

もっともっともらしい推定?

「あてはめる」ことは推定すること

ngt2016b (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (b) 2016-11-15 30 / 42

ポアソン分布のパラメーターの 最尤推定 もっとももっともらしい推定?

尤度 (likelihood) とは何か?

- 最尤推定法では、**尤度** というあてはまりの良さをあらわす統計量に着目
- 尤度はデータが得られる確率をかけあわせたもの
- この例題の場合、パラメーター λ を変えると尤度が変わる
- もっとも「あてはまり」が良くなる λ を見つけたい
- たとえば、いまデータが 3 個体ぶん、たとえば、 $\{y_1, y_2, y_3\} = \{2, 2, 4\}$ 、これだけだった場合、尤度はだいたい $0.180 \times 0.180 \times 0.19 = 0.006156$ といった値になる

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 31 / 42

ポアソン分布のパラメーターの 最尤推定 もっとももっともらしい推定?

尤度 $L(\lambda)$ はパラメーター λ の関数

この例題の尤度:

$$\begin{aligned} L(\lambda) &= (y_1 \text{が } 2 \text{ である確率}) \times (y_2 \text{が } 2 \text{ である確率}) \\ &\quad \times \cdots \times (y_{50} \text{が } 3 \text{ である確率}) \\ &= p(y_1 | \lambda) \times p(y_2 | \lambda) \times p(y_3 | \lambda) \times \cdots \times p(y_{50} | \lambda) \\ &= \prod_i p(y_i | \lambda) = \prod_i \frac{\lambda^{y_i} e^{-\lambda}}{y_i!}, \end{aligned}$$
ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 32 / 42

ポアソン分布のパラメーターの 最尤推定 もっとももっともらしい推定?

尤度はしんどいので対数尤度を使う

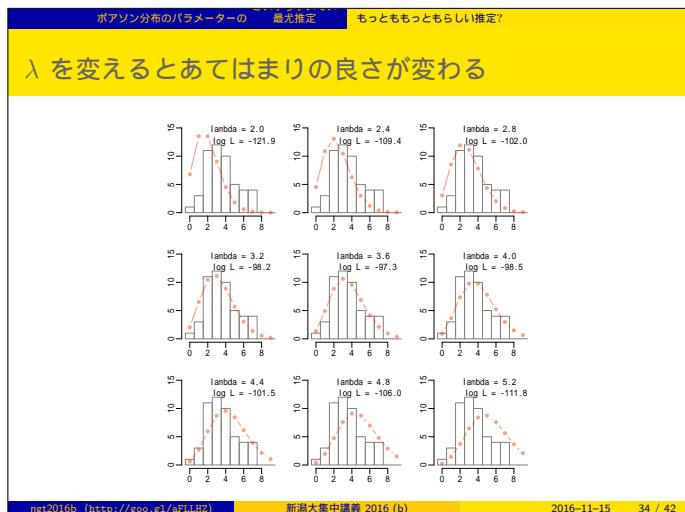
尤度は確率 (あるいは確率密度) の積であり、あつかいがふべん (大量のかけ算!)

そこで、パラメーターの最尤推定では、**対数尤度関数** (log likelihood function) を使う

$$\log L(\lambda) = \sum_i \left(y_i \log \lambda - \lambda - \sum_k^y \log k \right)$$

対数尤度 $\log L(\lambda)$ の最大化は尤度 $L(\lambda)$ の最大化になるから

まずは、平均をあらわすパラメーター λ を変化させていったときに、ポアソン分布のカタチと対数尤度がどのように変化するのかを調べてみましょう

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 33 / 42ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 34 / 42

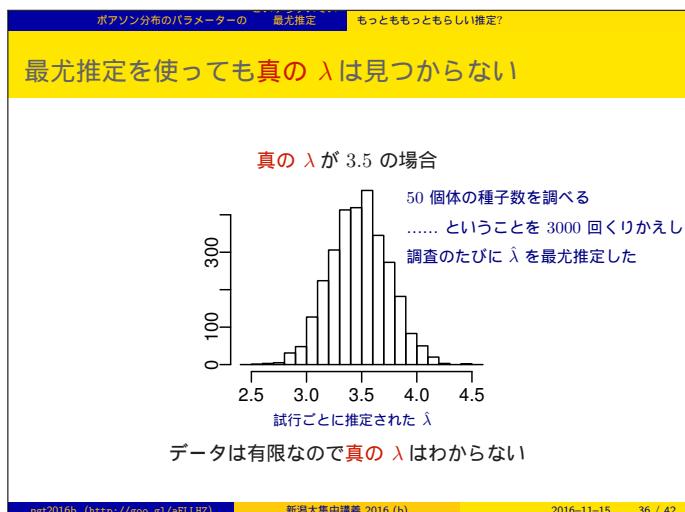
ポアソン分布のパラメーターの 最尤推定 もっとももっともらしい推定?

対数尤度を最大化する $\hat{\lambda}$ をさがす

対数尤度 $\log L(\lambda) = \sum_i (y_i \log \lambda - \lambda - \sum_k^y \log k)$

The graph plots $\log L(\lambda)$ against λ . The x-axis ranges from 2.0 to 5.0, and the y-axis ranges from -120 to -100. The curve is bell-shaped and symmetric. A vertical dashed line is drawn at $\lambda = 3.56$, which is marked with an asterisk (*). The text $\frac{d \log L}{d \lambda} = 0$ より $\hat{\lambda} = 3.56$ is written next to the curve.

- 最尤推定量 (ML estimator): $\sum_i y_i / 50$ 標本平均値!
- 最尤推定値 (ML estimate): $\hat{\lambda} = 3.56$ ぐらい

ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 35 / 42ngt2016b (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (b) 2016-11-15 36 / 42

統計モデルの要点 | 乱数発生・推定・予測

5. 統計モデルの要点

乱数発生・推定・予測

統計モデルとデータの対応づけ

ngt2016b (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 37 / 42

統計モデルの要点 | 乱数発生・推定・予測

確率分布: 亂数発生 と 推定

(人間には見えない)
真の統計モデル
 $\lambda = 3.5$ のポアソン分布

観測データから
推定された
 $\lambda = 3.56$ のポアソン分布

パラメーター推定

観測されたデータ

データをサンプル

確率分布から乱数を発生

データ?...ここでは確率・統計モデルが生成していると仮定

ngt2016b (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 38 / 42

統計モデルの要点 | 乱数発生・推定・予測

推定されたモデルを使った 予測

(人間には見えない)
真の統計モデル
 $\lambda = 3.5$ のポアソン分布

観測データから
推定された
 $\lambda = 3.56$ のポアソン分布

予測: 新しいデータに
あてはまるのか?
(予測の良さを調べている)

新しいデータをサンプル

同じ調査方法で得られた新データ

...
...

ngt2016b (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 39 / 42

統計モデルの要点 | 乱数発生・推定・予測

この講義で登場する確率分布

- ポアソン分布:** $y \in \{0, 1, 2, 3, \dots\}$ となるデータ, 「 y 回なにかがおこった」
- 二項分布:** $y \in \{0, 1, 2, \dots, N\}$ となるデータ, 「 N 個のうち y 個で何かがおこった」
- 正規分布:** $-\infty < y < \infty$ の連続値をとるデータ
- その他あれこれ — ちょっと登場するだけ

そんなに多くの確率分布は登場しません

ngt2016b (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 40 / 42

統計モデルの要点 | 乱数発生・推定・予測

いろいろな確率分布があるけれど.....

- この講義では多種多様な確率分布をあつかいません
- しかし 確率分布を混ぜあわせる ことによって, 自分で確率分布を作り出すことができます
- ハナシの後半に登場する GLMM や階層ベイズモデル

線形モデルの発展

階層ベイズモデル (HBM)
もっと自由な
統計モデル
が!

一般化線形混合モデル (GLMM)
複数の項目差
といった変動効果
をあつかいたい

一般化線形モデル (GLM)
正規分布以外の
確率分布をあつ
かいたい

線形モデル
最小二乗法
最大推定法
MCMC

ngt2016b (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 41 / 42

統計モデルの要点 | 乱数発生・推定・予測

次回予告

The next topic

YES!

一般化線形モデルのひとつ: ポアソン回帰

Poisson Regression, a Generalized Linear Model (GLM)

ngt2016b (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (b) 2016-11-15 42 / 42

新潟大集中講義 2016 (c)
一般化線形モデル（ポアソン回帰）とモデル選択

久保拓弥 kubo@ees.hokudai.ac.jp
新潟大の講義 <http://goo.gl/aFLLHZ>
2016-11-15
ファイル更新時刻: 2016-11-10 17:15

ngt2016c (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 1 / 66

もくじ

今日のハナシ I

- ① ポアソン回帰の統計モデル
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?
- ③ GLM の詳細を指定する
確率分布・線形予測子・リンク関数
- ④ R で 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
- ⑤ 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
- ⑥ モデル選択
予測力のよい統計モデルはどれか?
- ⑦ AIC を使ったモデル選択
あてはまりの悪さ: deviance

ngt2016c (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 2 / 66

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

ngt2016c (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 3 / 66

もくじ

一般化線形モデルって何だろう?

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)
-

ngt2016c (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 4 / 66

ポアソン回帰の統計モデル 応答変数 y と説明変数 x

1. ポアソン回帰の統計モデル

応答変数 y と説明変数 x

一般化線形モデルにとりくんぐみる

ngt2016c (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 5 / 66

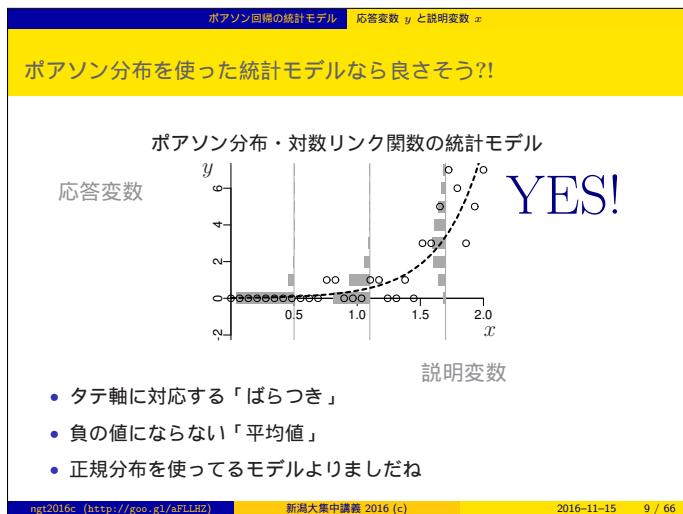
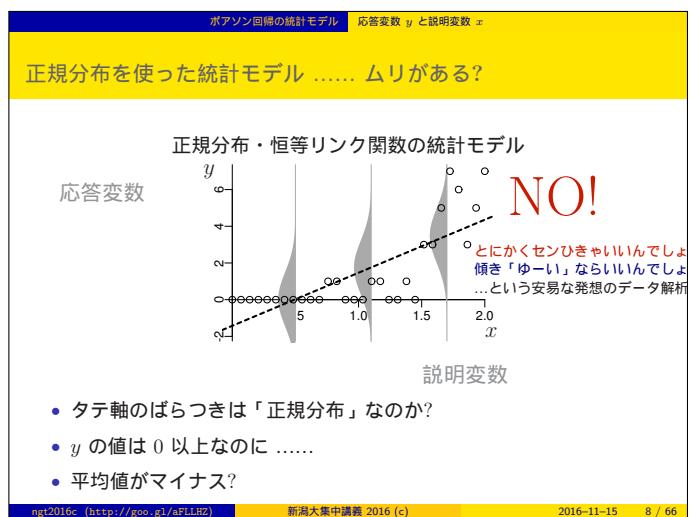
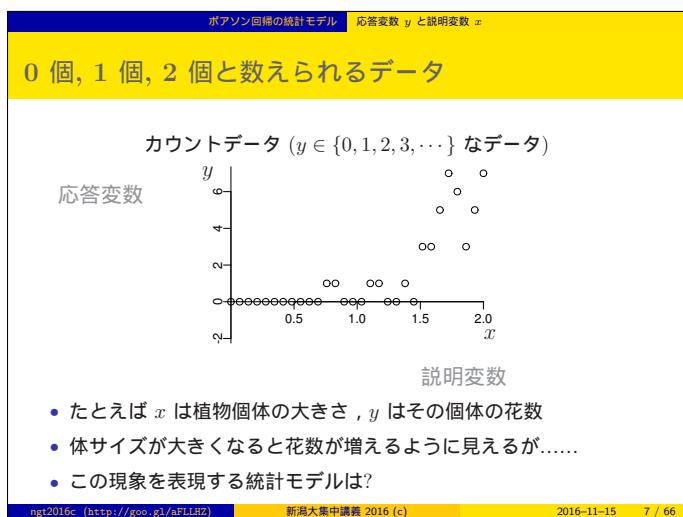
ポアソン回帰の統計モデル 応答変数 y と説明変数 x

この授業であつかう統計モデルたち

線形モデルの発展

データの特徴にあわせて線形モデルを改良・発展させる

ngt2016c (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 6 / 66



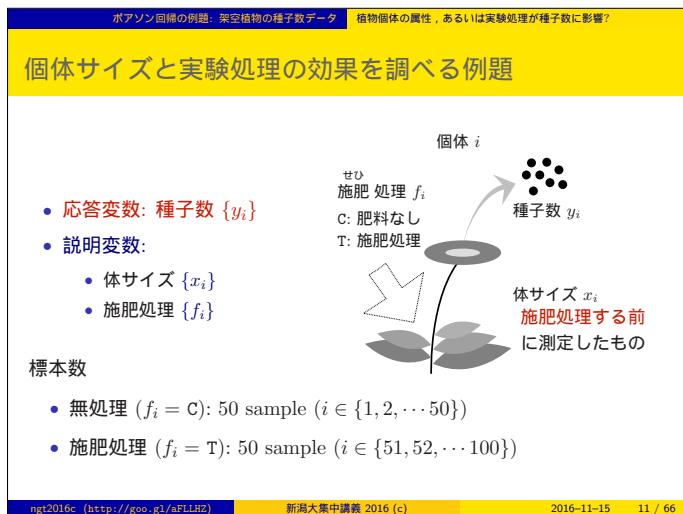
ポアソン回帰の例題: 架空植物の種子数データ 植物個体の属性, あるいは実験処理が種子数に影響?

7. 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?

まずはデータの概要を調べる

ngt2016c (<http://goo.gl/aEL1H2>) 新潟大集中講義 2016 (c) 2016-11-15 10 / 66



データファイルを読みこむ

R

data3a.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("data3a.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

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

ngt2016c (<http://goo.gl/aEL1H2>) 新潟大集中講義 2016 (c) 2016-11-15 12 / 66

data frame d を調べる: 連続値と整数値

```

> d$x
[1] 8.31 9.44 9.50 9.07 10.16 8.32 10.61 10.06
[9] 9.93 10.43 10.36 10.15 10.92 8.85 9.42 11.11
... (中略) ...
[97] 8.52 10.24 10.86 9.97

> d$y
[1] 6 6 6 12 10 4 9 9 9 11 6 10 6 10 11 8
[17] 3 8 5 5 4 11 5 10 6 6 7 9 3 10 2 9
... (中略) ...
[97] 6 8 7 9

```

ngt2016c (<http://goo.gl/aFLLHz>) 新潟大集中講義 2016 (c) 2016-11-15 13 / 66

data frame d を調べる：“因子型” のデータ

施肥処理の有無をあらわす \pm 列はちょっと様子がちがう

因子型データ: いくつかの水準をもつデータ
ここでは C と T の 2 水準

ngt2016c (<http://goo.gl/aFLLHz>) 新潟大集中講義 2016 (c) 2016-11-15 13 / 66

ngt2016c (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 14 / 66

Rのデータのクラスとタイプ

```
> class(d) # d は data.frame クラス
[1] "data.frame"
> class(d$y) # y 列は整数だけの integer クラス
[1] "integer"
> class(d$x) # x 列は実数も含むので numeric クラス
[1] "numeric"
> class(d$f) # そして f 列は factor クラス
[1] "factor"
```

ngt2016c (<http://goo.gl/aFLLHz>) 新潟大集中講義 2016 (c) 2016-11-15 15 / 66

data frame \emptyset summary()

```

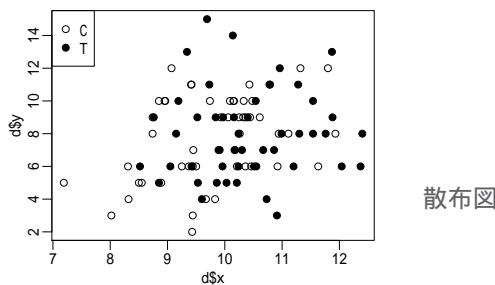
> summary(d)
      y                  x                  f
Min. : 2.00   Min. : 7.190   C:50
1st Qu.: 6.00  1st Qu.: 9.428   T:50
Median : 8.00  Median :10.155
Mean   : 7.83  Mean   :10.089
3rd Qu.:10.00  3rd Qu.:10.685
Max.  :15.00  Max.  :12.400

```

ngt2016c (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 16 / 66

データはとにかく図示する!

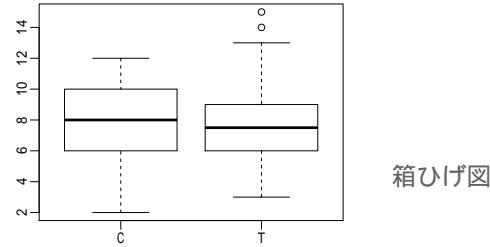
```
> plot(d$x, d$y, pch = c(21, 19)[d$f])
> legend("topleft", legend = c("C", "T"), pch = c(21, 19))
```



ngt2016c (<http://goo.gl/aFLLHz>) 新潟大集中講義 2016 (c) 2016-11-15 17 / 66

施肥処理 f を横軸とした図

```
> plot(d$f, d$y)
```



ngt2016c (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 18 / 66

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

3. GLM の詳細を指定する

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

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 19 / 66

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

一般化線形モデルを作る

一般化線形モデル (GLM)

- 確率分布は?
- 線形予測子は?
- リンク関数は?

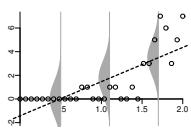
ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 20 / 66

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

- 確率分布: 正規分布
- 線形予測子: e.g., $\beta_1 + \beta_2 x_i$
- リンク関数: 恒等リンク関数



直線の式: (切片) + (傾き) $\times x_i$

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 21 / 66

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

結果 ← 原因 (かも?) を表現する線形モデル

- 結果: 応答変数
- 原因: 説明変数
- 線形予測子 (linear predictor):

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

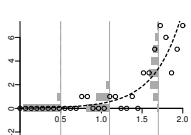
ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 22 / 66

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

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



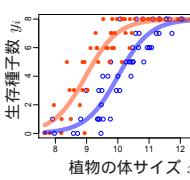
ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 23 / 66

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



ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 24 / 66

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.....

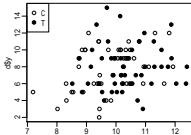
	確率分布	乱数発生	GLM あてはめ
(離散)	ベルヌーイ分布	rbinom()	glm(family = binomial)
	二項分布	rbinom()	glm(family = binomial)
	ポアソン分布	rpois()	glm(family = poisson)
	負の二項分布	rnbinoim()	glm.nb() in library(MASS)
(連続)	ガンマ分布	rgamma()	glm(family = gamma)
	正規分布	rnorm()	glm(family = gaussian)

- `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

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 25 / 66

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

さてさて、種子数の例題にもどって



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.....?

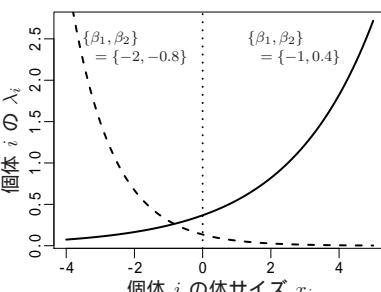
$$\lambda_i = \exp(\beta_1 + \beta_2 x_i)$$

- 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

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 26 / 66

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

指数関数ってなんだっけ?

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

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 27 / 66

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

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

$$\Updownarrow$$

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

log(平均) = 線形予測子

log リンク関数とよばれる理由は、上のようになっているから

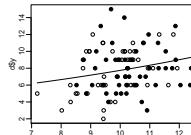
ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 28 / 66

GLM の詳細を指定する 確率分布・線形予測子・リンク関数

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


ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 29 / 66

R で 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

4. R で 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

推定計算はコンピューターにおまかせ

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 30 / 66

R で 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

```
> 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

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

ngt2016c (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 31 / 66

R で 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
)
```

- 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?

ngt2016c (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 32 / 66

R で 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 ^IAIC: 475

ngt2016c (http://geo.g1/aFLHZ) 新潟大集中講義 2016 (c) 2016-11-15 33 / 66
```

R で 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) .....
```

ngt2016c (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 34 / 66

R で 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いめーじ (かなりいいかけんな説明)

β_2 (Estimate 0.0757, SE 0.0356)

(Estimate 1.29, SE 0.364)

β_1

• 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)

ngt2016c (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 35 / 66

R で 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いめーじ (何がめんどくさいの?)

