

Analýza dat v neurologii

XI. Úvod do statistického usuzování – velikost účinku

Ve všech dosavadních dílech seriálu jsme se zabývali tzv. explorační analýzou dat a nabízelí jsme řešení pro popis různých typů výběrových rozdělení náhodných veličin. Vždy šlo o situace, kdy někdo nashromáždil konkrétní data a popisná analýza měla za úkol je popsat, zviditelnit, zpřehlednit. Nyní otevíráme další velkou kapitolu týkající se statistického usuzování, tzv. statistické inference. Zde již nepůjde o prostý popis dat, spíše naopak. Na základě provedeného výběru a předpokladů o rozdělení hodnot se budeme snažit výsledky měření zobecnit na širší skupinu subjektů, případně na celou populaci.

Jistou část této problematiky jsme již probrali, neboť statistické usuzování zahrnuje jednak metodiku odhadování charakteristik výběrového rozdělení a jednak metody tzv. statistického testování. Již dříve vysvětlený bodový a intervalový odhad (např. aritmetického průměru) slouží také k zobecnění hodnot výběrové populace na populaci celkovou, neboť uvádíme interval, v němž se populační hodnota nachází s určitou spolehlivostí. Při statistickém testování pak již přímo provádíme rozhodnutí o platnosti předem dané hypotézy, o rozdělení náhodné proměnné nebo o hodnotě určitého parametru v jedné nebo více populacích.

Je zřejmé, že statistické usuzování je výrazně ambicióznější než sumarizace naměřených dat v konkrétním výběru. Při usuzování bojujeme s variabilitou opakovaných výběrů a samozřejmě se snažíme, aby naše závěry co nejvíce odpovídaly realitě v cílové populaci. Všechny kroky procesu (způsob provedení výběru, velikost vzorku, správnost uplatněných předpokladů o výběrovém rozdělení, použitá statistická metodika)

mají na konečný výsledek výrazný vliv. Vždy, když vyslovíme nějaký „statistický soud“ (např. že daná hypotéza pravděpodobně neplatí), musíme ověřit, zda jsme v celém procesu postupovali skutečně správně a zda výsledek usuzování má i reálnou interpretační hodnotu.

Předpokládáme, že čtenáři tohoto seriálu se již s běžnými postupy statistického testování setkali (máme danou hypotézu k ověření → provedli jsme výběr z populace → aplikujeme statistický test → hypotézu prohlásíme za statisticky platnou nebo neplatnou). V závěru hovoříme o „statistické významnosti“ vlivu pokusného zásahu, o významnosti rozdílu dvou a více populací apod. Zcela záměrně ale náš výklad nezačínáme popisem techniky testování a zařazujeme zamyšlení nad smyslem a interpretační hodnotou statistického usuzování. Velmi často se totiž stává, že vlastní provedení výpočtů statistických testů převládá nad úvahami o dosaženém a dosažitelném výsledku. A jelikož statistické usuzování vždy znamená jisté zobecnění z náhodného výběru na celou populaci, je ověření interpretační hodnoty výsledku minimálně stejně významné jako vlastní výpočet. Řeč tedy bude o věcné (klinické) významnosti výsledku, která nemusí vždy odpovídat jeho statistické významnosti.

Vezměme si jako příklad srovnání průměrné výšky lidské postavy mezi dvěma populacemi, například Čechy a Slováky. Srovnáním bodových odhadů průměru na dvou výběrech můžeme dostat numerický rozdíl např. 0,5 cm, který při znalosti rozsahu hodnot jistě nikdo neoznačí za biologicky podstatný nebo významný. Přesto lze i tak malý rozdíl při velkém vzorku vyhodnotit jako statisticky významný a naopak při malém

L. Dušek, T. Pavlík, J. Koptíková

Institut biostatistiky a analýz
Masarykova univerzita, Brno



doc. RNDr. Ladislav Dušek, Dr.
Institut biostatistiky a analýz
Masarykova univerzita, Brno
e-mail: dusek@cba.muni.cz

vzorku neprokážeme statistickou významnost ani pro velké rozdíly. Tyto rozpory věcné a statistické významnosti lze v praxi minimalizovat, musíme ale k statistickému testování přistupovat s rozmyslem a plánovitě:

1. Kdykoli chystáme měření nebo experimentování za účelem statistického usuzování, měli bychom vědět, proč tak činíme, co chceme prokázat a jaké hodnoty měřených parametrů nebo jejich rozdíly jsou pro nás věcně podstatné. Měření bez této rozvahy nemá žádné opodstatnění a nechrání ho ani sebedokonalejší statistická analýza. Této části postupu říkáme plánování výběru nebo plánování experimentu („sampling design, experimental design“) a rozhodujeme zde především o způsobu a velikosti výběru nebo o typu uspořádání experimentálních variant. Experimentálními plány pro různé typy hypotéz se budeme zabývat v některém z dalších dílů seriálu.
2. Nad naměřenými daty v provedeném výběru vždy zkontrolujeme výběrové rozdělení a posoudíme, jakého jsme dosáhli numerického výsledku. Tato fáze znamená uplatnění prosté statis-

tické sumarizace na všechny získané výběrové soubory. Zahrnuje kontrolu výběrových rozdílů, hledání odlehklých hodnot, odhady statistických charakteristik.

