

8章 モデル比較

8.1 イントロ

この章ではベイズ統計からみたモデル比較について述べる。パラメータに関して2つの仮説を比較するという枠組みの中で、ベイズ因子の概念を紹介する。

母集団の平均の仮説検定を行うという状況で、片側・両側検定におけるベイズ因子の計算について解説する。その後、2つのベイズモデルで事前密度とサンプル密度を選べるという状況において、2つのベイズモデルを比較するという一般化を行う。このケースではベイズ因子は2つのモデルの**周辺(限界?)密度(marginal densities)**の比率である。ベイズ因子の計算を2つの例を使って行う。野球の打撃のデータ解析では、“安定モデル”と季節によって打率に波のある“波有り”モデルとを比較したい。2番目の例では2x2分割表の独立性に対するベイズ因子の計算を行う。

8.2 仮説の比較

ベイズ手法の尺度を紹介のために、 Y をサンプルの分布である $f(y|\theta)$ から観察し、以下の仮説を検定したいとする：

$$H_0: \theta \in \Theta_0, H_1: \theta \in \Theta_1$$

ここで Θ_0 と Θ_1 はパラメータ空間内に仕切り(partition)を作る。もしも、きちんとした事前密度(proper prior density) $g(\theta)$ を割り当てるなら、2つの仮説を事前オッズ比(prior odds ratio)によって事前条件(a priori)とする。

$$\frac{\pi_0}{\pi_1} = \frac{P(\theta \in \Theta_0)}{P(\theta \in \Theta_1)} = \frac{\int_{\Theta_0} g(\theta) d\theta}{\int_{\Theta_1} g(\theta) d\theta}$$

P164

データ $Y=y$ が観察された後で、パラメータの信頼は事後確率(posterior density)によって更新される。

$$g(\theta|y) \propto L(\theta)g(\theta)$$

ここで $L(\theta)$ は尤度関数である。2つの仮説に関する信頼は、事後オッズ比(posterior odds ratio)で要約される：

$$\frac{p_0}{p_1} = \frac{P(\theta \in \Theta_0|y)}{P(\theta \in \Theta_1|y)} = \frac{\int_{\Theta_0} g(\theta|y) d\theta}{\int_{\Theta_1} g(\theta|y) d\theta}$$

ベイズの因子は仮説の事後オッズ比と事前オッズ比との比率である。

$$BF = \frac{\text{posterior odds}}{\text{prior odds}} = \frac{p_0/p_1}{\pi_0/\pi_1}$$

統計量 BF は仮説 H_0 をサポートするデータによって与えられた証拠の計量である。仮説 H_0 の事後確率(posterior probability)は、ベイズ因子と仮説の事前確率の関数として表現される：

$$P_0 = \frac{\pi_0 BF}{\pi_0 BF + 1 - \pi_0}$$

8.3 通常平均の片側検定

Berry(1996)の14章の例のなかで、著者は異なる体重計で測ったときの本当の体重に興味がある。我々は、その計測は平均が μ 、標準偏差が δ で正規分布していると仮定する。著者は10回体重を測り、以下を得た：182, 172, 173, 176, 176, 180, 173, 174, 179, 175 (ポンド)。単純化のために、彼は体重計の精度を知っていて、 $\delta = 3$ ポンドであると

する。もし平均 μ が彼の本当の体重であり、彼の体重が175ポンドよりも重いことを評価しようとしているならば、やりたい仮説の検定は以下：

$$H_0: \mu \leq 175, \quad H_1: \mu > 175$$

著者には自分の体重に対する事前情報はないとすると、彼は μ に平均170で標準偏差5の正規事前分布(normal prior)を与える。

$$\mu \text{ distributed } N(170, 5)$$

帰無仮説 H_0 の**事前オッズ(prior odds)**は以下で与えられる：

$$\frac{\pi_0}{\pi_1} = \frac{P(\mu \leq 175)}{P(\mu > 175)}$$

我々は密度 $N(170, 5)$ からの事前オッズを `pnorm` 関数で計算する。以下のアウトプットで、`pmean` と `pvar` はそれぞれ事前平均(prior mean)と μ の事前分散(prior variance)である。

```
library(LearnBayes)
pmean <- 170; pvar <- 25
probH <- pnorm(175, pmean, sqrt(pvar))
probA <- 1 - probH
prior.odds <- probH / probA
prior.odds
[1] 5.302974: 事前オッズ
```

つまり、帰無仮説は対立仮説より 5 倍確からしいことになる。

10 の体重データを R に入力し、サンプル平均 \bar{y} と関連する標本分散(sample variance)である $\sigma^2 = \sigma^2/n$ を計算する。

```
weights <- c(182, 172, 173, 176, 176, 180,
             173, 174, 179, 175)
ybar <- mean(weights)
sigma2 <- 3^2 / length(weights)
```

良く知っている [normal density/normal prior](#) の更新公式を用いて、 μ の事後精度(posterior precision) (varianceの逆数) はデータとpriorの精度の合計である。

```
post.precision <- 1/sigma2 + 1/pvar
post.var <- 1/post.precision
```