β_2 (Estimate 0.0757, SE 0.0356)

(Estimate 1.29, SE 0.364)

β_1

- 区間 95% 内に「ゼロ」があるとしよう → 「だから何?」
- 多数のパラメーターがある場合には?
- 授業の後半であつかうベイズ統計モデルでの解釈は簡単になるはず.....

ngt2016c (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 36 / 66

R で 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

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))

ここでは観測データと予測の関係を見ているだけ、なのだが
```

ngt2016c (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (c) 2016-11-15 37 / 66

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

5. 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

数量型 + 因子型 という組み合わせで

ngt2016c (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (c) 2016-11-15 38 / 66

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

肥料の効果 f_i もいれましょう

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

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

- β_3 は施肥処理の効果の係数
- f_i のダミー変数

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

ngt2016c (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (c) 2016-11-15 39 / 66

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

glm(y ~ x + f, ...) 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) .....
```

ngt2016c (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (c) 2016-11-15 40 / 66

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

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
```

ngt2016c (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (c) 2016-11-15 41 / 66

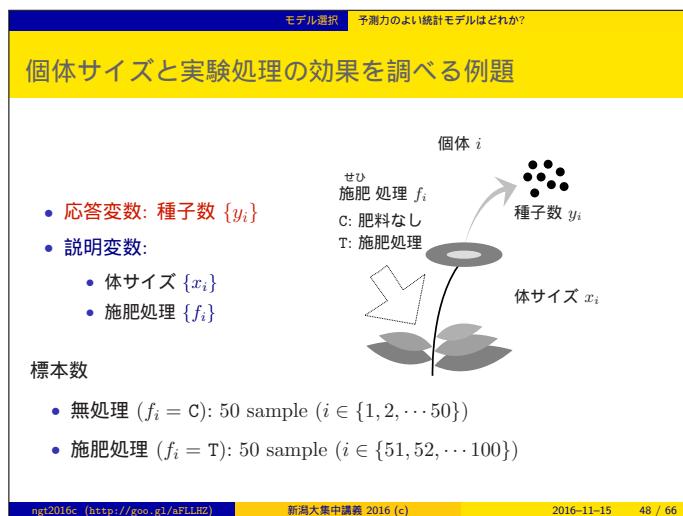
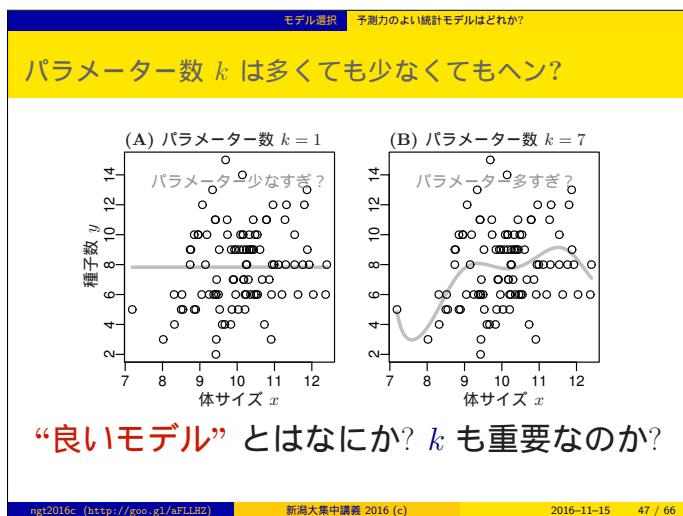
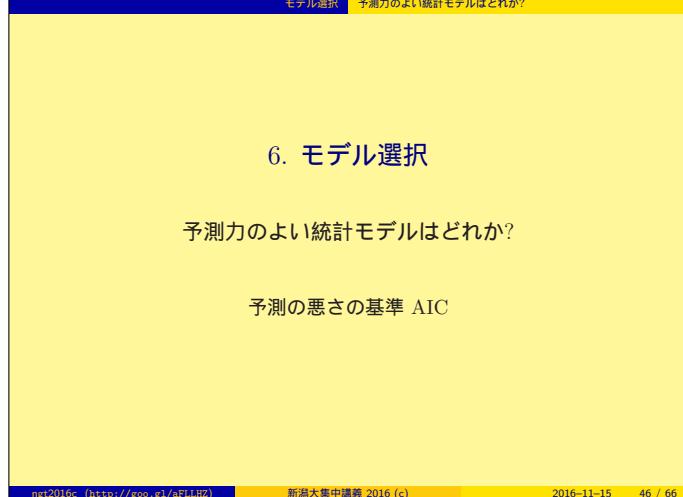
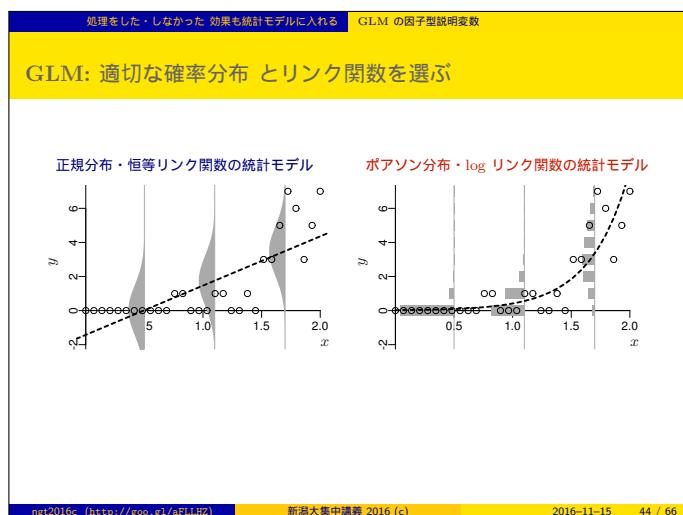
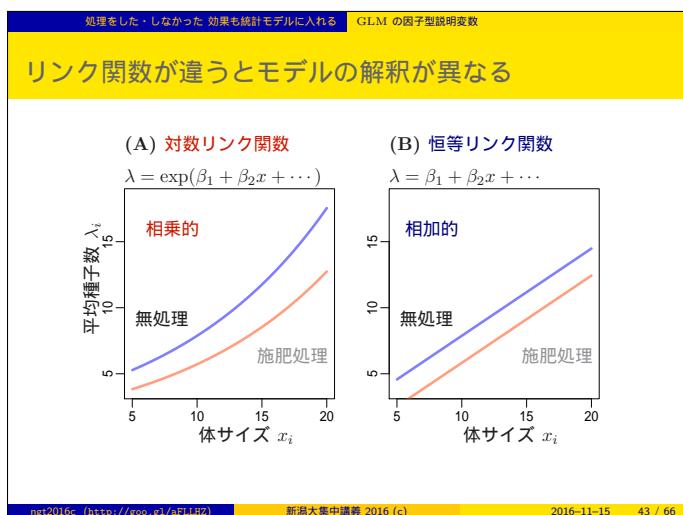
処理をした・しなかった 効果も統計モデルに入れる GLM の因子型説明変数

複数の説明変数をいたした場合の統計モデル

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

施肥効果である $\exp(-0.032)$ はかけ算できくことに注意!

ngt2016c (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (c) 2016-11-15 42 / 66



モデル選択 予測力のよい統計モデルはどれか?

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: $\beta_1 + \beta_2 x_i + \beta_3 f_i$
- リンク関数: 対数リンク関数

ngt2016c (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 49 / 66

モデル選択 予測力のよい統計モデルはどれか?

4 つの可能なモデル候補: (A) constant λ

$$\lambda_i = \exp(\beta_1)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ 1, data = d, family = poisson))
'log Lik.' -237.64 (df=1)
```

ngt2016c (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 50 / 66

モデル選択 予測力のよい統計モデルはどれか?

4 つの可能なモデル候補: (B) f model

$$\lambda_i = \exp(\beta_1 + \beta_3 f_i)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ f, data = d, family = poisson))
'log Lik.' -237.63 (df=2)
```

ngt2016c (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 51 / 66

モデル選択 予測力のよい統計モデルはどれか?

4 つの可能なモデル候補: (C) x model

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

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ x, data = d, family = poisson))
'log Lik.' -235.39 (df=2)
```

ngt2016c (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 52 / 66

モデル選択 予測力のよい統計モデルはどれか?

4 つの可能なモデル候補: (D) x + f model

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

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ x + f, data = d, family = poisson))
'log Lik.' -235.29 (df=3)
```

ngt2016c (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 53 / 66

モデル選択 予測力のよい統計モデルはどれか?

パラメーター数が多いとあてはまりが良い

(A) constant λ ($k = 1$)	-237.6	(B) f model ($k = 2$)	-237.6
			施肥處理 Control
(C) x model ($k = 2$)	-235.4	(D) x + f model ($k = 3$)	-235.3
			Control fertilization

ngt2016c (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (c) 2016-11-15 54 / 66

AIC を使ったモデル選択 あてはまりの悪さ: deviance

7. AIC を使ったモデル選択

あてはまりの悪さ: deviance

そして予測の悪さ: AIC

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 55 / 66

AIC を使ったモデル選択 あてはまりの悪さ: deviance

R の glm() は deviance を出力

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

Coefficients:
(Intercept)          x          fT 
    1.2631      0.0801     -0.0320 

Degrees of Freedom: 99 Total (i.e. Null); 97 Residual
Null Deviance: 89.5
Residual Deviance: 84.8      AIC: 477

Residual Deviance? Null Deviance? AIC?
```

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 56 / 66

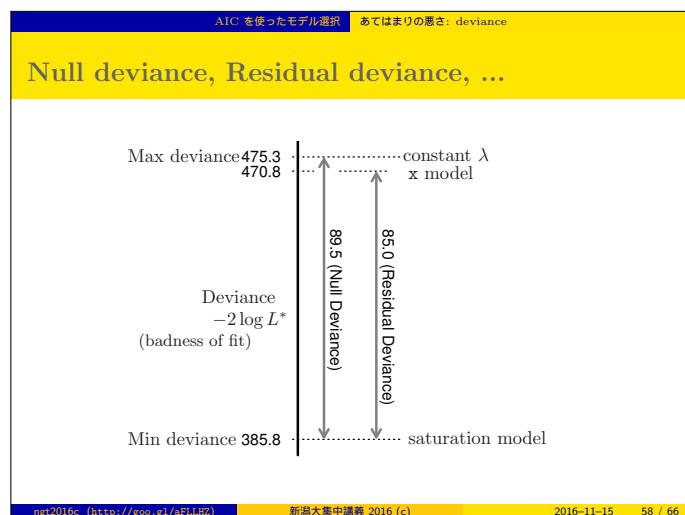
AIC を使ったモデル選択 あてはまりの悪さ: deviance

deviance $D = -2 \times \log L^*$

- Maximum log likelihood $\log L^*$: goodness of fit
- Deviance $D = -2 \log L^*$: badness of fit

model	k	$\log L^*$	Deviance $-2 \log L^*$	Residual deviance
constant λ	1	-237.6	475.3	89.5
f	2	-237.6	475.3	89.5
x	2	-235.4	470.8	85.0
x + f	3	-235.3	470.6	84.8
saturation	100	-192.9	385.8	0.0

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 57 / 66



AIC を使ったモデル選択 あてはまりの悪さ: deviance

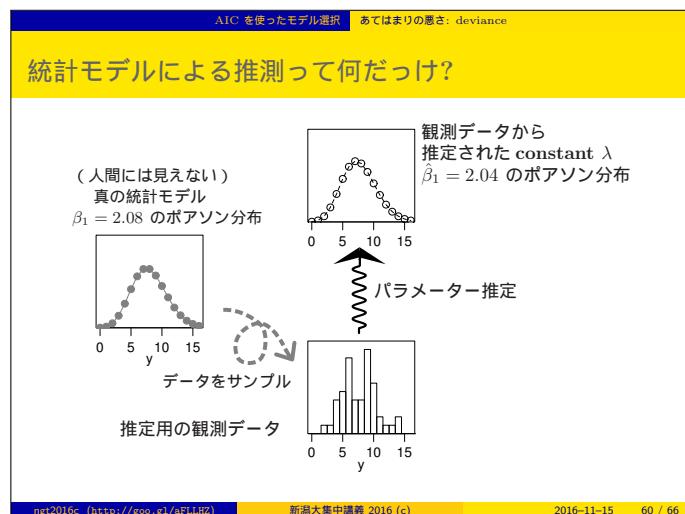
予測の悪さ: $AIC = -2 \log L^* + 2k$

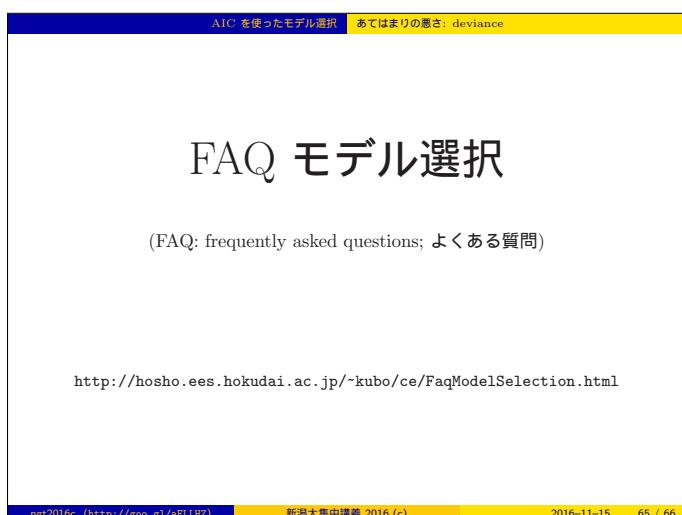
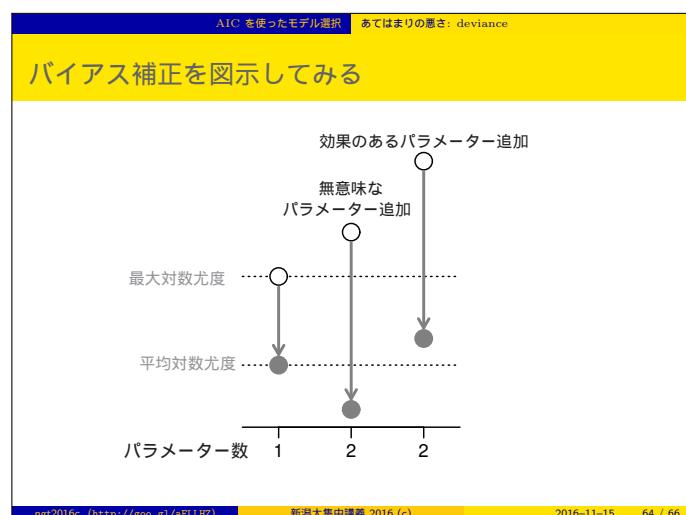
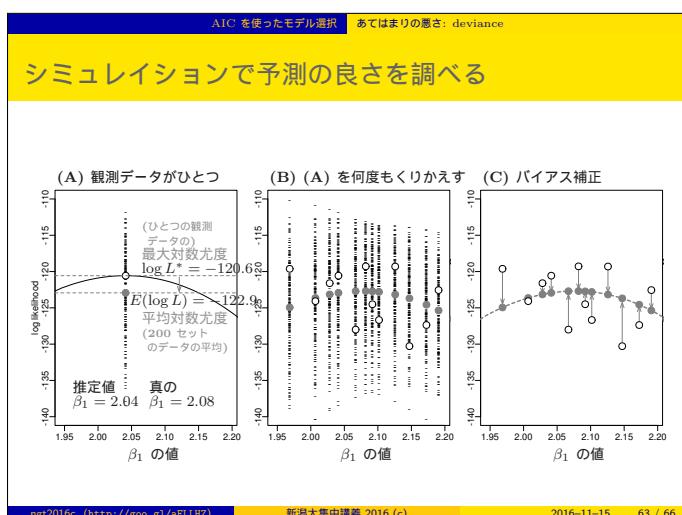
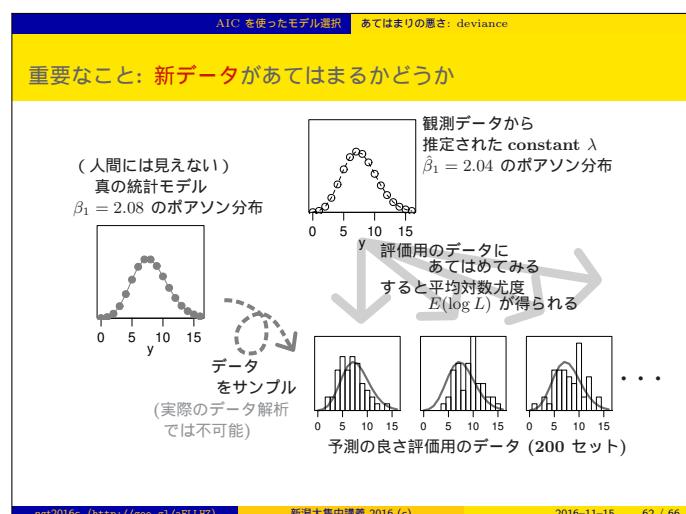
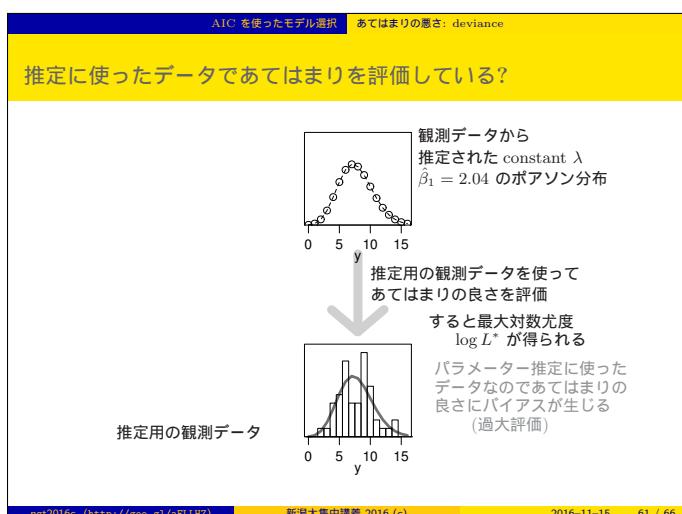
AIC 最小のモデルを選ぶ

model	k	$\log L^*$	Deviance $-2 \log L^*$	Residual deviance	AIC
constant λ	1	-237.6	475.3	89.5	477.3
f	2	-237.6	475.3	89.5	479.3
x	2	-235.4	470.8	85.0	474.8
x + f	3	-235.3	470.6	84.8	476.6
saturation	100	-192.9	385.8	0.0	585.8

AIC: A (or Akaike) information criterion

ngt2016c (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (c) 2016-11-15 59 / 66





次回予告

統計学的検定 と ロジスティック回帰 (GLM)

ngt2016c (<http://goo.gl/aFL1HZ>) 新潟大集中講義 2016 (c) 2016-11-15 66 / 66

新潟大集中講義 2016 (d)
統計学的検定 と ロジスティック回帰

久保拓弥 kubo@ees.hokudai.ac.jp
新潟大の講義 <http://goo.gl/aFLLHZ>
2016-11-15
ファイル更新時刻: 2016-11-10 17:16

ngt2016d (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 1 / 66

もくじ

今日のハナシ I

- ① 統計学的な検定
そして，その非対称性
- ② 統計学的な検定
そして，その非対称性
- ③ “ N 個のうち k 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
- ④ ロジスティック回帰の部品
二項分布 binomial distribution と logit link function
- ⑤ 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
- ⑥ 何でも「割算」するな!
「脱」割算の offset 項わざ

ngt2016d (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 2 / 66

統計学的な検定 | そして，その非対称性

1. 統計学的な検定

そして，その非対称性
ここでは 尤度比検定 を紹介

ngt2016d (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 3 / 66

統計学的な検定 | そして，その非対称性

モデル選択と検定の手順は途中まで同じ

```

    統計モデルの検定 | AIC によるモデル選択
    解析対象のデータを確定
    ↓
    データを説明できるような統計モデルを設計
    (帰無仮説・対立仮説) ↓ (単純モデル・複雑モデル)
    ネストした統計モデルたちのパラメーターの 最尤 推定計算
    ↓ ↓
    帰無仮説棄却の危険率を評価 モデル選択規準 AIC の評価
    ↓ ↓
    帰無仮説棄却の可否を判断 予測の良いモデルを選ぶ
  
```

ngt2016d (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 4 / 66

統計学的な検定 | そして，その非対称性

モデル選択 と 統計学的検定 は その目的がぜんぜんちがう

ngt2016d (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 5 / 66

統計学的な検定 | そして，その非対称性

目的?
モデル選択: 良い予測をするモデルをさがす

統計学的検定: 帰無仮説の排除

ngt2016d (<http://goo.gl/aFLLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 6 / 66

統計学的な検定 (Neyman-Pearson framework) そして、その非対称性

statistical test

Null hypothesis 帰無仮説 $\text{glm}(y \sim 1)$ is better!

Alternative hypothesis 対立仮説 $\text{glm}(y \sim x)$ is better!

VS

どうでもいい … 興味ない…

重要！これを主張したい！

非対称性 asymmetry?

ngt2016d (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (d) 2016-11-15 7 / 66

統計学的な検定 (Neyman-Pearson framework) そして、その非対称性

statistical test

Null hypothesis 帰無仮説 $\text{glm}(y \sim 1)$ is better!

Alternative hypothesis 対立仮説 $\text{glm}(y \sim x)$ is better!

VS

test! ↓
(if ...) reject 棄却 support 支持

非対称性 asymmetry?

ngt2016d (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (d) 2016-11-15 8 / 66

統計学的な検定 (Neyman-Pearson framework) そして、その非対称性

statistical test

Null hypothesis 帰無仮説 $\text{glm}(y \sim 1)$ is better!

Alternative hypothesis 対立仮説 $\text{glm}(y \sim x)$ is better!

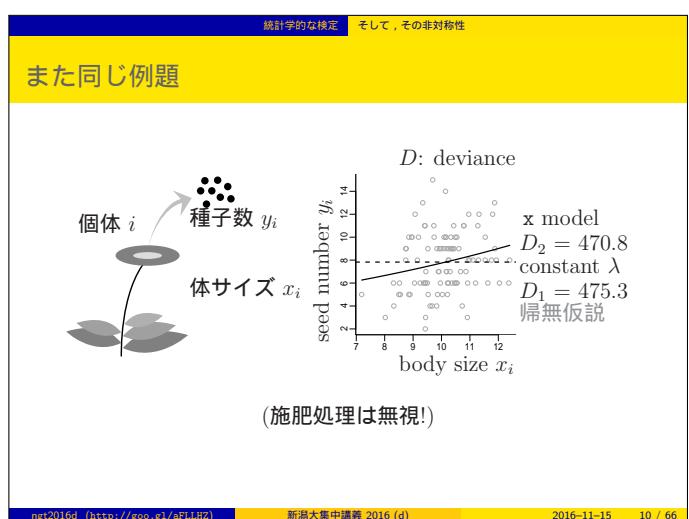
VS

test! ↓
(if ...) NOT reject

Say Nothing!?

非対称性 asymmetry?

ngt2016d (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (d) 2016-11-15 9 / 66



統計学的な検定 そして、その非対称性

検定統計量 $\Delta D_{1,2}$

difference in deviance $\Delta D_{1,2} = D_1 - D_2 = 4.51 \approx 4.5$

likelihood ratio? — $\log \frac{L^*_1}{L^*_2} = \log L^*_1 - \log L^*_2$

model	k	$\log L^*$	Deviance $-2 \log L^*$
constant λ	1	-237.6	$D_1 = 475.3$ 帰無仮説
x	2	-235.4	$D_2 = 470.8$ 対立仮説

検定の非対称性: 帰無仮説はゴミあつかい
……にもかかわらず、帰無仮説だけをしつこく調べる

ngt2016d (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (d) 2016-11-15 11 / 66

統計学的な検定 そして、その非対称性

帰無仮説のつくりかた

対立仮説の中に帰無仮説がある
(ネストした関係)

- カウントデータ $\{y_i\}$ は平均である λ_i のポアソン分布に従う
- 対立仮説の一例: $\log \lambda_i = \beta_1 + \beta_2 x_i$
- ネストした 帰無仮説: $\log \lambda_i = \beta_1$ (切片だけのモデル)

ngt2016d (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (d) 2016-11-15 12 / 66

統計学的な検定 そして、その非対称性

検定の目的: 帰無仮説の棄却

観察された逸脱度差 $\Delta D_{1,2} = 4.5$ は.....	
帰無仮説は	「めったにない差」 (帰無仮説を棄却) 「よくある差」 (棄却できない)
真のモデルである	第一種の過誤 (問題なし)
真のモデルではない	(問題なし) 第二種の過誤

	is ... significant (Reject	not significant (Not reject
TRUE	Type I error	(no problem)
NOT true	(no problem)	Type II error

検定の非対称性: 第一種の過誤だけに注目

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 13 / 66

統計学的な検定 そして、その非対称性

$\Delta D_{1,2}$ の分布を生成: ブートストラップ尤度比検定

帰無仮説 が真的モデルであるとしよう!

評価用データに constant λ と x model をあてはめて逸脱度差 $\Delta D_{1,2}$ の分布を予測 ($\beta_1 = 2.06$ のポアソン分布)

あてはまりの良さ評価用のデータ (多数)

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 14 / 66

統計学的な検定 そして、その非対称性

ブートストラップ法って何?

