

# Zadání příkladů – Statistická inference I – 2016

**Příklad 20 (standardizované normální rozdělení).** Vypočítejte kritické hodnoty  $u(\alpha)$  rozdělení  $N(0, 1)$ , kde  $\alpha = 0.1, 0.05, 0.01, 0.025$  a  $0.005$ .

Na výpočet pravděpodobnosti pod kvantilem se používá funkce `pnorm(Q)`. Na výpočet pravděpodobnosti nad kritickou hodnotou se používá funkce `1-pnorm(Q)`. Jelikož je standardizované normální rozdělení symetrické okolo nuly,  $u(\alpha) = u(1 - \alpha)$ .

**Příklad 21 (Studentovo  $t$ -rozdělení).** Vypočítejte kritické hodnoty Studentova  $t$ -rozdělení se stupni volnosti  $df = 10$ , tj.  $t_{df}(\alpha)$ , kde  $\alpha = 0.1, 0.05, 0.01, 0.025$  a  $0.005$ .

Na výpočet pravděpodobnosti pod kvantilem se využívá funkce `pt(Q, df)`. Na výpočet pravděpodobnosti nad kritickou hodnotou se využívá funkce `1-pt(Q, df)`. Jelikož Studentovo  $t$ -rozdělení je symetrické okolo nuly,  $t_{df}(\alpha) = t_{df}(1 - \alpha)$ . Nějaký kvantil standardizovaného normálního rozdělení je přibližně rovný kvantilu  $t$ -rozdělení (resp. pravděpodobnosti nad kritickými hodnotami jsou přibližně stejné) až pro velmi vysoké stupně volnosti. Např.  $1 - \text{pnorm}(1.644869) \approx 1 - \text{pt}(1.644869, 100\,000) = 0.05$ . Avšak např.  $1 - \text{pt}(1.644869, 100) \doteq 0.052$ .

**Příklad 22 ( $\chi^2$  rozdělení).** Vypočítejte kritické hodnoty  $\chi^2$ -rozdělení se stupni volnosti  $df = 10$ , tj.  $\chi^2_{df}(\alpha)$ , kde  $\alpha = 0.1, 0.05, 0.01, 0.025$  a  $0.005$ .

Na výpočet pravděpodobnosti pod kvantilem anebo nad kritickou hodnotou se používá funkce `pchisq(Q, df)`. Jelikož  $\chi^2$ -rozdělení není symetrické,  $\chi^2_{df}(\alpha) \neq \chi^2_{df}(1 - \alpha)$ .

**Příklad 23 ( $F$ -rozdělení).** Vypočítejte kritické hodnoty  $F$ -rozdělení se stupni volnosti  $df_1 = 20$  a  $df_2 = 20$ , tj.  $F_{df_1, df_2}(\alpha)$ , kde  $\alpha = 0.1, 0.05, 0.01, 0.025$  a  $0.005$ .


Na výpočet pravděpodobnosti pod kvantilem se používá funkce `pf(Q, df1, df2)`. Na výpočet pravděpodobnosti nad kritickou hodnotou se používá funkce `1-pt(Q, df1, df2)`. Jelikož  $F$ -rozdělení není symetrické,  $F_{df_1, df_2}(\alpha) \neq F_{df_1, df_2}(1 - \alpha)$ .

**Příklad 24 (binomické rozdělení, binomický experiment).** Experiment sestávající z fixního počtu Bernoulliho experimentů (ozn.  $N$ ) se nazývá binomický experiment. Pravděpodobnost úspěchu označme  $p$ , pravděpodobnost neúspěchu  $q = 1 - p$ . Náhodná proměnná  $X$  je počet pozorovaných úspěchů po dobu experimentu. Pravděpodobnost  $X = x$  za podmínky, že  $X$  pochází z binomického rozdělení  $\text{Bin}(N, p)$ , píšeme jako


$$\Pr(X = x) = \binom{N}{x} p^x (1 - p)^{N-x}, x = 0, 1, \dots, N \quad (1)$$

(Ugarte a kol. 2008). Střední hodnota  $E[X] = Np$  a rozptyl  $\text{Var}[X] = Np(1 - p)$ . Naprogramujte a zobrazte v R pravděpodobnostní funkci a (kumulativní) distribuční funkci pro  $\text{Bin}(5, 0.5)$ .

