

## Zadání příkladů - cvičení č.1 - 15-9-23

### Příklad č.1 (porovnání dvou typů modelů) (přednáška)

Model rozdělení pravděpodobnosti je modelem náhodné proměnné  $X$ , např. (1) model rozdělení pravděpodobnosti náhodné proměnné  $X$  šířka dolní čelisti, nebo (2) model rozdělení pravděpodobnosti náhodné proměnné  $X$  hrubost kožních řas u dospělých zdravých žen. *Statistický model* je modelem náhodné proměnné  $Y|X$  ( $Y$  kauzálně závisí na  $X$ ), např. (1) model závislosti náhodné proměnné  $Y$  šířka dolní čelisti na proměnné  $X$  pohlaví, nebo (2) model závislosti náhodné proměnné  $Y$  hrubost kožních řas u dospělých zdravých žen na proměnné  $X$  BMI. Všimněte si, že náhodné proměnné označujeme  $X$  anebo  $Y$  podle toho, jaký model je charakterizuje.

### Příklad č.2 (jednoduchý náhodný výběr)




V jednoduchém náhodném výběru o rozsahu  $n$  z populace s konečným rozsahem  $N$  má každý prvek stejnou pravděpodobnost vybrání. Pokud vybíráme bez vracení (opakování), mluvíme o *jednoduchém náhodném výběru bez vracení* (Dalgaard, 2008). Pokud vybíráme s vracením, mluvíme o *jednoduchém náhodném výběru s vracením*. Mějme množinu  $\mathcal{M}$  s  $N = 10$  prvky a chceme z ní vybrat  $n = 3$  prvky (a) bez vracení, (b) s vracením. Kolik máme možností? Jak vypadá jedna takováto možnost, pokud  $\mathcal{M} = \{1, 2, \dots, 10\}$ ? Zopakujte to samé pro  $N = 100$ ,  $n = 30$  a množinu  $\mathcal{M} = \{1, 2, \dots, 100\}$ .

### Příklad č.3 (jednoduchý náhodný výběr)

Mějme skupinu lidí označených identifikačními čísly (ID) od 1 do 30. Vyberte (a) náhodně 5 lidí z 30-ti bez návratu, (b) náhodně 5 lidí ze 30-ti s návratem a nakonec (c) náhodně 5 lidí ze 30-ti bez návratu, přičemž lidé s ID od 28-mi do 30-ti mají pravděpodobnost vybrání  $4 \times$  vyšší než lidé s ID od 1 do 27.

### Příklad č.4 (normální rozdělení)

Mějme náhodnou proměnnou  $X$  (může to být např. výška postavy desetiletých dívek) a předpokládejme, že tato náhodná proměnná má normální rozdělení s parametry  $\mu$  (střední hodnota) a  $\sigma^2$  (rozptyl), což zapisujeme jako  $X \sim N(\mu, \sigma^2)$ ,  $\mu = 140.83$ ,  $\sigma^2 = 33.79$ . Normální rozdělení představuje model rozdělení pravděpodobnosti pro tuto náhodnou proměnnou. Vypočítejte pravděpodobnost  $\Pr(a \leq X \leq b) = \Pr(X < b) - \Pr(X < a) = F_X(b) - F_X(a)$ , kde  $a = \mu - k\sigma$ ,  $b = \mu + k\sigma$ ,  $k = 1, 2, 3$ . Nakreslete hustotu rozdělení pravděpodobnosti, vybarvěte oblast mezi body  $a$  a  $b$  a popište osy  $x$  a  $y$  tak, jako je uvedeno na obrázku 1.




Obrázek 1: Míry normálního rozdělení; křivka hustoty s vybarveným obsahem pod touto křivkou mezi příslušnými kvantily na ose  $x$ ; obsah je rovný pravděpodobnosti výskytu subjektů s danou výškou v rozpětí těchto kvantilů.

Dostaneme pravidlo 68.27 – 95.45 – 99.73 (tzv. *míry normálního rozdělení*).

### Příklad č.5 (normální rozdělení)

Mějme  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 150$ ,  $\sigma^2 = 6.25$ . Vypočítejte  $a = \mu - x_{1-\alpha/2}\sigma$  a  $b = \mu + x_{1-\alpha/2}\sigma$  tak, aby  $\Pr(a \leq X \leq b) = 1 - \alpha$ , byla rovná 0.9, 0.95, 0.99. Číslo  $x_{1-\alpha/2}$  je kvantil normovaného normálního rozdělení, t.j.  $\Pr(Z = \frac{X-\mu}{\sigma} < x_{1-\alpha}, Z \sim N(0, 1))$ . Nakreslete hustotu rozdělení pravděpodobnosti, vybarvěte oblast mezi body  $a$  a  $b$  a popište osy  $x$  a  $y$  tak, jako je uvedeno na obrázku 2.



