

NÁHODNÝ VZOREK (RANDOM SAMPLE)

- seříděná konečná sekvence (zde reálných čísel) : $\{l_i\}_{i=1}^m$

a) definiční obor (zde \mathbb{R}) tvoří pravděpodobnostní prostor

b) funkce pravděpodobnosti pr definuje pravděpodobnost

výskytu prvku \tilde{l}_j : $pr(\tilde{l}_j) = c_j/m$, kde

c_j je četnost (frekvence) prvku \tilde{l}_j v sekvenci l

- poznámka : četnost výskytu všech možných hodnot

v sekvenci je celková pravděpodobnost

$$pr(l) = \sum_{j=1}^m pr(\tilde{l}_j) = 1$$

m ... počet různých prvků v sekvenci l

STATISTICKÉ PARAMETRY NÁHODNÉHO VZORKU

- střední hodnota vzorku $l = \{l_i\}_{i=1}^n$:

$$m_l = \frac{1}{n} \sum_{i=1}^n l_i = \sum_{j=1}^m \tilde{l}_j \text{pr}(\tilde{l}_j)$$

• použití expektace $m_l = E(l)$

- variance náhodného vzorku :

$$s_l^2 = \frac{1}{n} \sum_{i=1}^n (l_i - m_l)^2 = \sum_{j=1}^m (\tilde{l}_j - m_l)^2 \text{pr}(\tilde{l}_j)$$

• použití expektace $s_l^2 = E[l - E(l)]^2$


- další parametry : - median

- rozsah

} náhodného vzorku

HISTOGRAM A POLYGON

- seřazený náhodný vzorek $\{l_i\}_{i=1}^n$ lze rozdělit do tříd $\{\tilde{l}_j\}_{j=1}^m$



- pravděpodobnost, že $l_i = \tilde{l}_j$

$$pr(\tilde{l}_j) = \frac{c_j}{n}$$

kde $c_j \dots$ četnost $l \in \tilde{l}_j$

- pospojované středy tvoří tzv. **polygon** (nutno přidat 2 třídy)

- celková oblast pod polygonem je rovna 1

- polygon lze využít pro určení pravděpodobnosti hodnoty v určitém

- **integrace**

NÁHODNÁ PROMĚNNÁ (RANDOM VARIABLE)

- zobrazení konceptu náhodného vektoru
- každé hodnotě $l \in \mathbb{R}$ je přiřazeno kladné reálné číslo $\phi(l)$
- reálná funkce $\phi \in \{ \mathbb{R} \rightarrow \langle 0, \infty \rangle \}$ se nazývá

funkce hustoty pravděpodobnosti proměnné l

- funkce ϕ představuje vyhlazený polygon, tj. situaci, kdy $n \rightarrow \infty$ a také $m \rightarrow \infty$ ($\check{c}_j \rightarrow dl$)

- stále platí, že $\int_{\mathbb{R}} \phi(l) dl = 1$

(porovnej s výrazem pro náhodný vektor)

NÁHODNÝ VZOREK VS. NÁHODNÁ PROMĚNNÁ

- náhodný vzorek = vybrané (měřené) hodnoty náhodné proměnné
- střední hodnota náhodné proměnné l :

$$\mu_e = \int_{-\infty}^{\infty} \phi(l, \xi_1^l, \xi_2^l, \dots) l \, dl \neq m_e$$

- variance náhodné proměnné:

$$\sigma_e^2 = \int_{-\infty}^{\infty} \phi(l, \xi_1^l, \xi_2^l, \dots) (l - \mu_e)^2 \, dl \neq s_e^2$$

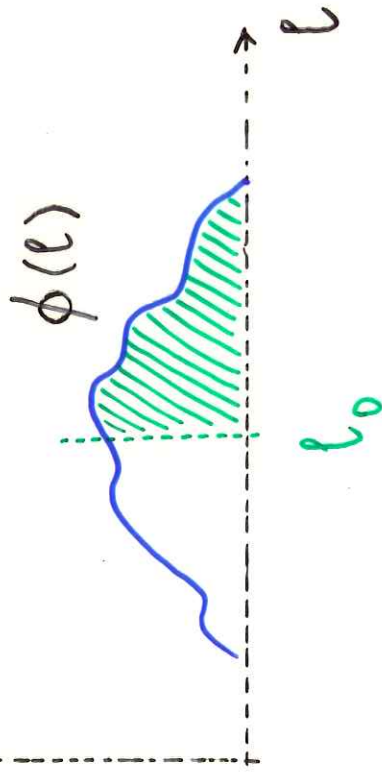
- mělo by ale stále platit: $\mu_e = E(m_e)$