**Pravdepodobnosti funkce rozdelení  $\text{Bin}(5, 0.5)$**



**Distribucní funkce rozdelení  $\text{Bin}(5, 0.5)$**



**Příklad 25 (podíl chlapců a dívek v rodinách).** Nechť  $X$  představuje početnost chlapců mezi dětmi v rodinách. Zde můžeme předpokládat, že  $X \sim \text{Bin}(N, p)$ , tj. rodina může mít vychýlený poměr pohlaví dětí ve směru k chlapcům nebo k dívкам. V realitě tedy můžeme mít velmi mnoho rodin jen s chlapci nebo jen s děvčaty a nemáme dostatek rodin s poměrem pohlaví blízkým 51 : 49 (poměr chlapců ku dívкам). Z toho nám vyplývá, že rozptyl početnosti chlapců bude ve skutečnosti větší než rozptyl předpokládaný binomickým rozdělením  $\text{Bin}(n, P)$ .

**Příklad 26 (overdispersion v binomickém modelu).** V klasické studii poměru pohlaví u lidí z roku 1889 na základě záznamů z nemocnic v Sasku (více informací viz Lindsey a Altham, (1998)) zaznamenal Geissler (1889) rozdělení počtu chlapců v rodinách. Mezi  $M = 6115$  rodinami s  $N = 12$  dětmi pozoroval následující početnosti chlapců ( $n$  jsou početnosti chlapců a  $m_n$  početnosti rodin s  $n$  chlapci).

$n$	0	1	2	3	4	5	6	7	8	9	10	11	12
$m_n$	3	24	104	286	670	1033	1343	1112	829	478	181	45	7


Vypočítejte  $m_n$  za předpokladu, že početnosti chlapců  $X$  v rodinách mají binomické rozdělení s parametry

$$\pi = \frac{\sum_{n=0}^N nm_n}{NM} = 0.5192 \quad (2)$$

a  $N = 12$ , ozn.  $X \sim \text{Bin}(N, \pi)$ .

```
##          0   1   2   3   4   5   6   7   8   9   10  11  12
## pozorovane 3  24 104 286 670 1033 1343 1112 829 478 181 45  7
## ocekavane  1 12  72 258 628 1085 1367 1266 854 410 133 26  2
```


### Pozorovane a ocekavane poc. chlapcu v rodine s 12 detmi



```
## [1] 3.489269
## [1] 2.993832
```

**Příklad 27 (Poissonovo rozdělení; počet havárií za týden).** Pokud každý z 50 milionů lidí řídí v Itálii řídí auto následující týden nezávisle, potom pravděpodobnost smrti při autonehodě bude 0.000002, kde počet úmrtí má binomické rozdělení  $\text{Bin}(50\text{mil}, 0.000002)$  anebo limitní Poissonovo rozdělení s parametrem  $\lambda = 50\text{mil} \times 0.000002 = 100$ .