Obrázek 2: Upravené míry normálního rozdělení; křivka hustoty s vybarveným obsahem pod touto křivkou mezi příslušnými kvantily na ose  $x$ ; obsah je rovný pravděpodobnosti výskytu subjektů s danou normovanou výškou v rozpětí těchto kvantilů.

Dostaneme pravidlo 90 – 95 – 99 (tzv. *upravené míry normálního rozdělení*). Použili jsme nerovnost  $\Pr(u_{\alpha/2} < Z < u_{1-\alpha/2}) = \Phi(x_{1-\alpha/2}) - \Phi(x_{\alpha/2}) = 1 - \alpha$ , kde  $\Phi$  je distribuční funkce normálního normovaného rozdělení a všeobecně ( $\alpha \in (0, 1/2)$ ); v příkladě  $\alpha = 0.1, 0.05$  a  $0.01$ .

### Příklad č.6 (normální rozdělení)

Předpokládejme model normálního rozdělení  $N(130, 13^2)$  pro systolický krevní tlak. Jaká část populace (v %) bude mít hodnoty vyšší než 160 mm Hg?

### Příklad č.7 (binomické rozdělení)

Předpokládejme, že počet lidí upřednostňujících léčbu  $A$  před léčbou  $B$  se řídí modelem binomického rozdělení s parametry  $N$  (rozsah náhodného výběru) a  $p$  (pravděpodobnost výskytu), ozn.  $Bin(N, p)$ , kde  $N = 20$ ,  $p = 0.5$ , t.j. lidé preferují oba dva typy léčby stejnou měrou. (a) Jaká je pravděpodobnost, že 16 a více pacientů upřednostní léčbu  $A$  před léčbou  $B$ ? (b) Jaká je pravděpodobnost, že 16 a více a zároveň 4 a méně pacientů upřednostní léčbu  $A$  před léčbou  $B$ ?

### Příklad č.8 (binomické rozdělení)

Předpokládejme, že  $\Pr(vir) = 0.533 = p_1$  je pravděpodobnost výskytu dermatoglyfického vzoru vír na palci pravé ruky mužů české populace a  $\Pr(ostatni) = 0.467 = p_2$  je pravděpodobnost výskytu ostatních vzorů na palci pravé ruky mužů české populace, přičemž  $X$  je počet vírů a  $Y$  je počet

ostatních vzorů, kde  $X \sim \text{Bin}(N, p_1)$  a  $Y \sim \text{Bin}(N, p_2)$ . Vypočítejte (1)  $\Pr(X \leq 120)$ , když  $N = 300$  a (2)  $\Pr(Y \leq 120)$ , když  $N = 300$ .

**Příklad č.9 (parametry)** (*přednáška*)

Příklady parametrů  $\theta$  - střední hodnota  $\mu$ , rozptyl  $\sigma^2$ , korelační koeficient  $\rho$ , pravděpodobnost  $p$  výskytu nějaké události, rozdíl dvou středních hodnot  $\mu_1 - \mu_2$ , podíl dvou rozptylů  $\sigma_1^2/\sigma_2^2$ , rozdíl dvou korelačních koeficientů  $\rho_1 - \rho_2$ , rozdíl dvou pravděpodobností  $p_1 - p_2$  apod.

**Příklad č.10 (binomické rozdělení)** (*přednáška*)

Pokud  $X \sim \text{Bin}(N, \theta)$ ,  $\theta = p \in \langle 0; 1 \rangle$ , potom  $\mathcal{Y}_\theta$  je stejný pro všechny  $\theta$  a koinciduje s výběrovým prostorem  $\mathcal{Y} = \{0, 1, \dots, N\}$ .

**Příklad č.11 (počet členů v mnohorozměrném LRM)** (*z přednášky*)

Mějme mnohorozměrný lineární regresní model  $\mathcal{L}$  o 20-ti proměnných, ve kterém jsou obsaženy všechny možné interakce těchto proměnných (dvojné, trojné, ...). Kolik členů (jednoduché regresory + všechny interakce) má takový model?