$$\sigma_e^2 = E(s_e^2)$$

FUNKCE HUSTOTY PRAVDĚPODOBNOTI

- funkce $\phi \in \{ \mathbb{R} \rightarrow \langle 0, \infty \rangle \}$: platí, že

$$\int_{-\infty}^{\infty} \phi(l) dl = \text{pr}(-\infty \leq l \leq \infty) = 1$$



$$\int_{l_0}^{\infty} \phi(l) dl = \text{pr}(l \geq l_0)$$

: atd.

- funkce ϕ má obecně libovolný počet parametrů, zde pouze 2:

$$\phi(l, \xi_1^l, \xi_2^l) : \xi_1^l = \mu_l, \xi_2^l = \sigma_l^2$$



- nebo se používají hodnoty m_l a s_l^2 (vzorek)

ZÁKLADNÍ POSTULÁT STATISTIKY



- každý náhodný vzorek má svoji "materštinu" náhodnou proměnnou, které odpovídá příslušná funkce hustoty pravděpodobnosti
- správnost této hypotézy bude muset být testována:
 - správnost **matematického vyjádření** funkce ϕ
 - správnost volby **parametrů** ξ_1^l, ξ_2^l, \dots
- správně zvolená funkce ϕ = správně zodpovězené otázky ohledně pravděpodobnosti výskytu hodnot ve vzorku a dalších statistických vlastností

PŘÍKLADY ŠPATNÉHO ODHADU FUNKCE HUSTOTY PRAVDĚPOBNOSTI

- matematický popis funkce ϕ :



- parametrický popis funkce ϕ : $\phi(l, \xi_1^l, \xi_2^l)$



\Rightarrow nutné testy!

VEKTOR NÁHODNÝCH PROMĚNNÝCH

- další zobecnění konceptu : $\underline{l} = [l_1, l_2, \dots, l_m]$ + $\phi(\underline{l})$

každá složka vektoru \underline{l} je náhodná proměnná

- funkce hustoty pravděpodobnosti $\phi(\underline{l}) \in \{ \mathbb{R}^m \rightarrow \langle 0, \infty \rangle \}$

obecně $\phi(\underline{l}, \xi_1^l, \xi_2^l) = \phi_e(\underline{\mu}_e, \underline{\sigma}_e^2)$,

kde $\underline{\mu}_e = [\mu_{e_1}, \mu_{e_2}, \dots, \mu_{e_m}]^T$, $\underline{\sigma}_e^2 = [\sigma_{e_1}^2, \dots, \sigma_{e_m}^2]^T$

- pravděpodobnost :

$$Pr(\underline{l}_1 \leq \underline{l} \leq \underline{l}_2) = \int_{\underline{l}_1}^{\underline{l}_2} \phi(\underline{l}, \xi_1^l, \xi_2^l) d\underline{l}$$

... n -dimenzionální integrace

VARIANČNĚ - KOVARIANČNÍ MATICE

- kovariance mezi dvěma prvky vektoru \underline{l} - l_j a l_k :

$$\begin{aligned}\hat{\sigma}_{jk} &= \int_{\mathbb{R}^n} (l_j - \mu_{e_j})(l_k - \mu_{e_k}) \phi(\underline{l}) d\underline{l} = \\ &= E[(l_j - \mu_{e_j})(l_k - \mu_{e_k})] = \hat{\sigma}_{kj}\end{aligned}$$

- pro statisticky nezávislé prvky platí $\hat{\sigma}_{jk} = \hat{\sigma}_{kj} = 0$

$$\text{- matice } \underline{C}_{\underline{l}} = \begin{bmatrix} \hat{\sigma}_{e_1}^2 & \hat{\sigma}_{e_1 e_2} & \dots & \hat{\sigma}_{e_1 e_n} \\ \hat{\sigma}_{e_2 e_1} & \hat{\sigma}_{e_2}^2 & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\sigma}_{e_n e_1} & \dots & \dots & \hat{\sigma}_{e_n}^2 \end{bmatrix} = \underline{E}[\underline{(l - \underline{\mu}_e)(l - \underline{\mu}_e)^T}]$$

vlastnosti $\underline{C}_{\underline{l}}$?

