

# Uvod v Bayesovsko statistiko

Gregor Gorjanc

Univerza v Ljubljani, Biotehniška Fakulteta, Oddelek za zootehniko,  
Katedra za znanosti o rejah živali



Ljubljana (IBMI), 2013

# Okvirni vozni red

Uvod

Osnove verjetnosti

Verjetje

Bayesovski pristop



Metode MCMC




# 0. Uvod

- ▶ Zgodovina (Laplace in Bayes)
- ▶ Moje izkušnje (genetika)
- ▶ Poimenovanje?
  - ▶ Bayesova
  - ▶ Bayesovska
- ▶ Bayesian = “probabilistic modelling”

# Nekaj literature



# Literature je več kot dovolj

# 1. Osnove verjetnosti



# Verjetnost



- ▶ Mečemo kocko
- ▶ Dva pogleda na verjetnost:
  - ▶ verjetnost dogodka, da pade 6 pik:  $\Pr(6 \text{ pik}) = 1/6$
  - ▶ mečemo kocko in spremljamo frekvenco (= verjetnost) dogodkov
- ▶ Porazdelitev verjetnosti dogodkov,  $\sum_i \Pr(i \text{ pik}) = 1$ :

Št. pik	1	2	3	4	5	6
Verjetnost	$1/6$	$1/6$	$1/6$	$1/6$	$1/6$	$1/6$


# Skupna verjetnost (ang. joint prob.)



- ▶ Mečemo **dve** kocki
- ▶ Ali je št. pik na prvi kocki povezano s št. pik na drugi kocki? NE.  
→ Dogodka sta torej neodvisna.
- ▶ Verjetnost skupnega dogodka, da pade dvakrat 6 pik:  
 $\Pr(6 \text{ pik}, 6 \text{ pik}) = \Pr(6 \text{ pik}) \times \Pr(6 \text{ pik}) = 1/6 \times 1/6 = 1/36$
- ▶ Porazdelitev verjetnosti dogodkov,  $\sum_{i,j} \Pr(i \text{ pik}, j \text{ pik}) = 1$ :

Št. pik	1	2	3	4	5	6
1	1/36	1/36	1/36	1/36	1/36	1/36
2	1/36	1/36	1/36	1/36	1/36	1/36
3	1/36	1/36	1/36	1/36	1/36	1/36
4	1/36	1/36	1/36	1/36	1/36	1/36
5	1/36	1/36	1/36	1/36	1/36	1/36
6	1/36	1/36	1/36	1/36	1/36	1/36

# Robna verjetnost (ang. marginal prob.)



- ▶ Mečemo **dve** kocki
- ▶ Porazdelitev verjetnosti za število pik 1, 2, ..., 6:

Št. pik	1	2	3	4	5	6	Skupaj
1	1/36	1/36	1/36	1/36	1/36	1/36	1/6
2	1/36	1/36	1/36	1/36	1/36	1/36	1/6
3	1/36	1/36	1/36	1/36	1/36	1/36	1/6
4	1/36	1/36	1/36	1/36	1/36	1/36	1/6
5	1/36	1/36	1/36	1/36	1/36	1/36	1/6
6	1/36	1/36	1/36	1/36	1/36	1/36	1/6
Skupaj	1/6	1/6	1/6	1/6	1/6	1/6	1

$$\Pr(A) = \sum_B \Pr(A, B) \quad p(a) = \int p(a, b) db$$

## Skupna verjetnost II



- ▶ Mečemo **eno** kocko
- ▶ Ali je št. pik na kocki povezano z naravo števila (sodo ali liho)? DA.  
-> Dogodka sta torej odvisna.
- ▶ Verjetnost dogodka, da je število sodo in da pade 6 pik:

$$\Pr(6 \text{ pik, sodo št.}) = \Pr(6 \text{ pik} | \text{sodo št.}) \times \Pr(\text{sodo št.})$$

$$\Pr(6 \text{ pik, sodo št.}) = 1/6$$

$$\Pr(\text{sodo št.}) = 1/2$$

$$\Pr(6 \text{ pik} | \text{sodo št.}) = \frac{\Pr(6 \text{ pik, sodo št.})}{\Pr(\text{sodo št.})} = \frac{1/6}{1/2} = 1/3$$

- ▶  $\Pr(6 \text{ pik} | \text{sodo št.})$  -> Pogojna verjetnost (ang. conditional prob.)