コンピューターに大量の乱数を発生させる チカラまかせの方法

- 計算機に莫大な数の乱数を発生させる パターン生成
- (例 1): 確率分布の乱数の和 正規分布?
- (例 2): この回の例題の $\Delta D_{1,2}$ の確率分布

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 15 / 66

統計学的な検定 そして、その非対称性

How to generate $\Delta D_{1,2}$ under is TRUE?

```
> d$y.rnd <- rpois(100, lambda = mean(d$y))
> fit1 <- glm(y.rnd ~ 1, data = d, family = poisson)
> fit2 <- glm(y.rnd ~ x, data = d, family = poisson)
> fit1$deviance - fit2$deviance
```

- rpois() によるポアソン乱数の生成 (架空データ)
- 架空データを使って glm() あてはめ

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 16 / 66

統計学的な検定 そして、その非対称性

パラメトリック・ブートストラップの結果

この例題における $\Delta D_{1,2}$ の分布 反復数 10000 回

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 17 / 66

統計学的な検定 そして、その非対称性

あらかじめ棄却域を決めておく

たとえば 5% とか? — (注) “5%” には 何の意味も正当化もない てきとーに決めただけ

NOT significant ←

→ significant (5%)

$3.81 < \Delta D_{1,2}$ となっている領域

帰無仮説 を棄却できる

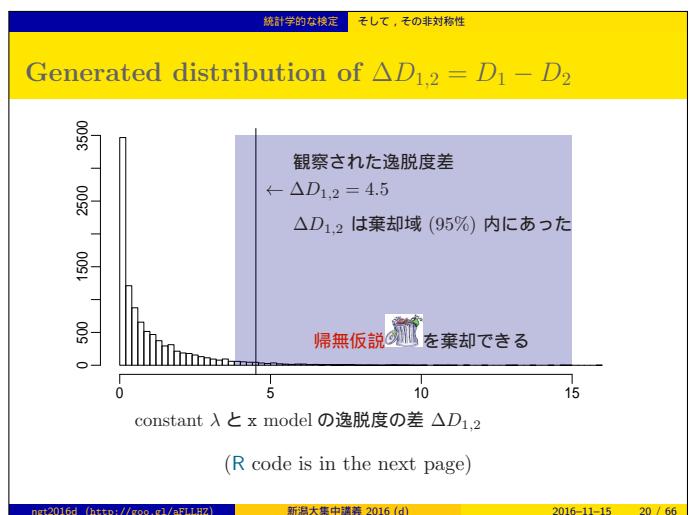
ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 18 / 66

統計学的な検定 そして、その非対称性

A random $\Delta D_{1,2}$ generator in R

```
get.dd <- function(d) # データの生成と逸脱度差の評価
{
  n.sample <- nrow(d) # データ数
  y.mean <- mean(d$y) # 標本平均
  d$y.rnd <- rpois(n.sample, lambda = y.mean)
  fit1 <- glm(y.rnd ~ 1, data = d, family = poisson)
  fit2 <- glm(y.rnd ~ x, data = d, family = poisson)
  fit1$deviance - fit2$deviance # 逸脱度の差を返す
}
pb <- function(d, n.bootstrap)
{
  replicate(n.bootstrap, get.dd(d))
}
```

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 19 / 66



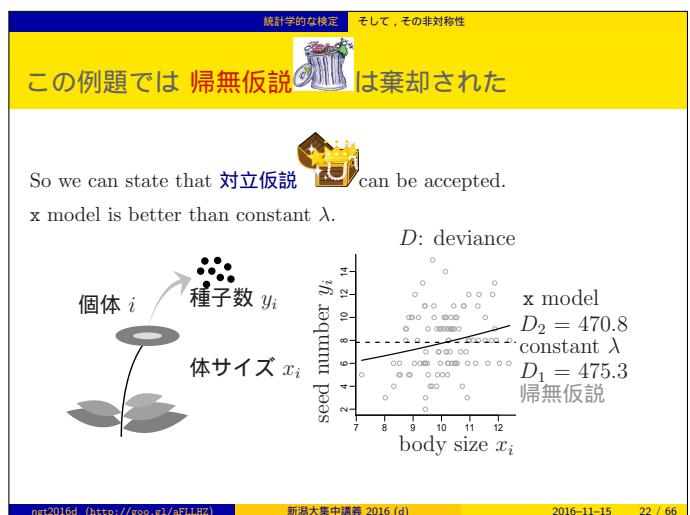
統計学的な検定 そして、その非対称性

Probability{ $\Delta D_{1,2} \geq 4.5\}$ } = $\frac{332}{10000} = 0.0332$

```
> source("pb.R") # reading "pb.R" text file
> dd12 <- pb(d, n.bootstrap = 10000)
> hist(dd12, 100) # to plot histogram
> abline(v = 4.5, lty = 2)
> sum(dd12 >= 4.5)
[1] 332

so-called "P-value" is 0.0332.
```

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 21 / 66



統計学的な検定 そして、その非対称性

In case that $P > 0.05$...?

何も結論できない.....

λ 一定のモデルが良いとは言えない

検定の非対称性: 帰無仮説 はけっして受容されない

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 23 / 66

- 統計学的な検定 そして、その非対称性
- ### 「検定」問題あれこれ
- 統計学的な検定はうまいアイデアだが、誤用も多い
 - 帰無仮説は何があっても受容されない
 - $p = 0.01$ は $p = 0.0001$ より「えらい」わけではない
 - 統計モデルをまちがえると p 値の分布がゆがむ
 - 無意味な $p < 0.05$ にこだわるあまり p hacking という詐術が発達 — $p = 0.04$ ぐらい, という論文がやたらが多い
- ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 24 / 66

統計学的な検定 | そして，その非対称性

2. 統計学的な検定

そして，その非対称性

ここでは 尤度比検定 を紹介

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 25 / 66

統計学的な検定 | そして，その非対称性

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



ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 26 / 66

統計学的な検定 | そして，その非対称性

この授業であつかう統計モデルたち

線形モデルの発展



データの特徴にあわせて線形モデルを改良・発展させる

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 27 / 66

統計学的な検定 | そして，その非対称性

一般化線形モデルって何だろう？

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)
-

ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 28 / 66

統計学的な検定 | そして，その非対称性

一般化線形モデルを作る

一般化線形モデル (GLM)

- 確率分布は？
- 線形予測子は？
- リンク関数は？

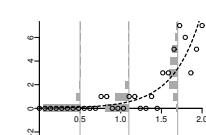
ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 29 / 66

統計学的な検定 | そして，その非対称性

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

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



ngt2016d (<http://goo.gl/aFLHZ2>) 新潟大集中講義 2016 (d) 2016-11-15 30 / 66

統計学的な検定 そして、その非対称性

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

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 31 / 66

「N 個のうち k 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

3. 「N 個のうち k 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

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

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 32 / 66

“N 個のうち k 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 発芽可能 だった! というデータ

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 33 / 66

“N 個のうち k 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

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://hoshohes.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

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 34 / 66

“N 個のうち k 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
```

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 35 / 66

“N 個のうち k 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))
```

今回は施肥処理 がきいている?

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 36 / 66

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

4. ロジスティック回帰の部品

二項分布 binomial distribution と logit link function

ngt2016d (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 37 / 66

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

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」

ngt2016d (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 38 / 66

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")
```

ngt2016d (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 39 / 66

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

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 .

ngt2016d (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 40 / 66

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

ngt2016d (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (d) 41 / 66

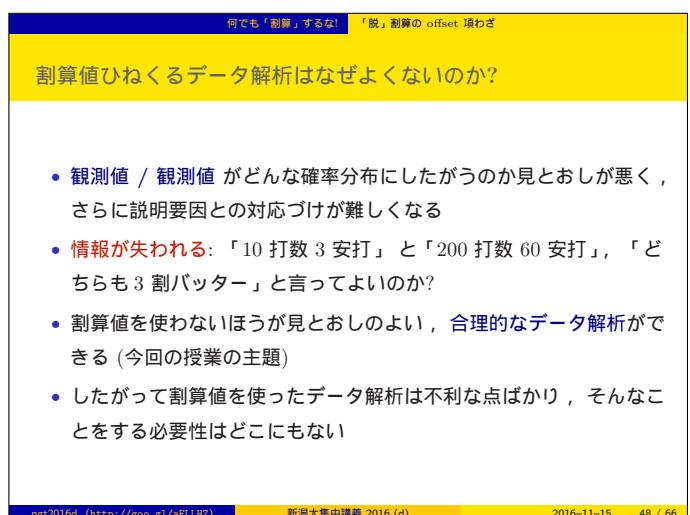
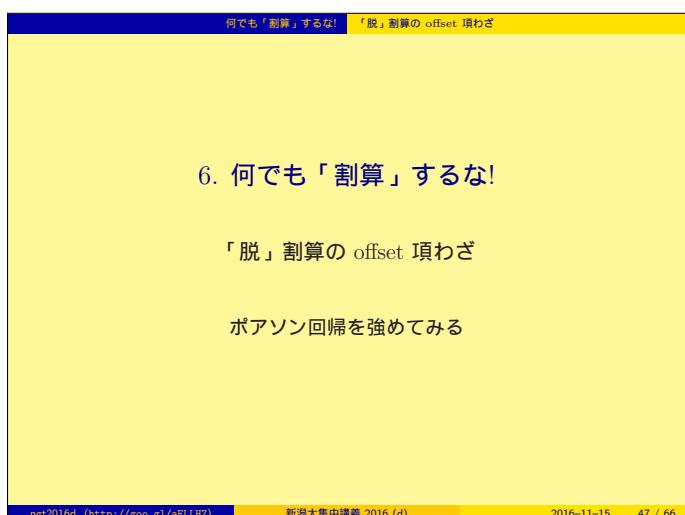
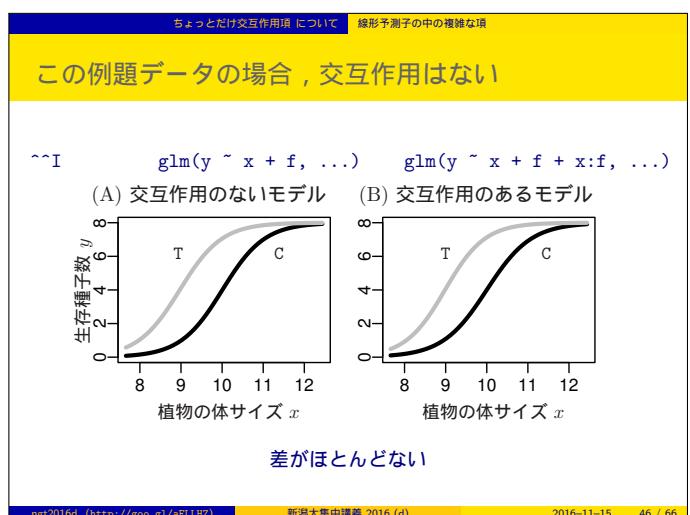
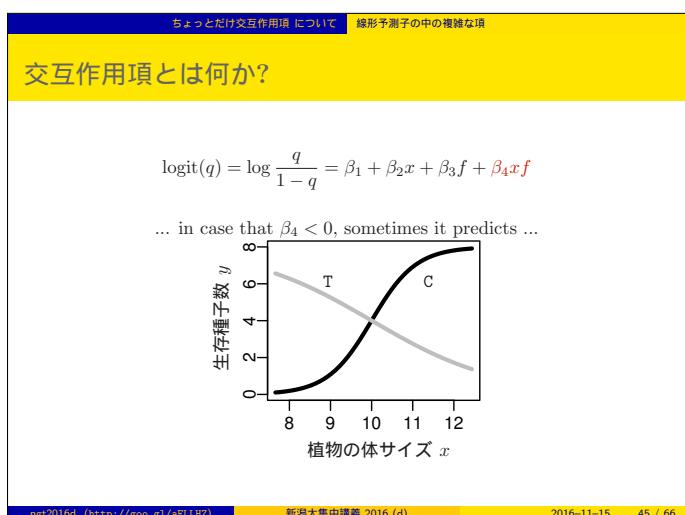
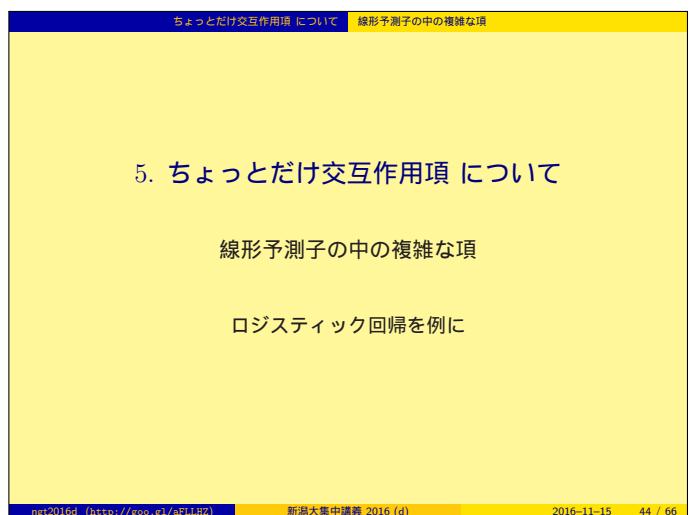
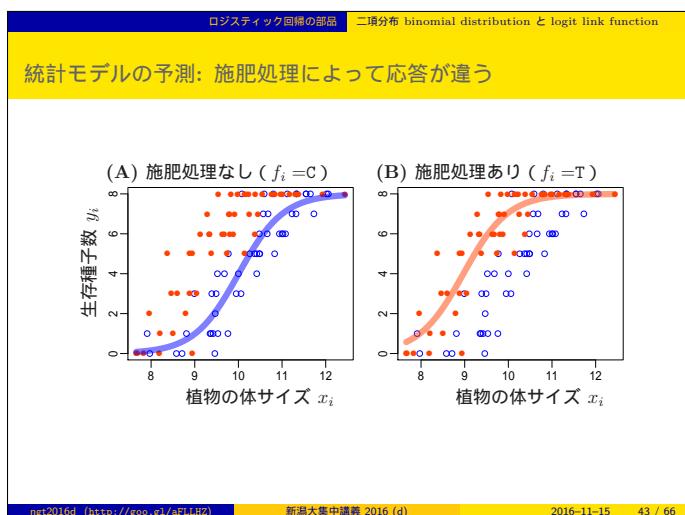
ロジスティック回帰 — β_1 と β_2 の最尤推定

(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
```

ngt2016d (<http://geo.g1/aFLHZ>) 新潟大集中講義 2016 (d) 42 / 66



何でも「割算」するな! 「脱」割算の offset 項わざ

避けられるわりざん

- 避けられる割算値
 - 確率

例: N 個のうち k 個にある事象が発生する確率
対策: ロジスティック回帰など **二項分布モデル** で
 - 密度などの指標

例: 人口密度, specific leaf area (SLA) など
対策: **offset 項わざ** — このあと解説!

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 49 / 66

何でも「割算」するな! 「脱」割算の offset 項わざ

避けにくいわりざん

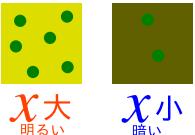
- 避けにくい割算値
 - 測定機器が内部で割算した値を出力する場合
 - 割算値で作図せざるをえない場合があるかも

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 50 / 66

何でも「割算」するな! 「脱」割算の offset 項わざ

offset 項の例題: 調査区画内の個体密度

- 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
- 明るさ x は $\{0.1, 0.2, \dots, 1.0\}$ の 10 段階で観測した

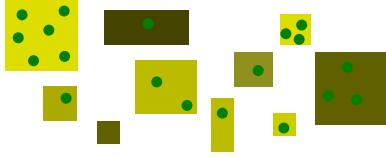


これだけなら単純に `glm(..., family = poisson)` とすればよいのだが

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 51 / 66

何でも「割算」するな! 「脱」割算の offset 項わざ

「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

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 52 / 66

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

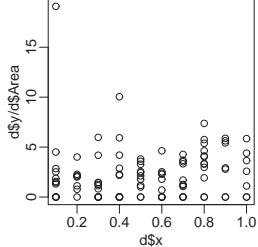
```
> load("d2.RData")
> head(d, 8) # 先頭 8 行の表示
   Area   x y
1 0.017249 0.5 0
2 1.217732 0.3 1
3 0.208422 0.4 0
4 2.256265 0.1 0
5 0.794061 0.7 1
6 0.396763 0.1 1
7 1.428059 0.6 1
8 0.791420 0.3 1
```

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 53 / 66

何でも「割算」するな! 「脱」割算の offset 項わざ

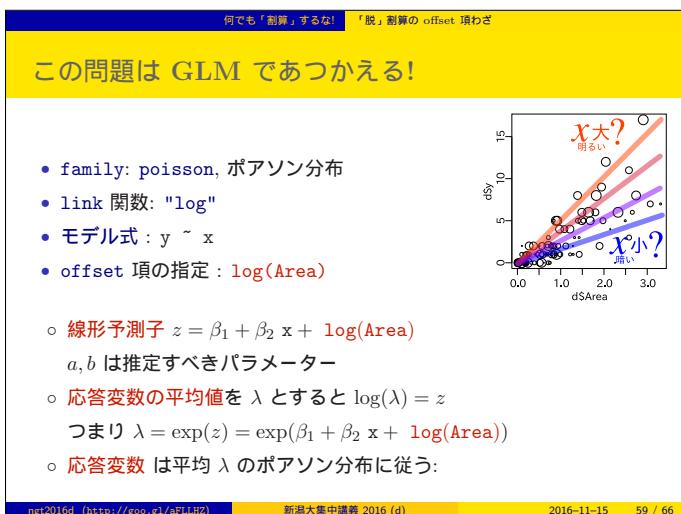
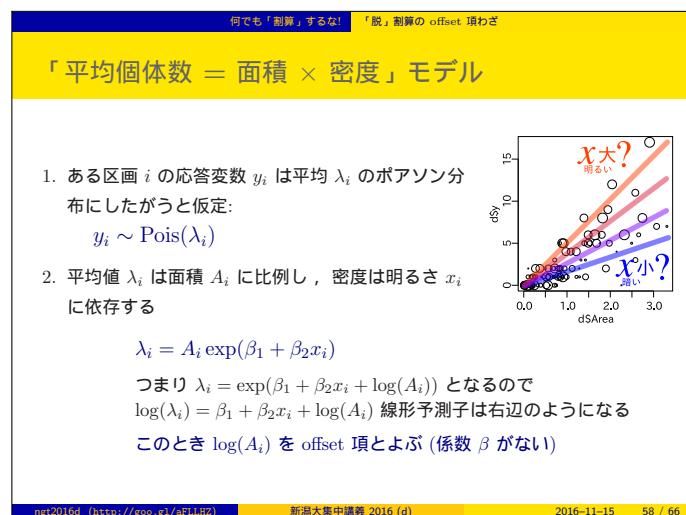
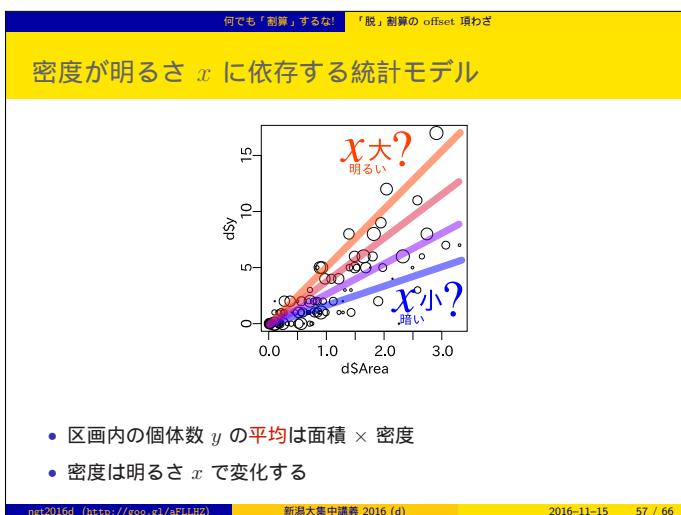
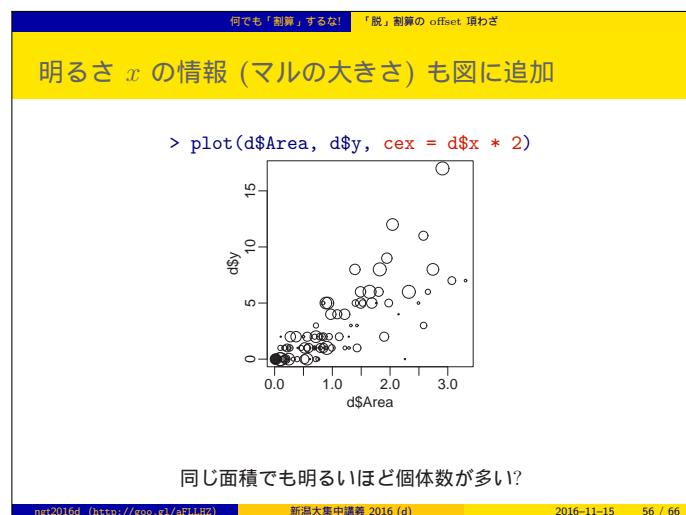
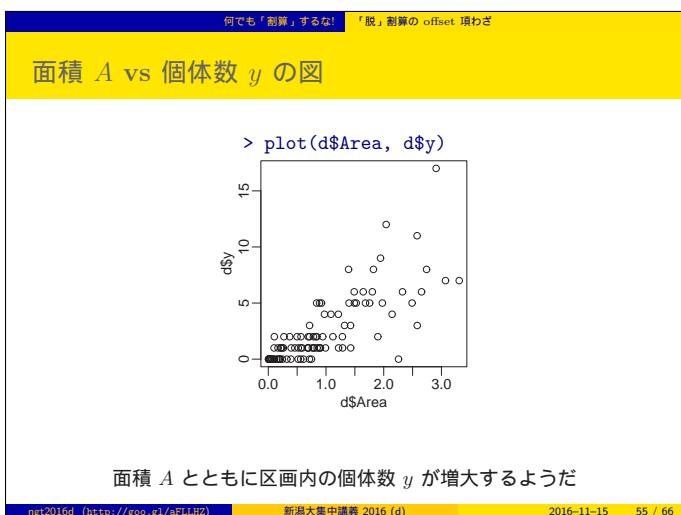
明るさ vs 割算値図の図

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



いまいちよくわからない

ngt2016d (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (d) 2016-11-15 54 / 66



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

ngt2016d (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (d) 2016-11-15 61 / 66
```

何でも「割算」するな! 「脱」割算の offset 項わざ

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
- 破線はデータ生成時に指定した関係

```
ngt2016d (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (d) 2016-11-15 62 / 66
```

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

```
ngt2016d (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (d) 2016-11-15 63 / 66
```

何でも「割算」するな! 「脱」割算の offset 項わざ

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
 - 確率

例: N 個のうち k 個にある事象が発生する確率

対策: ロジスティック回帰など二項分布モデル
 - 密度などの指數

例: 人口密度, specific leaf area (SLA) など

対策: `offset` 項わざ — 統計モデリングの工夫!

```
ngt2016d (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (d) 2016-11-15 64 / 66
```

何でも「割算」するな! 「脱」割算の offset 項わざ

ポアソン分布 GLM と二項分布 GLM のつながり

ポアソン分布の GLM (A 種) ポアソン分布の GLM (B 種)

三項分布・多項分布で威力を發揮!