### Srovnání binomickeho a poissonova rozdělení



**Příklad 28 (Poissonovo rozdělení; pruské armádní jednotky).** Nechť početnosti úmrtí  $X$  jako následek kopnutí koněm v Pruských armádních jednotkách (Bortkiewicz, 1898) mají Poissonovo rozdělení s parametrem  $\lambda$ , tj.  $X \sim \text{Poiss}(\lambda)$ . Pravděpodobnost, že někdo bude smrtně zraněný v daném dni, je extrémně malá. Mějme


10 vojenských jednotek za 20-letou periodu s rozsahem  $M = 200$  ( $200 = 10 \times 20$ ), kde, při početnostech úmrtí  $n = 1, 2, 3, 4, 5+$  v dané jednotce a v daném roce, zaznamenáváme také početnosti vojenských jednotek  $m_n$  při daném  $n$ , kde  $M = \sum m_n$  (viz tabulka). Vypočítejte očekávané početnosti, za předpokladu  $X \sim Poiss(\lambda)$ , kde

$$\lambda = \frac{\sum_n nm_n}{\sum_n m_n}. \quad (3)$$

n	0	1	2	3	4	5+
$m_n$	109	65	22	3	1	0

```
## [1] 0.61
##          0 1 2 3 4 5+
## pozorovane 109 65 22 3 1 0
## ocekavane 109 66 20 4 1 0
```

Pozorovane a ocek. poc. umrti v pruskych arm. jednotkach



**Příklad 29 (overdispersion v Poissonově modelu).** Mějme početnosti úrazů  $n$  mezi dělníky v továrně, kde početnosti dělníků  $m_n$  při daném  $n$  (viz tabulka) (Greenwood a Yule (1920)).

n	0	1	2	3	4	$\geq 5$
$m_n$	447	132	42	21	3	2


Vypočítejte očekávané početnosti dělníků za předpokladu, že početnosti úrazů na dělníka  $X$  mají Poissonovo rozdělení s parametrem

$$\lambda = \frac{\sum_n nm_n}{\sum_n m_n} = 0.47. \quad (4)$$

Ozn.  $X \sim Poiss(\lambda)$ .

```
##          0 1 2 3 4 5+
## pozorovane 447 132 42 21 3 2
## ocekavane 406 189 44 7 1 0
```

### Pozorovane a ocekavane poc. úrazu mezi delníky v tovarne




```
## [1] 0.6908308
## [1] 0.4683702
```

**Příklad 30 (binomické rozdělení, simulační studie).** Vygenerujte pseudonáhodná čísla  $X$  (početnosti úspěchů) opakovaná  $M$ -krát ( $M = 1000$ ) z  $\text{Bin}(N, p)$ , kde  $N = 5$  a  $p = 0.5$ . Vytvořte tabulkou vygenerovaných (simulovaných) i teoretických relativních početností (pro  $n = 0, 1, \dots, 5$ ). Superponujte histogram vygenerovaných pseudonáhodných čísel s teoretickou pravděpodobnostní funkcí.


```
##          0      1      2      3      4      5 
## simulovane 0.036 0.155 0.329 0.288 0.160 0.032 
## teoreticke 0.031 0.156 0.312 0.312 0.156 0.031
```

Pseudonah. cisla X-Bin(5,0,5)




**Příklad 31 (normální rozdělení, simulační studie).** Na základě simulační studie prověrte, že pokud  $X \sim N(150, 6.25)$ , potom  $\bar{X}_n \sim N(150, \frac{6.25}{n})$ . Použijte  $n = 30$ . Pro každou simulaci  $X$  vypočítejte aritmetické průměry  $\bar{x}_m$ ,  $m = 1, 2, \dots, M$ , kde  $M = 500\,000$ . Superponujte je histogramem v relativní škále s teoretickou křivkou hustoty pro  $\bar{X}_n$ . Vypočítejte  $\Pr(\bar{X}_n > 151)$  ze simulovaných dat a porovnejte tento výsledek s teoretickou (očekávanou) pravděpodobností. Řešení viz obrázek ??.

```
## [1] "teoreticka:" "0.1855"
## [1] "simulovana:" "0.18616"
## [1] "teoreticka:" "0.0142"
## [1] "simulovana:" "0.01374"
## [1] "teoreticka:" "0"
## [1] "simulovana:" "2e-05"
```



