

2012-12-18

## 漁業統計検討会 (清水)

「統計モデリングセミナー」(2012年12月)投影資料

全部で7回中の6回目

## 階層ベイズモデルの応用




資源分配など割合をつかう

久保拓弥 kubo@ees.hokudai.ac.jp

<http://goo.gl/0yB2k>

# 今日のハナシ: 連續値の割算値をやつつける

- 例題 1. 植物の地上部・地下部の重量比 (基本篇)
- 例題 2. 植物の地上部・地下部の重量比 (発展篇)
- 例題 3. 植物の葉のタテヨコ比 (カタチ篇)
- 例題 4. 植物の葉のタテヨコ比 (種識別篇)




## 前半：植物の地上部・地下部の重量比のハナシ

1. まずは  $\{X, Y\}$  誤差ありデータ解析における、ありがちな回帰適用お作法の問題点について検討
2. 解決策のひとつになりうる重量分割モデルの紹介
  - とても簡単な架空データ例題を使って
3. 重量分割モデルの拡張方法を検討
  - もう少し現実的な架空データ例題を使って
  - モデルの発展や他の問題への応用を考える

たとえばこういうデータがあったとしましょう

## 架空植物の地下部 ( $X$ ) と地上部 ( $Y$ ) の重量




$X$  と  $Y$  の関係を調べたい

生態学における  $\{X, Y\}$  誤差ありデータ解析の典型

(今日はずっとこのたぐいの架空植物例題ばかり)

# 「あろめとらー」たちのお作法!


1.  $X$  も  $Y$  もすぐに対数変換してしまう
2.  $\log Y \sim N(a + b \log X, \sigma^2)$  な回帰をやっちゃう
3. 「ゆーい」とか「せつめい力  $R^2$ 」とか言ってみる




定義

あろめとらー: 上記のようなことをするヒトたち

つまりこのように対数変換してしまって




「センをひっぱる」なる行動をします、と……



# あろめとらーなお作法の問題点

- それって地下部重 ( $X$ ) が原因で地上部重 ( $Y$ ) が結果なのか?
  - 因果関係がわからんのに回帰してよいの?
- なぜ  $E(\log Y) = a + b \log X$ ?
  - これって何を表現しているモデル?
- $X$  の測定時の誤差はどこにいった?
  - なぜ  $Y$  軸方向にだけ「誤差」?



# こういう現象をあつかうもうひとつのモデル?



重量分割モデル: 階層ベイズモデルとして定式化

- $X$  も  $Y$  も結果である, 原因ではない
  - (バイオマスの) 重量分割という現象の結果
- 全重量 → 地下部 ( $X$ ) + 地上部 ( $Y$ ) と考える
  - これも「近似的な」現象のとらえかたではあるけれど
- $X$  と  $Y$  の測定時の誤差を明示的にあつかう
  - そして「個体差」由来のばらつき(random effects) も考慮する

## 例題 1



「アロメトリーな回帰」はヤメて  
重量分割モデルを作ってみよう

# 架空データ 1: 地下部・地上部の重量




- 対数をとらなくても「直線」にのってる?
- つまり、むしろアイソメトリック (isometric)?
- 重量が重くなるとばらつきが大きくなる?

# 対数スケイルでみるとこうなってます




- とはいえる世界で「センをひっぱる」わけではない

# 重量分割モデル (階層ベイズモデル): そのプロセス



# 重量分割モデル(階層ベイズモデル): 「誤差」の入りかた



## 重量分配モデルを BUGS code で (process の部分のみ)

```
for (i in 1:N) {  
    Y[i] ~ dnorm(y[i], Tau.err) # 地上部の重量  
    X[i] ~ dnorm(x[i], Tau.err) # 地下部の重量  
    y[i] <- q[i] * w[i]  
    x[i] <- (1 - q[i]) * w[i]  
    logit(q[i]) <- a + re[i]  
    w[i] <- exp(log.w[i])  
    log.w[i] ~ dnorm(0, Tau.noninformative) # !!  
}# log.w[i] は地上部 + 地下部の重量
```



このように明示的にモデルを記述できる!