# Pogojna verjetnost (ang. conditional prob.)



- ▶ Verjetnost dogodka, da pade 6 pik, če vemo, da je padlo sodo število:  $\Pr(6 \text{ pik} | \text{sodo število}) = 1/3$
- ▶ Porazdelitev verjetnosti dogodkov,  $\sum_i \Pr(i \text{ pik} | \text{liho število}) = 1$ :

Liho število						
Št. pik	1	2	3	4	5	6
Verjetnost	1/3	0	1/3	0	1/3	0

- ▶ Porazdelitev verjetnosti dogodkov,  $\sum_i \Pr(i \text{ pik} | \text{sodo število}) = 1$ :

Sodo število						
Št. pik	1	2	3	4	5	6
Verjetnost	0	1/3	0	1/3	0	1/3

# Bayesov teorem




$$\begin{aligned}\Pr(A, B) &= \Pr(A|B) \times \Pr(B) = \Pr(B|A) \times \Pr(A) \\ \Pr(A|B) &= \frac{\Pr(B|A) \times \Pr(A)}{\Pr(B)} \\ &= \frac{\Pr(B|A) \times \Pr(A)}{\sum_A \Pr(B|A) \times \Pr(A)} \\ \Pr(A|B) &\propto \Pr(B|A) \times \Pr(A)\end{aligned}$$

# Vaja

Frekvenca obolelih v populaciji znaša 0.008. Obstaja test za določitev obolelosti, ki je lažno pozitiven v 10 % in lažno negativen v 5 %.

- ▶ Koliko znaša verjetnost, da ima posameznik bolezen, če je rezultat testa zanj pozitiven?
- ▶ Kakšen je vpliv predhodne (apriorne) informacije?
- ▶ Koliko znaša verjetnost, da ima posameznik bolezen, če je rezultat ponovljenega testa zanj ponovno pozitiven?



# Vaja (rešitev)

Dogodki:

- ▶ status: zdrav, bolan
- ▶ test: negativen, pozitiven

Predhodna verjetnost obolelosti brez testa:

$$\Pr(bolan) = 0.008$$

Test:

Test	Status	
	Zdrav	Bolan
Negativen	$\Pr(negativen zdrav) = 0.90$	$\Pr(negativen bolan) = 0.05$
Pozitiven	$\Pr(pozitiven zdrav) = 0.10$	$\Pr(pozitiven bolan) = 0.95$
Skupaj	1	1

## Vaja (rešitev) II

- ▶ Koliko znaša verjetnost, da ima naključni posameznik bolezen, če je rezultat testa zanj pozitiven?


$$\Pr(bolan|pozitiven) = \frac{\Pr(pozitiven|bolan) \times \Pr(bolan)}{\Pr(pozitiven)}$$
$$= \frac{\Pr(pozitiven|bolan) \times \Pr(bolan)}{\Pr(pozitiven|bolan) \times \Pr(bolan) + \Pr(pozitiven|zdrav) \times \Pr(zdrav)}$$
$$= \frac{0.95 \times 0.008}{0.95 \times 0.008 + 0.1 \times 0.992} = \frac{0.0076}{0.1068} = 0.071$$

$$\Pr(zdrav|pozitiven) = \frac{\Pr(pozitiven|zdrav) \times \Pr(zdrav)}{\Pr(pozitiven)}$$
$$= \frac{\Pr(pozitiven|zdrav) \times \Pr(zdrav)}{\Pr(pozitiven|bolan) \times \Pr(bolan) + \Pr(pozitiven|zdrav) \times \Pr(zdrav)}$$
$$= \frac{0.10 \times 0.992}{0.95 \times 0.008 + 0.1 \times 0.992} = \frac{0.0992}{0.1068} = 0.929$$

$$\Pr(bolan|pozitiven) + \Pr(zdrav|pozitiven) = 0.071 + 0.929 = 1$$
$$\Pr(pozitiven) = 0.0076 + 0.0992 = 0.1068$$

## Vaja (rešitev) III

- ▶ Kakšen je vpliv predhodne (apriorne) informacije?