平均 μ の事後平均はウエイトをそれぞれの精度で重みづけしたサンプル平均と事前平均の合計である。

```
post.mean <- (ybar / sigma2 + pmean /
             pvar) / post.precision
c(post.mean, sqrt(post.var))
```

```
[1] 175.7915058 0.9320547
```

μ の事後 (分布) 密度は $N(175.79, 0.93)$ である。この正規事後密度?(normal posterior density)を

用いて、帰無仮説のオッズを計算する。

```
post.odds <- pnorm(175, post.mean,
                  sqrt(post.var))/(1 - pnorm(175,
                  post.mean, sqrt(post.var)))
post.odds
```

```
[1] 0.2467017: 帰無仮説のオッズ
```

よって帰無仮説を支持するベイズ因子(Bayes factor)は

```
BF = post.odds / prior.odds
BF
```

```
[1] 0.04652139: ベイズ因子
```

事前確率(prior probabilities)とベイズ因子 BF から、帰無仮説の事後確率(posterior probability)を計算する：

P166

```
postH = probH * BF / (probH * BF + probA)
postH
```

```
[1] 0.1978835: 帰無仮説の事後確率
```

この計算から、著者は彼の体重が最大で 175 ポンドであるとは考えられないと結論する。

このベイズによる手法と頻度主義の p 値の間には興味深い関係がある。既知の標準偏差 δ とともに、伝統的な帰無仮説の検定は検定統計量

$$z = \frac{\sqrt{n}(\bar{y} - 175)}{3}$$

にもとづく。

p 値は、標準正規変量(standard normal variate)が Z を超える確率である。R のアウトプットでは、p 値を `pnorm` 関数で計算する。

```
z = sqrt(length(weights)) *
    (mean(weights) - 175)/3
1 - pnorm(z)
```

```
[1] 0.1459203
```

仮に平均 170、標準偏差 100 のとても平らである事前分布 (flat prior) を使ったベイズ解析を繰

コメント [LE1]: 帰無仮説 $H_0: \mu \leq 175$ が起こりえる事後確率が 19% と低い、ということか?

り返したとする。LearnBayes パッケージの関数 `mnormt.onesided` は、(1) テストされるべき平均値、標準事前分布の平均と標準偏差のパラメータ、(3) サンプルデータの値 (サンプル平均、サンプルサイズ、既知のサンプルの標準偏差) をインプットして計算を実行する。

```
library(LearnBayes)
weights = c(182, 172, 173, 176, 176, 180,
173, 174, 179, 175)
data = c(mean(weights), length(weights),
3)
prior.par = c(170, 1000)
mnormt.onesided(175, prior.par, data)
```

```
$BF : ベイズ因子
[1] 0.1694947
$prior.odds : 事前オッズ
[1] 1.008011
$post.odds : 帰無仮説のオッズ
[1] 0.1708525
$postH : 帰無仮説の事後確率
[1] 0.1459215
```

帰無仮説の確率はだいたい p 値と同じであることに留意せよ。これは、粗い事前分布情報がパラメータに与えられた時のベイズ確率は、片側検定の p 値と同じであることを示している。

8.4 Normal meanの両側検定

標準偏差がわかっている正規分布の平均値が、ある値と同じである、という仮説の両側検定を考える。前例につづいて、Berry さんは去年の体重が 170 ポンドであったことを知っているとして、今年も 170 ポンドかどうかを心配しているとする。すると、帰無仮説 H_0 としては、現在の彼の本当の体重 μ は 170 であるとする。対立仮説 H_1 は、彼の体重は 170 よりも重いかまたは軽いとする。

事前分布の作成はユニークである、なぜなら帰無仮説では本当の体重 μ 値には点の塊 (a point mass) が存在するからである。この例では、彼の体重は去年から変化していないという可能性があるとして著者は信じているから、彼は $\mu=170$ であると宣言し、

その確率を 0.5 とする。

次に、仮に帰無仮説 H_0 は正しくないとする、著者は本当の体重 μ に信憑性のある値を与えなければならない。もしも彼の体重は去年から変化したとしても、今年の体重は 170 からは大きくかけ離れていないと考えるだろう。そこで平均 170 で標準偏差が τ (tau) の正規分布が μ の対立値 (alternative values) のための適したモデル (suitable model) となるだろう。

一般的に我々は、標準偏差が δ だとわかっている時には、帰無仮説 $H_0 : \mu = \mu_0$ を対立仮説 $H_1 : \mu \neq \mu_0$ に対して検定する。平均が μ_0 で標準偏差が τ である標準事前分布 (normal prior distribution) は、対立仮説 H_1 の下での意見を代表するために使われる。

この状況では、仮説 H をサポートするベイズ因子は以下のとおり与えられる

$$BF = \frac{\frac{n^{\frac{1}{2}}}{\sigma} \exp\left\{-\frac{n}{2\sigma^2}(\bar{y} - \mu_0)^2\right\}}{\left(\frac{\sigma^2}{n} + \tau^2\right)^{-1/2} \exp\left\{-\frac{1}{2\left(\frac{\sigma^2}{n} + \tau^2\right)}(\bar{y} - \mu_0)^2\right\}}$$