# 階層ベイズモデルのパラメーター推定: MCMC

1. BUGS code で重量分割モデルを記述する (model1.txt)
2. これにデータを渡したりする R スクリプトを書く (runbus1.R)
3. R で runbus1.R を実行 (source("runbugs1.R"))
4. R 内から library(R2WinBUGS) によって WinBUGS が起動
5. WinBUGS 内で Markov chain Monte Carlo (MCMC) サンプリング
6. 事後分布からのサンプリング結果が R に渡される



必要なファイルは自由集会サイトからダウンロードできます

# 推定結果を組みあわせた予測



- オレンジ色の線は中央値 (median)
- 黄色の領域は個体差による予測のばらつき (95% CI)

# 個体差によるばらつき，そして測定時の誤差



- 総重量が小さいときには測定時の誤差が相対的に大きく
- 総重量が大きくなると個体差が占める割合が大きくなる



## このモデルの問題点

- 測定時の誤差は正規分布と仮定していいのか?
  - そうですね、重量は非負の値なのに……
- 測定時の誤差の大きさはどうやって推定したの?
  - 今回は「真の値」をほうりこみました
  - 実際には、測定機器のカタログとか見ながら「てきとー」に決めるしかないのかも？（主観的な事前分布）
  - ひとつの観測対象に対して、複数の測定値が得られていれば、階層ベイズモデルで測定時の誤差の大きさを推定できます
- 状況がちょっと単純すぎない?
  - それでは次の例題を……

# 例題 2


## もうちょっと複雑な 重量分割モデル

## 架空データ 2: 重量増大とともに分配が変化




- 小さいときには地上部重量を大きくする
- 総重量が大きくなってくれば地下部を大きくする

# これはアロメトリーな問題なのだろうか?



- 両対数で直線になっているのか?
- ま、 それはあとで考えることにして……

# 重量分割モデルの改造: $q$ を $w$ 依存にするだけ



# BUGS code の変更点

- 先ほどの簡単な例では (切片) + (個体差) だったが

```
logit(q[i]) <- a + re[i]
```

- ここを以下のように総重量 ( $w$ ) 依存に変更するだけ

( $b \sim dnorm(0, Tau.noninformative)$  追加も必要だけど)


```
logit(q[i]) <- (
  a + b * (log.w[i] - Mean.log.w) + re[i]
```

```
)
```

# Mean.log.w うんぬんは WinBUGS に必須な中央化ワザ



- あとは R と WinBUGS で MCMC するだけ

# 推定結果: 総重量増大 → 地上部への分配減少





- 総重量  $w$  依存のパラメーター  $b$  はマイナス
- こういう問題は MCMC 収束が遅い

# このモデルで複雑な重量分配を表現できる



- オレンジ色の線は中央値 (median)
- 黄色の領域は個体差による予測のばらつき (95% CI)

## 対数の世界でも曲がっている（アロメトリーじゃない!）



- 「両対数表示でも曲がっている」状況でも重量分配モデルは柔軟に対応できる（さらに改訂するのも簡単）

## 連続数量の分配モデルの応用例

- Iijima & Shibuya. 2010. J. For. Res 15:46–54.
- 雌雄同株の植物個体内でのオス・メス繁殖器官への資源分配
- 植物個体内での資源分配を調べる安定同位体の存在比の解析
- 動物の行動観察記録に見られる「時間の分配」のモデル化……ただし時系列構造の考慮も必要
- ほかにもいろいろあるかも?

## 今日のハナシのながれ

1. まずは  $\{X, Y\}$  誤差ありデータ解析における、ありがちな回帰適用お作法の問題点について検討
  - 因果関係なさそうなのに無理に回帰するのはヤメよう！
2. 解決策のひとつになりうる重量分割モデルの紹介
  - $X$  と  $Y$  はどちらも結果だ
  - できればいくつかの  $X$  と  $Y$  の複数回測定を！
3. 重量分割モデルの拡張方法を検討
  - さらに生物学的な過程をとりこんだ改造も可能

## 例題 3


モウセンゴケの葉のカタチ

「面積」分割モデルを作ってみよう

# 例題 3, 4 のデータ


ここで保要さんにモウセンゴケ研究の概要  
とそのデータについて解説をお願いします

# さてさて、まずは作図についての検討から



- うーむ、R の作図機能をもっと使ってみよう！

# 半透過色指定で見えなかったデータを見る



- それから図のタテヨコの range (`xlim, ylim`) 指定も正確に!