## Vaja (rešitev) IV

- ▶ Koliko znaša verjetnost, da ima naključni posameznik bolezen, če je rezultat ponovljenega testa zanj pozitiven?

$$\begin{aligned} \Pr(bolan|pozitiven) &= 0.071 \implies \Pr(bolan) \\ \Pr(bolan|2x\ pozitiven) &\implies \Pr(bolan|pozitiven) \\ \Pr(bolan|pozitiven) &= \frac{\Pr(pozitiven|bolan) \times \Pr(bolan)}{\Pr(pozitiven)} \\ &\quad \frac{\Pr(pozitiven|bolan) \times \Pr(bolan)}{\Pr(pozitiven|bolan) \times \Pr(bolan) + \Pr(pozitiven|zdrav) \times \Pr(zdrav)} \\ &= \frac{0.95 \times 0.071}{0.95 \times 0.071 + 0.1 \times 0.929} = \frac{0.06745}{0.16035} = 0.421 \end{aligned}$$

# Porazdelitve

Prikaz nekaj pogosto uporabljenih porazdelitev v statistiki in njihovih lastnosti

# Porazdelitve - diskrete

Porazdelitev	Zapis	$\Pr(x)$	$E(x)$	$Var(x)$
Bernoullijeva	$B(1, \theta)$	$\theta^x (1 - \theta)^{1-x}$	$\theta$	$\theta(1 - \theta)$
Binomska	$B(n, \theta)$	$\binom{n}{x} \theta^x (1 - \theta)^{n-x}$	$n\theta$	$n\theta(1 - \theta)$
Poissonova	$P(\lambda)$	$\frac{\lambda^x \exp(-\lambda)}{x!}$	$\lambda$	$\lambda$

Each row contains five columns: Porazdelitev (Distribution Name), Zapis (Notation), Pr(x) (Probability Mass Function), E(x) (Expected Value), and Var(x) (Variance). Below each column is a histogram representing the distribution's shape.

- Bernoullijeva:** A histogram with two bars. The first bar at  $x=0$  has height  $(1-\theta)$ . The second bar at  $x=1$  has height  $\theta$ .
- Binomska:** A histogram showing a bell-shaped curve. The number of bars increases as  $n$  increases, and the peak shifts towards  $x=n$  as  $\theta$  increases.
- Poissonova:** A histogram showing a decreasing trend from left to right. The peak is at  $x=\lambda$ , and the distribution is centered around  $\lambda$ .

# Porazdelitve - zvezne

Porazdelitev	Zapis	$p(x)$	$E(x)$	$Var(x)$
Enakomerna	$U(\alpha, \beta)$	$\frac{1}{\beta - \alpha}$	$\frac{\alpha + \beta}{2}$	$\frac{(\beta - \alpha)^2}{12}$
Gaussova	$N(\mu, \sigma^2)$	$\frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$	$\mu$	$\sigma^2$
Beta <sup>1</sup>	$Be(\alpha, \beta)$	$\frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} x^{\alpha-1} (1-x)^{\beta-1}$	$\frac{\alpha}{\alpha+\beta}$	$\frac{\alpha\beta}{(\alpha+\beta)^2(\alpha+\beta+1)}$

<sup>1</sup> $\Gamma(x) = \text{gama funkcija}$

# Porazdelitve - zvezne II

Porazdelitev	Zapis	$p(x)$	$E(x)$	$Var(x)$
Gama <sup>2</sup>	$G(\alpha, \beta)$ $G(\alpha, \theta = 1/\beta)$	$\beta^\alpha \frac{1}{\Gamma(\alpha)} x^{\alpha-1} \exp(-\beta x)$ $\frac{1}{\theta^\alpha} \frac{1}{\Gamma(\alpha)} x^{\alpha-1} \exp(-\frac{x}{\theta})$	$\alpha/\beta$ $\alpha\theta$	$\alpha/\beta^2$ $\alpha\theta^2$
Inverzna gama	$IG(\alpha, \beta)$	$\beta^\alpha \frac{1}{\Gamma(\alpha)} (x)^{-\alpha-1} \exp(-\frac{\beta}{x})$	$\frac{\beta}{\alpha-1}$	$\frac{\beta^2}{(\alpha-1)^2(\alpha-2)}$


The figure contains two sets of plots. The top row shows three curves for the Gamma distribution: a black curve peaking at x=0, a red curve peaking at x=1, and a blue curve peaking at x=2. The bottom row shows four curves for the Inverse Gamma distribution: a green curve peaking sharply near x=0.5, followed by a red, blue, and then a black curve that are broader and shift to the right as their parameters increase.