(τ :標準偏差; μ :体重)

前と同様に、もしも π_0 が $\mu = \mu_0$ である帰無仮説 H_0 の事前確率 (prior probability) ならば、 H_0 の事後確率は以下である:

$$\rho_0 = \frac{\pi_0 BF}{\pi_0 BF + 1 - \pi_0}$$

ベイズ因子 BF を計算するために、対立仮説 $H_1 : \mu \neq \mu_0$ のもとでの正規密度 (normal density) の標準偏差 τ をインプットしなければならない。もしも著者の体重は去年から変化したのならば、その変化はどのくらい大きければ変化したとみなしてよいのだろうか。標準偏差 τ を得る方法の一つは対立値 μ のレンジを考えることであり、そうすればこの正規分布の 95%レンジ 4τ として標準偏差が解決する。イメージとしては、著者は彼の現在の体重は 170 ポンドよりも 5 ポンド程度多いか少ないと考

えている。対立仮説の体重 μ のレンジは 175–165 = 10 で、 $4\tau = 10$ とすると $\tau = 2.5$ となる。

LearnBayse の関数 `mnormt.twosided` は、ベイズ因子と帰無仮説の事後確率 (posterior probability of the null hypothesis) を計算する。関数 `mnormt.twosided` に代入するのは、テストされる平均 μ_0 、帰無仮説 H_0 の事前確率 π_0 、事前標準偏差 τ (prior standard deviation τ)、データの値 (サンプル平均、サンプルサイズ、既知のサンプルの標準偏差) である。

P168

事前標準偏差 τ を見積もるのは困難なため、関数 `mnormt.twosided` はユーザーがそれらしいベクトル値を入力することを認めている。

以下に R コードを示す (τ には 0.5, 1, 2, 4 を入れた)。

```
weights=c(182, 172, 173, 176, 176, 180,
173, 174, 179, 175)
data = c(mean(weights), length(weights),
3)
t = c(0.5, 1, 2, 4, 8)
mnormt.twosided(170, 0.5, t, data)
$bf
[1] 1.462146e-02 3.897038e-05 1.894326e-07
2.591162e-08 2.309739e-08
$post
[1] 1.441076e-02 3.896887e-05 1.894325e-07
2.591162e-08 2.309739e-08
```

事前標準偏差 τ のそれぞれの値 (0.5, 1, 2, 4) ついて、`mnormt.twosided` は、仮説 H は正しいとする事後確率と μ の値をとる、という仮説を支持して、ベイズ因子をそれぞれの τ に対して返している。もしも著者が彼の体重 μ に対立する値を反映するために正規密度 (170, 2) を用いれば、仮説 $\mu = 170$ を支持するベイズ因子は 0.0000002 となる。この、彼の体重は変化していないとする事後確率 (posterior probability) は 0.0000002 であり、これは著者の事前確率 0.5 よりもずっと低い。よって彼

の現在の体重は 170 と同じではないと結論すべきである。

8.5 2つのモデルの比較

仮説を比較するベイズアプローチは、2つのモデルを比較することに一般化できる。まず、 y はデータのベクトルを意味するとする、そして θ はパラメータだとする。するとベイジアンモデルはサンプル密度 $f(y|\theta)$ と事前密度 (prior density) $g(\theta)$ の詳細を含む。このモデルが与えられるとすれば、データの限界 (marginal) または事前 (prior) 予測密度:

$$m(y) = \int f(y|\theta)g(\theta)d\theta$$

を計算することができる。

我々は2つのベイジアンモデルを比較したいと仮定する:

$M_0: y \sim f_1(y|\theta_0), \theta_0 \sim g_1(\theta_0), M_1: y \sim f_2(y|\theta_1), \theta_1 \sim g_2(\theta_1)$

ここではパラメータ θ の定義はモデル間で異なってもよい。そこでモデル M_0 を支持するベイズ因子は2つのモデルデータの marginal density (限界密度) (または事前予測密度) の比率である。

$$BF = \frac{m_0(y)}{m_1(y)}$$

P169

もしも π_0 と π_1 がモデル M_0 と M_1 の事前確率を表すなら、モデル M_0 の事後確率は以下である:

$$P(M_0|y) = \frac{\pi_0 BF}{\pi_0 BF + \pi_1}$$

marginal density (限界密度) を要約する単純な方法は5章3節のLaplaceの方法である。 $\hat{\theta}$ は事後モデルを表し、 $H(\hat{\theta})$ は対数事後密度 (log posterior density) の Hessian (second derivative matrix) であるとする。すると事前予測密度 (prior predictive density) は以下で要約される:

$$m(y) \approx (2\pi)^{d/2} g(\hat{\theta}) f(y|\hat{\theta}) | -H(\hat{\theta}) |^{1/2}$$

ここで d はパラメータの数である。対数スケールでは

$$\log m(y) \approx \left(\frac{d}{2}\right) \log(2\pi) + \log(g(\hat{\theta})f(y|\hat{\theta})) + (1/2)\log| - H(\hat{\theta})|$$