**Příklad 32 (normální rozdělení, simulační studie).** Nechť  $X \sim N(\mu_1, \sigma_1^2)$  a  $Y \sim N(\mu_2, \sigma_2^2)$ . Potom  $\bar{X}_{n_1} - \bar{Y}_{n_2} \sim N(\mu_1 - \mu_2, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2})$ . Generujte pseudonáhodná čásla  $X$  a  $Y$  rozdělení  $N(\mu_j, \sigma_j^2)$ ,  $j = 1, 2$ , kde  $\mu_1 = 100$ ,  $\sigma_1 = 10$ ,  $\mu_2 = 50$ ,  $\sigma_2 = 9$  při (a)  $n_1 = 4$ ,  $n_2 = 5$ , (b)  $n_1 = 100$ ,  $n_2 = 81$ . Pro každou simulaci  $X$  a  $Y$  vypočítejte rozdíl  $\bar{x}_m - \bar{y}_m$ ,  $m = 1, 2, \dots, M$ , kde  $M = 1000$ . Superponujte histogram těchto rozdílů v relativní škále s teoretickou křivkou hustoty rozdílu  $\bar{X}_{n_1} - \bar{Y}_{n_2}$ . Pro případ (a) i (b) vypočítejte  $\Pr(\bar{X}_{n_1} - \bar{Y}_{n_2} \leq 52)$  na základě empirického (vygenerovaného) a teoretického rozdělení  $\bar{X}_{n_1} - \bar{Y}_{n_2}$ .

```
## [1] "teoreticke" "0.622"
## [1] "simulovane" "0.618"
## [1] "teoreticke" "0.921"
## [1] "simulovane" "0.936"
```




**Příklad 33 (statistika).** Mějme náhodný výběr  $(X_1, X_2, \dots, X_n)^T$ , kde  $X_i \in \mathbb{R}, i = 1, 2, \dots, n$ , potom příklady statistik jsou:










- $T_1 = \sum_{i=1}^n X_i \in \mathbb{R}$ ,
- $T_2 = \sum_{i=1}^n X_i^2 \in \mathbb{R}^+ \cup \{0\}$ ,
- $T_3 = (\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2) \in \mathbb{R}^2$ .




**Příklad 34 (testovací statistika, simulační studie).** Na základě simulační studie prověřte, že pokud náhodná proměnná  $X$  má asymptoticky binomické rozdělení  $Bin(N, p)$ , potom testovací statistika

$$Z_W = \frac{X/N - p}{\sqrt{p(1-p)/N}}$$

má asymptoticky normální rozdělení  $N(0, 1)$ . Použijte  $p = 0.1, 0.5, 0.9$  a  $1$ , a  $N = 5, 10, 30, 50$  a  $100$ . Okomentujte výsledky ve spojitosti s Haldovou podmínkou  $Np(1-p) > 9$ . Pro každou simulaci  $X$  vypočítejte  $z_{W,m}$ ,  $m = 1, 2, \dots, M$ , kde  $M = 1000$ . Superponujte histogram vygenerovaných testovacích statistik v relativní škále s teoretickou křivkou hustoty  $Z_W$ .










Příklad 34 mluví o použití jednovýběrové testovací statistiky pro parametr binomického rozdělení (pravděpodobnost) pro různé pravděpodobnosti a různé početnosti. Pokud není Haldova odmínka splněná, není možné testovací statistiku použít.

**Příklad 35** (testovací statistika, simulační studie). Na základě simulační studie prověrte, že pokud

- a)  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 0$ ,  $\sigma^2 = 1$ ;
- b)  $X \sim [(1-p)N(\mu, \sigma^2) + pN(\mu, \sigma_1^2)]$ , kde  $\mu = 0$ ,  $\sigma^2 = 1$ ,  $p = 0.05$ ,  $\sigma_1^2 = 2$ ,

potom testovací statistika  $F = \frac{(n-1)S^2}{\sigma^2}$  má asymptoticky  $\chi_{n-1}^2$  rozdělení o  $n-1$  stupních volnosti. Použijte rozsahy náhodných výběrů  $n = 15$  a  $n = 100$ . Pro každou simulaci  $X$  vypočítejte  $F_{poz,m}$ ,  $m = 1, 2, \dots, M$ , kde  $M = 1000$ . Superponujte histogram vygenerovaných testovacích statistik v relativní škále s teoretickou křivkou hustoty  $F$ .