3. Přistupujeme k aplikaci statistických testů dle jejich metodiky.

Jak vidno, vlastní statistické výpočty jsou pouze nástrojem, který dokládá spolehlivost dosažených výsledků a umožňuje zobecnění závěrů. Nesmíme je tedy přeceňovat. Platí, že statisticky podložené zobecňování věcně nepodstatných rozdílů nemá žádný smysl a může být dokonce velmi zavádějící. Výsledky úvah popsanych výše v bodě 1 a 2 jsou zásadní, rozhodují o věcném významu výsledku a určují použitelnou statistickou metodologii, neboť ta vždy vychází z ověřených předpokladů o výběrových rozděleních náhodných proměnných. V bodě 2 dále zjišťujeme, jakého efektu jsme u měřené proměnné experimentem dosáhli. **Hovoříme o velikosti účinku (ES, Effect Size)** experimentálního zásahu nebo intervence.

Absolutní velikost účinku je při srovnání kontrolní a pokusné varianty měřitelná například jako rozdíl odhadů aritmetického průměru ($\bar{x}_1 - \bar{x}_2$). Jak ale zjistíme, jaký účinek je věcně podstatný, významný a interpretovatelný? Zde žádné univerzální pravidlo neexistuje, neboť vše závisí na konkrétní situaci, měřeném parametru a cílech výzkumu. V jedné situaci může být za podstatný považován účinek, který v jiném kontextu podstatný není. Nastavení vždy musí provádět člověk znalý věci, který čerpá ze znalosti problému nebo z informací dostupných z literatury. Určením věcně podstatného účinku dáváme zadání i pro plánování velikosti výběru, který musí být nastaven tak, aby minimálně právě takový účinek zachytil a prokázal jako statisticky významný.

Tím, že si stanovíme, jaký účinek je pro nás podstatný, ovšem nijak neovlivňujeme výsledek vlastního měření, a tedy velikost skutečně dosaženého účinku musíme ověřit. K tomu slouží tzv. **koeficienty velikosti účinku**. Jejich význam je především v tom, že dosažený efekt

standardizují a jsou tak využitelné pro srovnávání různých postupů nebo experimentů. Hodnota těchto koeficientů je nezávislá na velikosti výběru. Proto také našly rozsáhlé uplatnění v tzv. metaanalýzách, které sumarizují výsledky dvou nebo více dílčích empirických studií zabývajících se stejným anebo podobným problémem. Pro taková srovnání je nutný odhad velikosti účinků bez ovlivnění velikostí vzorku v konkrétních experimentech. Jako učebnicový příklad takového koeficientu zde uvádíme Cohenův koeficient d používaný pro hodnocení velikosti účinku v testech o dvou výběrových odhadech průměru:

$$d = \frac{\bar{X}_1 - \bar{X}_2}{s}$$

kde $\bar{x}_1 - \bar{x}_2$ značí rozdíl aritmetických průměrů naměřených hodnot dvou skupin (pokus, kontrola) a s je společná směrodatná odchylka obou měření. Ze vzorce vyplývá, že hodnota d skutečně standardizuje rozdíly mezi dvěma skupinami pomocí směrodatné odchylky a je nezávislá na rozsahu výběru. Pro jednoduchost budeme uvažovat, že hodnota d nabývá pouze kladných hodnot, tedy že hodnotou \bar{x}_1 označíme větší z vypočtených průměrů obou skupin a naopak \bar{x}_2 označíme menší z vypočtených průměrů obou skupin.

V literatuře se můžeme setkat s různými formami výpočtu koeficientu d , které se liší v odhadu směrodatné odchylky ve jmenovateli:

- Za určitých okolností je do vzorce za s dosazována hodnota směrodatné odchylky pouze jedné z variant, typicky varianty kontrolní. V literatuře takový koeficient figuruje také pod názvem Glassovo delta. Tento postup je optimální za situace, kdy v experimentu existuje skutečná kontrolní varianta a její variabilita je pro měřenou veličinu reprezentativnější než jiné hodnoty (například pokud je rozptyl hodnot v experimentální variantě změněn v důsledku provedení zásahu).
- Běžně bývá za s dosazován prostý průměr obou výběrových odhadů směrodatných odchylek. Tento postup lze doporučit, pokud jsou velikosti obou výběrů přibližně stejné a hodnoty s_1 a s_2 příslušející jednotlivým výběrům se podstatně neliší.
- Další možností je výpočet vážené směrodatné odchylky obou výběrů, kdy je výsledný odhad s (v literatuře: S_{pooled}) vážen velikostí vzorku v jednotlivých výběrech. Výpočet můžeme vyjádřit následovně:

$$s = \sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}}$$

Příklad na obr. 1 dokumentuje právě tento postup výpočtu Cohena d doplněný 95% intervalem spolehlivosti.