$${}^2\Gamma(x) = \text{gama funkcija}$$

# Vaja

Razložimo gostoto verjetnosti za binomsko porazdelitev:

$$\Pr(x) = \binom{n}{x} \theta^x (1 - \theta)^{n-x}$$



## Vaja (rešitev)

Gostota verjetnosti za Bernoullijevo porazdelitev  $B(1, \theta)$ :

$$\Pr(x) = \theta^x (1 - \theta)^{1-x}$$

- ▶ zaloga vrednosti je  $[0, 1]$   
(0=cifra ali 1=glava pri metu kovanca, 0=zdrav ali 1=bolan, ...)
- ▶ verjetnost, da se zgodi dogodek 1 je enaka:  $\Pr(x = 1) = \theta$   
( $\theta = 1/2$  pri poštenem kovancu)
- ▶ splošni zapis (glej zgoraj):
  - ▶  $\Pr(x = 0) = \theta^0 (1 - \theta)^{1-0} = 1 (1 - \theta)^1 = 1 - \theta$
  - ▶  $\Pr(x = 1) = \theta^1 (1 - \theta)^{1-1} = \theta^1 (1 - \theta)^0 = \theta$

Če spremljamo več zaporednih dogodkov iz  $B(1, \theta)$  je število možnih kombinacij dogodkov enako  $\binom{n}{x}$ . Tako je gostota verjetnosti za binomsko porazdelitev  $B(n, \theta)$ :

$$\Pr(x) = \binom{n}{x} \theta^x (1 - \theta)^{n-x}$$



- ▶ Uporabite spodnjo kodo

```
n <- 10; theta <- 0.5
## Verjetnost, da dobimo x=1, x=5 ali x=9?
x <- c(1, 5, 9)
choose(n, x)*theta^x*(1-theta)^(n-x)


## Vzorčimo vrednosti iz Binomske porazdelitve
x <- rbinom(n=100, size=n, prob=theta)

## Pregled vzorca
table(x); hist(x)

## Izračun povprečja in variance
n*theta; n*theta*(1-theta) ## pričakovano
mean(x); var(x) ## opaženo
```

- ▶ Povečajte vzorec s 100 na 100.000 in ponovite. Kaj opazite?

## 2. Verjetje (ang. likelihood)



# Primer

Obiščemo 7 neodvisnih lokacij in opravimo po 5 neodvisnih zanesljivih testov za določitev obolelosti. Rezultati so:

Lokacija	1	2	3	4	5	6	7	Skupaj
Št. pozitivnih	2	0	1	1	1	1	2	8

- ▶ Koliko znaša delež obolelih v populaciji?
  - ▶ Število pozitivnih testov na lokaciji  $i$ :  $y_i$  (poznamo)
  - ▶ Delež obolelih:  $\theta$  (ne poznamo)
  - ▶ Predpostavljeni model:  $\Pr(y_i|n=5, \theta) \sim B(5, \theta)$
  - ▶ Princip verjetja (Fisher): “**Poiščimo takšno vrednost parametrov ( $\theta$ ), da bodo zbrani podatki ( $y$ ), kar se da najbolj verjetni.**“
  - ▶ Gostota verjetnosti  $\Pr(y|n=5, \theta)$  in verjetje  $L(y|n=5, \theta)$ :

$$\Pr(y|n=5, \theta) = \prod_{i=1}^7 \binom{n}{y_i} \theta^{y_i} (1-\theta)^{n-y_i} \quad L(y|n=5, \theta) = \prod_{i=1}^7 \binom{n}{y_i} \theta^{y_i} (1-\theta)^{n-y_i}$$

## Primer II

Iščemo vrednost parametra ( $\theta$ ), da bodo zbrani podatki ( $y$ ), kar se da najbolj verjetni.  $\rightarrow$  Poiskati moramo maksimum funkcije  $L(y|n, \theta)$ . Standarden postopek:

1. "Računalniki ne marajo zelo majhnih števil"

$$\log(L(y|n, \theta)) = I(y|n, \theta)$$

2. "Zmasiramo" izraz  $I(y|n, \theta)$

3. Odvajamo in odvod enačimo z nič

4. Rešimo enačbo  $\rightarrow$  izračunamo oceno parametra  $(\hat{\theta}_{MLE})$  (direktno ali z numeričnimi metodami)