**Příklad 36 (hypergeometrické rozdělení).** Koupili jsme 10 cibulek červených tulipánů a 5 cibulek žlutých tulipánů. Zasadili jsme 8 náhodně vybraných cibulek.

- Jaká je pravděpodobnost, že žádná nebude cibulka žlutých tulipánů?
- Jaká je pravděpodobnost, že jsme zasadili všech 5 cibulek žlutých tulipánů?
- Jaká je pravděpodobnost, že aspoň dvě budou cibulky žlutých tulipánů?

**Příklad 37 (hypergeometrické rozdělení).** Dítě dostalo sáček, v němž bylo 5 červených a 5 žlutých bonbónů. Dítě náhodně vybralo ze sáčku 6 bonbónů. Jaká je pravděpodobnost, že mezi vybranými bonbóny budou právě 2 červené?

**Příklad 38 (multinomické rozdělení – definice).** Nechť  $N$  je počet nezávislých identických pokusů a v každém z nich může nastat  $J \geq 2$  navzájem disjunktních událostí s možnými odpověďmi  $X_{ij} = 1$  (událost nastala) nebo  $X_{ij} = 0$  (událost nenastala), kde  $i = 1, 2, \dots, N$  a  $j = 1, 2, \dots, J$ . Potom  $X_j = \sum_{i=1}^N X_{ij}$ . Pravděpodobnost nastání  $j$ -té události v  $i$ -tém pokuse  $\Pr(X_{ij} = 1) = p_j$ ,  $\sum_{j=1}^J p_j = 1$ . Náhodná proměnná  $\mathbf{X} = (X_1, \dots, X_J)^T$  má ( $J$ -rozměrné) multinomické rozdělení s parametry  $N$  a  $\mathbf{p}$ , t.j.  $\mathbf{X} \sim \text{Mult}_J(N, \mathbf{p})$ . Pravděpodobnost, že  $X_j$  je rovné nějakému číslu  $n_j$  zapisujeme jako

$$\Pr(X_1 = x_1, \dots, X_J = x_J) = \frac{N!}{x_1! x_2! \dots x_J!} p_1^{x_1} p_2^{x_2} \dots p_J^{x_J} = \frac{N!}{\prod_j x_j!} \prod_{j=1}^J p_j^{x_j},$$

kde  $N = \sum_{j=1}^J X_j$ ,  $X_j \geq 0$  a  $x_j = n_j$  jsou realizace  $X_j$ . Potom  $\mathbf{n} = (n_1, n_2, \dots, n_J)^T$ . Pro marginální rozdělení píšeme  $X_j \sim \text{Bin}(N, p_j)$ , kde střední hodnota  $E[X_j] = Np_j$ , rozptyl  $\text{Var}[X_j] = Np_j(1-p_j)$ , kovariance  $\text{Cov}[X_i, X_j] = -Np_i p_j$ , korelační koeficient  $\text{Cor}[X_i, X_j] = (-p_i p_j)/\sqrt{p_i(1-p_i)p_j(1-p_j)}$ . Střední hodnota  $E[\mathbf{X}] = N\mathbf{p}$  a kovarianční matice  $\text{Var}[\mathbf{X}] = N(\mathbf{D}_{\mathbf{p}} - \mathbf{p}\mathbf{p}^T)$ , kde  $\mathbf{D}_{\mathbf{p}} = \text{diag}(\mathbf{p})$  a

$$(\mathbf{D}_{\mathbf{p}} - \mathbf{p}\mathbf{p}^T)_{ij} = \begin{cases} p_i(1-p_i) & \text{pokud } i=j \\ -p_i p_j & \text{pokud } i \neq j. \end{cases}$$