STATISTICKÁ ZÁVISLOST - NEZÁVISLOST

- někdy lze psát $\phi(\underline{l}) = \phi_1(l_1) \cdot \phi_2(l_2) \dots \phi_n(l_n)$

- pak také platí, že

$$\text{pr}(\underline{l}_1 \leq \underline{l} \leq \underline{l}_2) = \prod_{i=1}^n \text{pr}(l_{1,i} \leq l_i \leq l_{2,i})$$

a komponenty vektoru \underline{l} jsou statisticky nezávislé

- velmi důležitý koncept, neboť variance nejjadřivějších stochastické vlastnosti vektoru náhodných proměnných úplně \Rightarrow nutnost rozšíření vektoru variancí na

variančně - kovarianční matrici

ŽPĚT K REALITĚ : NÁHODNÉ VZORKY

- vektor měření $\underline{l} = [l_1 \ l_2 \ \dots \ l_n]^T$, $l_i \dots$ náhodný vzorek
- vektor středních hodnot $\underline{m}_l = [m_{e_1} \ m_{e_2} \ \dots \ m_{e_n}]^T$
- vektor variancí $\underline{S}^2_l = [S^2_{e_1} \ S^2_{e_2} \ \dots \ S^2_{e_n}]^T$
- + kovariance $S_{jk} = \frac{1}{n} \sum_{i=1}^n [(l_j - m_{e_j}) (l_k - m_{e_k})]$

pozor: výpočet kovariancí mezi prvky vektoru náhodných

vzorků je většinou nemožný (viz. předpoklady) \Rightarrow

\Rightarrow variančně - kovarianční matici nelze dát dohromady

- její odhad : kritická záležitost !

MÍRA STATISTICKÉ ZÁVISLOSTI - KORELACE

- korelační koeficient $\rho_{jk} = \frac{S_{jk}}{s_j \cdot s_k}$, $s_j \neq 0, s_k \neq 0$

- pro korelační koeficient platí:

a) $\rho \in (-1, +1)$

b) $\rho_{jk} = 0 \Rightarrow l_j$ a l_k nekorelované

c) $|\rho_{jk}| < 1 \Rightarrow l_j$ a l_k korelované

d) $\rho_{jk} = \pm 1 \dots l_j$ a l_k úplně korelované

- vektor náhodných proměnných: $S \rightarrow \zeta$

} vztah ke statistické závislosti?

MATEMATICKÁ STATISTIKA

- systematická metoda pro studium stochastických vlastností parametrů
 - upozornění: statistika musí být používána opatrně ve spojení s praktickými zkušenostmi, dalšími důkazy a "selstým rozumem"
 - statistika může určit stupeň důvěryhodnosti v řešení rovnaní
 - možné poddělení statistiky:
 - **parametrická**: normální rozdělení
 - **robustní**: i pro nenormální rozdělení
 - **neparametrická**: nezávisle na rozdělení
 - **Bayesovská**: apriori informace o x a \underline{L}_x
- bez apriori informací

STATISTICKÉ TESTOVÁNÍ

- může poskytnout odpovědi na otázky typu:
 - odpovídá zvolená funkce hustoty pravděpodobnosti danému vzorku?
 - jsou parametry funkce hustoty pravděpodobnosti zvoleny správně?
 - jsou tyto parametry konsistentní s jejich jinými odhady?
- hypotéza: kvantitativní výrok o funkci hustoty pravděpodobnosti a hodnotách jejich parametrů
- nulová hypotéza vs. alternativní hypotézy : testování na základě statistické proměnné, která je funkcí parametrů funkce hustoty pravděpodobnosti

STATISTICKÁ PROMĚNNÁ

- nástroj k ověření či vyloučení platnosti dané hypotézy
- obecně: statistická proměnná y má funkci hustoty pravděpodobnosti s obdobně funkce vzorku l :

$$\phi_y(\xi_1^y, \xi_2^y) = \det \underline{J} \phi_e(\xi_1^e, \xi_2^e)$$

- důležité: každá hypotéza H_0 má svoji funkci ϕ_y a proměnnou y
- problém: většina testů hypotéz platí pro náhodné proměnné a jejich platnost pro náhodné vzorky je limitována

\Rightarrow nutné testovat vztah vzorku a proměnné!