5. Varianco ocene izračunamo na osnovi informacijske matrike

$$\left( \text{Var}(\hat{\theta}_{MLE}) = \left( -E \left( \frac{\partial^2 \log(L(y|n, \theta))}{\partial \theta \partial \theta'} \right) \right)^{-1} \right)$$

MLE = ang. Maximum Likelihood Estimate, slo. cenilka po metodi največjega verjetja

## Primer II



Ocena deleža obolelih glede na zbrane podatke:

$$\begin{aligned}\hat{\theta}_{MLE} &= \frac{y}{n} \\ &= \frac{8}{35} = 0.23\end{aligned}$$

Standardna napaka ocene:

$$\begin{aligned}SE(\hat{\theta}_{MLE}) &= \sqrt{\frac{-1}{-\frac{y}{p^2} - \frac{n-y}{(1-p)^2}}} \\ &= \sqrt{\frac{-1}{-\frac{8}{0.23^2} - \frac{35-8}{(1-0.23)^2}}} = 0.07\end{aligned}$$

## Primer III





- ▶ Uporabite spodnjo kodo

```
n <- 35
y <- 8
p <- seq(from=0, to=1, by=0.01)
MLE <- y/n
MLE_SE <- sqrt(-1 / (-y/MLE^2 - (n-y)/(1-MLE)^2))
MLE_CI <- MLE + c(-1.96, 0, 1.96) * MLE_SE
L <- choose(n, y)*p^y*(1-p)^(n-y)
l <- log(L)
par(mfrow=c(1, 2))
plot(L ~ p, type="l"); abline(v=MLE_CI)
plot(l ~ p, type="l"); abline(v=MLE_CI)
```

- ▶ Kaj se spremeni, če imamo vzorec velikosti 10 in 2 pozitivna rezultata ali vzorec velikosti 1000 in 230 pozitivnih rezultatov?

### 3. Bayesovski pristop k statistike



# Bayesov teorem

- ▶ Koliko znaša delež obolelih v populaciji?
  - ▶ Število vseh in pozitivnih testov:  $n = 35, y = 8$  (poznamo)
  - ▶ Delež obolelih:  $\theta$  (ne poznamo)

$$\begin{aligned} p(\theta|y, n) &= \frac{p(y|n, \theta) \times p(\theta)}{p(y)} \\ &= \frac{p(y|n, \theta) \times p(\theta)}{\int_{\theta} p(y|n, \theta) \times p(\theta)} \\ p(\theta|y, n) &\propto p(y|n, \theta) \times p(\theta) \end{aligned}$$

“posterior is proportional to likelihood times prior”

- ▶ Slovar:
  - ▶  $p(\theta|y, n)$  = posteriorna porazdelitev (rezultat)
  - ▶  $p(y|n, \theta)$  = verjetje (predpostavljen model + podatki)
  - ▶  $p(\theta)$  = apriorna porazdelitev (predpostavka = predhodno znanje)

## Tip porazdelitve?


- ▶ Koliko znaša delež obolelih v populaciji?
  - ▶ Število vseh in pozitivnih testov:  $n = 35, y = 8$  (poznamo)
  - ▶ Delež obolelih:  $\theta$  (ne poznamo)

$$\begin{aligned} p(\theta|y, n) &\propto p(y|n, \theta) \times p(\theta) \\ &\propto \binom{n}{y} \theta^y (1-\theta)^{n-y} \times p(\theta) \\ &\propto \theta^y (1-\theta)^{n-y} \times p(\theta) \end{aligned}$$

“after the inspection beta distribution can be recognized”

$$\begin{aligned} x &\sim Be(\alpha, \beta) & p(x|\alpha, \beta) &= \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} x^{\alpha-1} (1-x)^{\beta-1} \\ p(y|n, \theta) &= Be(y+1, n-y+1) \end{aligned}$$

## Tip porazdelitve $Be(y + 1, n - y + 1)$



## Konjugirana apriorna porazdelitev

- Konjugirana apriorna porazdelitev ima enako "obliko" kot verjetje:

$$p(y|n, \theta) = Be(y+1, n-y+1)$$

$$p(\theta) = Be(\alpha, \beta)$$

















$$\begin{aligned} p(\theta|y, n) &\propto \theta^y (1-\theta)^{n-y} \times \theta^{\alpha-1} (1-\theta)^{\beta-1} \\ &\propto \theta^{y+\alpha-1} (1-\theta)^{n-y+\beta-1} \end{aligned}$$