## 統計モデリング: 単位長さとタテヨコ比

- 単位長さ =  $\sqrt{\text{タテの長さ} \times \text{ヨコ幅}}$ 
  - つまり 単位長さ =  $\sqrt{\text{葉面積みたいなもの}}$
- タテヨコ比  $c = \text{タテの長さ} / \text{ヨコ幅}$ , という概念
  - タテの長さ = 単位長さ  $\times \sqrt{c}$
  - ヨコ幅 = 単位長さ  $/ \sqrt{c}$
  - $c > 0$
- これらの事前分布を考える
  - $\log(\text{単位長さ})$ : 無情報事前分布  $N(0, 10^2)$
  - $\log(c)$ : 無情報事前分布  $N(0, 10^2)$

## 葉のタテヨコモデルを BUGS code で (process の部分のみ)


```
Y[i] ~ dnorm(y[i], Tau.err)
X[i] ~ dnorm(x[i], Tau.err)
y[i] <- unit.length[i] * sqrt(rxy[i])
x[i] <- unit.length[i] / sqrt(rxy[i])
rxy[i] <- exp(log.rxy[i])
log.rxy[i] ~ dnorm(mean.log.rxy[i], tau[Spc[i]])
mean.log.rxy[i] <- (
  bs[1, Spc[i]]
  + bs[2, Spc[i]] * (unit.length[i] - Mean.ul)
)
unit.length[i] <- exp(log.unit.length[i])
log.unit.length[i] ~ dnorm(0, Tau.noninformative)
```

# 切片 $\beta_1$ の事後分布




- 平均的な単位長さでの長さ / 幅

# 傾き $\beta_2$ の事後分布




- 単位長さが増大すると細長くなるか、幅が広くなるのか？

# 中央値の変化: 成長とともに葉のカタチは変わる



- ナガバ・モウセンゴケ は次第に長細くなる
- 雜種 は同じカタチのままなのかな?

# 個体差によるばらつきを図示してみる




- 分布が重なっている?

## 例題 4


モウセンゴケの葉のカタチに  
もとづく種識別のベイズモデル

# Q. 種の識別って? A. こんな図を作りたい




- ある葉の幅・長さが得られたときに、その情報にもとづいて、その葉はどの種のものであるかを知りたい

# 観測値どうしのタテわるヨコといった割算値はダメ!




- 葉のサイズが変わると、タテヨコ比も変わるから
- さきほど得た推定結果、曲がる中央値

# ある「面積」の葉が与えられたときに……と考える



- ある双曲線は同じ「面積(単位長さ)」の葉をあらわす
- タテ×ヨコ = 面積, つまり  $y = \text{面積}/x$



# ある単位長さにおけるタテヨコ比 $c$ で種を判別



- この曲線上にさまざまなタテヨコ比の葉があると考える
- ただし観測値を割算するわけではない!

# 種ごとの強度 $v$ という概念を導入する

単位長さが  $\sqrt{2}$  のときの  
強度  $v$  の分布




- データから種ごとの  $v$  の分布を推定する
- 3種の  $v$  の相対値で識別の確率を評価する

## 葉のタテヨコモデルを BUGS code で (追加部分周辺)


```
spc[i] ~ dcat(q[i,]) # 計算させながら変化させる種
Spc[i] ~ dcat(q[i,]) # データ（正解）へのあてはめ
q[i, 1] <- v[i, 1] * w[1] / total.v[i]
q[i, 2] <- v[i, 2] * w[2] / total.v[i]
q[i, 3] <- v[i, 3] / total.v[i]
total.v[i] <- v[i, 1] * w[1] + v[i, 2] * w[2] + v[i,
for (s in 1:N.spc) {
  v[i, s] <- exp(
    -pow(log.rxy[i] - mean.log.rxy[i, s], 2) * tau[s]
  ) / sigma[s]
}
```

# また WinBUGS → 傾き $\beta_2$ などの事後分布



- 単位長さが増大すると細長くなるか、幅が広くなるのか？
- 先にやったカタチのあてはめモデルとほぼ同じ結果



# 推定結果: 種を識別する領域



# 葉が小さい（単位長さが短い）ときの種の識別

単位長さが  $\sqrt{0.5}$  のときの



強度  $v$  の分布



- ??ガバ・雑種 の識別が難しい


# 葉が大きい（単位長さが長い）ときの種の識別

単位長さが  $\sqrt{2}$  のときの  
強度  $v$  の分布



- 大きな葉では、3種の識別は比較的容易

# データがないところは除外してみる



- $v$  が小さいところでは識別する能力が低くなるような図示

このあたりで終了