TESTOVÁNÍ STATISTICKÝCH HYPOTÉZ

- testování platnosti hypotézy H_0 : přijmout - vyloučit
- stejný osud se týká testu alternativní hypotézy H_1 :
- testování H_0 a H_1 by mělo vést k závěru, které z hypotéz se dá více věřit \Rightarrow žádná absolutně platná odpověď!
- pozor: neplatnost hypotézy H_0 (dle výsledku testu)
neznamená platnost hypotézy H_1 a obráceně!
- každý výsledek testu má pouze omezenou platnost resp. je spojen s jistou mírou pravděpodobnosti \Rightarrow chyby jsou možné (např. test přijme H_0 , ale H_0 neplatí)

TYPY CHYB PŘI STATISTICKÉM TESTOVÁNÍ HYPOTÉZ


- chyba 1. druhu : H_0 je zamítnuta, ale ve skutečnosti je správně
- chyba 2. druhu : H_0 je přijata, ale ve skutečnosti není správně
- pravděpodobnost chyby 1. druhu je dána úrovní významnosti α ,
 $\alpha \in (0, 1)$ - volí se pokud možno co nejmenší; bohužel pro
 $\alpha = 0$ neexistuje žádná přijatelná hypotéza H_0 .
- pravděpodobnost chyby 2. druhu je dána silou testu $1 - \beta$,
 $\beta \in (0, 1)$, hodnota β by měla být také malá a
 $\beta > 0$, hodnoty α a β jsou na sobě závislé!

HLADINA VÝZNAMNOSTI α

- v geodézii se nejčastěji používá $\alpha \in \langle 0, 01; 0, 05 \rangle$

- rozdíl $1 - \alpha$ se nazývá hladina pravděpodobnosti

$$Pr (y > y_{1-\alpha}) = \int_{y_{1-\alpha}}^{\infty} \phi(y, \xi_1^y, \xi_2^y) dy = \alpha$$



- alternativní hypotéza H_1 :


funkce ϕ_{y, H_1} má většinou

stejnou formu jako ϕ_{y, H_0} , liš se hodnoty parametrů tj.

$$\phi_{y, H_0} (\xi_1^y, \xi_2^y) \text{ vs. } \phi_{y, H_1} (\hat{\xi}_1^y, \hat{\xi}_2^y)$$

SÍLA STATISTICKÉHO TESTU β

- míra odlišitelnosti dvou statistických hypotéz



- alternativní hypotéza \mathcal{H}_1
se má dostatečně lišit od \mathcal{H}_0
ale ne zbytečně mnoho

- hypotéza \mathcal{H}_1 je lepší
než \mathcal{H}_2 , neboť $\beta_1 < \beta_2$

- platí: $\text{pr}(y < y_{1-\alpha}) = \int_{-\infty}^{y_{1-\alpha}} \phi_{\mathcal{H}_1}(y, \xi_1^y, \xi_2^y) dy = \beta$


TESTOVÁNÍ HYPOTÉZY H_0 A JEJÍ ALTERNATIVY

výstup situace	test říká přijmi H_0	test říká zamítni H_0
H_0 je správně	správně rozhodnutí pr = $1 - \alpha$	chyba 1. druhu pr = α
H_0 je špatně	chyba 2. druhu pr = β	správně rozhodnutí pr = $1 - \beta$

- zmenšení hodnoty α = zvětšení hodnoty β
=> nutný kompromis !!

OBLASTI PRAVDĚPODOBNOSTI

- alternativa k testování hypotéz (= nutná formulace hypotéz)
- pravděpodobnost $\text{pr} (y_{\frac{\alpha}{2}} < y < y_{1-\frac{\alpha}{2}}) = 1 - \alpha$



- kritická úroveň významnosti $\alpha_c = \text{pr} (y > y_0)$
- nastane - li $\alpha > \alpha_c \Rightarrow \text{ll}_0$ není přijatelná na hladině α
- testy mohou být jednostranný či dvostranný (viz. obrázky)