```
ngt2016d (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (d) 2016-11-15 65 / 66
```

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)

```
ngt2016d (http://goo.gl/aFLHZ2) 新潟大集中講義 2016 (d) 2016-11-15 66 / 66
```

新潟大集中講義 2016 (e)

階層ベイズモデル – 個体差・場所差のモデリング

久保拓弥 kubo@ees.hokudai.ac.jp

新潟大の講義 <http://goo.gl/aFLHZ>

2016-11-15

ファイル更新時刻: 2016-11-10 17:16

ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 1 / 82

今日の統計モデル: 階層ベイズモデル

線形モデルの発展

The diagram illustrates the evolution of statistical modeling:

- 線形モデル** (Linear Model) at the bottom right, using **最小二乗法** (Least Squares) for **推定計算方法** (Estimation Method).
- An arrow points up to **一般化線形モデル (GLM)** (Generalized Linear Model), which uses **正規分布以外の確率分布をあつかいたい** (Want to use probability distributions other than normal) as its motivation.
- From GLM, an arrow points up to **一般化線形混合モデル (GLMM)** (Generalized Linear Mixed Model), which addresses **個体差・場所差といった変量効果をあつかいたい** (Want to handle individual differences and spatial effects).
- Finally, an arrow points up to **階層ベイズモデル (HBM)** (Hierarchical Bayesian Model), which is motivated by **もっと自由な統計モデリングを!** (More free statistical modeling!).

そして **Markov Chain Monte Carlo (MCMC)** を用了 Bayesian Estimation (ベイズ推定)

ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 2 / 82

GLM ではうまく説明できない観測データ

種子数分布

観測された個体数

生存種子数 y_i

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?

階層ベイズモデルが必要!

Apply Hierarchical Bayesian Model (HBM)!

ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 3 / 82

今日のハナシ

- MCMC サンプリングのための例題
logistic regression: binomial distribution
- 同じような推定を MCMC でやってみる
最尤推定と Markov chain Monte Carlo (MCMC) はちがう!
- Softwares for MCMC sampling
“Gibbs sampling” などが簡単にできるような
- 個体差の階層ベイズモデル
個体差のばらつきをあらわす
- 複数ランダム効果の階層ベイズモデル
個体差 + グループ差, など

もくじ

ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 4 / 82

MCMC サンプリングのための例題 logistic regression: binomial distribution

1. MCMC サンプリングのための例題

logistic regression: binomial distribution

and logit link function

ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 5 / 82

MCMC サンプリングのための例題 logistic regression: binomial distribution

例題: 植物の種子の生存確率

- 架空植物の種子の生存を調べた
- 種子: 生きていれば発芽する
 - どの個体でも 8 個の種子を調べた
- 生存確率: ある種子が生きている確率
- データ: 植物 20 個体, 合計 160 種子の生存の有無を調べた
- 73 種子が生きていた — このデータを統計モデル化したい

種子数 $N_i = 8$
生存数 $y_i = 3$

個体 i

ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 6 / 82

MCMC サンプリングのための例題 logistic regression: binomial distribution

たとえばこんなデータが得られたとしましょう

個体ごとの生存数	0	1	2	3	4	5	6	7	8
観察された個体数	1	2	1	3	6	6	1	0	0

これは個体差なしの均質な集団

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 7 / 82

MCMC サンプリングのための例題 logistic regression: binomial distribution

生存確率 q と二項分布の関係

- 生存確率を推定するために二項分布という確率分布を使う
- 個体 i の N_i 種子中 y_i 個が生存する確率

$$p(y_i | q) = \binom{N_i}{y_i} q^{y_i} (1-q)^{N_i-y_i},$$

- ここで仮定していること
 - 個体差はない
 - つまり すべての個体で同じ生存確率 q

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 8 / 82

MCMC サンプリングのための例題 logistic regression: binomial distribution

ゆうど 尤度: 20 個体ぶんのデータが観察される確率

- 観察データ $\{y_i\}$ が確定しているときに
- パラメータ q は値が自由にとりうると考える
- 尤度は 20 個体ぶんのデータが得られる確率の積、パラメータ q の関数として定義される

$$L(q | \{y_i\}) = \prod_{i=1}^{20} p(y_i | q)$$

個体ごとの生存数	0	1	2	3	4	5	6	7	8
観察された個体数	1	2	1	3	6	6	1	0	0

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 9 / 82

MCMC サンプリングのための例題 logistic regression: binomial distribution

対数尤度方程式と最尤推定

- この尤度 $L(q | データ)$ を最大化するパラメータの推定量 \hat{q} を計算したい
- 尤度を対数尤度になおすと

$$\log L(q | データ) = \sum_{i=1}^{20} \log \binom{N_i}{y_i} + \sum_{i=1}^{20} \{y_i \log(q) + (N_i - y_i) \log(1 - q)\}$$

- この対数尤度を最大化するように未知パラメーター q の値を決めてやるのが最尤推定

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 10 / 82

MCMC サンプリングのための例題 logistic regression: binomial distribution

最尤推定 (MLE) とは何か

- 対数尤度 $L(q | データ)$ が最大になるパラメーター q の値をさがしだすこと
- 対数尤度 $\log L(q | データ)$ を q で偏微分して 0 となる \hat{q} が対数尤度最大

$$\partial \log L(q | データ) / \partial q = 0$$
- 生存確率 q が全個体共通の場合の最尤推定量・最尤推定値は

$$\hat{q} = \frac{\text{生存種子数}}{\text{調査種子数}} = \frac{73}{160} = 0.456 \text{ ぐらい}$$

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 11 / 82

MCMC サンプリングのための例題 logistic regression: binomial distribution

二項分布で説明できる 8 種子中 y_i 個の生存

$\hat{q} = 0.46$ なので $\binom{8}{y} 0.46^y 0.54^{8-y}$

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 12 / 82

同じような推定を MCMC でやってみる 最尤推定と Markov chain Monte Carlo (MCMC) はちがう!

2. 同じような推定を MCMC でやってみる

最尤推定と Markov chain Monte Carlo (MCMC) はちがう!
そして“なんとなーく”ベイズ統計モデルと関連づけ

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 13 / 82

同じような推定を MCMC でやってみる 最尤推定と Markov chain Monte Carlo (MCMC) はちがう!

ここでやること: 尤度と MCMC の関係を考える

- さきほどの簡単な例題(生存確率)のデータ解析を
- 最尤推定ではなく
- Markov chain Monte Carlo (MCMC) 法のひとつである**メトロポリス法** (Metropolis method) であつかう
- 得られる結果: 「パラメーターの値の分布」 ??

MCMC をもちださなくともいい簡単すぎる問題
説明のためあえてメトロポリス法を適用してみる

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 14 / 82

同じような推定を MCMC でやってみる 最尤推定と Markov chain Monte Carlo (MCMC) はちがう!

メトロポリス法を説明するための準備

連続的な対数尤度関数 $\log L(q)$
離散化: q がとびとびの値をとる

説明を簡単にするため
生存確率 q の軸を離散化する
(実際には離散化する必要などない)

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 15 / 82

同じような推定を MCMC でやってみる 最尤推定と Markov chain Monte Carlo (MCMC) はちがう!

試行錯誤による q の最尤推定値の探索

ちょっと効率の悪い「試行錯誤の最尤推定」

- q の値の「行き先」を「両隣」どちらかにランダムに決める
- 「行き先」が現在の尤度より高ければ、 q の値をそちらに変更
- 尤度が変化しなくなるまで (1), (2) をくりかえす

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 16 / 82

同じような推定を MCMC でやってみる 最尤推定と Markov chain Monte Carlo (MCMC) はちがう!

メトロポリス法のルール: この例題の場合

- パラメーター q の初期値を選ぶ
(ここでは q の初期値が 0.3)
- q を増やすか減らすかをランダムに決める
(新しく選んだ q の値を q_{new} としましょう)
- q_{new} における尤度 $L(q_{\text{new}})$ ともとの尤度 $L(q)$ を比較
 - $L(q_{\text{new}}) \geq L(q)$ (あてはまり改善): $q \leftarrow q_{\text{new}}$
 - $L(q_{\text{new}}) < L(q)$ (あてはまり改善):
 - 確率 $r = L(q_{\text{new}})/L(q)$ で $q \leftarrow q_{\text{new}}$
 - 確率 $1 - r$ で q を変更しない
- 手順 2. にもどる
($q = 0.01$ や $q = 0.99$ でどうなるんだ? といった問題は省略)

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 17 / 82

同じような推定を MCMC でやってみる 最尤推定と Markov chain Monte Carlo (MCMC) はちがう!

メトロポリス法のルールで q を動かす

最尤推定法 メトロポリス法 (MCMC)

メトロポリス法だと「単調な山のぼり」にはならない

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 18 / 82

同じような推定を MCMC でやってみる。最尤推定と Markov chain Monte Carlo (MCMC) はちがう。

対数尤度関数の「山」でうろうろする q の値

メトロポリス法 (そして一般的な MCMC) は
最適化ではない

ときどきはすでに落っこちる
何のためにこんなことをやるのか?
 q の変化していく様子を記録してみよう

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 19 / 82

同じような推定を MCMC でやってみる。最尤推定と Markov chain Monte Carlo (MCMC) はちがう。

ステップごとに q の値をサンプリング

この曲線、何の分布?
もっと試行錯誤してみたほうがいいのか?

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 20 / 82

同じような推定を MCMC でやってみる。最尤推定と Markov chain Monte Carlo (MCMC) はちがう。

もっと長くサンプリングしてみる

まだまだ ?
この曲線、何の分布?
サンプルされた q のヒストグラム

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 21 / 82

同じような推定を MCMC でやってみる。最尤推定と Markov chain Monte Carlo (MCMC) はちがう。

もっともっと長くサンプリングしてみる

なんだか、ある「山」のかたちにまとまつたぞ?
じつはこれは「 q の確率分布」このあと説明
サンプルされた q のヒストグラム

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 22 / 82

同じような推定を MCMC でやってみる。最尤推定と Markov chain Monte Carlo (MCMC) はちがう。

MCMC は何をサンプリングしている?

対数尤度 $\log L(q)$

尤度 $L(q)$ に
比例する確率分布

尤度に比例する確率分布からのランダムサンプル
最尤推定はパラメーターの値の点推定
MCMC は“パラメーターの事後分布”(推定したいこと)
は こういう分布ですよ と推定している

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 23 / 82

同じような推定を MCMC でやってみる。最尤推定と Markov chain Monte Carlo (MCMC) はちがう。

MCMC の結果として得られた q の経験分布

- データと統計モデル (二項分布) を決めて、MCMC サンプリングすると、 $p(q)$ からのランダムサンプルが得られる
- このランダムサンプルをもとに、 q の平均や 95% 区間などがわかる—便利じゃないか!

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 24 / 82

同じような推定を MCMC でやってみる。 最尤推定と Markov chain Monte Carlo (MCMC) はちがう。

ベイズ統計モデルの推定

統計モデルとデータにもとづいて事後分布の推定

- パラメーター数の少ないベイズモデルであれば、尤度の数値計算やメトロポリス法で可能
- パラメーター数の多い複雑な統計モデルであれば、あとで説明するサンプリングソフトウェアを使用する

事後分布 $p(q | Y)$ 尤度 $L(q)$ 事前分布 $p(q)$

生存確率 q

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 25 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

3. Softwares for MCMC sampling

“Gibbs sampling”などが簡単にできるような

事後分布から効率よくサンプリングしたい

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 26 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

統計ソフトウェア R

<http://www.r-project.org/>

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 27 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

簡単な GLMM なら R だけで推定可能

- R にはいろいろな GLMM の最尤推定関数が準備されている
 - library(glmmML) の glmmML()
 - library(lme4) の lmer()
 - library(nlme) の nlme() (正規分布のみ)
- しかし もうちょっと複雑な GLMM , たとえば個体差 + 地域差をいたれた統計モデルの最尤推定は **かなり難しい** (ヘンな結果が得られたりする)
- 積分がたくさん入っている尤度関数の評価がしんどい

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 28 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

どのようなソフトウェアで MCMC 計算するか?

- 自作プログラム
 - 利点: 問題にあわせて自由に設計できる
 - 欠点: 階層ベイズモデル用の MCMC プログラミング, けっこうめんどう
- R のベイズな package
 - 利点: 空間ベイズ統計など便利な専用 package がある
 - 欠点: 汎用性, とぼしい
- “BUGS”で“Gibbs sampler”なソフトウェア
 - 利点: 幅ひろい問題に適用できて, 便利
 - 欠点というほどでもないけど, 多少の勉強が必要
 - えーっと “Gibbs sampler”って何?

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 29 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

さまざまな MCMC アルゴリズム

いろいろな MCMC

- メトロポリス法:** 試行錯誤で値を変化させていく MCMC
 - メトロポリス・ヘイスティングス法: その改良版
- ギブス・サンプリング:** 条件つき確率分布を使った MCMC
 - 複数の変数 (パラメーター・状態) を効率よくサンプリング

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 30 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

Gibbs sampling とは何か?

- MCMC アルゴリズムのひとつ
- 複数のパラメーターの MCMC サンプリングに使う
- 例: パラメーター β_1 と β_2 の Gibbs sampling
 - β_2 に何か適当な値を与える
 - β_2 の値はそのままにして、その条件のもとでの β_1 の MCMC sampling をする (条件つき事後分布)
 - β_1 の値はそのままにして、その条件のもとでの β_2 の MCMC sampling をする (条件つき事後分布)
 2. - 3. をくりかえす
- 教科書の第 9 章の例題で説明

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 31 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

図解: Gibbs sampling (統計モデリング入門の第 9 章)

MCMC β_1 のサンプリング β_2 のサンプリング

step 1 → step 2 → step 3

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 32 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

便利な“BUGS”汎用 Gibbs sampler たち

- BUGS 言語 (+ っぽいもの) でベイズモデルを記述できるソフトウェア
 - WinBUGS — 歴史を変えて さようなら?
 - OpenBUGS — 予算が足りなくて停滞?
 - JAGS — お手軽で良い、どんな OS でも動く
 - Stan — いま一番の注目
— 今日は紹介しません
- リンク集: <http://hosho.ees.hokudai.ac.jp/~kubo/ce/BayesianMcmc.html>

えーと BUGS 言語って何?

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 33 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

このベイズモデルを BUGS 言語で記述したい

データ $Y[i]$
種子数8個のうちの生存数

二項分布
 $dbin(q, 8)$

生存確率 q

無情報事前分布

BUGS 言語コード

```
for (i in 1:N.sample) {
  Y[i] ~ dbin(q, 8)
}
q ~ dunif(0.0, 1.0)
```

矢印は手順ではなく、依存関係をあらわしている

BUGS 言語: ベイズモデルを記述する言語

Spiegelhalter et al. 1995. BUGS: Bayesian Using Gibbs Sampling version 0.50.

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 34 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

いろいろな OS で使える JAGS4.2.0

- R core team のひとり Martyn Plummer さんが開発
 - Just Another Gibbs Sampler
- C++ で実装されている
 - R がインストールされていることが必要
- Linux, Windows, Mac OS X バイナリ版もある
- 開発進行中
- R からの使う: `library(rjags)`

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 35 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

JAGS を R の“したうけ”として使う

R

BUGS言語

モデルの構造
データとパラメーターの初期値
サンプリングの詳細
Input

JAGS

事後分布からのランダムサンプル
Trace of beta[1]
Trace of beta[2]
Density of beta[1]
Density of beta[2]

Output

ngt2016e (<http://goo.gl/aFLHqZ>) 新潟大集中講義 2016 (e) 2016-11-15 36 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

R から JAGS にこんなかんじで仕事を命じる (1 / 3)

```
library(rjags)
library(R2WinBUGS) # to use write.model()

model.bugs <- function()
{
  for (i in 1:N.data) {
    Y[i] ~ dbin(q, 8) # 二項分布にしたがう
  }
  q ~ dunif(0.0, 1.0) # q の事前分布は一様分布
}
file.model <- "model.bug.txt"
write.model(model.bugs, file.model) # ファイル出力

# 次につづく
```

ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 37 / 82

Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

R から JAGS にこんなかんじで仕事を命じる (2 / 3)

```
load("mcmc.RData") # (data.RData ではなく mcmc.RData!!)
list.data <- list(Y = data, N.data = length(data))
inits <- list(q = 0.5)
n.burnin <- 1000
n.chain <- 3
n.thin <- 1
n.iter <- n.thin * 1000

model <- jags.model(
  file = file.model, data = list.data,
  inits = inits, n.chain = n.chain
)

# まだ次につづく
```

ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 38 / 82

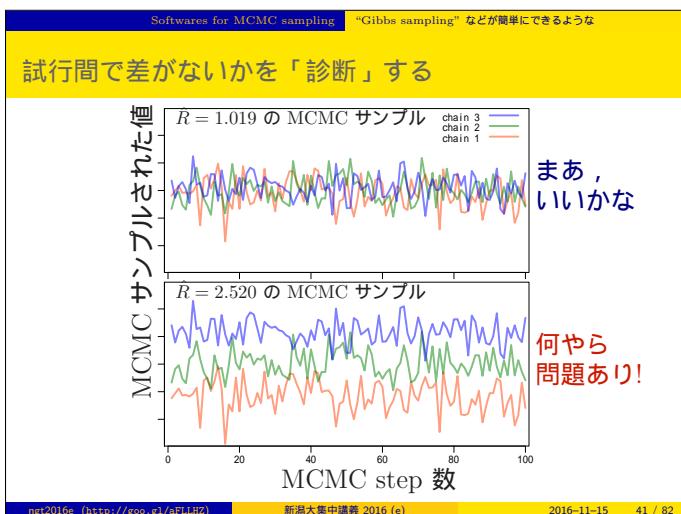
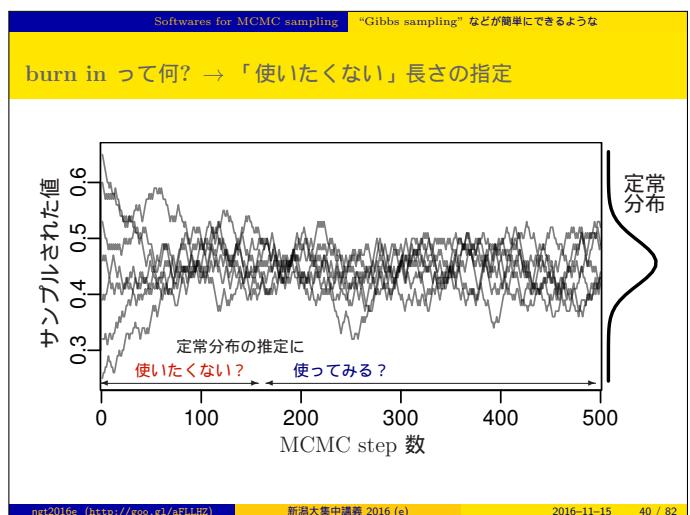
Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような

R から JAGS にこんなかんじで仕事を命じる (3 / 3)