いちどR関数によって積 $f(y|\theta)g(\theta)$ の対数が計算できれば、関数 **laplace** が適用でき、アウトプットの一部である **int** が $\log m(y)$ を与える。この方法を複数のモデルに用いれば、 $m(y)$ の値をベイズ因子の計算に使うことができる。

8.6 サッカーゴールのモデル

ベイズ因子の計算関数 **laplace** の使用を説明するため、サッカーの平均ゴール数に興味があるとする。n回の試合のゴール数は y_1, \dots, y_n とする。ゴールは比較的まれな出来事なので、**試合のゴール数 y_i は平均 λ の Poisson 分布型の分布** をするということがもっともらしいと考える。 λ に関する以下4つの主観的な**事前情報 (priors)** を考える：

事前情報 1. 結合 γ 事前情報 (conjugate gamma prior) を式の λ にあてる

$$g(\lambda) \propto \lambda^{\alpha-1} \exp\{-\beta\lambda\}, \lambda > 0,$$

$$\alpha = 4.57 \text{ かつ } \beta = 1.43$$

この事前情報は、チームの平均ゴール数は3で λ の4分位点は2.10と4.04だとあなたが信じていることを表している。

事前情報 2. シンメトリック分布に関する事前意見 (prior opinion) を述べることは便利なことである。そこで $\log \lambda$ は平均1で標準偏差0.5の正規分布だと仮定する。 $\log \lambda$ の事前四分位点は0.66と1.34となり、つまり λ の事前四分位点は1.94と3.81である。事前情報1とこの事前情報は平均率 λ の位置についての類似の考えを反映している。

PI 70

事前情報 3. この事前情報は $\log \lambda$ が **N(2, 0.5)** と仮定する。率 λ (prior quartiles for the rate λ) の事前四分位は5.27と10.35である。この事前情報は、チームのゴール数がとても多いと考えていることになる。

事前情報 4. この事前情報は $\log \lambda$ を **N(1, 2)** と仮定し、付随する rate λ の四分位点は1.92と28.5とする。これはサッカーのゴールについての知識が乏しいことを反映したものである。

2006年のシーズンで、あるチームについてゴール数を記録した。データは **soccergoals** に記録されている。 λ の尤度は、ポアソンモデルを仮定すると以下となる：

$$L(\lambda) = \frac{\exp(-n\lambda)\lambda^s}{\prod_{i=1}^n y_i!},$$

ここで $s = \sum_{i=1}^n y_i$ である。我々のデータセットでは、 $n = 35, s = 57$ である。図8.1が $\log \lambda$ スケールの尤度と4つの事前情報を示す。事前情報1と2はかなり類似している。事前情報3は尤度とは対立しており、4は非常に平坦な形をしている。

laplace 関数を使うために、我々は対数事後分布 (log posterior) を定義するための短い関数を記載しなければならない。はじめの関数 **logpoissgamma** はポアソンサンプリングとガンマ事前分布 (a gamma prior) を用いた対数事後分布 (log posterior) を計算する。その後はいつものとおり、 λ を変換して実際の値のパラメータ $\theta = \log \lambda$ とする。関数の議論は **theta** と **datapar** であり、ベクトル **data** とガンマ事前分布 (gamma prior) である **par** である。Rの関数である **dgamma** を尤度と事前分布の両方の計算に使う。

```
logpoissgamma <- function(theta,
datapar)
{
y <- datapar$data
npar <- datapar$par
lambda <- exp(theta)
loglike <- log(dgamma(lambda, shape =
sum(y)+1, rate = length(y)))
logprior <- log(dgamma(lambda, shape =
npar[1], rate = npar[2]) * lambda)
return(loglike + logprior)
}
```

同様に、関数 `logpoissnormal` を、ポアソンサンプリング?と正規事前分布(normal prior)?のための $\log \lambda$ の対数事後分布を計算するために記述する。(意味解読できず翻訳失敗)。関数は R の `dgamma` と `dnorm` を用いる。

```
logpoissnormal = function(theta,
  datapar)
{
  y <- datapar$data
  npar <- datapar$par
  lambda <- exp(theta)
  loglike <- log(dgamma(lambda, shape =
  sum(y)+1, scale = 1/length(y)))
  logprior <- log(dnorm(theta, mean =
  npar[1], sd = npar[2]))
  return(loglike + logprior)
}
```

P171

我々ははじめにデータファイル `soccergoals` をロードする。`soccergoals` の中身には変数 `goals` があり、`attach` コマンドによって使えるようになる。4つの事前分布の1つずつのうち、我々は関数 `laplace` を用いて事後分布を要約する。もしも関数のアウトプットが `fit` であれば、`fit$mode` は事後のモード (posterior mode)、`fit$var` は事後分散 (posterior variance) と関連する推定であり、`fit$int` は $m(y)$ の推定である。

<= Fig8.1

```
data(soccergoals)
attach(soccergoals)
datapar <- list(data = goals, par=c(4.57,
  1.43))
fit1 <- laplace(logpoissgamma, 0.5, 10,
  datapar)
datapar <- list(data = goals, par = c(1,
  0.5))
fit2 <- laplace(logpoissnormal, 0.5, 10,
  datapar)
datapar <- list(data = goals, par=c(2,
  0.5))
fit3 <- laplace(logpoissnormal, 0.5, 10,
```

```
datapar)
datapar <- list(data = goals, par=c(1,
  2))
fit4 <- laplace(logpoissnormal, 0.5, 10,
  datapar)
```

