

O b s a h

Úvod	Parametrické a neparametrické modely ...	7
Kapitola 1.	Opakování základů teorie testování hypotéz	13
1.1.	Formulace problému	13
1.2.	Princip invariance v testování hypotéz	19
Kapitola 2.	Základní výběrové statistiky: pořadí a pořádkové statistiky	25
	Problémy a cvičení	33
Kapitola 3.	Testy hypotézy o shodnosti dvou populací	35
3.1.	Dvouvýběrový t-test	35
3.2.	F-test	37
3.3.	Permutační t-test	38
3.4.	Pořadové testy rozdílu v poloze dvou populací	43
3.4.1.	Klotzův test	56
3.5.2.	Kvartilový test	57
3.6.	Testy založené na empirických distri- bučních funkcích	58
3.6.1.	Kolmogorov-Smirnovův test	60
3.6.2.	Cramér-von Misesův test	63
3.7.	Pořadové testy při výskytu shodných pozorování	64
3.7.1.	Metoda znáhodnění	66
3.7.2.	Metoda průměrných pořadí	67

Kapitola 4.	Testy hypotézy o symetrii jednoroz- měrného a dvourozměrného rozdělení ...	71
4.1.	Párový t-test	72
4.2.	Testy H_1 založené na pořadích	72
4.2.1.	Wilcoxonův test symetrie	75
4.2.2.	Znaménkový test	76
4.3.	Problémy a cvičení	80
Kapitola 5.	Testy hypotézy o shodnosti několika populací (ošetření)	83
5.1.	Model jednoduchého třídění	83
5.1.1.	F-test	84
5.1.2.	Kruskal-Wallisův pořadový test	84
5.1.3.	Mediánový test	87
5.2.	Model dvojného třídění (náhodné bloky)	87
5.2.1.	F-test	89
5.2.2.	Friedmanův pořadový test	89
5.3.	Problémy a cvičení	91
Kapitola 6.	Testy hypotézy nazávislosti ve dvourozměrné populaci	93
6.1.	t-test	94
6.2.	Permutační t-test	95
6.3.	Pořadové testy nezávislosti	97
6.3.1.	Spearmanův korelační koeficient	98
6.3.2.	Kvadrantový test	100
6.3.3.	Kendallův pořadový korelační koefi- cient	100
6.4.	Problémy a cvičení	101

Kapitola 7.	Některé úvahy o vydatnosti a optimalitě testů	103
7.1.	Lokálně nejsilnější pořadové testy ..	104
7.1.1.	Lokálně nejsilnější pořadové testy hypotézy náhodnosti	105
7.1.2.	Lokálně nejsilnější pořadové testy hypotézy symetrie	114
7.1.3.	Lokálně nejsilnější pořadové testy pro hypotézu nezávislosti	116
7.2.	Asymptotická relativní vydatnost testů	117
7.2.1.	Pitmanova vydatnost	118
Tabulka 1.	Jednovýběrový Wilcoxonův test ..	128
Tabulka 2.	Wilcoxonův test	129
Tabulka 3.	Van der Waerdenův test	137
Tabulka 4.	Kolmogorov-Smirnovův test	138
Tabulka 5.	Spearmanův test	140
Literatura		141

Úvod : Parametrické a neparametrické modely

Matematická statistika zpracovává data, která vznikla při realizaci nějakého náhodného pokusu. Z těchto dat pak odvozuje závěry o celé populaci, a to pokud možno optimálním způsobem.

Dříve, než může statistik odvodit jakékoli závěry o populaci, musí uvážit, co lze předpokládat o rozdělení pravděpodobnosti pozorovaných dat; závěry pak odvozuje v rámci těchto předpokladů. Silnější předpoklady umožňují použít objektivnější metody odhadu, testu, apod.; nejsou-li však tyto předpoklady splněny, je nebezpečí, že závěry, jakkoli za daných předpokladů správné, mohou být naprosto nevhodné pro danou experimentální situaci.

Tento problém nejlépe objasníme na konkrétních příkladech.

Příklad 1. Model měření. Experimentátor provede n nezávislých určení (měření) X_1, \dots, X_n hodnoty určité fyzikální konstanty μ . Jeho měření podléhají náhodným fluktuacím (chybám), proto můžeme psát

$$(1) \quad X_i = \mu + \varepsilon_i, \quad i=1, \dots, n$$

kde $\varepsilon = (\varepsilon_1, \dots, \varepsilon_n)$ je vektor chyb. Co lze předpokládat o rozdělení pravděpodobností vektoru ε , které spolu s hodnotou μ určuje sdružené rozdělení X_1, \dots, X_n ? Obvykle přijímáme tyto minimální předpoklady :

- (1) Rozdělení ε nezávisí na μ .
- (2) $\varepsilon_1, \dots, \varepsilon_n$ jsou nezávislé.