```
# burn-in
update(model, n.burnin) # burn in

# サンプリング結果を post.mcmc.list に格納
post.mcmc.list <- coda.samples(
  model = model,
  variable.names = names(inits),
  n.iter = n.iter,
  thin = n.thin
)
# おわり
```

ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 39 / 82



- Softwares for MCMC sampling “Gibbs sampling”などが簡単にできるような
- ### 収束診断の \hat{R} 指数
- gelman.diag(post.mcmc.list) → 実演表示
 - R-hat は Gelman-Rubin の収束判定用の指数
 - $\hat{R} = \sqrt{\frac{\bar{v}\hat{r}^+(\psi|y)}{W}}$
 - $\bar{v}\hat{r}^+(\psi|y) = \frac{n-1}{n}W + \frac{1}{n}B$
 - W : サンプル列内の variance の平均
 - B : サンプル列間の variance
 - Gelman et al. 2004. Bayesian Data Analysis. Chapman & Hall/CRC
- ngt2016e (<http://goo.gl/aFLHZ>) 新潟大集中講義 2016 (e) 2016-11-15 42 / 82

Softwares for MCMC sampling: "Gibbs sampling" などが簡単にできるような.....

Gibbs sampling → 事後分布の推定

- `plot(post.mcmc.list)`

Trace of q

Iterations

Density of q

N = 1000 Bandwidth = 0.0083e

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 43 / 82

個体差の階層ベイズモデル 個体差のばらつきをあらわす

4. 個体差の階層ベイズモデル

個体差のばらつきをあらわす

階層事前分布の設定

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 44 / 82

個体差の階層ベイズモデル 個体差のばらつきをあらわす

二項分布では説明できない観測データ!

100 個体の植物の合計 800 種子中 403 個の生存が見られたので、平均生存確率は 0.50 と推定されたが.....

観察された植物の個体数

二項分布による予測

せんぜんうまく表現できていない!

生存した種子数 y_i

さっきの例題と同じようなデータなのに?
(「統計モデリング入門」第 10 章の最初の例題)

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 45 / 82

個体差の階層ベイズモデル 個体差のばらつきをあらわす

個体差 → 過分散 (overdispersion)

極端な過分散の例

観察された植物の個体数

生存した種子数 y_i

- 種子全体の平均生存確率は 0.5 くらいかもしれないが.....
- 植物個体ごとに種子の生存確率が異なる: 「個体差」
- 「個体差」があると overdispersion が生じる
- 「個体差」の原因是観測できない・観測されていない

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 46 / 82

個体差の階層ベイズモデル 個体差のばらつきをあらわす

モデリングやりなおし: 個体差を考慮する

- 生存確率を推定するために **二項分布**という確率分布を使う
- 個体 i の N_i 種子中 y_i 個が生存する確率は二項分布

$$p(y_i \mid q_i) = \binom{N_i}{y_i} q_i^{y_i} (1 - q_i)^{N_i - y_i},$$

- ここで仮定していること
 - **個体差**があるので個体ごとに生存確率 q_i が異なる

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 47 / 82

個体差の階層ベイズモデル 個体差のばらつきをあらわす

GLM わざ: ロジスティック関数で表現する生存確率

- 生存確率 $q_i = q(z_i)$ をロジスティック関数 $q(z) = 1/(1 + \exp(-z))$ で表現

- 線形予測子 $z_i = a + r_i$ とする
 - パラメーター a : 全体の平均
 - パラメーター r_i : 個体 i の個体差 (ずれ)

ngt2016e (<http://goo.gl/aFLH2z>) 新潟大集中講義 2016 (e) 2016-11-15 48 / 82

個体差の階層ベイズモデル | 個体差のはらつきをあらわす

個々の個体差 r_i を最尤推定するのはまずい

パラメーター数 > サンプルサイズ

- 100 個体の生存確率を推定するためにパラメーター 101 個 (a と $\{r_1, r_2, \dots, r_{100}\}$) を推定すると……
- 個体ごとに生存数 / 種子数を計算していることと同じ! (「データのよみあげ」と同じ)

そこで、次のように考えてみる

個体差の階層ベイズモデル | 個体差のはらつきをあらわす

$\{r_i\}$ のばらつきは正規分布だと考えてみる

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

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 がゼロにちかい個体はわりと「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」。

個体差の階層ベイズモデル | 個体差のはらつきをあらわす

ひとつの例示: 個体差 r_i の分布と過分散の関係

(A) 個体差のはらつきが小さい場合 (B) 個体差のはらつきが大きい場合

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

$p(r_i | s)$ が生成した 50 個体ぶんの $\{r_i\}$

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

$p(y_i | q_i)$ が生成した生存種子数の一例

個体差の階層ベイズモデル | 個体差のはらつきをあらわす

これは r_i の事前分布の指定、ということ

前回の講義で $\{r_i\}$ は正規分布にしたがうと仮定したが
ベイズ統計モデリングでは「100 個の r_i たちに
共通する事前分布として正規分布を指定した」
ということになる

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

個体差の階層ベイズモデル | 個体差のはらつきをあらわす

ベイズ統計モデルでよく使われる三種類の事前分布

たいていのベイズ統計モデルでは、ひとつのモデルの中で複数の種類の事前分布を混ぜて使用する。

(A) 主観的な事前分布 (B) 無情報事前分布 (C) 階層事前分布

(できれば使いたくない!)

信じる!

わからない?

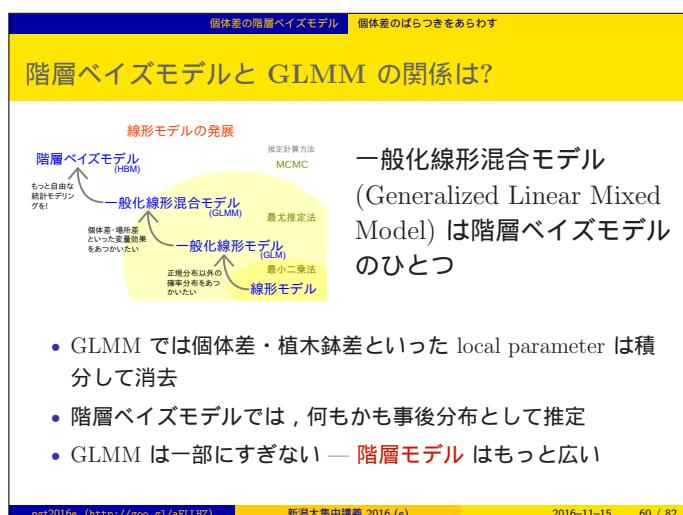
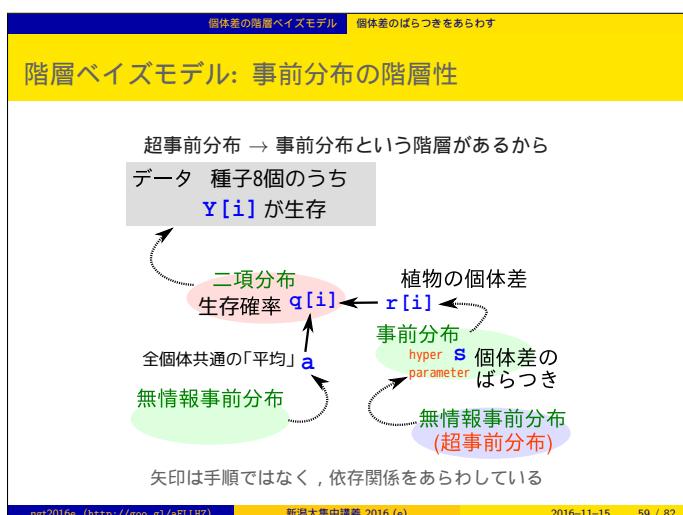
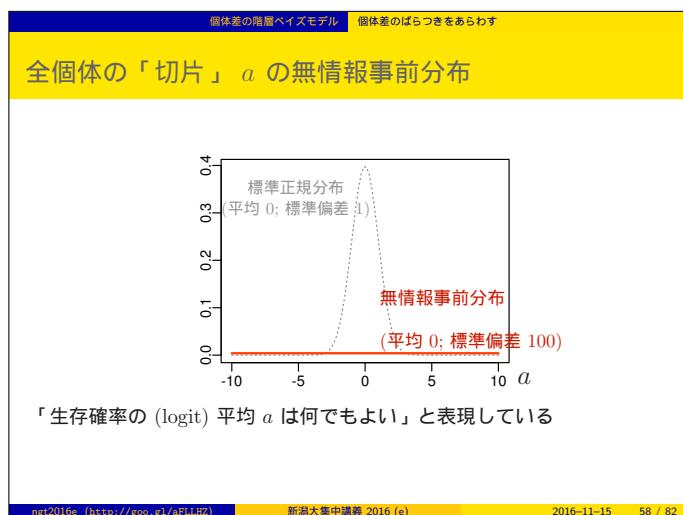
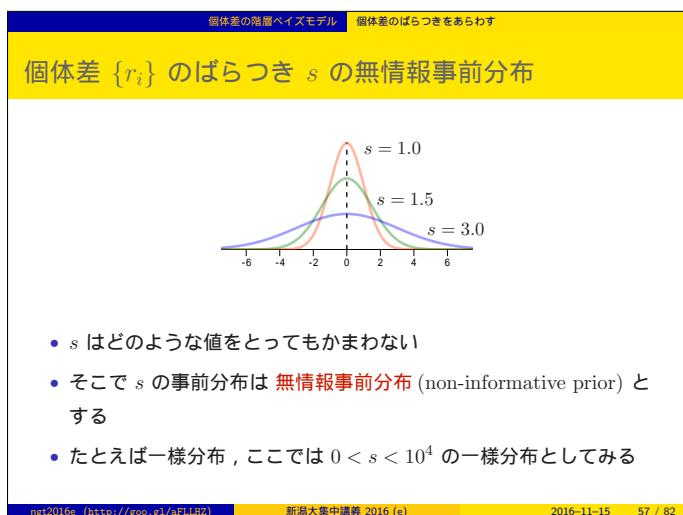
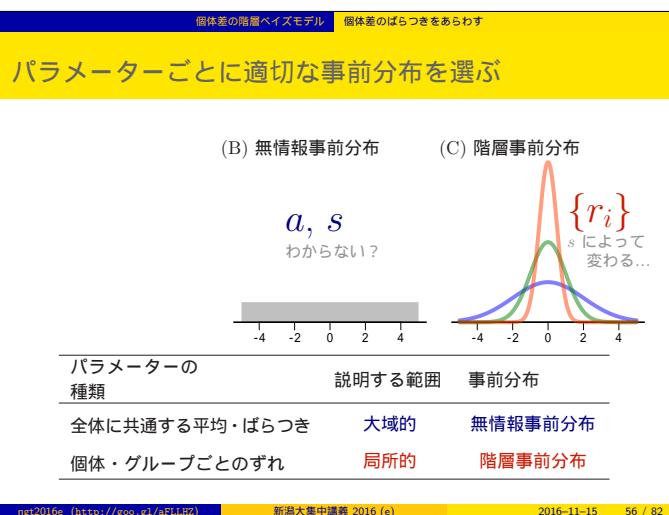
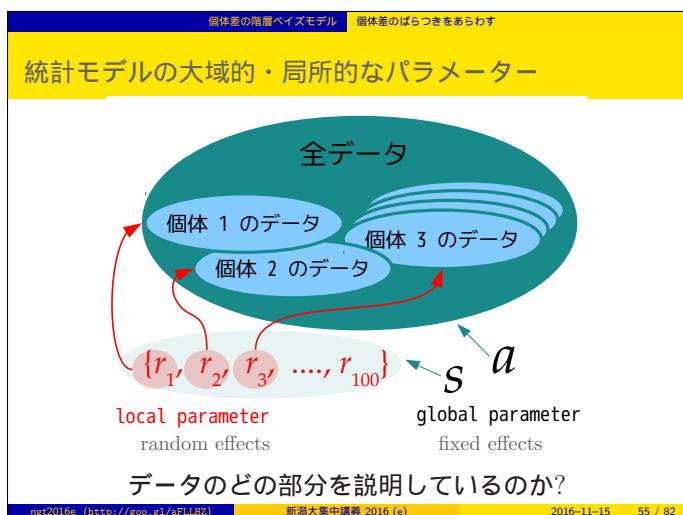
s によって
変わるもの

個体差の階層ベイズモデル | 個体差のはらつきをあらわす

r_i の事前分布として階層事前分布を指定する

階層事前分布の利点
「データにあわせて」事前分布が変形!

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



複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

5. 複数ランダム効果の階層ベイズモデル

個体差 + グループ差, など

そして“てぬき” モデリングの危なさについて

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 61 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

架空植物の例題: またまた種子数データ

- 肥料をやったら個体ごとの種子数 y_i が増えるかどうかを調べたい
- 植木鉢 10 個, 各鉢に 10 個体の架空植物 (合計 100 個体)
 - コントロール ($f_j = \mathbf{C}$) 5 鉢 (合計 50 個体)
 - 肥料をやる処理 ($f_j = \mathbf{T}$) 5 鉢 (合計 50 個体)

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 62 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

データはこのように格納されている

```
> d <- read.csv("d1.csv")
> head(d)
  id pot f y
1 1 A C 6
2 2 A C 3
3 3 A C 19
4 4 A C 5
5 5 A C 0
6 6 A C 19
```

- id 列: 個体番号 {1, 2, 3, ..., 100}
- pot 列: 植木鉢名 {A, B, C, ..., J}
- f 列: 処理: コントロール C, 肥料 T
- y 列: 種子数 (応答変数)

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 63 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

データはとにかく図示する!!

- plot(d\$id, d\$y, pch = as.character(d\$pot), ...)
- コントロール・処理 でそんなに差がない!

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 64 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

処理ごとの平均も図に追加してみる

- むしろ 処理 のほうが平均種子数が低い?
- (注) この架空データは 肥料の効果はゼロ と設定して生成した

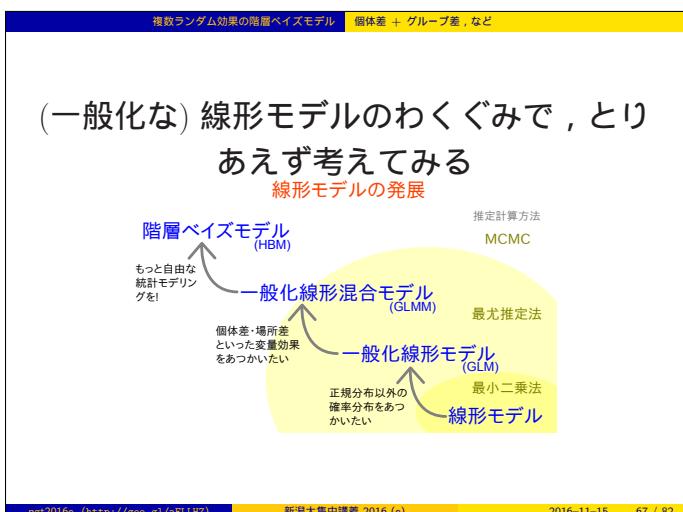
ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 65 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

個体差だけでなく植木鉢差もありそう?

- plot(d\$pot, d\$y, col = rep(c("blue", "red"), each = 5))
- 植木鉢由来の random effects みたいなものは ブロック差 と呼ばれる

ngt2016e (<http://goo.gl/aFLHHz>) 新潟大集中講義 2016 (e) 2016-11-15 66 / 82



複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

GLM: 個体差もブロック差も無視

```
> summary(glm(y ~ f, data = d, family = poisson))
... (略)...
Coefficients:
Estimate Std. Error z value Pr(>|z|)
(Intercept) 1.8931    0.0549   34.49 < 2e-16
fT          -0.4115    0.0869   -4.73  2.2e-06
... (略)...
```

- 肥料をやる処理 (f) をすると、平均種子数が下がる?
- AIC でモデル選択しても同じような結果に

ngt2016e (http://goo.gl/aFLHZ) 新潟大集中講義 2016 (e) 2016-11-15 68 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

GLMM: 個体差だけ考慮、ブロック差は無視

```
> library(glmmML)
> summary(glmmML(y ~ f, data = d, family = poisson,
+ cluster = id))
... (略)...
coef se(coef)      z Pr(>|z|)
(Intercept) 1.351   0.192  7.05 1.8e-12
fT          -0.737   0.280 -2.63 8.4e-03
... (略)...
```

- やっぱり同じ?
- むしろ肥料処理の悪影響が強い?

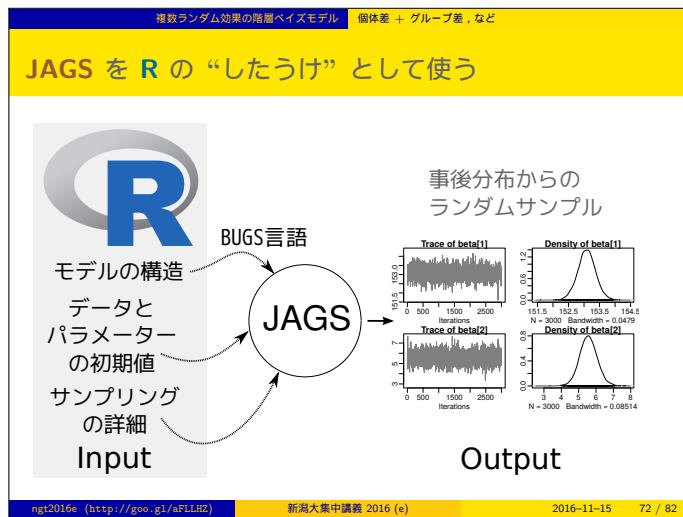
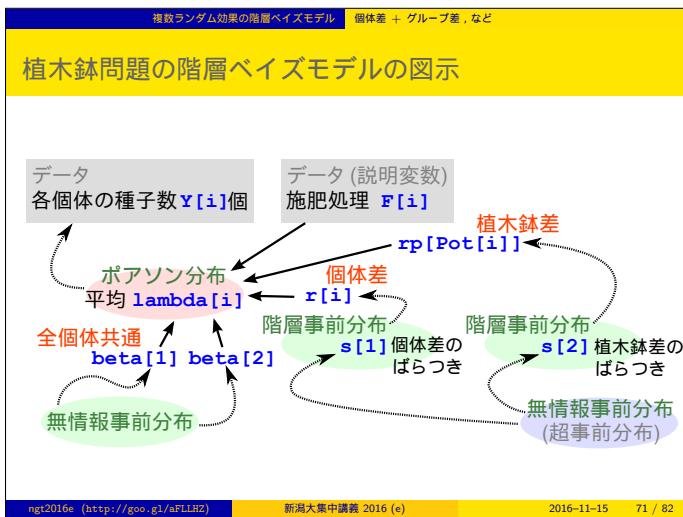
ngt2016e (http://goo.gl/aFLHZ) 新潟大集中講義 2016 (e) 2016-11-15 69 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

個体差 + ブロック差を考える階層ベイズモデル

- ここでは log リンク関数を使う
- 平均の対数 $\log(\lambda_i) = a + b f_i + (\text{個体差}) + (\text{ブロック差})$
- 事前分布の設定
 - 切片 a と f_i の係数 b は無情報事前分布 (すごく平らな正規分布)
 - 個体差とブロック差は階層的な事前分布 (それぞれ標準偏差 σ_1, σ_2 の正規分布, 平均はゼロ)
 - 標準偏差 σ_* は無情報事前分布 ($[0, 10^4]$ の一様分布)

ngt2016e (http://goo.gl/aFLHZ) 新潟大集中講義 2016 (e) 2016-11-15 70 / 82



複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

個体差 + ブロック差のあるポアソン回帰の BUGS code (1)

```
model
{
  for (i in 1:N.sample) {
    Y[i] ~ dpois(lambda[i])
    log(lambda[i]) <- a + b * F[i] + r[i] + rp[Pot[i]]
  }
}
```

次のページの事前分布の定義につづく

ここでの BUGS coding のポイント

- 因子型の説明変数 $f_i \in \{C, T\}$ は、それぞれ $F[i]$ を 0, 1 と置きかえる
- $Pot[i]$ は 1, 2, ..., 10 と数字になおした植木鉢名をいれておいて、植木鉢の効果 $rp[\dots]$ を参照させる

ngt2016e (<http://goo.gl/aFLHZ>)

新潟大集中講義 2016 (e)

2016-11-15 73 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

個体差 + ブロック差のあるポアソン回帰の BUGS code (2)

