

9 Věrohodnost – Binomické rozdělení

Příklad 9.1. Maximálně věrohodný odhad parametru p binomického modelu

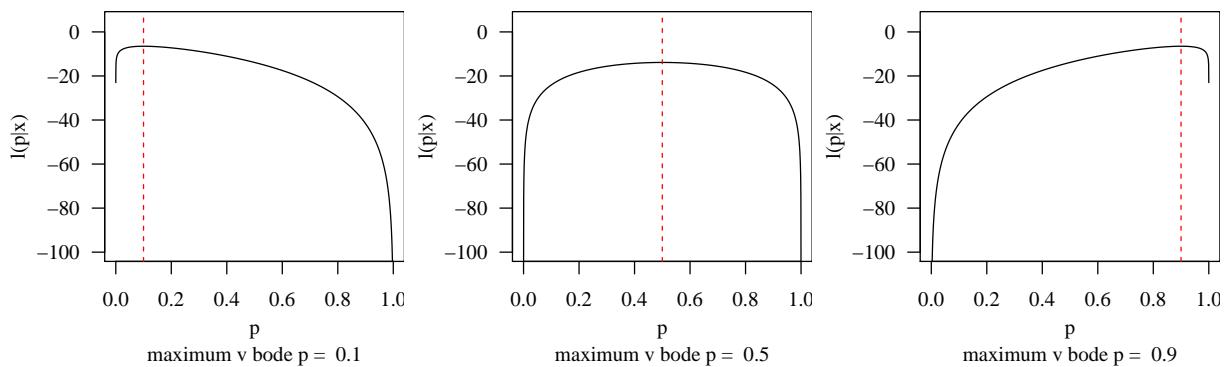
Nechť $X \sim \text{Bin}(N, p)$ a realizace X jsou x . Předpokládejme, že jsme pozorovali (i) $x = 2$, (ii) $x = 10$ a (iii) $x = 18$ úspěchů v $N = 20$ pokusech.

1. Odvod'te
 - a. tvar jádra věrohodnostní funkce $L(p|x)$ binomického modelu;
 - b. tvar jádra logaritmu věrohodnostní funkce $\ell(p|x)$ binomického modelu;
 - c. skóre funkci pro parametr p + MLE odhad parametru p ;
 - d. Fisherovo informační číslo + rozptyl MLE odhadu parametru p .
2. Dosazením do vzorců stanovte přesnou hodnotu odhadu parametru p , tj. \hat{p} , a odhad rozptylu odhadu parametru p , tj. $\text{Var}[\hat{p}]$.
3. Pomocí maximalizace logaritmu věrohodnostní funkce $\ell(p|x)$ binomického modelu nalezněte maximálně věrohodný odhad parametru p pro situaci (i), (ii) a (iii). Pro každou situaci vykreslete křivku logaritmu věrohodnostní funkce binomického modelu spolu s maximálně věrohodným odhadem parametru p . Maximalizaci proved'te
 - a. pomocí funkce `optimize()`;
 - b. pomocí vlastnoručně naprogramované Newton-Raphsonovy metody `NRbin()`;
 - c. pomocí vlastnoručně naprogramované metody sečen `MSbin()`.
4. Pro situaci (i), (ii) a (iii) vykreslete křivku věrohodnostní funkce binomického modelu spolu s maximálně věrohodným odhadem parametru p získaným optimalizací věrohodnostní funkce $L(p|x)$ pomocí funkce `optimize()`.