"after the inspection beta distribution can be recognized"

$$p(\theta|y, n) = Be(y+1+\alpha, n-y+1+\beta)$$


Moramo določiti parametra apriorne porazdelitve:  $\alpha, \beta$

# Apriorna porazdelitev $Be(\alpha, \beta)$




# Posteriorna porazdelitev $Be(y + 1 + \alpha, n - y + 1 + \beta)$


$Be(1, 1)$




$Be(1, 3)$



$Be(3, 1)$



$Be(3, 3)$




Posteriorna porazdelitev  $Be(y + 1 + \alpha, n - y + 1 + \beta)$

$$E(x|\alpha, \beta) = \frac{\alpha}{\alpha + \beta} \quad Var(x|\alpha, \beta) = \frac{\alpha\beta}{(\alpha + \beta)^2(\alpha + \beta + 1)}$$


Apriorna p.	$E(\theta y, n, \alpha, \beta)$	$SE(\theta y, n, \alpha, \beta)$
$Be(1, 1)$	0.256	0.069
$Be(1, 3)$	0.243	0.066
$Be(3, 1)$	0.293	0.070
$Be(3, 3)$	0.279	0.068

$$\hat{\theta}_{MLE} = 0.23, \quad SE(\hat{\theta}_{MLE}) = 0.07$$

# Apriorna porazdelitev $Be(\alpha, \beta)$



# Posteriorna porazdelitev $Be(y + 1 + \alpha, n - y + 1 + \beta)$



- ▶ S pomočjo spodnje kode izračunajte in narišite posteriorno porazdelitev za sledeče primere:


- ▶ vzorec velikosti 10 in 2 pozitivna rezultata
- ▶ vzorec velikosti 1000 in 230 pozitivnih rezultatov?

```
n <- 35; y <- 8
alpha <- 1; beta <- 10
a <- y + alpha; b <- n - y + beta
MLE <- y/n
MLE_SE <- sqrt(-1 / (-y/MLE^2 - (n-y)/(1-MLE)^2))
POS <- a / (a + b)
POS_SE <- sqrt(a * b / (((a + b)^2) * (a + b + 1)))
p <- seq(from=0, to=1, by=0.01)
dL <- dbeta(x=p, shape1=y+1, shape2=n-y+1)
dPRI <- dbeta(x=p, shape1=alpha, shape2=beta)
dPOS <- dbeta(x=p, shape1=a, shape2=b)
matplot(y=cbind(dL, dPRI, dPOS), x=p, type="l",
        col=c("black", "red", "blue"))
abline(v=MLE)
```

# Intervali

- ▶ Credible interval (analogija intervala zaupanja)
  - ▶ v primeru, da poznamo posteriorno porazdelitev lahko enostavno izračunamo kvantile
  - ▶ kot približek lahko vzamemo interval, ki je simetričen okoli povprečja porazdelitve (predpostavljamo, da je posteriorna porazdelitev normalna)
- ▶ Highest Posterior Density (HPD) (interval, ki je čim krajši in zajema določen % porazdelitve!)

$$CI(\theta|y, n, \alpha, \beta) = 0.11 - 0.38, \quad HPD(\theta|y, n, \alpha, \beta) = 0.14 - 0.41$$



## Vaja II



- ▶ S pomočjo spodnje kode vzorčite iz izračunanih posteriornih porazdelitev in izračunajte:

- ▶ povprečje
- ▶ standardni odklon
- ▶ credible interval
- ▶ highest posterior density

```
n <- 35; y <- 8
alpha <- 1; beta <- 1
a <- y + 1 + alpha; b <- n - y + 1 + beta
x <- rbeta(n=100000, shape1=a, shape2=b)
hist(x)
mean(x)
sd(x)
mean(x) + c(-1, 1)*1.96*sd(x)
library(package="coda")
HPDinterval(as.mcmc(x))
```

## Apriorna porazdelitev

“Tisti, ki uporablja Bayesovsko statistiko, na podlagi nejasnega/meglenega pričakovanja konja in bežnega pogleda na osla, trdno sklepa, da je videl mulo.” Senn (1997)