- (3) $\varepsilon_1, \dots, \varepsilon_n$ mají stejné rozdělení.
(4) Společné rozdělení $\varepsilon_1, \dots, \varepsilon_n$ je absolutně spojitě s hustotou symetrickou kolem 0.

Těmito předpoklady jsme již vymezili model, který se ve statistické praxi velmi často vyskytuje, a to nejen u měření, ale i v párových pokusech apod. Nazýváme ho jednovýběrový model polohy.

Jakkoli se předpoklady (1), (2), (3), (4) zdají slabé, je třeba si uvědomit, že jsou to jen předpoklady a i ty mohou být splněny pouze přibližně. Např. je-li μ délka nějakého předmětu, jsou měření X_1, \dots, X_n nezáporná, což je v rozporu s předpokladem (1) a (4).

Ovšem bez předpokladů bychom nemohli odvodit žádný závěr o skutečné hodnotě μ . Praxe je naopak taková, že předpokládáme dokonce mnohem více.

- (5) Společné rozdělení chyb je $N(0, \sigma^2)$, kde σ^2 je neznámé; to znamená, že X_1, \dots, X_n je náhodný výběr z populace $N(\mu, \sigma^2)$.

A občas se předpokládá:

- (6) Rozptyl σ^2 rozdělení v předpokladu (5) je známý.

Co nás vede k právě takovým předpokladům? V tomto případě zřejmě zkušenost, fyzikální úvahy a přání. Výhodou předpokladů typu (1)-(6) je, že jsou-li správné, dovedeme odhadnout μ na základě X_1, \dots, X_n velmi vydatným způsobem.

V některých aplikacích nemáme pochybnosti o teoretickém modelu, zvláště jsou-li pozorované náhodné veličiny diskrétního typu. Nepochybujeme o tom, že počet zmetků v náhodném

výběru z konečné populace výrobků se řídí hypergeometrickým rozdělením; víme, kdy vzniká binomické rozdělení a že počet α -částic emitovaných radioaktivní látkou za krátký časový interval se řídí Poissonovým rozdělením.

Další příklad bude důležitý pro naše další úvahy.

Příklad 2. Srovnání účinnosti dvou různých typů ošetření

Chceme porovnat účinnost 2 různých postupů, např.: redukce úniku škodlivých látek do ovzduší, léčení choroby, výroby energie apod. Tyto postupy obvykle nazýváme ošetření a úlohu lze chápat jako srovnání účinnosti 2 typů ošetření aplikovaných na členy nějaké populace. K tomu účelu provedeme $m+n$ nezávislých pokusů takto: náhodně zvolíme $m+n$ členů populace, prvních m členů podrobíme prvnímu typu ošetření a zbývajících n členů druhému typu ošetření. Každý jednotlivý pokus dává určitou míru, kvantitativní nebo kvalitativní, účinnosti příslušného ošetření.

Představme si např., že chceme testovat vliv určité drogy na krevní tlak; je známo, že droga buď tlak nemění nebo snižuje. Označme X_1, \dots, X_m krevní tlak m pacientů, kterým byla podána droga, a Y_1, \dots, Y_n krevní tlak pacientů, kterým byla podána neutrální látka.

Označíme-li F společnou distribuční funkci X_1, \dots, X_m a G společnou distribuční funkci Y_1, \dots, Y_n , pak hypotéza

$$H : F = G$$

znamená, že droga nepůsobí na krevní tlak.

Podle toho, jaké předpoklady přijmeme o rozděleních F a G , dostaneme různé alternativy hypotézy H :

i zde. Naším úkolem v dalších kapitolách bude mj. nalézt testy hypotézy H , vhodné za předpokladů (1) příp. (2).

Nyní definujeme prvky statistického modelu :

Uvažujme náhodný pokus se základním prostorem výsledků Ω . Na Ω nechť je definován náhodný vektor $\underline{X} = (X_1, \dots, X_n)$. Vede-li pokus k výsledku ω , registrujeme hodnotu $\underline{X}(\omega)$ (samotné ω obvykle nepozorujeme). $\underline{X}(\omega) = (X_1, \dots, X_n)$ pak nazýváme pozorování nebo data. Protože pozorujeme pouze \underline{X} , stačí uvažovat rozdělení pravděpodobností \underline{X} . O tomto rozdělení předpokládáme, že je prvkem určitého systému \mathcal{P} rozdělení na $(\mathbb{R}^n, \mathcal{B}^n)$. Systém rozdělení \mathcal{P} nazveme model. Např. jsou-li v příkladě 1 splněny předpoklady (1)-(4), je \mathcal{P} systémem všech rozdělení náhodných vektorů (X_1, \dots, X_n) , jejichž složky jsou nezávislé a mají stejné rozdělení s hustotou symetrickou kolem nějakého bodu μ .