**Příklad 39 (multinomické rozdělení).** Mějme proměnnou barva vlasů (blond – BlH, hnědá – BrH, zrzavá – RH) a proměnnou barva očí (modrá – BlE, hnědá – BrE, zelená – GE). Jejich interakce jsou uspořádané v tabulce jako  $X_1$  (BlH-BlE),  $X_2$  (BlH-BrE),  $X_3$  (BlH-GE),  $X_4$  (BrH-BlE),  $X_5$  (BrH-BrE),  $X_6$  (BrH-GE),  $X_7$  (RH-BlE),  $X_8$  (RH-BrE),  $X_9$  (RH-GE). Předpokládejme, že máme náhodný výběr s rozsahem  $N = 100$ . Pravděpodobnosti  $p_j$ ,  $j = 1, \dots, 9$  viz následující tabulka.

Barva vlasů / barva očí	modrá (BlE)	hnědá (BrE)	zelená (GE)
blond (BlH)	0.12	0.15	0.03
hnědá (BrH)	0.22	0.34	0.04
zrzavá (RH)	0.06	0.01	0.03

Vypočítejte  $E[X_2]$ ,  $E[X_8]$ ,  $\text{Var}[X_2]$ ,  $\text{Var}[X_8]$ ,  $\text{Cov}[X_2, X_8]$  a  $\text{Cor}[X_2, X_8]$ .

**Příklad 40 (součinové multinomické rozdělení – definice).** Nechť  $N_k$  je počet nezávislých identických pokusů a v každém z nich může nastat  $J \geq 2$  navzájem disjunktních událostí s možnými odpověďmi  $X_{kji} = 1$  (událost nastala) anebo  $X_{kji} = 0$  (událost nenastala), kde  $i = 1, 2, \dots, N_k$ ,  $k = 1, 2, \dots, K$  a  $j = 1, 2, \dots, J$ . Nechť  $X_{kj}$  =  $\sum_{i=1}^{N_k} X_{kji}$  a  $\sum_{k=1}^K N_k = N$ . Pravděpodobnost nastání ( $j$ -té události v  $i$ -tém pokuse  $k$ -té skupiny) je  $\Pr(X_{kji} = 1) = p_{kj} = p_{j|k}$ ,  $\sum_{j=1}^J p_{kj} = 1$ . Náhodná proměnná  $\mathbf{X}_k = (X_{k1}, X_{k2}, \dots, X_{kJ})^T$  má ( $J$ -rozměrné) multinomické rozdělení s parametry  $N_k$  a  $\mathbf{p}_k = (p_{k1}, \dots, p_{kJ})^T$ , t.j.  $\mathbf{X}_k \sim \text{Mult}_J(N_k, \mathbf{p}_k)$ . Realizace náhodné proměnné  $\mathbf{X}_k$  označujeme jako  $\mathbf{x}_k$ . Potom  $x_{kj} = n_{kj}$  a navíc  $\mathbf{n}_k = (n_{k1}, n_{k2}, \dots, n_{kJ})^T$ . Nechť  $\mathbf{X}_k$  jsou nezávislé, potom  $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_K)^T$  má součinové multinomické rozdělení s parametry  $\boldsymbol{\theta}_k = \mathbf{p}_k$ ,  $k = 1, 2, \dots, K$ .