P172

我々は4つの事前情報に対する4つのモデルについて、事後モード、事後標準偏差、`log marginal densities` (対数限界密度?) を表示する。

```
postmode <- c(fit1$mode, fit2$mode,
  fit3$mode, fit4$mode)
postsd <- sqrt(c(fit1$var, fit2$var,
  fit3$var, fit4$var))
logmarg <- c(fit1$int, fit2$int,
  fit3$int, fit4$int)
cbind(postmode, postsd, logmarg)
  postmode  postsd  logmarg
[1,] 0.5247821 0.1274428 -1.502965
[2,] 0.5207796 0.1260714 -1.255170
[3,] 0.5825327 0.1224715 -5.076322
[4,] 0.4899378 0.1320168 -2.137214
```

$\log m(y)$ の値の利用によりベイズ因子を比較することで違うモデルを比較することができる。もし我々が事前 γ (4.57, 0.7) を λ に用いるか、正規分布 (1, 0.5) を $\log \lambda$ に用いるのは問題になるか? この回答には、我々はベイズ因子を計算して、Prior2 を Prior1 よりサポートすることができる。

$$BF_{21} = \frac{m_2(y)}{m_1(y)} = \exp(-1.255170 + 1.502965) = 1.28$$

正規事前情報(normal prior)へのサポートはわずかである — これは図 8.1 から納得できる。なぜなら Prior2 はわずかに尤度関数に近い。Prior2 と Prior3 を比較すると、ベイズ因子は Prior2 を支持して

$$BF_{23} = \frac{m_2(y)}{m_3(y)} = \exp(-1.255170 + 5.076322) = 45.6$$

これは Prior2 を大きく支持することを意味する。実際、尤度と Prior3 の位置は互いに離れていて、データと prior と $m_3(y)$ の小さな値の対立を意味している。Prior2 と Prior4 を比較すると、Prior2 を支持するベイズ因子は

$$BF_{24} = \frac{m_2(y)}{m_4(y)} = \exp(-1.255170 + 2.137214) = 2.42$$

概して事前情報の限界確率(marginal probability for a prior)は事前密度(prior density)がより散乱するに伴って減少する。

8.7 野球の打者は打撃に波があるか？

P173

スポーツでは選手やチームの波のある活躍を見る。野球の打者の成功は、平均打率やヒットの率である。シーズン中に選手の調子が上がっている次期では打率が非常に上がり、調子が悪い時期は打率が下がるものだ。選手の調子の波はさまざまである。ここでの疑問はこの波のあるデータは、選手の能力の違いを伝えるのかどうかである。

野球では選手はシーズンごとに打席に立つチャンスがあり、これを我々は打席数 (at-bats) と呼ぶ。打数は、ヒットかアウトに分けられる。あるシーズンの打数を N 個の期間に分割するとする。 $i = 1, \dots, N$ であるとき、 i 番目の期間にヒットを打つ確率 (打率) を p_i とする。

もしも選手が本当に一貫したプレーをするならば、打率は期間を通して一定である。本書ではこれを nonstreaky model (“波無しモデル”) M_0 と呼ぶ

$$M_0: p_1 = \dots = p_N = p.$$

モデルを完結するためには、共通の確率(common probability) p に統一の事前確率 (uniform prior) $(0, 1)$ を与える。

一方でもしも選手の打率に本当に波があれば、ヒットの確率 p_i はシーズン中に変化する。この打率の変化をモデル化する簡単な方法は、 p_1, \dots, p_N はベ

ータ密度からランダムサンプルしたと仮定することである：

$$g(p) = \frac{1}{B(K\eta, K(1-\eta))} p^{K\eta-1} (1-p)^{K(1-\eta)-1}, 0 < p < 1.$$

密度 g では、 η (eta) は平均で K は精密パラメータ (precision parameter) である。我々はこの”波有りモデル”をパラメータ K によってインデックス化できる：

$$M_K: p_1, \dots, p_N \text{ iid beta } (K\eta, K(1-\eta)).$$

個のモデルでは統一事前確率(uniform prior)を平均パラメータ η (mean parameter η) の上に置き、ランダム効果の分布(random effects distribution) の位置 (location) についての知識がほとんどないということを反映している。正確パラメータ K が無限大に近づくために、”波有りモデル” M_K は”波無しモデル” M_0 に近づくことを注記しておく。

モデル M_0 と M_K を比較するためには、関連する marginal densities 周辺密度? を計算する必要がある。モデル M_0 ではヒットの数 y_1, \dots, y_N は独立して y_i は二項分布 (n_i, p) である。 p は一様分布 $(0, 1)$ とすると、周辺密度は以下である：

$$m_0(y) = \int \prod_{i=1}^N \binom{n_i}{y_i} p^{y_i} (1-p)^{n_i-y_i} dp = \prod_{i=1}^N \binom{n_i}{y_i} B\left(\sum_{i=1}^N y_i + 1, \sum_{i=1}^N (n_i - y_i) + 1\right).$$