Obvykle nás zajímají parametry systému \mathcal{P} ; např. střed symetrie μ v příkladě 1. V systému se mohou vyskytnout i další, rušivé parametry, které odpovídají dalším neznámým vlastnostem rozdělení \underline{X} (např. neznámý rozptyl σ^2 za předpokladu (5)). Obvykle zahrnujeme všechny parametry systému pod jediný společný parametr θ ; je-li každý prvek systému \mathcal{P} jednoznačně určen hodnotou θ a θ probíhá danou množinu Θ , píšeme model ve tvaru $\mathcal{P} = \{P_\theta : \theta \in \Theta\}$. Model lze parametrizovat mnoha způsoby; je však třeba vždy dbát na to, aby parametr byl identifikovatelný, tj. aby $\theta_1 \neq \theta_2$ implikovalo $P_{\theta_1} \neq P_{\theta_2}$ pro vš. $\theta_1, \theta_2 \in \Theta$.

Modely, u kterých je Θ vhodná, např. konvexí podmnožina \mathbb{R}^k , označujeme jako parametrické.

i zde. Naším úkolem v dalších kapitolách bude mj. nalézt testy hypotézy H , vhodné za předpokladů (1) příp. (2).

Nyní definujeme prvky statistického modelu :

Uvažujme náhodný pokus se základním prostorem výsledků Ω . Na Ω nechť je definován náhodný vektor $\underline{X} = (X_1, \dots, X_n)$. Vede-li pokus k výsledku ω , registrujeme hodnotu $\underline{X}(\omega)$ (samotné ω obvykle nepozorujeme). $\underline{X}(\omega) = (X_1, \dots, X_n)$ pak nazýváme pozorování nebo data. Protože pozorujeme pouze \underline{X} , stačí uvažovat rozdělení pravděpodobností \underline{X} . O tomto rozdělení předpokládáme, že je prvkem určitého systému \mathcal{P} rozdělení na $(\mathbb{R}^n, \mathcal{B}^n)$. Systém rozdělení \mathcal{P} nazveme model. Např. jsou-li v příkladě 1 splněny předpoklady (1)-(4), je \mathcal{P} systémem všech rozdělení náhodných vektorů (X_1, \dots, X_n) , jejichž složky jsou nezávislé a mají stejné rozdělení s hustotou symetrickou kolem nějakého bodu μ .

Obvykle nás zajímají parametry systému \mathcal{P} ; např. střed symetrie μ v příkladě 1. V systému se mohou vyskytnout i další, rušivé parametry, které odpovídají dalším neznámým vlastnostem rozdělení \underline{X} (např. neznámý rozptyl σ^2 za předpokladu (5)). Obvykle zahrnujeme všechny parametry systému pod jediný společný parametr θ ; je-li každý prvek systému \mathcal{P} jednoznačně určen hodnotou θ a θ probíhá danou množinou Θ , píšeme model ve tvaru $\mathcal{P} = \{P_\theta : \theta \in \Theta\}$. Model lze parametrizovat mnoha způsoby; je však třeba vždy dbát na to, aby parametr byl identifikovatelný, tj. aby $\theta_1 \neq \theta_2$ implikovalo $P_{\theta_1} \neq P_{\theta_2}$ pro vš. $\theta_1, \theta_2 \in \Theta$.

Modely, u kterých je Θ vhodná, např. konvexní podmnožina \mathbb{R}^k , označujeme jako parametrické.

Parametr však nemusí být vždy reálné číslo nebo vektor : za předpokladů (1)-(4) v příkladě 1 je nejvhodnější charakterizace rozdělení chyb pomocí dvojice $\theta = (\mu, f)$, kde μ probíhá R^1 a f probíhá množinu všech hustot symetrických kolem 0. Takové modely nazýváme neparametrické.

V parametrických modelech obvykle máme silně omezující předpoklady a rozdělení dat je plně určeno několika momenty nejnižších řádů. Naopak v neparametrických modelech připouštíme, že se mohou měnit i tvary rozdělení.