```
# 前のページからのつづき
a ~ dnorm(0, 1.0E-4) # 切片
b ~ dnorm(0, 1.0E-4) # 肥料の効果
for (i in 1:N.sample) {
  r[i] ~ dnorm(0, tau[1]) # 個体差
}
for (j in 1:N.pot) {
  rp[j] ~ dnorm(0, tau[2]) # 植木鉢の差 (ブロック差)
}
for (k in 1:N.tau) {
  tau[k] <- 1.0 / (sigma[k] * sigma[k]) # 個体・植木鉢のばらつき
  sigma[k] ~ dunif(0, 1.0E+4)
}
```

ngt2016e (<http://goo.gl/aFLHZ>)

新潟大集中講義 2016 (e)

2016-11-15 74 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

WinBUGS による事後分布の推定、R で収束判定

ngt2016e (<http://goo.gl/aFLHZ>)

新潟大集中講義 2016 (e)

2016-11-15 75 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

肥料の効果 (パラメーター b) はなさそう?

	mean	sd	2.5%	25%	50%	75%	97.5%	Rhat
a	1.501	0.529	0.482	1.157	1.493	1.852	2.565	1.0
b	-1.016	0.706	-2.436	-1.476	-0.993	-0.565	0.395	1.0
sigma[1]	1.020	0.114	0.822	0.939	1.014	1.089	1.265	1.0
...(略)...								

この架空データを生成した種子数シミュレーションでは、肥料の効果はまったく無いと設定していた

ngt2016e (<http://goo.gl/aFLHZ>)

新潟大集中講義 2016 (e)

2016-11-15 76 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

推定された植木鉢の差 (ブロック差)

ngt2016e (<http://goo.gl/aFLHZ>)

新潟大集中講義 2016 (e)

2016-11-15 77 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

統計モデリングの手ぬきは危険!

- random effects つまり 個体差・ブロック差が大きい
- random effects の影響が大きいときには、fixed effects の大きさが見えにくくなる—二セの「効果」が見えることもあれば、見えるはずの傾向が隠されること
- 個体差・ブロック差の階層ベイズモデルが必要!
- もしブロック差を人為的に小さくできないなら、ブロック数をもっと増やして、より正確な植木鉢の効果のばらつきを正確に推定するしかない

ngt2016e (<http://goo.gl/aFLHZ>)

新潟大集中講義 2016 (e)

2016-11-15 78 / 82

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

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

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

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

複数ランダム効果の階層ベイズモデル 個体差 + グループ差, など

GLMM は階層ベイズモデル (HBM) で!

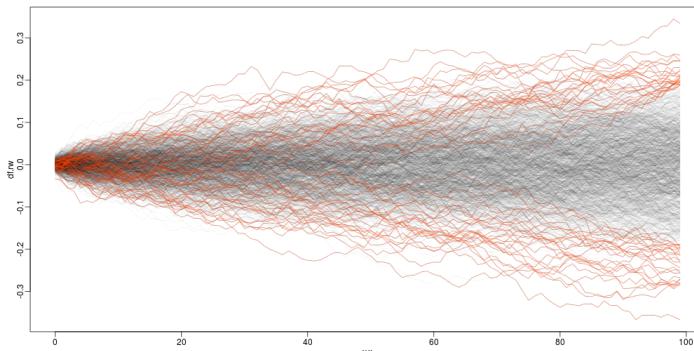
- 現実のデータ解析では個体差・場所差の効果を統計モデルに組みこまなければならない
- これらは歴史的には random effects とよばれてきた
- 用語の整理: 統計モデルには global parameter と local parameter があると考えればよい
- GLMM では global parameter を最尤推定する— local parameter は積分して消す
- local parameter が増えると (e.g. 個体差 + 場所差) 最尤推定が難しい → 階層ベイズモデル (Hierarchical Bayesian Model) で事後分布 (posterior) 推定!

次回予告

時間変化データの階層ベイズモデル

階層ベイズモデル – 時間変化の統計モデリング

久保拓弥 <mailto:kubo@ees.hokudai.ac.jp>



2016-11-17

ngt2016f

1/80

今回・次回の要点

「あぶない」時系列データ解析は
やめましょう!

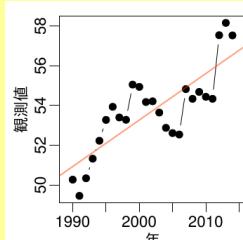
統計モデル
のあてはめ

(危1) 時系列データの GLM あてはめ

(危2) 時系列 $Y_t \sim$ 時系列 X_t

各時刻の個体数 ~ 気温とか
(これは次回)

(危1) 時系列データを GLM で



「ゆーいな傾き」を
ねつぞうする原因

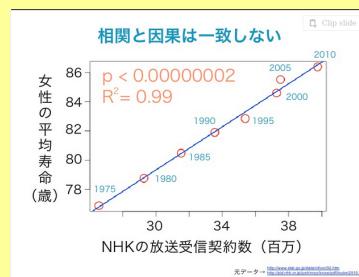
傾きの検定やめて
AIC モデル選択
しても同様になる

検定とかモデル選択とかそういう問題ではない
統計モデルがおかしい?

(危2) 時系列 $Y_t \sim$ 時系列 X_t

「相関は因果関係ではない」

問題の一部: にせの回帰 (これは次回)



<http://www.slideshare.net/takehikohayashi/ss-13441401>

時系列データの統計モデリング

- ・安易に「回帰」してはいけない
- ・ランダムウォークモデルが基本
- ・統計モデルが生成する時系列パターンを意識する
- ・階層ベイズモデルで推定

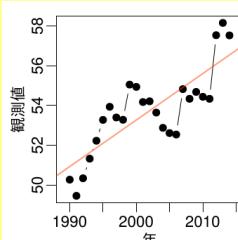
状態空間モデル

2016-11-17

ngt2016f

5/80

(危1) 時系列データを GLM で

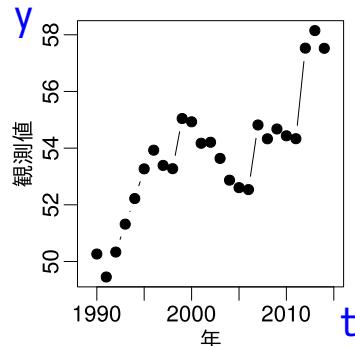


「ゆーいな傾き」を
ねつぞうする原因

傾きの検定やめて
AIC モデル選択
しても同様になる

検定とかモデル選択とかそういう問題ではない
統計モデルがおかしい?

このような時系列データがあったとしましょう



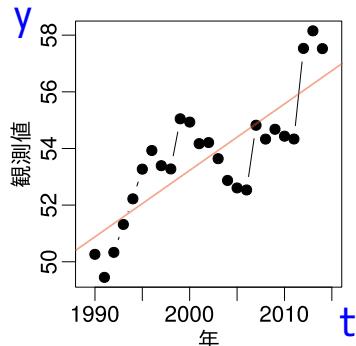
y は何か連続値と
しましょう
(今日でてくる y は
連続値ばかり、と
いうことで)

2016-11-17

ngt2016f

7/80

時系列データの統計モデリング入門



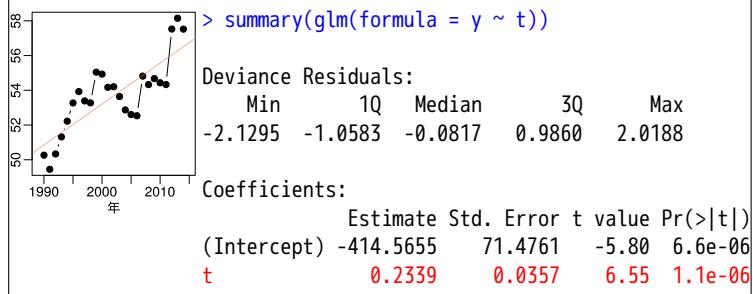
$glm(y \sim t)$
…とモデル
をあてはめてみた

2016-11-17

ngt2016f

8/80

「やったー ゆーいだ!!」 ……??



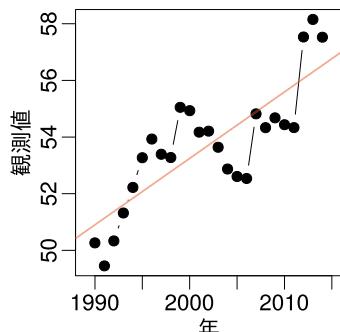
これはまちがい → $glm(\text{時系列}Y \sim \text{時間 } t)$

2016-11-17

ngt2016f

9/80

時系列の各点は独立ではない



「ゆーいな傾き」(偽)
が「ぞろぞろ」でます
傾きの検定やめて
AIC モデル選択
しても同様になる

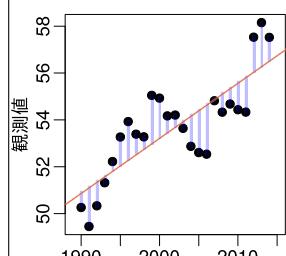
検定とかモデル選択とかそういう問題ではない
統計モデルがおかしい?

2016-11-17

ngt2016f

10/80

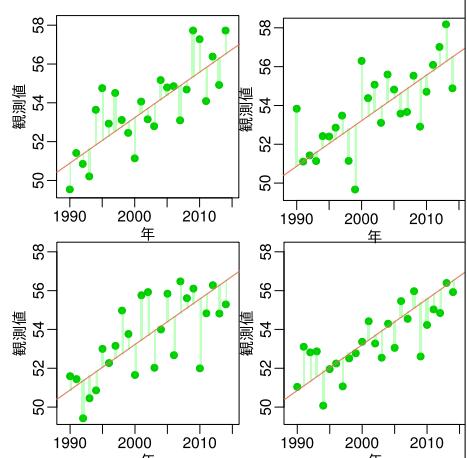
時系列の「ずれ」



ずれかたが
ちがってる?

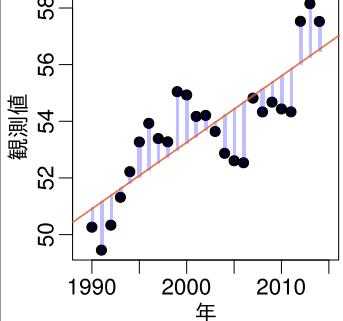
2016-11-17

GLM のずれ



11/80

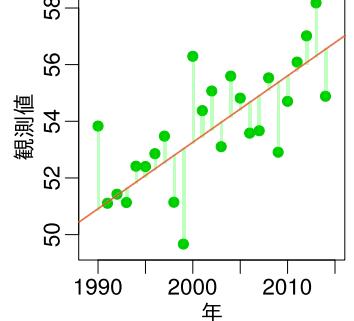
時系列の「ずれ」



直線からのずれがちがう!

時間的自己相関がある

GLM のずれ



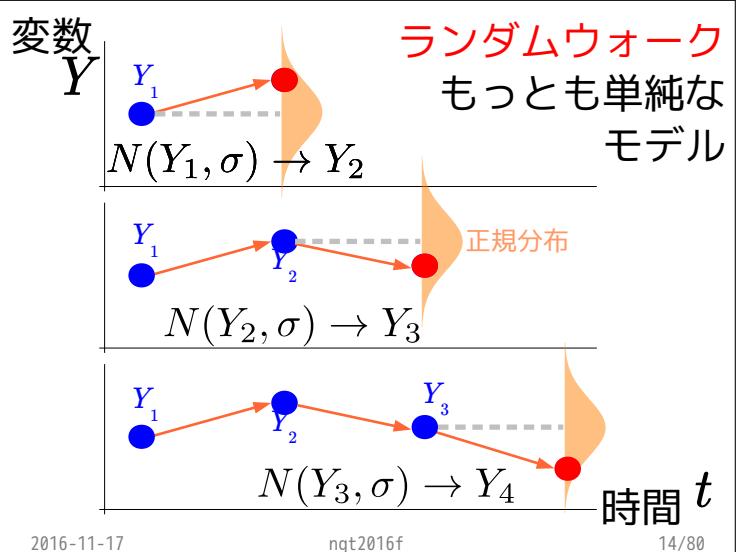
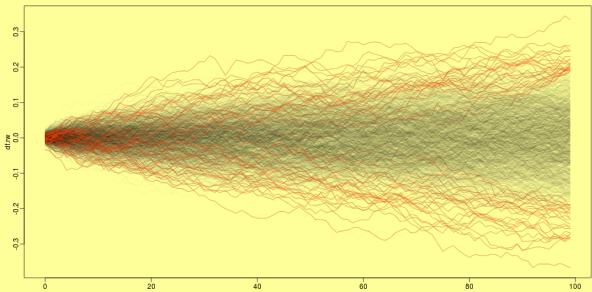
時間的自己相関がない

2016-11-17

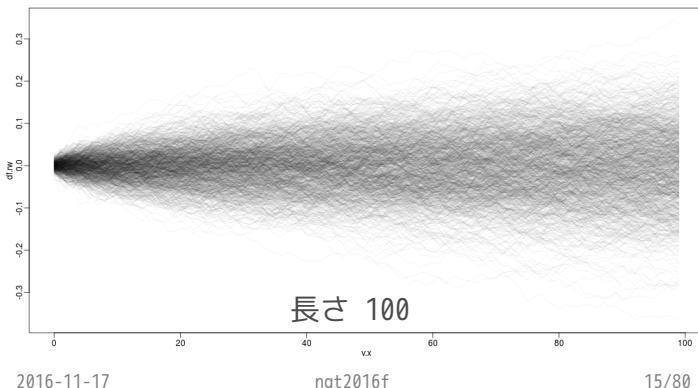
ngt2016f

12/80

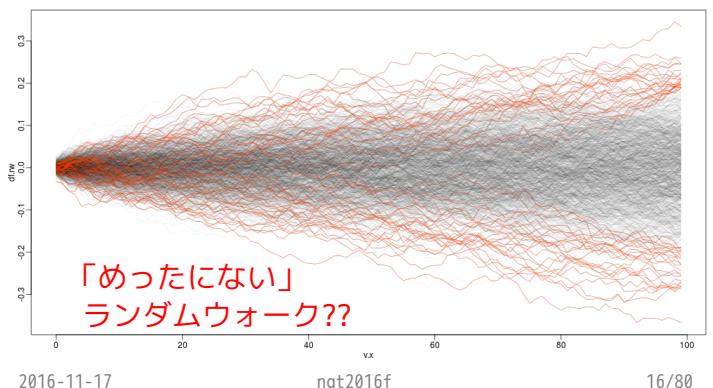
時系列の基本モデルのひとつ ランダムウォーク（乱歩）



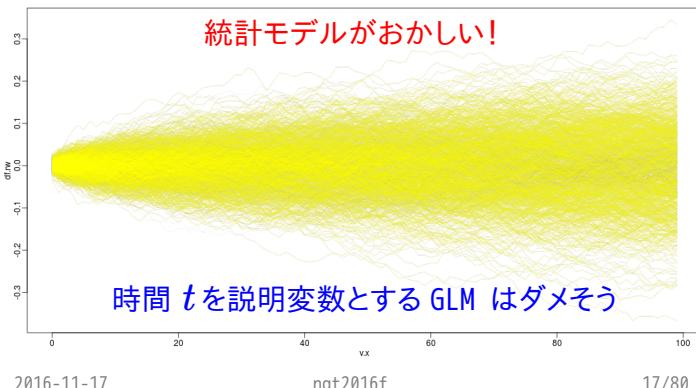
ランダムウォークなサンプル時系列
とりあえず 1000 本ほど生成してみました



例外的な時系列というのはありえる
たとえば $t = 100$ でかなり外れている 50 本

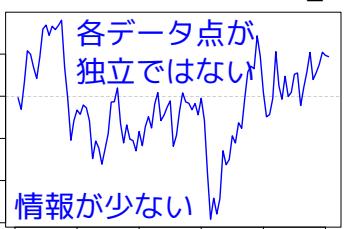


しかし直線回帰 GLM あてはめると…
ほとんどすべての場合で「ゆーい」！

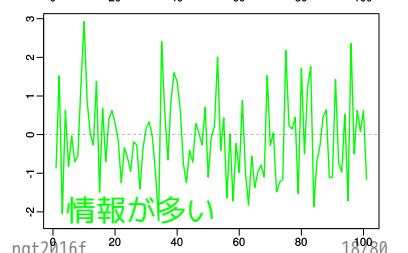


ちょっとでも傾いてたら「ゆーい」

実際には
こんなデータ
なのに



R の `glm()` は
こんなデータ
だとみなしている



時間的自己相関

(略称:自己相関, 時間相関)

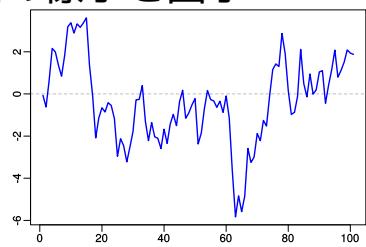
を調べたらいいの?

$$\rho_k = \frac{\text{Cov}(y_t, y_{t-k})}{\sqrt{\text{Var}(y_t) \cdot \text{Var}(y_{t-1})}}$$

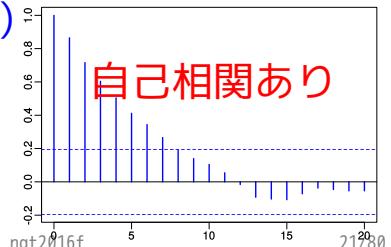


自己相関減衰の様子を図示

`plot(ts(Y))`



`plot(acf(ts(Y)))`



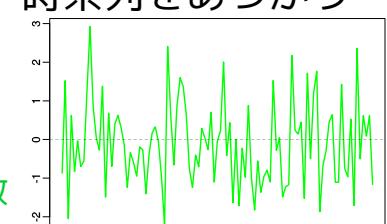
2016-11-17

ngt2016f 21/80

R の `ts` クラス: 時系列をあつかう

`plot(ts(Y))`

これはたんなる
100 個の正規乱数



`plot(acf(ts(Y)))`

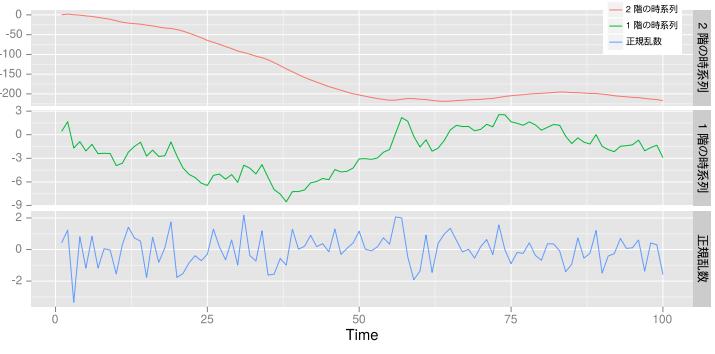
自己相関ない

2016-11-17

ngt2016f 20/80

時系列データの「差分」をみよう

自己相関係数もいいけど差分を調べるのが基本



2016-11-17

ngt2016f

23/80

変数

Y

$N(Y_1, \sigma)$

$\rightarrow Y_2$

$N(Y_2, \sigma)$

$\rightarrow Y_3$

$N(Y_3, \sigma)$

$\rightarrow Y_4$

「時間相関がある」とは?

Y_t と Y_{t+1} は似ている!

正規分布

2016-11-17

ngt2016f

22/80

時間的自己相関

いつも役にたつわけではない?

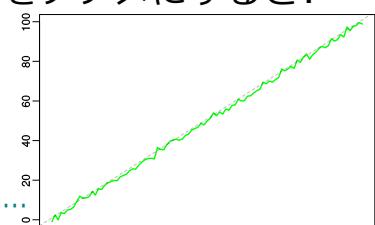
$$\rho_k = \frac{\text{Cov}(y_t, y_{t-k})}{\sqrt{\text{Var}(y_t) \cdot \text{Var}(y_{t-1})}}$$



各点独立のデータをナナメにすると?

`plot(ts(Y))`

これを
ナナメに
したもの
なんだけど…



`plot(acf(ts(Y)))`

自己相関あり
え?

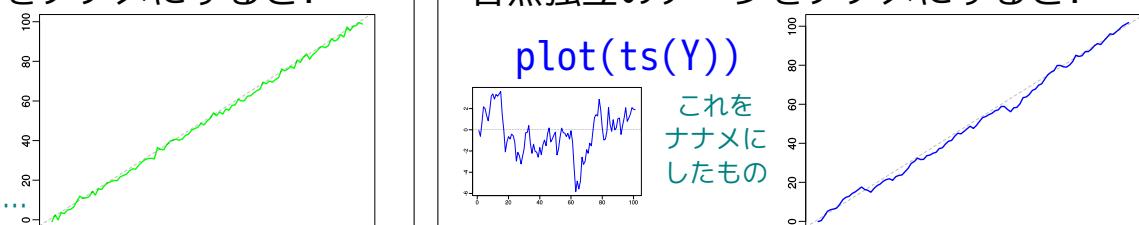
2016-11-17

ngt2016f 25/80

各点独立のデータをナナメにすると?

`plot(ts(Y))`

これを
ナナメに
したもの



`plot(acf(ts(Y)))`

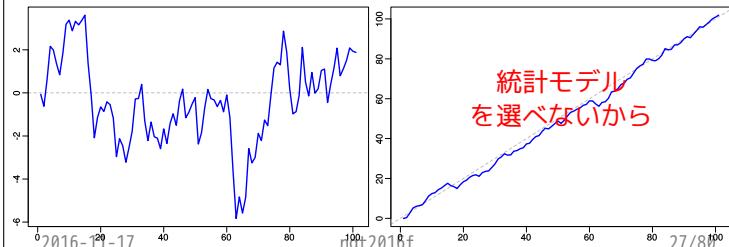
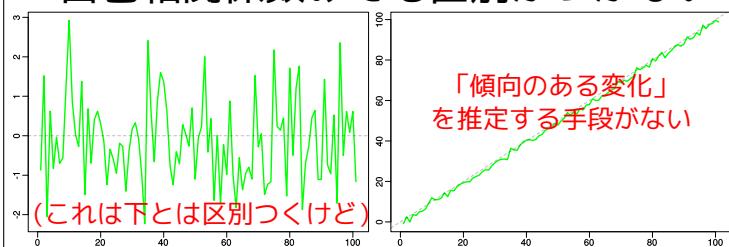
自己相関あり

2016-11-17

ngt2016f 26/80

自己相関係数みても区別がつかない

「傾向のある変化」
を推定する手段がない

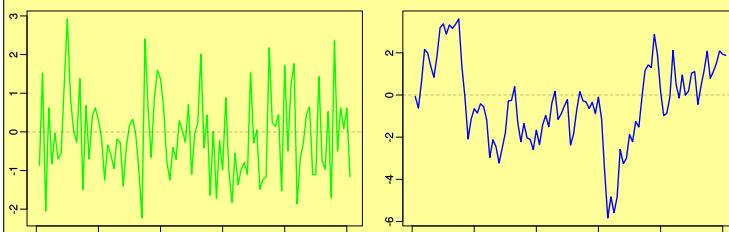


(これは下とは区別つくけど)

統計モデル
を選べないから

状態空間モデルでたちむかう
時系列データ解析

いろいろな時系列データを
統一的にあつかえないか?



変数

Y_1

$N(Y_1, \sigma) \rightarrow Y_2$

Y_1

$N(Y_2, \sigma) \rightarrow Y_3$

Y_1

$N(Y_3, \sigma) \rightarrow Y_4$

ランダムウォーク
もっとも単純な
モデル

2016-11-17

ngt2016f

28/80

時系列データ解析の教科書、ねえ……

- モデルがあれこれ多すぎる
- 経済学よりのモデルばかり
- なんでも正規分布

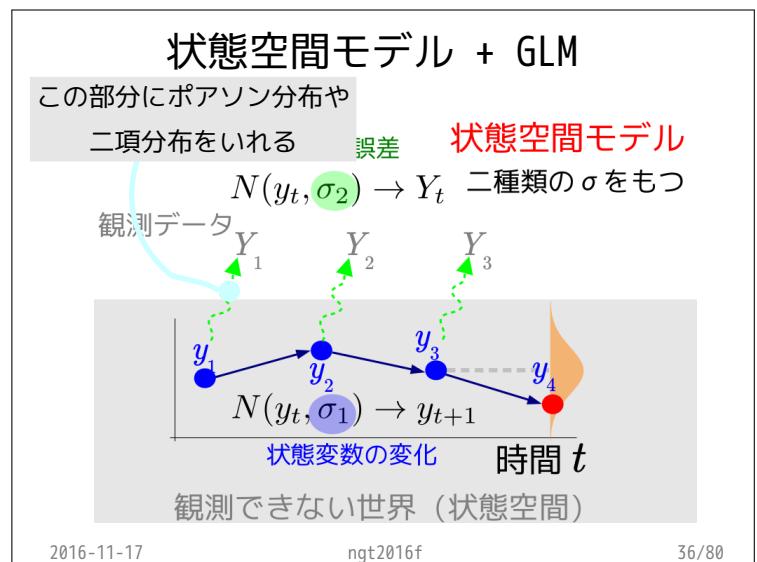
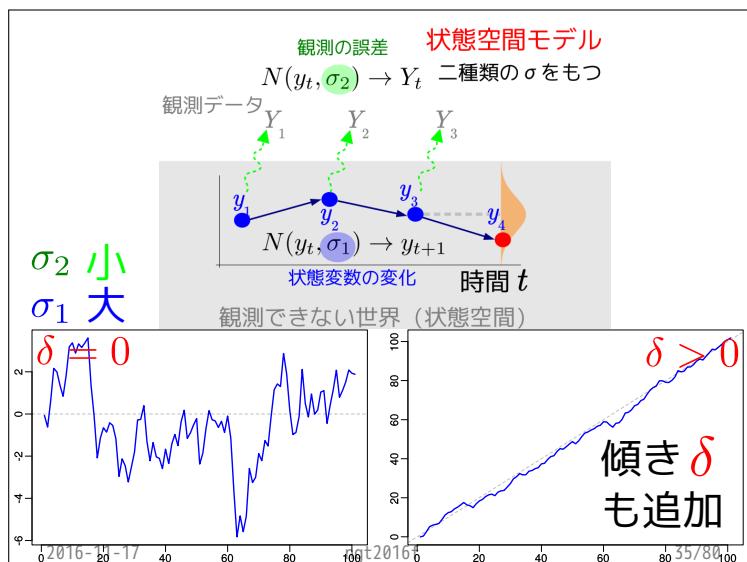
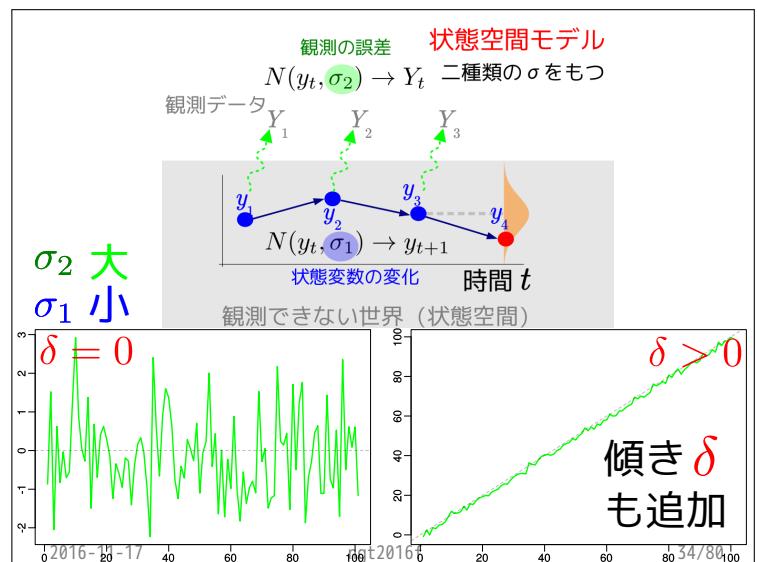
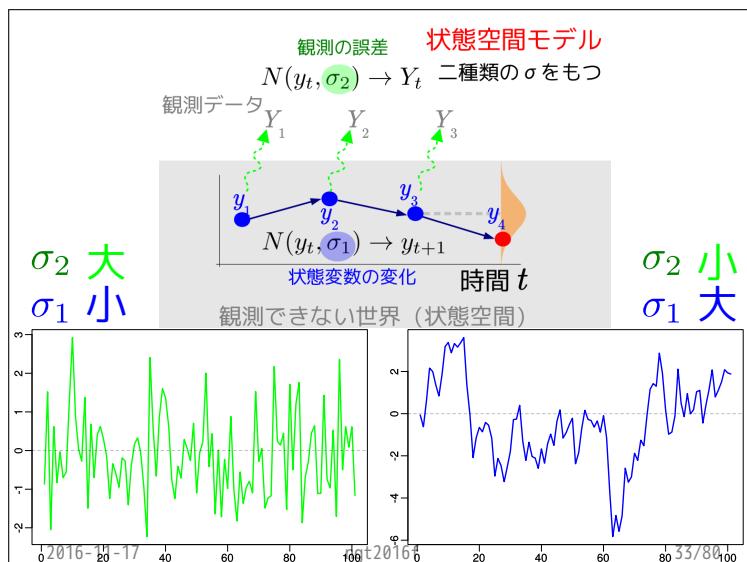
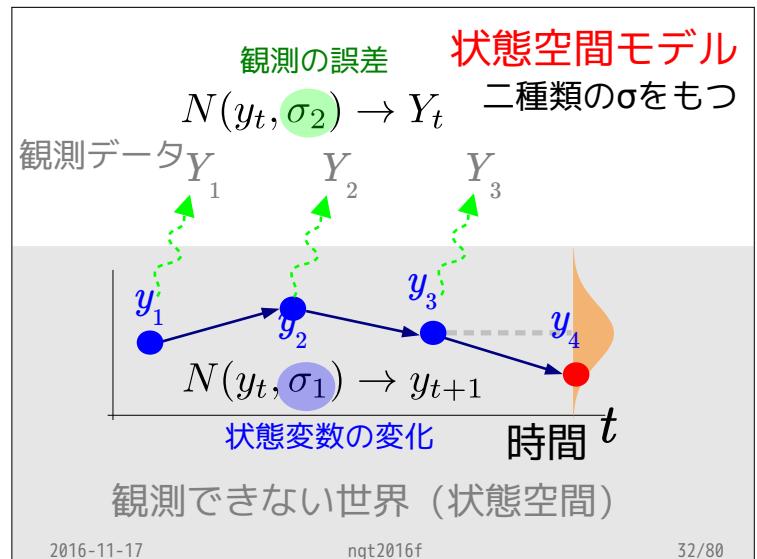
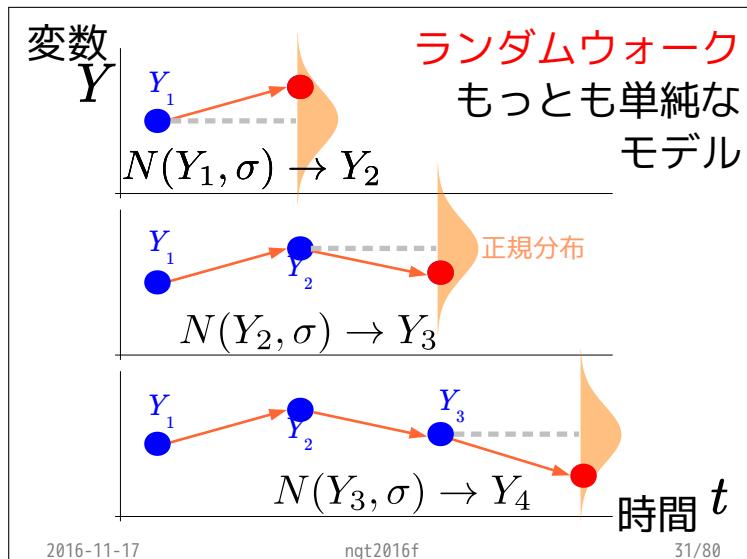
なんとかならないかな?

状態空間モデル、どうでしょう?

2016-11-17

ngt2016f

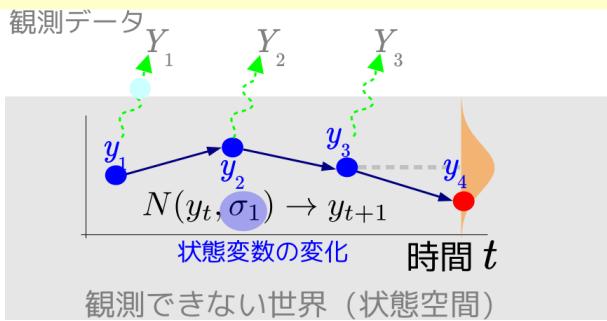
30/80



状態空間モデル + GLM

他にも季節変動などを
入れることができます

今日は
省略…
すみません



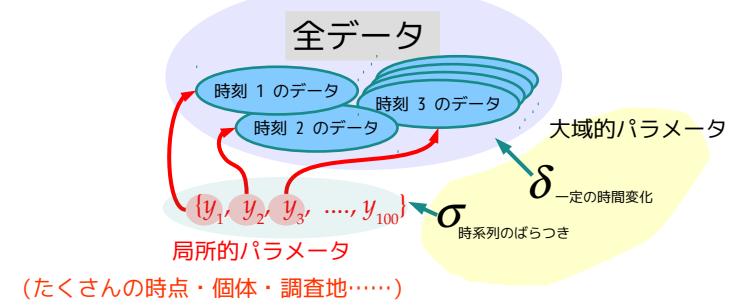
2016-11-17

ngt2016f

37/80

階層ベイズモデルとは?

多数の「似たようなパラメーター」たちに
「適切」な制約を加えて推定できる



2016-11-17

ngt2016f

38/80

どうやってモデルをあてはめる?



R の状態空間モデルの
package いろいろある

`library(dlm)`

`library(KFAS)`

(けっこうめんどう?)

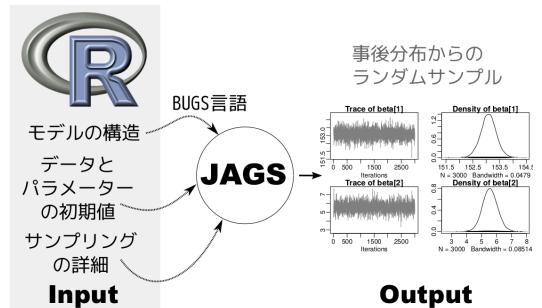
2016-11-17

ngt2016f

39/80

こういう問題も JAGS で

BUGS 言語でこの単純な
階層ベイズモデルを記述できる



2016-11-17

ngt2016f

40/80

model