**Příklad 41 (součinové multinomické rozdělení).** 1. Mějme data z příkladu 39 a náhodný výběr s rozsahy  $N_1 = 30$  pro blond barvu vlasů,  $N_2 = 60$  pro hnědou barvu vlasů a  $N_3 = 10$  pro zrzavou barvu vlasů. Označme interakce proměnných následovně:  $X_{11} = X_{1|1}$  (BlH-BlE),  $X_{12} = X_{2|1}$  (BlH-BrE),  $X_{13} = X_{3|1}$  (BlH-GE),  $X_{21} = X_{1|2}$  (BrH-BlE),  $X_{22} = X_{2|2}$  (BrH-BrE),  $X_{23} = X_{3|2}$  (BrH-GE),  $X_{31} = X_{1|3}$  (RH-BlE),  $X_{32} = X_{2|3}$  (RH-BrE),  $X_{33} = X_{3|3}$  (RH-GE), kde  $\mathbf{X}_1 = (X_{11}, X_{12}, X_{13})^T$ ,  $\mathbf{X}_2 = (X_{21}, X_{22}, X_{23})^T$  a  $\mathbf{X}_3 = (X_{31}, X_{32}, X_{33})^T$ . Potom  $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3)^T$  má součinové multinomické rozdělení s  $K = 3$ ,  $N_1 = 30$ ,  $J_1 = 3$ ,  $N_2 = 60$ ,  $J_2 = 3$  a  $N_3 = 10$ ,  $J_3 = 3$ . Zápis s  $X_{j|k}$ , kde  $j = 1, 2, 3$  a  $k = 1, 2, 3$  zvýrazňuje fakt, že rozdělení je podmíněno barvou vlasů, t.j. rozdělení ve sloupcích tabulky je podmíněné jejím rádkem. Realizace  $x_{j|k}$  značíme jako  $n_{j|k}$ , pravděpodobnosti ekvivalentní  $X_{j|k} = x_{j|k}$  značíme jako  $p_{j|k} = p_{kj}$ . Vypočítejte podmíněné pravděpodobnosti  $p_{j|k}$ , očekávané početnosti  $N_k p_{kj}$ ,  $\text{Var}[X_{22}]$ ,  $\text{Var}[X_{32}]$ ,  $\text{Var}[X_{23}]$ ,  $\text{Cov}[X_{22}, X_{32}]$ ,  $\text{Cov}[X_{22}, X_{32}]$  a  $\text{Cor}[X_{22}, X_{32}]$ ,  $\text{Cor}[X_{22}, X_{23}]$ .

2. Celý postup zopakujte pro  $N_1 = 20$ ,  $N_2 = 30$  a  $N_3 = 50$ .

**Příklad 42 (součinové multinomické rozdělení).** Mějme proměnnou barva vlasů (blond – BlH, hnědá – BrH, zrzavá – RH) a proměnnou barva očí (modrá – BlE, hnědá – BrE, zelená – GE). Jejich interakce jsou uspořádané v tabulce jako  $X_1$  (BlH-BlE),  $X_2$  (BlH-BrE),  $X_3$  (BlH-GE),  $X_4$  (BrH-BlE),  $X_5$  (BrH-BrE),  $X_6$  (BrH-GE),  $X_7$  (RH-BlE),  $X_8$  (RH-BrE),  $X_9$  (RH-GE). Jim odpovídají pravděpodobnosti  $p_j$ ,  $j = 1, \dots, 9$

Barva vlasů / barva očí	modrá (BlE)	hnědá (BrE)	zelená (GE)
blond (BlH)	0.12	0.15	0.03
hnědá (BrH)	0.22	0.34	0.04
zrzavá (RH)	0.06	0.01	0.03

$\mathbf{X} = (X_1, X_2, \dots, X_9)^T \sim \text{Mult}_9(N, \mathbf{p})$ . Transformujte multinomický model na součinový multinomický model následovně:

1. vypočítejte rádkově marginální pravděpodobnosti  $p_j$ ;
2. vypočítejte sloupcově marginální pravděpodobnosti  $p_k$ ;

3. podmíněné pravděpodobnosti  $p_{j|k} = p_{kj}$ ;

Jakému číslu jsou rovné sumy  $\sum_{j=1}^3 p_{j|k}$  pro každé  $k$ ?