もう一つの”波有りモデル”のもとでは、周辺密度は P174

以下で与えられる：

$$\begin{aligned}
& m_K(y) \\
&= \int \prod_{i=1}^N \binom{n_i}{y_i} p_i^{y_i} (1-p)^{n_i-y_i} \frac{p_i^{K\eta-1} (1-p_i)^{K(1-\eta)-1}}{B(K\eta, K(1-\eta))} dp_1 \dots dp_N \\
&= \prod_{i=1}^N \binom{n_i}{y_i} \int_0^1 \frac{\prod_{i=1}^N B(y_i + K\eta, n_i - y_i + K(1-\eta))}{B(K\eta, K(1-\eta))^N} d\eta
\end{aligned}$$

“波有りモデル” H_K をサポートして“波無しモデル” H_0 と比較するベイズ因子は以下で与えられる：

$$B_K = \frac{m_K(y)}{m_0(y)} = \frac{1}{B(\sum y_i + 1, \sum (n_i - y_i) + 1)} \int_0^1 \frac{\prod_{i=1}^N B(y_i + K\eta, n_i - y_i + K(1-\eta))}{B(K\eta, K(1-\eta))^N} d\eta$$

我々は関数 **laplace** をベイズ因子 B_K の積分計算に用いる。はじめに積分の中の変数 η を変換して真に価値のある変数 $\theta = \log(\eta / (1-\eta))$ にする。R関数 **lbeta** はベータ関数の対数を計算するのでこれを用いて **bfexch** を定義し、積分の対数を計算する。この関数へは **theta** と **data** と **K** コンポーネントを持つリスト **datapar** (列 **y** と **n** のマトリクス) を代入する。

```

bfexch = function(theta, datapar) {
  y = datapar$data[,1]; n = datapar$data[,2]; K = datapar$K
  eta = exp(theta)/(1+exp(theta))
  N = length(y)
  z = 0*theta;
  for (i in 1:N)
    z = z+lbeta(K * eta + y[i], K*(1-eta) + n[i] - y[i])
  z = z-N*lbeta(K*eta, K*(1-eta)) + log(eta * (1-eta))
  z = z - lbeta(sum(y) + 1, sum(n-y)+1)
  return(z)
}

```

とある値、たとえば K_0 、におけるベイズ因子 B_K を計算するには、我々は代入関数 **bfexch** とともに関数 **laplace** を用いる。スタートとして $\eta=0$ から始めて Newton 法を 10 回繰り返し、値 K_0 を用いて **datapar** をリストする。

```

s = laplace(bfexch, 0, 10, list(data = data, K = K0))

```

コメント [LE2]: なぜか関数が機能しない!

リスト **s** は **laplace** 関数のアウトプットである。要素 **s\$int** はベイズ因子の対数值、 $\log B_K$ 、を推定した値である。

P175

この方法を描写するために我々はヤンキースの Derek Jeter の 2004 年の打撃データを使用する。彼は 2004 年の前半にスランプに陥った。

ジータが出場した 155 試合のデータを集計した。よって $N=155$ とする。打者は 1 ゲームで 4-5 回しか打席に立たないため、波を検出するのは困難である。そこで我々はデータを 5 ゲームごとにまとめた。オリジナルのデータは **jeter2004** にまとめている。以下の R コードでは打撃データを読み込みそれから **regroup** 関数を用いて 5 ゲームごとにまとめたデータを作成した。

```

data(jeter2004)
attach(jeter2004)
data = cbind(H, AB)
data1 = regroup(data, 5)

```

マトリクス **data1** はグループ化した打席データ (y_i, n_i), $i = 1, \dots, 31$, ここで i 番目の期間の中での打席数 n_i 回のうちジータが売ったヒットの数が y_i である (表 8.1)。

我々は $\log K$ の値の数列のために、**laplace** 関数と **bfexch** で定義された \log 積分の定義を用いてベイズ因子を計算する。この例ではベクトル $\log K$ は値 $\log(K) = 2, 3, 4, 5, 6$ を持ち、ベクトル $\log BF$ はベイズ因子 $\log B_K$ の値を持つ。マトリクスは $\log K, K, \log B_K$ の値をとる。

```

logK = seq(2,6)
logBF = 0*logK
for (j in 1: length(logK)){
  s = laplace(bfexch, 0, 10, list(data = data1, K = exp(logK[j])))
}

```

```
logBF[j] = s$int
}
cbind(logK,      exp(logK),      logBF,
exp(logBF))
```

```
      logK      logBF
[1,]  2  7.389056 -2.9441184 0.05264845
[2,]  3 20.085537  1.0482050 2.85252615
[3,]  4 54.598150  1.4380139 4.21232144
[4,]  5 148.413159 0.8160940 2.26164853
[5,]  6 403.428793 0.3538978 1.42460960
>
```

p176

アウトプットから見えるのは $\log K = 4$ の値は関係するベイズ因子である $B_K = 4.21$ というデータによって最も支持されているということである。この特に波ありモデルは”波無しモデル”よりも 4 倍もっともらしい。このことはジータは打撃に波があることを示している。