Řešení příkladu 9.1

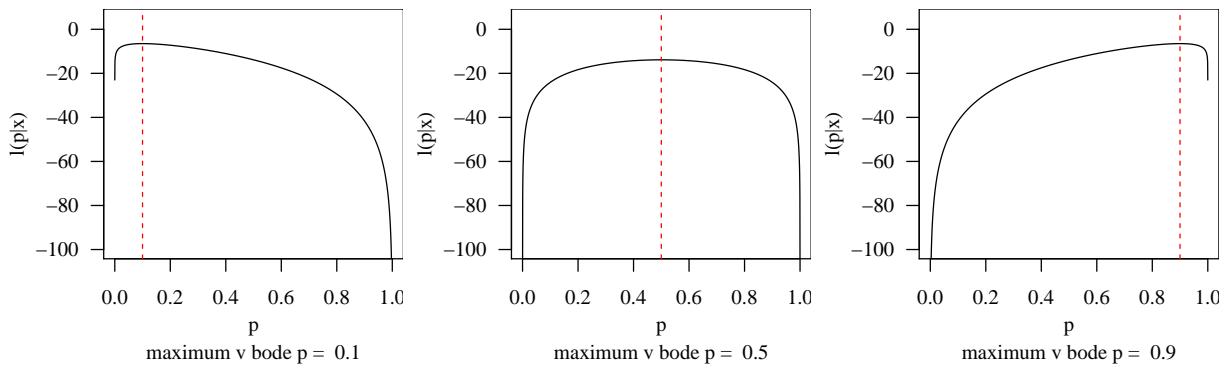
$x = 2$	$x = 10$	$x = 18$	
p	0.1000	0.5000	0.9000
$\text{Var}[p]$	0.0045	0.0125	0.0045

1
2
3

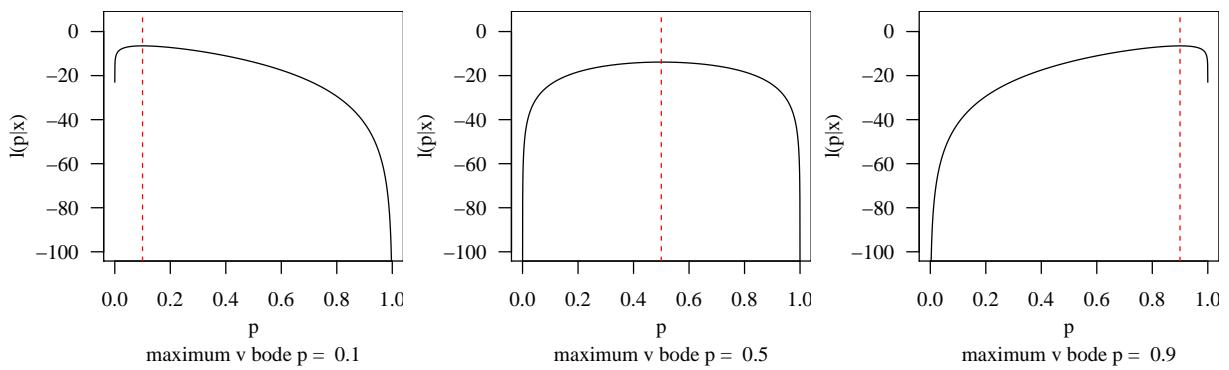


Obrázek 1: Logaritmus věrohodnostní funkce + MLE odhad parametru p pomocí funkce `optimize()`





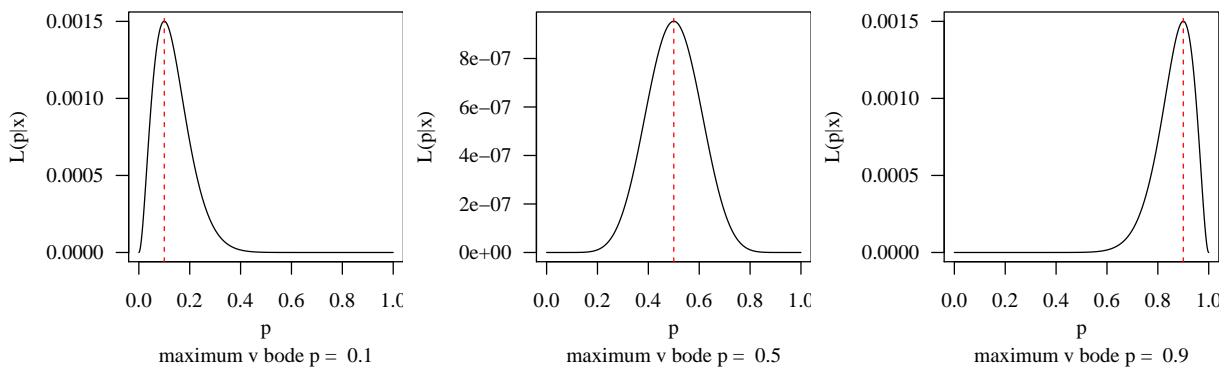
Obrázek 2: Logaritmus věrohodnostní funkce + MLE odhad parametru p pomocí Newton-Raphsonovy metody