- ▶ Neinformativna apriorna p. **ne obstaja**. Celo enakomerna apriorna porazdelitev pravi, da so vse vrednosti enako verjetne.
- ▶ Ni vse tako “črno”, saj obstajajo pristopi za izpeljavo t.i. neinformativnih apriorih porazdelitev
  - ▶ Jefreys-ove apiorne porazdelitve
  - ▶ referenčne apiorne porazdelitve (Bernardo)
  - ▶ ...
- ▶ Analiza občutljivosti
- ▶ Uporaba smiselne apiorne informacije vodi do pristranih (ang. biased) ocen, ki pa imajo manjšo varianco (kombinacija dveh virov informacije → zmanjšana varianca)
- ▶ Prednost dajemo konjugiranim apiornim p., ki so podobne oblike kot posteriorna p.
- ▶ S povečevanjem števila podatkov se vpliv apiorne p. zmanjšuje

## “Splošna” apriorna porazdelitev

- Za apriorno porazdelitev lahko načeloma izberemo poljubni tip porazdelitve:

$$p(y|n, \theta) = Be(y+1, n-y+1)$$

$$p(\theta) = U(\alpha, \beta)$$

$$p(\theta|y, n) \propto \theta^y (1-\theta)^{n-y} \times \frac{1}{\beta - \alpha}$$

$$\propto \int_{\alpha}^{\beta} Be(y+1, n-y+1) \frac{1}{\beta - \alpha} d\theta$$


$$\propto ????$$

“after the inspection no standard distribution can be recognized”

Ne moremo direktno izračunati (včasih možno ampak bolj poredko).  
Potreben drugačen pristop!

## “Splošna” apriorna porazdelitev - enakomerna

$$\text{Be}(8+1, 35-8+1) \times U(0.1, 0.5)$$



## Večje število parametrov?


- ▶ Statistični modeli imajo običajno več kot en parameter
- ▶ Npr. Gaussova porazdelitev

$$p(y|\mu, \sigma^2) = N(\mu, \sigma^2)$$

$$p(\mu) = N(\dots)$$

$$p(\sigma^2) = IG(\dots)$$

$$p(\mu, \sigma^2 | y) \propto p(y|\mu, \sigma^2) p(\mu) p(\sigma^2)$$





Ampak mi bi radi kot rezultat robne (enodimensionalne) posteriorne porazdelitve:  $p(\mu|y)$  in  $p(\sigma^2|y)$

# Večje število parametrov?

Ampak mi bi radi kot rezultat robne (enodimenzionalne) posteriorne porazdelitve!

$$p(\mu|y) = \int_0^{\infty} p(\mu, \sigma^2|y) d\sigma^2 \quad p(\sigma^2|y) = \int_{-\infty}^{+\infty} p(\mu, \sigma^2|y) d\mu$$



## Še večje število parametrov?

$$p(\theta_1, \theta_2, \dots, \theta_p | y) \propto p(y | \theta_1, \theta_2, \dots, \theta_p) p(\theta_1) p(\theta_2) \dots p(\theta_p)$$
$$p(\theta_1 | y) = \int_{\theta_2} \int_{\dots} \int_{\theta_p} p(\theta_1, \theta_2, \dots, \theta_p | y) d\theta_2 d\dots d\theta_p$$
$$p(\theta_2 | y) = \int_{\theta_1} \int_{\dots} \int_{\theta_p} p(\theta_1, \theta_2, \dots, \theta_p | y) d\theta_1 d\dots d\theta_p$$
$$\dots$$
$$\boldsymbol{\theta} = \theta_1, \theta_2, \dots, \theta_p$$
$$p(\theta_i | y) = \int_{\boldsymbol{\theta}_{-i}} p(\boldsymbol{\theta} | y) d\boldsymbol{\theta}_{-i}$$

**Običajno analitično nerešljivo!!!**



## 4. Metode MCMC




# MCMC

- ▶ MCMC
  - ▶ ang. Monte Carlo Markov Chain
  - ▶ slo. Monte Carlo z Markovskimi verigami
- ▶ Monte Carlo - stohastična metoda za rešitev računsko/analitično zahtevnih primerov
- ▶ Markovske verige - sedanja vrednost parametra je odvisna le od predhodne vrednosti
- ▶ U okviru Bayesovske statistike uporabljamo metodo MCMC za vzorčenje iz (pogojnih) posteriornih porazdelitev
- ▶ Številni algoritmi
  - ▶ Metropolis sampling
  - ▶ Metropolis-Hastings sampling
  - ▶ Gibbs sampling
  - ▶ ...