```
{
  Tau.Noninformative <- 0.0001
  Y[1] ~ dnorm(y[1], tau[2])
  y[1] ~ dnorm(0, Tau.Noninformative)
  for (t in 2:N.Y) {
    Y[t] ~ dnorm(y[t], tau[2])
    y[t] ~ dnorm(m[t], tau[1])
    m[t] <- delta + y[t - 1]
  }
  delta ~ dnorm(0, Tau.Noninformative)
  for (k in 1:2) {
    tau[k] <- 1 / (s[k] * s[k])
    s[k] ~ dunif(0, 10000)
  }
}
```

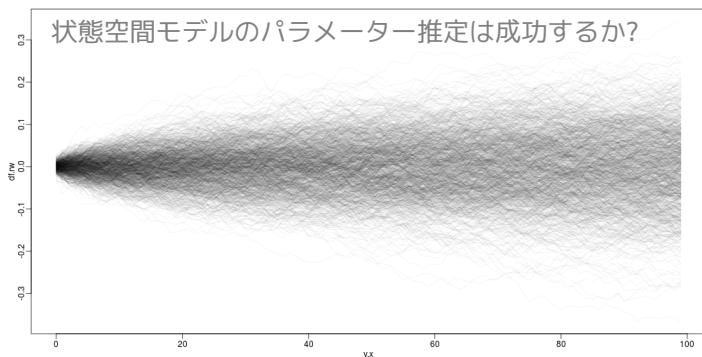
2016-11-17

ngt2016f

41/80

1000 個の架空データを推定

いろいろなランダムウォークが生成される



2016-11-17

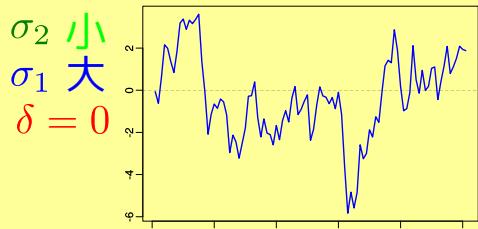
ngt2016f

42/80

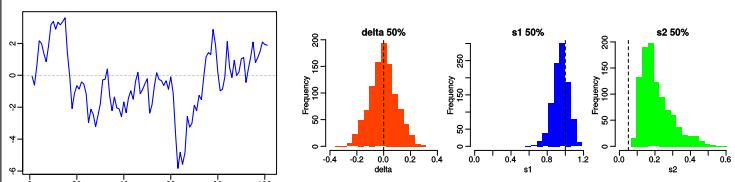
状態空間モデルを

「かたむきゼロ」ランダムウォーク
 $\delta = 0$

な架空データにあてはめる



「傾き」 δ の事後分布を見る



2016-11-17

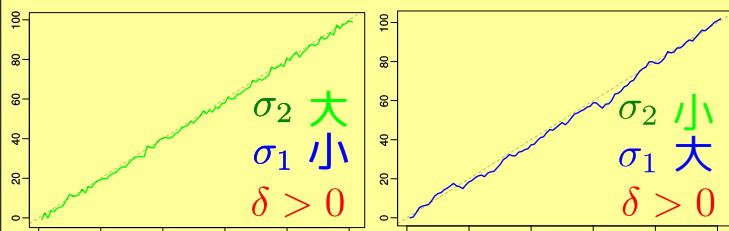
ngt2016f

44/80

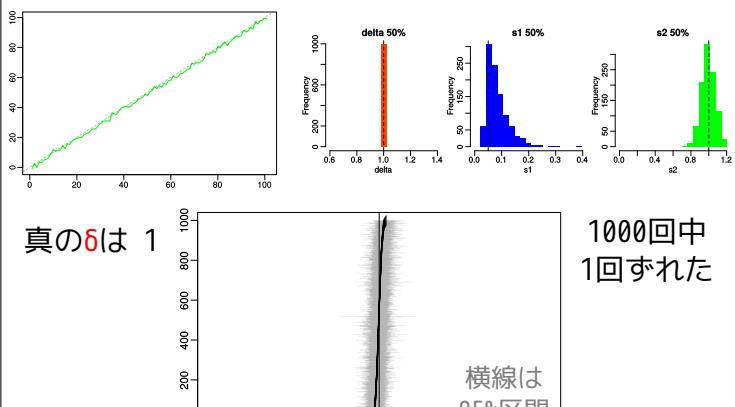
状態空間モデルを

「かたむきあり」ランダムウォーク
 $\delta > 0$

な架空データにあてはめる



「傾き」 δ の事後分布を見る

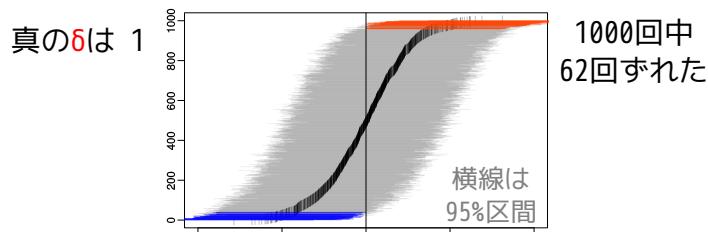
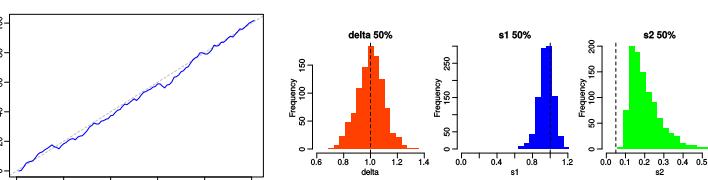


2016-11-17

ngt2016f

46/80

「傾き」 δ の事後分布を見る



2016-11-17

ngt2016f

47/80

とりあえずの結論

観測の誤差 状態空間モデル

$N(y_t, \sigma_2) \rightarrow Y_t$ 二種類の σ をもつ

観測データ Y_1, Y_2, Y_3

y_1, y_2, y_3

$N(y_t, \sigma_1) \rightarrow y_{t+1}$

状態変数の変化 時間 t

観測できない世界 (状態空間)

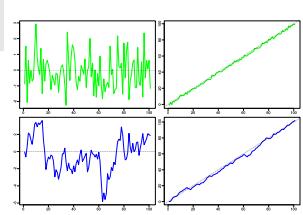
ひとつの状態空間
モデルを使って

右の4状態は
区別可能でしょう

2016-11-17

ngt2016f

48/80



今回、説明してみたいこと

- ・時系列データ: 単純な回帰はダメ(続)
- ・状態空間モデル: 乱歩と雑音の分離
- ・欠測と不等間隔
- ・時系列「ばらばら解析」やめよう
- ・「うたがわしい回帰」への対策

階層ベイズモデル!

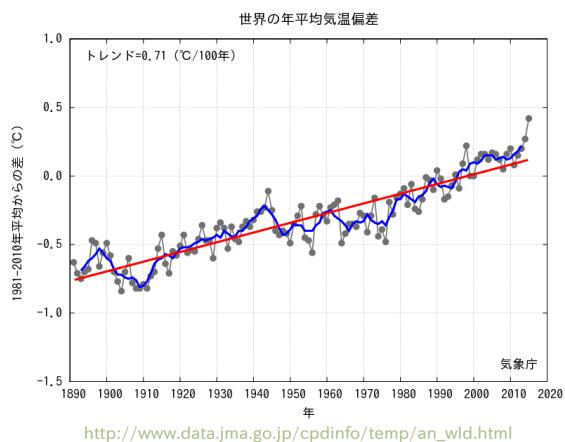
2016-11-17

49/80

状態空間モデルを使う利点

- 「ばらばら解析」の回避
- 気象庁のデータ解析?

気象庁の長期変化傾向（トレンド）の解説

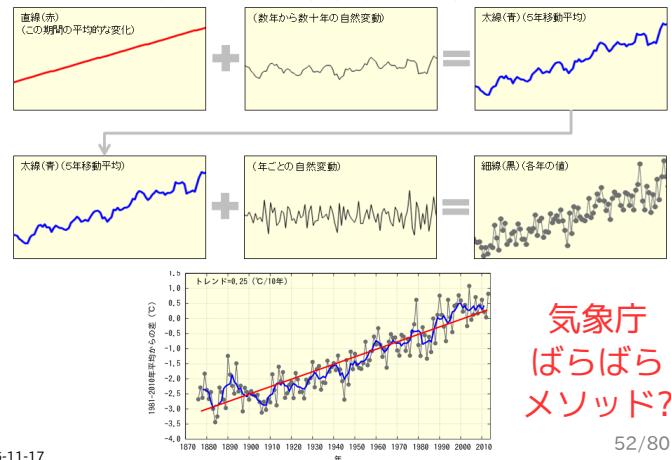


2016-11-17

51/80

気象庁の長期変化傾向（トレンド）の解説

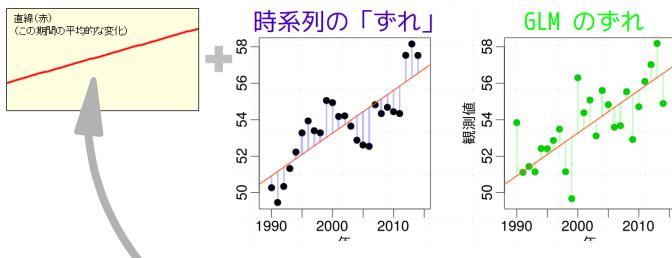
<http://www.data.jma.go.jp/cpdinfo/temp/trend.html>



52/80

気象庁ばらばらメソッド何がまずいか?

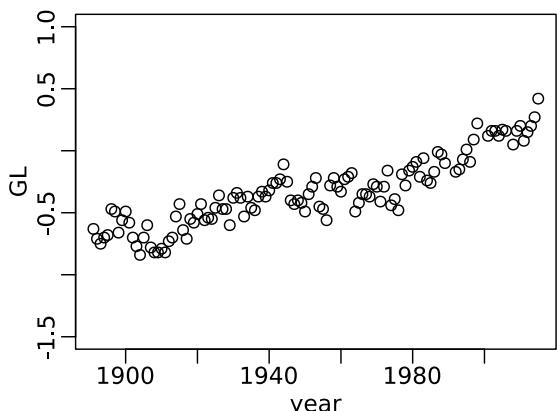
<http://www.data.jma.go.jp/cpdinfo/temp/trend.html>



2016-11-17

53/80

公開データをダウンロード



2016-11-17

54/80

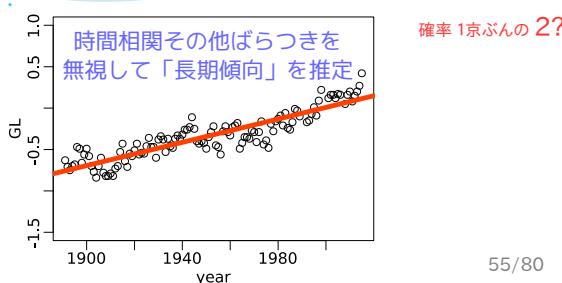
「とりあえず、直線回帰」の危険性

```
> summary(glm(GL ~ year, data = d))
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-1.41e+01	6.21e-01	-22.6	<2e-16
year	7.03e-03	3.18e-04	22.1	<2e-16

100年
あたり
0.70°C



55/80

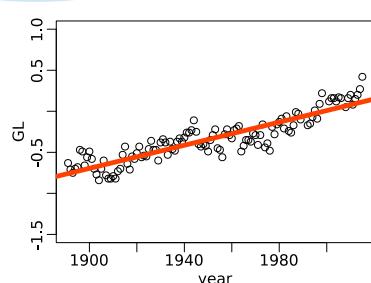
直線あてはめ (GLM) が予測した「温暖化」

```
> summary(glm(GL ~ year, data = d))
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-1.41e+01	6.21e-01	-22.6	<2e-16
year	7.03e-03	3.18e-04	22.1	<2e-16

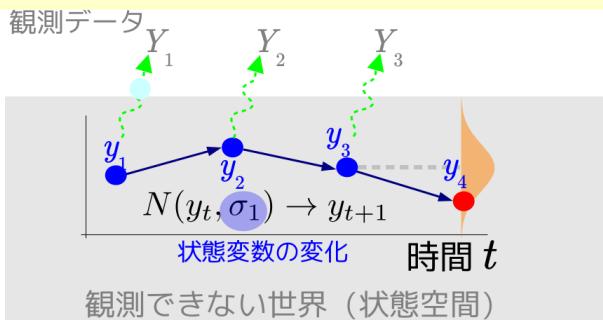
100年
あたり
0.70°C



56/80

状態空間モデル：すべてを同時に推定

ランダムウォーク+各年独立なノイズ



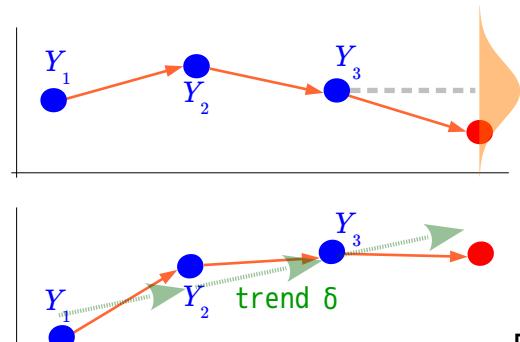
2016-11-17

ngt2016f

57/80

状態空間モデル：すべてを同時に推定

ランダムウォーク+各年独立なノイズ



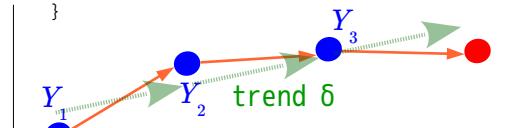
2016-11-17

ngt2016f

58/80

状態空間モデル：すべてを同時に推定

```
Y[1] ~ dnorm(y[1], tau[2])
y[1] ~ dnorm(0.0, Tau.Noninformative)
for (t in 2:N.Y) {
  Y[t] ~ dnorm(y[t], tau[2])
  y[t] ~ dnorm(m[t], tau[1])
  m[t] <- delta + y[t - 1]
}
delta ~ dnorm(0, Tau.Noninformative)
for (k in 1:2) {
  tau[k] <- 1.0 / (s[k] * s[k])
  s[k] ~ dunif(0, 1.0E+4)
}
```



2016-11-17

ngt2016f

59/80

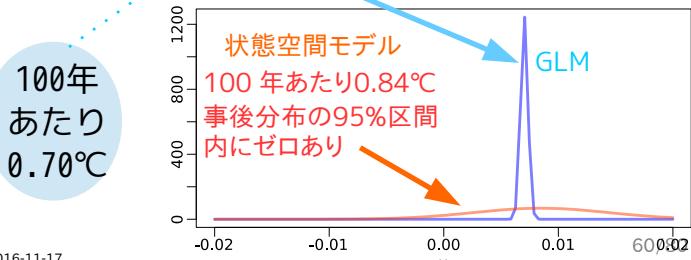
状態空間モデルが予測した「温暖化」

```
> summary(glm(GL ~ year, data = d))
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-1.41e+01	6.21e-01	-22.6	<2e-16
year	7.03e-03	3.18e-04	22.1	<2e-16

100年
あたり
0.70°C

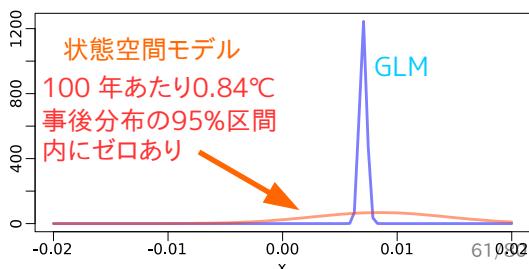


2016-11-17

ngt2016f

60/80

観測値間に相関あり →
実質的な
サンプルサイズが小さくなる



疑わしい回帰
spurious regression

時系列どうしの回帰

time series $Y \sim$ time series X

時系列データの統計モデリング でやめたほうがいいこと

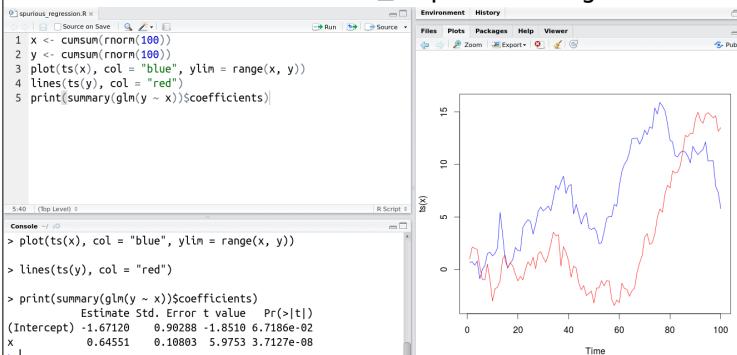
- GLM: $Y(t) \sim t$ とか $Y(t) \sim X(t)$
- 段階的解析: 観測値の四則演算
- 「残差」の再解析
- 「対応」の無視 – 再測は時系列

2016-11-17

ngt2016f

63/80

「見せかけの回帰」 spurious regression



ちょっとだけ実演してみます

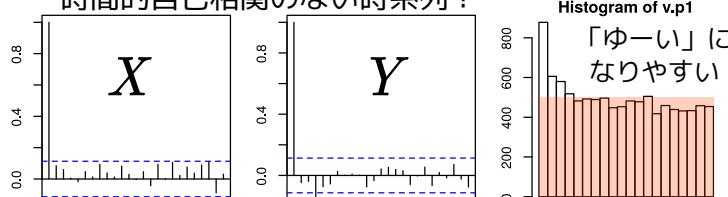
2016-11-17

ngt2016f

64/80

ノイズの大きな時系列にうもれたワナ？

時間的自己相関のない時系列？

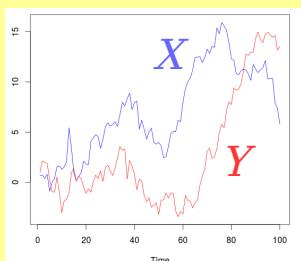


しかし $\text{glm}(Y \sim X)$ とすると…

2016-11-17

65/80

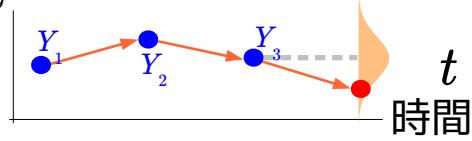
$Y \sim X$
疑わしい回帰
spurious
regression



この問題も
状態空間モデル (SSM) で
解決できないだろうか？

二変量のランダムウォーク モデルを作れないか?

$$Y_{t+1} \sim N(Y_t, s_y)$$



2016-11-17

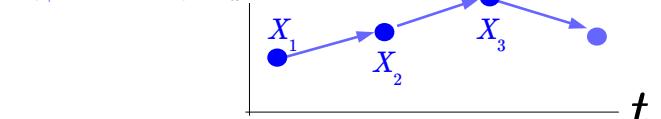
ngt2016f

67/80

二変量のランダムウォーク Y_t と X_t は独立

$$Y_{t+1} \sim N(Y_t, s_y)$$

$$X_{t+1} \sim N(X_t, s_x)$$



2016-11-17

ngt2016f

68/80

二変量のランダムウォーク Y_t と X_t は独立

$$Y_{t+1} \sim N(Y_t, s_y)$$



$$X_{t+1} \sim N(X_t, s_x)$$

このあたりで
何とかならないか?