8.8 2 x 2 分割表の独立性の検定

統計学の基本的な問題は、二つのカテゴリカルな計測同士の関係を探ることである。これを描写するために Moore(1995)にある、ノースカロライナ州立大学が実施した化学工学専攻の生徒が履修したあるコースでの成績の例を考える。研究者は課外活動に費やした時間とコースの成績との関係に興味があった。データは 119 人の生徒から 2 つのカテゴリについて採取した。結果は分割表 8.2 のとおりである。

表 8. 2

学生の課外活動への参加と成績との関係を学ぶために、独立性の検定を行う。通常の非ベジアンアプローチでの独立性の検定では、Pearson の χ^2 乗統計量に基づいて行われる、これは観察されたカウントと期待されたカウントを独立モデルの下で比較して行うものである。R では、カウントのテーブルを読み込み、関数 `chisq.test` によって独立仮説をテストする：

P177

```
data = matrix(c(11, 9, 68, 23, 3, 5),
c(2,3))
```

```
data
      [,1] [,2] [,3]
[1,]   11   68   3
[2,]   9   23   5
```

```
chisq.test(data)
```

Pearson's Chi-squared test

```
data: data
X-squared = 6.9264, df = 2, p-value = 0.03133
```

```
Warning message:
In chisq.test(data) : Chi-squared approximation may be incorrect
```

ここでは p 値は約 0.03 であり、成績は課外活動に費やした時間に関係があるという証拠の一部となる。

ベイズの視点からは、2 つのモデルが可能である。モデル M_I は 2 つのカテゴリカル変数は独立しているといもので、モデル M_D は 2 つの変数はある意味で依存しているというものである。ベイズモデルを描写するために、これらのデータはターゲットの母集団からのランダムサンプルを表していると仮定し、テーブルにあるカウント数は比率値が表 8.3 にしめたような多項分布であるとする。依存モデル M_D のもとでは、比率値 p_{11}, \dots, p_{23} は合計が 1 になるあらゆる値をとることができ、我々は事前密度 (prior density) は空間上に一様に分布すると仮定する。

独立モデル M_I のもとでは、表内の比率は表 8.4 にしめすような周辺分布 $\{p_{1+}, p_{2+}\}$ と $\{p_{+1}, p_{+2}\}$ によって決定される。ここでは未知のパラメータは学生が異なった課外活動レベルを持っている比率と異なった成績を取っている比率である。我々は、知っているこの 2 セットの比率 $\{p_{i+}\}$ $\{p_{+j}\}$ は独立であると仮定し、それぞれのセットに一様な密度 (a uniform density over all possible values) を与える。

我々は 2 つのモデルを定義した：依存モデル M_D は多項比率 (multinomial proportions) が一様に分布しており、独立モデル M_I は多項比率は独立な構

成であり周辺比率(marginal proportions)は振り分けられた独立な一様事前分布? (uniform priors)に等しい。

P178

依存モデルよりも独立モデルを支持するベイズ因子は、以下のように見えるだろう：

$$BF = \frac{D(y+1)D(1_R)D(1_C)}{D(1_{RC})D(y_R+1)D(y_C+1)}$$

yは数のマトリクス、yRは行トータルのベクトル、yCは列トータルのベクトル、1Rは長さRのベクトル、D(v)は以下で定義されるDirichlet関数である：

$$D(v) = \prod \Gamma(v_i) / \Gamma(\sum v_i)$$

R関数c**table**はこの2 x 2分割表のベイズ因子を計算する。ユーザーは確率のマトリクスのために事前パラメータのマトリクスであるaをインプットする。マトリクスaを手に入れることによって、依存モデルのもとでは一様事前情報(a uniform prior)を{p_{ij}}に与え、一様事前情報(uniform priors)を{p₊₊}と{p_{·j}}に与える。この問題のアウトプットはベイズ因子の値である。ここではBF値は1.66であり、これは独立に反対するには控えめな支持である。

a = matrix(rep(1,6), c(2,3))

a

```
      [,1] [,2] [,3]
[1,]    1    1    1
[2,]    1    1    1
```

> ctable(data, a)

```
[1] 1.662173
```

我々は分割表における”uniform”と”independence”モデルを比較している。この方法への批判としては、我々は本来は”uniform”な代替モデルには興味はないかもしれないことである。[おそらく我々は独立性”independence”と、セルの確率が“独立に近い\(close to independence\)”モデル](#)

[ルとを比較したいのだろう。](#)そのようなモデルはAlbert and Gupta(1981)によって提唱された。分割表の確率{p_{ij}}は[a conjugate Dirichlet distribution](#)(共役デリヒレット分布)

$$g(p) \propto \prod p_{ij}^{K\eta_{ij}-1}$$

であると仮定する。ただし事前平均(prior means){η_{ij}}は独立配置

$$\eta_{ij} = \eta_i^A \eta_j^B$$

を満たす。

P179

[prior means](#)の構成は表 8.5 の例にあるとおりである。[margins {η_i^A}と {η_j^B}のprior meansのベクトル](#)は一様分布が割り当てられる。