# Večje število parametrov?

- ▶ Statistični modeli imajo običajno več kot en parameter
- ▶ Npr. Gaussova porazdelitev

$$\begin{aligned} p(y|\mu, \sigma^2) &= N(\mu, \sigma^2) \\ p(\mu) &= N(\dots) \\ p(\sigma^2) &= IG(\dots) \\ p(\mu, \sigma^2|y) &\propto p(y|\mu, \sigma^2) p(\mu) p(\sigma^2) \end{aligned}$$



Ampak mi bi radi kot rezultat robne (enodimenzionalne) posterorne porazdelitve:  $p(\mu|y)$  in  $p(\sigma^2|y)$

# MCMC - pogojne porazdelitve





- ▶ Izpeljemo pogojne porazdelitve za vsak parameter posebej (lahko tudi za skupine/bloke parametrov skupaj)
- ▶ Iz enodimensionalnih pogojnih porazdelitev je enostavno vzorčiti
- ▶ Pogojne porazdelitve za Gaussov model:

$$p(\mu, \sigma^2 | y) \propto p(y | \mu, \sigma^2) p(\mu) p(\sigma^2)$$


$$p(\mu | y, \sigma^2) \propto p(y | \mu, \sigma^2) p(\mu) \cancel{p(\sigma^2)}$$

$$p(\sigma^2 | y, \mu) \propto p(y | \mu, \sigma^2) \cancel{p(\mu)} p(\sigma^2)$$





# MCMC - pogojne porazdelitve (prikaz)




## MCMC - vzorčenje




# MCMC - vzorčenje II




# MCMC - Markovska veriga





# MCMC - robne porazdelitve





# MCMC - robne porazdelitve II





## MCMC - različne apriorne p. za $\mu$





## MCMC - različne apriorne p. $\mu$



## MCMC - različne apriorne p. $\sigma^2$



## MCMC - različne apriorne p. $\sigma^2$ ||




# Splošni MCMC programi


- ▶ BUGS - samostojno (BUGS, WinBUGS in **OpenBUGS**) in preko R paketov (R2OpenBUGS, BRugs)
- ▶ JAGS - samostojno in preko R paketov (jags in rjags)
- ▶ BayesX - samostojno in preko R paketa BayesX
- ▶ R paketi

<http://cran.r-project.org/web/views/Bayesian.html>

- ▶ MCMCglmm
- ▶ ...




# OpenBUGS




- ▶ OpenBUGS
  - ▶ <http://www.openbugs.info>
  - ▶ namestite si program (Downloads ...)
- ▶ Video “Welcome to WinBUGS - the movie!”  
[http://www.mrc-bsu.cam.ac.uk/bugs/winbugs/  
winbugsthemovie.html](http://www.mrc-bsu.cam.ac.uk/bugs/winbugs/winbugsthemovie.html)
  - ▶ prepišite model, podatke in začetne vrednosti in ponovite celoten postopek
  - ▶ narišimo DAG za model
  - ▶ simulirajmo meritve na osnovi modela in izbranih vrednosti parametrov ( $\mu = 175, \sigma = 10$ )
- ▶ Med primeri (Examples → Examples Vol I) odprite primer “Rats” (rast mladih podgan)
  - ▶ preberite opis primera
  - ▶ preučite model
  - ▶ izvedite analizo
  - ▶ spremenite model tako, da boste lahko spremljali vrednosti za  $\sigma_a^2$  in  $\sigma_b^2$  ter  $\sigma_a$  in  $\sigma_b$

# Rast mladih podgan




# R2OpenBUGS



- ▶ R2OpenBUGS - R paket za povezavo med programoma OpenBUGS in R
  - ▶ <http://cran.r-project.org/web/packages/BRugs/index.html>
- ▶ Namestite si paket in sledite spodnjim ukazom

```
install.packages(pkg="R2OpenBUGS")
library(package="R2OpenBUGS")
vignette("R2OpenBUGS")
?bugs # izvedite ukaze iz primera ("Schools example")
```

# BRugs



- ▶ BRugs - R paket za izvajanje ukazov programa OpenBUGS v R
  - ▶ <http://cran.r-project.org/web/packages/BRugs/index.html>
- ▶ Namestite si paket in sledite spodnjim ukazom

```
install.packages(pkg="BRugs")
library(package="Brugs")
?BRugs # izvedite ukaze iz primera ("Rats example")
```