2016-11-17

ngt2016f

69/80

$$Y_{t+1} \sim N(Y_t, s_y) \quad \text{一変量の正規分布(密度関数)}$$



二変量の正規分布(密度関数)

Bivariate case

In the 2-dimensional nonsingular case ($k = \text{rank}(\Sigma) = 2$), the **probability density function** of a vector $[X \ Y]'$ is:

$$f(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)} \left[\frac{(x-\mu_X)^2}{\sigma_X^2} + \frac{(y-\mu_Y)^2}{\sigma_Y^2} - \frac{2\rho(x-\mu_X)(y-\mu_Y)}{\sigma_X\sigma_Y} \right]\right)$$

where ρ is the **correlation** between X and Y and where $\sigma_X > 0$ and $\sigma_Y > 0$. In this case,

$$\mu = \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \quad \Sigma = \begin{pmatrix} \sigma_X^2 & \rho\sigma_X\sigma_Y \\ \rho\sigma_X\sigma_Y & \sigma_Y^2 \end{pmatrix}.$$

分散共分散行列

相関係数 ρ

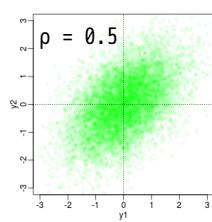
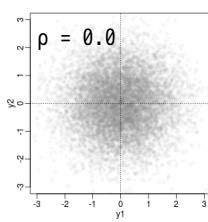
https://en.wikipedia.org/wiki/Multivariate_normal_distribution

2016-11-17

ngt2016f

70/80

無相関



正の相関

Bivariate case

In the 2-dimensional nonsingular case ($k = \text{rank}(\Sigma) = 2$), the **probability density function** of a vector $[X \ Y]'$ is:

$$f(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)} \left[\frac{(x-\mu_X)^2}{\sigma_X^2} + \frac{(y-\mu_Y)^2}{\sigma_Y^2} - \frac{2\rho(x-\mu_X)(y-\mu_Y)}{\sigma_X\sigma_Y} \right]\right)$$

where ρ is the **correlation** between X and Y and where $\sigma_X > 0$ and $\sigma_Y > 0$. In this case,

$$\mu = \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \quad \Sigma = \begin{pmatrix} \sigma_X^2 & \rho\sigma_X\sigma_Y \\ \rho\sigma_X\sigma_Y & \sigma_Y^2 \end{pmatrix}.$$

分散共分散行列

相関係数 ρ

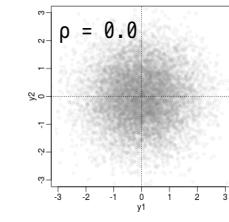
https://en.wikipedia.org/wiki/Multivariate_normal_distribution

2016-11-17

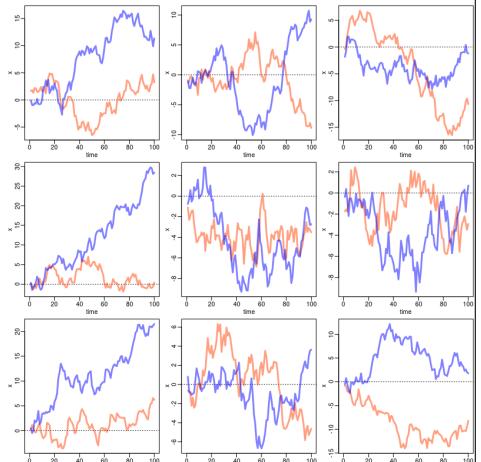
ngt2016f

71/80

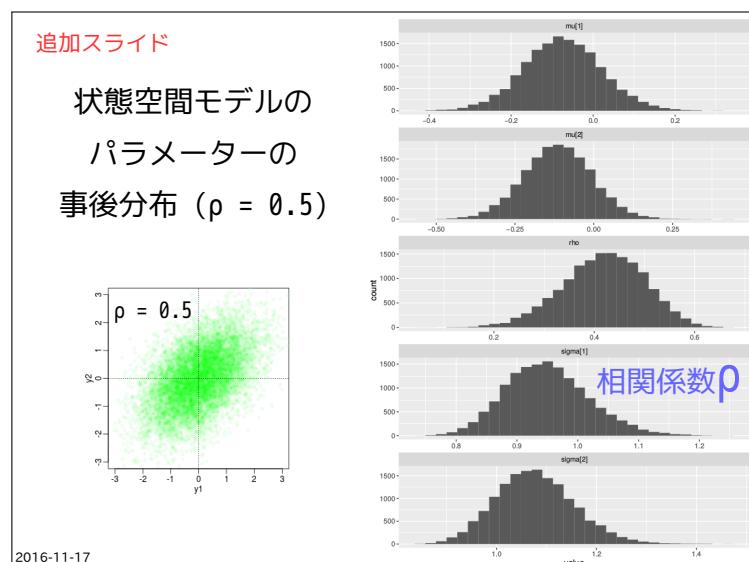
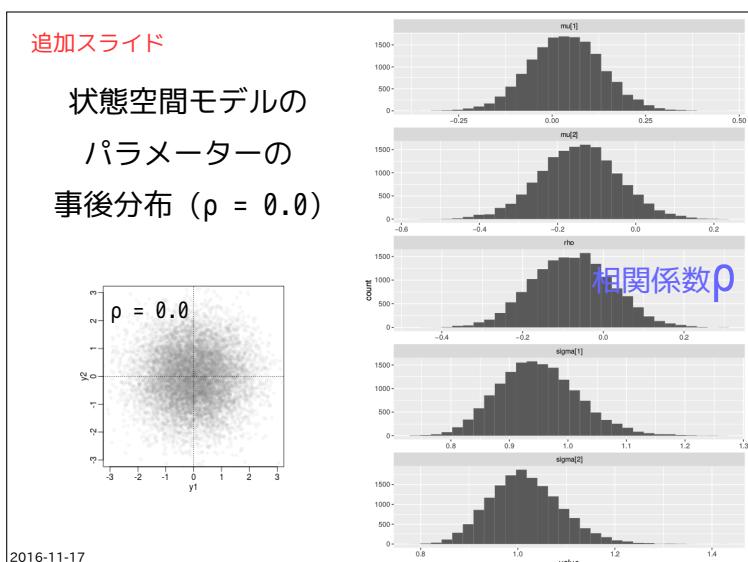
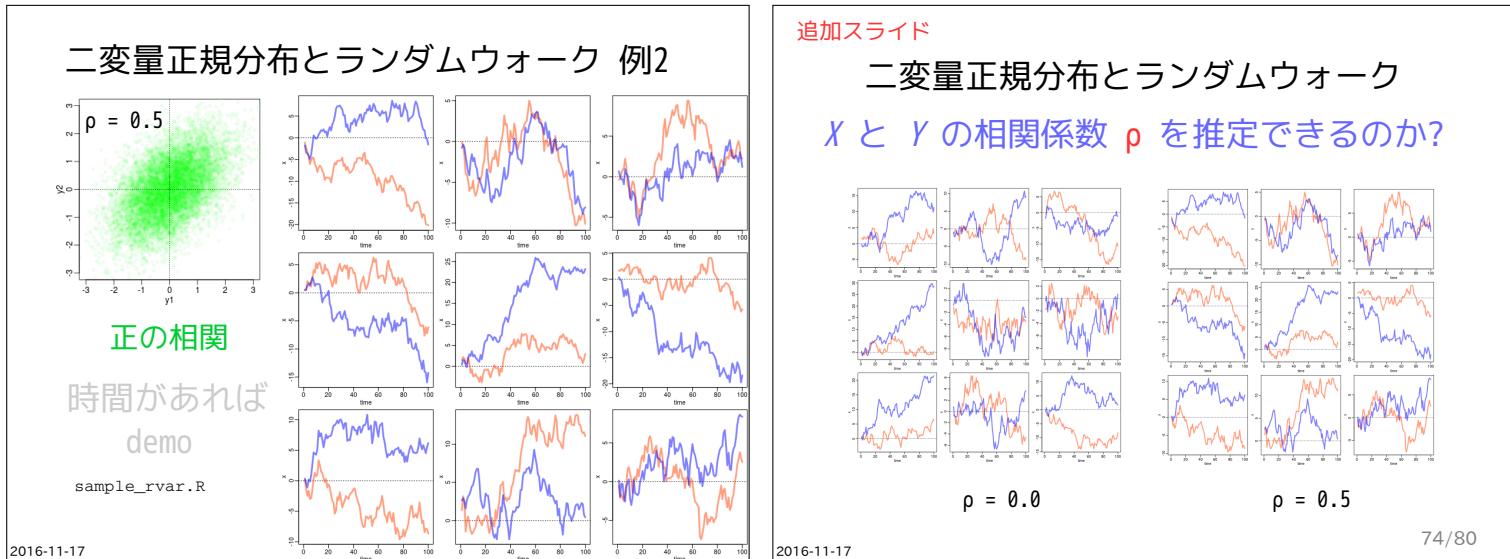
二変量正規分布とランダムウォーク 例1



無相関



2016-11-17



時系列データの統計モデリング

- ・安易に「回帰」してはいけない
- ・ランダムウォークモデルが基本
- ・統計モデルが生成する時系列パターンを意識する
- ・階層ベイズモデルで推定

状態空間モデル

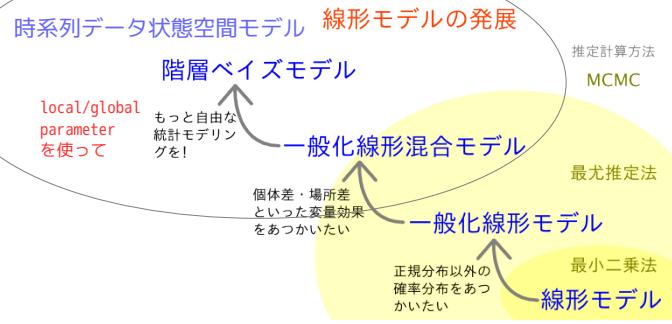
2016-11-17

ngt2016f

79/80

統計モデリング入門, ここまで…

データの性質・構造をよくみて統計モデルを作る



2016-11-17

ngt2016f

80/80

R の練習 (r1) 2016-10-07

久保拓弥 kubo@ees.hokudai.ac.jp

この授業の web page: <http://goo.gl/aFLLHZ>

統計ソフトウェア R は研究にたいへん役にたつ free software (無料で入手でき , しかも内部を自由に調べられる) です . 今回は R のデータ操作・作図の基本わざを説明します .

R を使ったデータ解析の基本的な流れは次のようにになります :

1. データを読みこむ (データフレイム data.frame を作る)
2. 読みこんだデータをいろいろ整理する (データフレイムの操作)
3. データをさまざまな方法で図示する
4. 統計モデリングの設計・あてはめを行う
5. あてはめの結果やモデルの予測を図示する
6. 解析結果をさまざまな方法で出力し , 保存する

今日は時間も限られているので , データの読み込み , 基本的なデータフレイム操作 , 簡単な図示について説明します . 上述の授業 web site のあちこちを見て , さらに発展したわざも勉強してください .

1 R でデータフレイムの操作

1.1 データを読みこんで data.frame を作り , それを表示する

```
> d <- read.csv("data.csv")
> d
   treatment size seed
1    control  21.3    9
2      trtX  24.2   19
3    control  12.0    1
4      trtX  16.1    4
5    control  21.8   13
6      trtX  20.2    6
7    control  22.7    8
8      trtX  23.8    8
9    control  19.5    7
10     trtX  26.4   22
11    control  20.1    3
12      trtX  27.3   31
```

```
13 control 22.5 14
14     trtX 21.8 19
15 control 18.6 4
16     trtX 25.3 26
17 control 23.5 11
18     trtX 19.7 6
19 control 27.9 22
20     trtX 22.0 17
```

```
> head(d) # 最初の 6 行が表示される
```

```
  treatment size seed
1 control 21.3 9
2     trtX 24.2 19
3 control 12.0 1
4     trtX 16.1 4
5 control 21.8 13
6     trtX 20.2 6
```

```
> head(d, 3) # 最初の 3 行が表示される
```

```
  treatment size seed
1 control 21.3 9
2     trtX 24.2 19
3 control 12.0 1
```

```
> tail(d, 3) # 最後の 3 行が表示される
```

```
  treatment size seed
18     trtX 19.7 6
19 control 27.9 22
20     trtX 22.0 17
```

```
> edit(d) # d を編集する
```

1.2 data.frame から行と列をとりだす

```
> d[1:3,] # 1 行めから 3 行めをとりだす
```

```
  treatment size seed
1 control 21.3 9
2     trtX 24.2 19
3 control 12.0 1
```

```
> d[c(1, 3, 5),] # 1, 3, 5 行めをとりだす
```

```
  treatment size seed
```

```

1   control 21.3    9
3   control 12.0    1
5   control 21.8   13

> d[, 1] # 1 列めをとりだす
[1] control trtX      control trtX      control trtX ... 略
Levels: control trtX

> d[4:6, 2:3] # 4-6 行めの 2-3 列めをとりだす
  size seed
4 16.1    4
5 21.8   13
6 20.2    6

# 列の選びかたに 3 とおりある (どれも重要)
> d[, 3] # 3 列めをとりだす
[1]  9 19  1  4 13  6  8  8  7 22  3 31 14 19  4 26 11  6 22 17

> d$seed # 上とおなじことをやっている
[1]  9 19  1  4 13  6  8  8  7 22  3 31 14 19  4 26 11  6 22 17

> d[, "seed"] # これも同じ
[1]  9 19  1  4 13  6  8  8  7 22  3 31 14 19  4 26 11  6 22 17

```

1.3 data.frame から条件つきデータとりだし

treatment が trtX のデータ

```

> d[d$treatment == "trtX",]
  treatment size seed
2       trtX 24.2   19
4       trtX 16.1    4
6       trtX 20.2    6
8       trtX 23.8    8
10      trtX 26.4   22
12      trtX 27.3   31
14      trtX 21.8   19
16      trtX 25.3   26
18      trtX 19.7    6
20      trtX 22.0   17

```

size が 25.0 より大きいデータ

```
> d[d$size > 25.0,]
```

```
treatment size seed
10      trtX 26.4   22
12      trtX 27.3   31
16      trtX 25.3   26
19    control 27.9   22
```

seed が 6 以下であるデータ

```
> d[d$seed <= 6,]
3     control 12.0   1
4      trtX 16.1   4
11    control 20.1   3
15    control 18.6   4
...
```

seed が 6 以下 , かつ 2 より大

```
> d[d$seed <= 6 & d$seed > 2,]
...
```

seed が 6 より大 , または 2 以下

```
> d[d$seed > 6 | d$seed <= 2,]
...
```

1.4 data.frame 内でのならびかえ

```
> d <- d[order(d$size),] # d$size の小さい順に並べかえる
> d <- d[rev(order(d$size)),] # d$size の大きい順に並べかえる
```

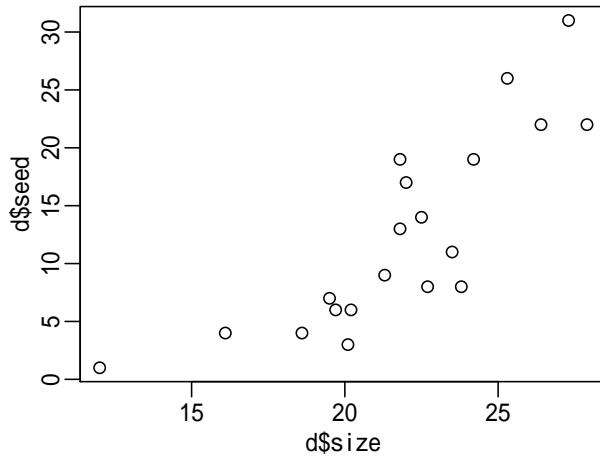
2 R で作図

R 作図の基本 (plot() 関数を使う場合)

- いっぺんに図を作ろうとするのではなく , 必要な要素を足していく
- plot() で「わく」を描く
- points(), lines(), legend() で必要なものを追加していく
- par(new = TRUE) による方法は使わないほうがよい (わくを何重にも描くことになったりするから)

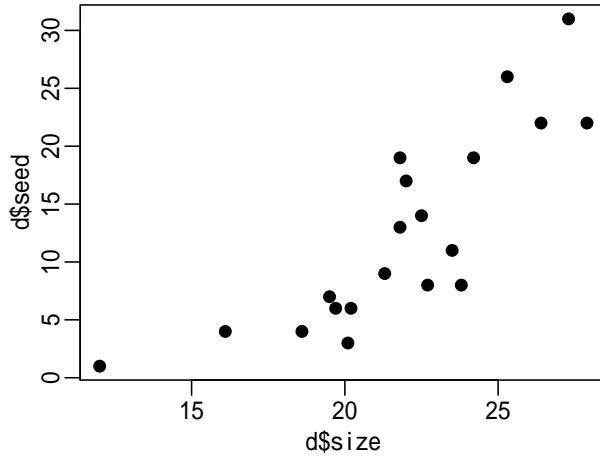
2.1 data.frame のデータを表示する

```
> d <- read.csv("r1.csv")
> plot(d$size, d$seed)
```



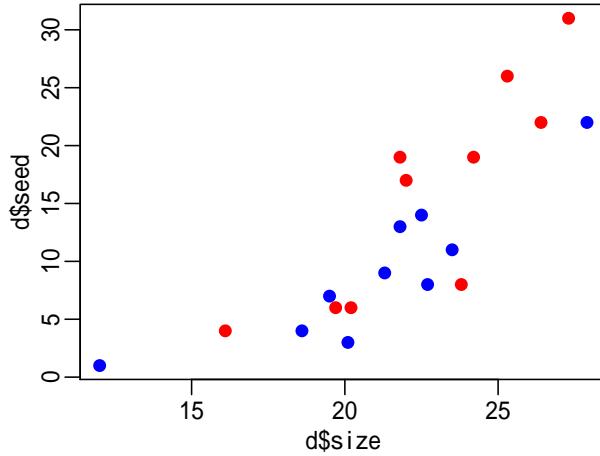
pch 引数で点の種類を変える

```
> plot(d$size, d$seed, pch = 19)
```



col 引数で点の色を変える

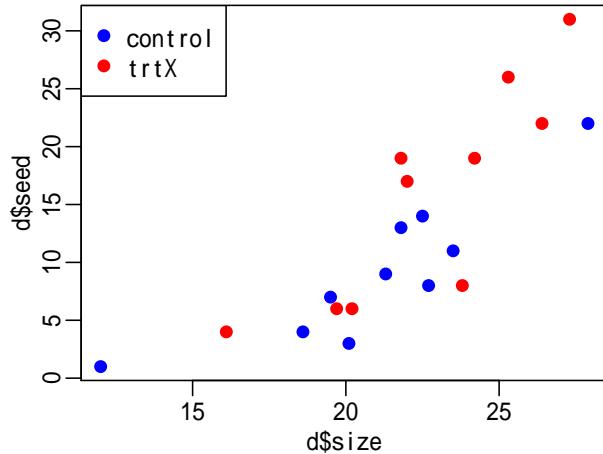
```
> plot(d$size, d$seed, pch = 19, col = c("blue", "red")[d$treatment])
```



legend() 関数で凡例を追加

上の図に legend を追加

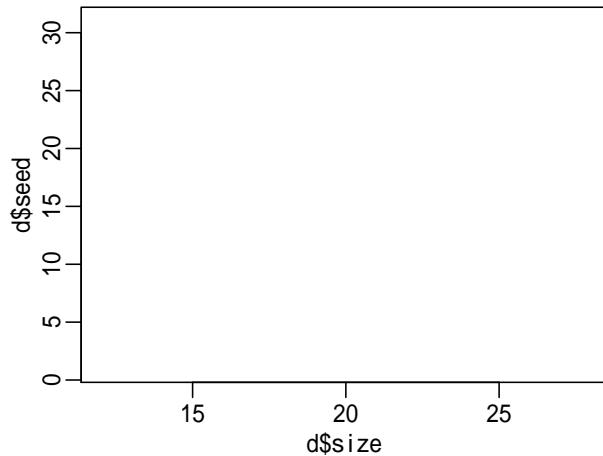
```
> legend("topleft", legend = levels(d$treatment), pch = 19, col = c("blue", "red"))
```



2.2 図を順にかさねていくわざ

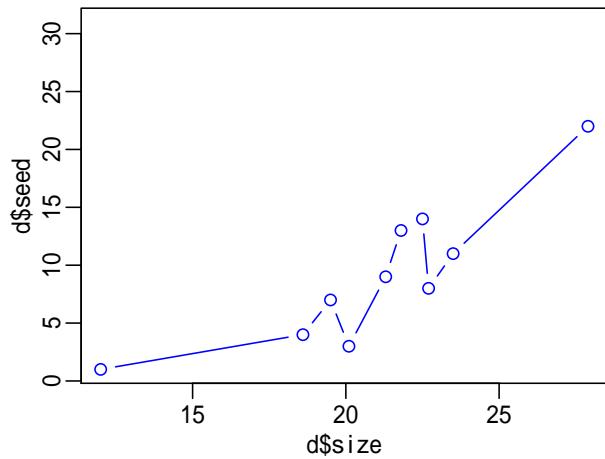
最初にわくだけ描く

```
> plot(d$size, d$seed, type = "n") # わくだけ描く
```



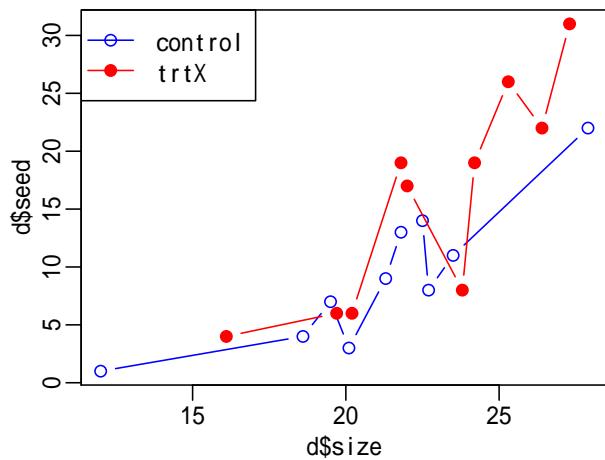
処理が control である線だけ描く

```
> dC <- d[d$treatment == "control",] # treatment が control のデータだけ
> dC <- dC[order(dC$dsize),] # size 順にならびかえる
> lines(dC$dsize, dC$dseed, pch = 21, col = "blue") # 線を追加
```



次に処理が trtX である線を描き，凡例を追加する

```
> dX <- d[d$treatment == "trtX",] # treatment が trtX のデータだけ
> dX <- dX[order(dX$dsize),] # size 順にならびかえる
> lines(dX$dsize, dX$dseed, pch = 21, col = "red") # 線を追加
> legend("topleft", legend = levels(d$treatment),
  pch = c(21, 19), col = c("blue", "red"), lwd = 1)
```



3 その他あれこれ

- `pdf()`, `jpg()`, `png()` といった `device` 指定でいろいろな形式で図を出力できる
- R 作図に慣れてきたら, `library(lattice)` や `library(ggplot2)` で, より「全体像のみやすい」図を作ろう
 - `library(lattice)` を使った条件ごとプロットの例:

```
> d <- d[order(d$size),] # size 順にデータをならびかえ  
> print(xyplot(seed ~ size | treatment, data = d, type = "b"))
```