Obrázek 3: Logaritmus věrohodnostní funkce + MLE odhad parametru p pomocí metody sečen

Tabulka 1: Odhady parametru p binomického rozdělení

	$x = 2$	$x = 10$	$x = 18$
exaktní výpočet	0.100000	0.500000	0.900000
funkce <code>optimize()</code>	0.100001	0.500000	0.899999
Newton-Raphsonova metoda	0.100000	0.500000	0.900000
metoda sečen	0.100000	0.500000	0.900000



Obrázek 4: Věrohodnostní funkce + MLE odhad parametru p pomocí funkce `optimize()`

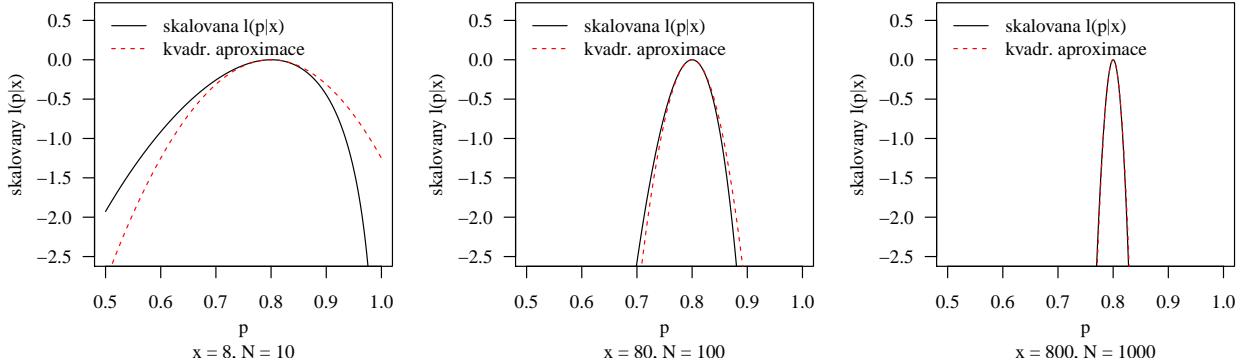
Příklad 9.2. Kvadratická approximace v binomickém modelu

- Nakreslete škálovaný logaritmus funkce věrohodnosti binomického rozdělení. Na x -ové ose bude p a na y -ové ose $\ln \mathcal{L}(p) = l(p|\mathbf{x}) - \max(l(p|\mathbf{x}))$. Porovnejte $\ln \mathcal{L}(p)$ s kvadratickou approximací vypočítanou pomocí Taylorova rozvoje $\ln \mathcal{L}(p) = \ln \left(\frac{L(p|\mathbf{x})}{L(\hat{p}|\mathbf{x})} \right) \approx -\frac{1}{2}\mathcal{I}(\hat{p})(p - \hat{p})^2$.
- Nechť skóre funkce $S(p) = \frac{\partial}{\partial p} \ln L(p|\mathbf{x})$. Vezmeme-li derivaci kvadratické approximace uvedené výše, dostaneme $S(p) = -\mathcal{I}(\hat{p})(p - \hat{p})$ anebo $-\mathcal{I}^{-1/2}(\hat{p})S(p) \approx \mathcal{I}^{1/2}(\hat{p})(p - \hat{p})$. Potom zobrazením pravé strany na x -ové ose a levé strany na y -ové ose dostaneme asymptoticky lineární funkci s jednotkovým sklonem. Asymptoticky také platí $\mathcal{I}^{1/2}(\hat{p})(p - \hat{p}) \sim N(0, 1)$. Je postačující mít rozsah x -ové osy $(-2; 2)$, protože funkce je asymptoticky (lokálně) lineární na tomto intervalu. Rozumně škálujte y -vou osu. Zobrazte pro (a) $n = 8$, $N = 10$, (b) $n = 80$, $N = 100$ a (c) $n = 800$, $N = 1000$ ($p \in (0.5; 0.99)$). Okomentujte rozdíly mezi (a), (b) a (c).