このモデルはM_Kとラベルされる、というのは[Dirichlet precision parameter](#)(デリヒレット精度パラメータ?)であるKによってインデックス化されるからである。Kは無限大に近づくため、モデルは独立仮説MIに近づく。そこでは[marginal probabilities](#)(限界確率?)は一様分布をする。

表 8.5: 独立に近いモデルの下でのテーブルのセル確率の事前平均 (prior means)。

独立モデル M_Iよりも“独立に近い”モデル M_Kをサポートするベイズ因子(Bayes factor)は以下で与えられる：

BF_K

$$= \frac{1}{D(y_R+1)D(y_C+1)} \int \frac{D(K\eta^A\eta^B+y)}{D(K\eta^A\eta^B)} d\eta^A d\eta^B$$

ここでKη^Aη^B+yは値{Kη_i^Aη_j^B+y_{ij}}のベクトルであり、その積分は・marginal prior meansであるη^A={η_i^A}とη^B={η_j^B}にとって代わられる。

素直なベイズ因子の計算方法は重要サンプリン

グ(importance sampling?)によるものである。ベイズ因子は以下の積分で表現できる:

$$BF_K = \int h(\theta) d\theta$$

ただし $\theta = (\eta^A, \eta^B)$ である。

積分は密度 $g(\theta)$ (ただし g は簡単にシミュレートできる) によって要約できると仮定すると、積分は以下と書ける:

$$BF_K = \int \frac{h(\theta)}{g(\theta)} g(\theta) d\theta$$

積分は以下として近似できる:

$$BF_K \approx \frac{\sum_{j=1}^m h(\theta_j) / g(\theta_j)}{m}$$

ただし $\theta_1, \dots, \theta_m$ は独立にシミュレートされた $g(\theta)$ からの draws (意味不明?) である。この importance sampler estimate? のシミュレーションの標準誤差は以下で与えられる:

P180

$$se = \text{standard deviation}(\{\frac{h(\theta_j)}{g(\theta_j)}\}) / \sqrt{m}$$

この例では、 K は無限大に近づくので、marginal prior means η^A と η^B のベクトルの事後分布 (posterior) は独立なものとして以下で示される:

$$\eta^A \text{ distributed Dirichlet}(y_R + 1), \eta^B \text{ distributed Dirichlet}(y_C + 1)$$

ここで、ベクトル η に関する Dirichlet 分布は $\prod \eta_i^{\alpha_i - 1}$ に比例する密度を持つ。この密度は importance sampler としては便利な選択である、といのも Dirichlet 分布からの draws をシミュレートするのが簡単だからである。

importance sampling のアルゴリズムを用いて、関数 bfindep はこの対立する "close to independence" モデルを用いてベイズ因子を計算する。データマトリクス y 、Dirichlet 精度パラメ

ータ K 、シミュレートしたサンプル m をインプットする。アウトプットは bf (ベイズ因子の値) と nse (計算された BF 値の標準偏差の推定値) の 2 つの要素からなるリストである。

以下の R のインプットでは、我々は logK 値の数列のベイズ因子を計算する。そのアウトプットは log ベイズ因子の値と、logK の値のベイズ因子を出す。図 8.2 は logK の関数としての対数ベイズ因子と 10,000 回シミュレーションの結果を示している

(R の SemiPar パッケージにある関数 spm を用いて推定エラーを取り除いた)。このベイズ因子の最大値は 2.3 で、独立モデルの近所にある対立モデルへのサポートを示唆している。

```
logK = seq(2, 7, by= 0.2)
logBF = 0*logK
for(j in 1:length(logK)) + {x =
bfindep(data, exp(logK[j]), 100000);
logBF[j] = log(x$bf)}
cbind(logK, logBF, exp(logBF))
```

	logK	logBF	
[1,]	2.0	-1.7393843	0.1756285
[2,]	2.2	-1.0494239	0.3501394
[3,]	2.4	-0.8431378	0.4303580
[4,]	2.6	-0.1796282	0.8355808
[5,]	2.8	-0.2013881	0.8175951
[6,]	3.0	0.2131446	1.2375636
[7,]	3.2	0.3621546	1.4364210
[8,]	3.4	0.7901360	2.2036961
[9,]	3.6	0.6935077	2.0007212
[10,]	3.8	0.7545760	2.1267096
[11,]	4.0	0.7593722	2.1369342
[12,]	4.2	0.8172366	2.2642341
[13,]	4.4	0.8019619	2.2299114
[14,]	4.6	0.7977221	2.2204772
[15,]	4.8	0.7688568	2.1572986
[16,]	5.0	0.7282715	2.0714969
[17,]	5.2	0.6791026	1.9721072
[18,]	5.4	0.6143356	1.8484281
[19,]	5.6	0.5609184	1.7522811
[20,]	5.8	0.4966223	1.6431618
[21,]	6.0	0.4359152	1.5463776
[22,]	6.2	0.3781691	1.4596098
[23,]	6.4	0.3257384	1.3850530
[24,]	6.6	0.2782086	1.3207617
[25,]	6.8	0.2351368	1.2650818
[26,]	7.0	0.1988317	1.2199766

8.9 書籍紹介