Řešení příkladu 9.2

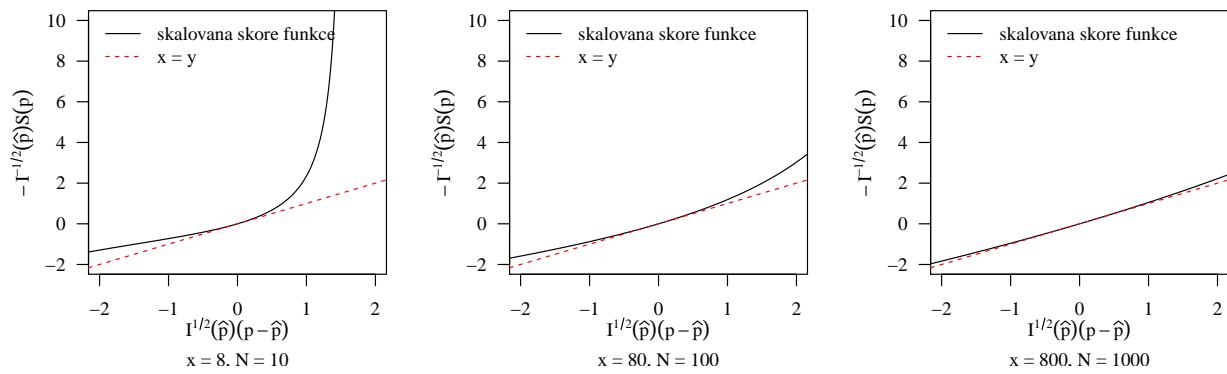
```

4 kvadr_aprox <- function(p, x, max.ylim, plot = 'aproximace'){
5   l <- function(p, x, N) {...} # log. veroh. fce
6   pmax <- optimize(...)$maximum # MLE odhad parametru p
7   lr <- l(p, x, N) - l(pmax, x, N) # skalovaný logaritmus veroh. fce v posloupnosti p
8   FIM <- function(p, N) {...} # Fisherovo inf. cislo (FIM)
9   Ip <- FIM(...) # hodnota FIM pro p = pmax
10  kv.aproximace <- -1 / 2 * Ip * (p - pmax)^2 # kvadraticka approximace
11
12 # graf kvadraticke approximace
13 if(plot == 'aproximace'){
14   par(...) # nastaveni okraji 4, 4, 1, 1
15   plot(p, lr, ylim = c(-2.5, 0.6), xlab = '', ...) # graf skalovaneho logaritmu
16   lines(p, kv.aproximace, ...) # krvka kvard. approximace
17   mtext(...) # popisek osy x
18   mtext(paste('x = ', x, ', N = ', N, sep = ''), ... ) # druhý popisek osy x
19   legend(...) # legenda
20 }
21 # graf linearity skalovaneho logaritmu
22 if(plot == 'linearita'){
23   S <- function(p, x, N){x / p - (N - x) / (1 - p)} # skóre funkce
24   Sp <- S(...) # vypocet konkretni hodnoty skóre funkce
25   par(...) # nastaveni okraju 4, 4, 1, 1
26   plot(Ip^(1 / 2) * (p - pmax), -Ip^(-1 / 2) * Sp, xlim = c(-2, 2),
27         ylim = c(-2, max.ylim), ...) # graf skalovaneho logaritmu (vztah z bodu 2)
28   abline(a = 0, b = 1, ...) # referencni primka y = x
29   mtext(bquote(paste(I^{1/2} * (widehat(p)) * (p - widehat(p)))), ... ) # popisek osy x
30   mtext(...) # druhý popisek osy x
31   mtext(bquote(paste(-I^{-1/2} * (widehat(p)) * S(p))), side = 2, ... ) # popisek osy y
32   legend(...) # legenda
33 }
34 }
```



Obrázek 5: Kvadratická approximace škálovaného logaritmu funkce věrohodnosti binomického rozdělení





Obrázek 6: Asymptotická linearita skóre funkce logaritmů funkce věrohodnosti binomického rozdělení