Rozhodování o velikosti účinku provádíme na základě konvenčně daných li-

Koeficient d	Směrodatná odchylka odhadu d	95% interval spolehlivosti odhadu d
$d = \frac{\bar{x}_1 - \bar{x}_2}{s}$	$s_{[d]} = \sqrt{\frac{n_1 + n_2}{n_1 \times n_2} + \frac{d^2}{2(n_1 + n_2)}}$	dolní mez: $d - 1,96 \times s_{[d]}$ horní mez: $d + 1,96 \times s_{[d]}$
Kde: \bar{x}_1, \bar{x}_2 – odhady průměru skupin 1 a 2 s – vážený odhad směrodatné odchylky n_1, n_2 – počet hodnot ve výběrových skupinách 1 a 2		
Příklad výpočtu:		
$x_1 = 54,8$ $x_2 = 50,2$	$n_1 = 47$ $n_2 = 35$ $s = 5,8$	$\Rightarrow s_{[d]} = 0,23; d = 0,79$ 95% IS pro d : 0,34–1,24

Obr. 1. Výpočet Cohena koeficientu d a jeho 95% intervalu spolehlivosti [3].

Tab. 1. Interpretace velikosti účinku na základě Cohena koeficientu *d*.

Velikost <i>d</i>	0,0	0,2	0,5	0,8	1,0	1,2	1,6	2,0
podíl hodnot (v %) ve skupině 2, které jsou nižší než průměr skupiny 1	50	58	69	79	84	88	95	98
podíl hodnot (v %), které se ve skupině 1 a 2 nepřekrývají	0	15	33	47	55	62	73	81

Pozn. Srovnávány jsou průměry hodnot měřené ve dvou skupinách jedinců: 1 a 2

mitů pro hodnotu *d*: při *d* > 0,8, je efekt velký; pro *d* v intervalu 0,5–0,8 je efekt střední; efekt pod hodnotou 0,2 označujeme za malý. S rostoucím rozdílem hodnot v čitateli hodnota *d* logicky roste a dělení směrodatnou odchylkou činí z rozdílu měřítko překrývání srovnávaných výběrových rozdělení: při *d* = 0 jde o 100% překryv hodnot obou skupin; *d* rovno 0,8 znamená, že hodnota \bar{x}_1 převyšuje 79 % všech hodnot ve skupině 2 atd. (tab. 1).

Výpočet Cohena *d* je dobrým příkladem univerzálnosti koeficientů účinku. Standardizace pomocí *s* totiž rozdíl obou průměrů vztahuje k variabilitě (rozsahu) měřené veličiny. Lze tak rovnocenně srovnávat velikost účinku u dvou studií, které měří daný jev pomocí různých ukazatelů, například s rozsahy 0–100 a 0–10. Nutno ovšem připomenout, že všechny zde uvedené výpočty týkající se koeficientu *d* předpokládají normální rozdělení náhodné veličiny. Koeficientů velikosti účinku existuje samozřejmě více a jejich aplikace se liší podle typu experimentu a rozdělení měřené veličiny. Často jsou takto užívány korelační koeficienty pro hodnocení míry vztahu dvou proměnných. Jiným příkladem může být odvození koeficientu velikosti účinku z analýzy rozptylu. Tzv. Effect Size Correlation i další pokročilé metody budou námětem dalších dílů našeho seriálu.

Velikost účinku lze částečně doložit také pomocí intervalů spolehlivosti prováděných odhadů. Při srovnání dvou výběrových průměrů můžeme například porovnávat intervaly spolehlivosti pro odhad průměru v obou výběrových po-

pulacích, nebo bodový odhad průměru v jednom výběru s intervalem spolehlivosti pro výběrový odhad průměru v druhém výběru (experimentální variantě). Takové srovnání nenahrazuje statistický test, ale umožní srovnat skutečné naměřené hodnoty s věcně významným účinkem. Alternativně můžeme provést intervalový odhad přímo pro rozdíl dvou výběrových průměrů a posoudit, zda je klinicky podstatný účinek tímto intervalem pokryt či nikoli. Příklad takového výpočtu je na obr. 2. Je zřejmé, že šířka intervalu spolehlivosti souvisí s velikostí vzorku, takže plně standardizované hodnocení účinku nahradit nemůže. Přesto lze intervaly spolehlivosti doporučit pro prezentaci výsledků, zvláště pokud statistické testy

neprokáží významné rozdíly srovnávaných skupin [6]. V takovém případě interval spolehlivosti pro rozdíl průměrů zahrnuje nulu (obr. 2, příklad 2). Z šířky intervalu můžeme usuzovat i na velikost hodnoceného účinku, která je podporována již naměřenými daty.

Pevně věříme, že jsme tímto úvodem k statistickému usuzování čtenáře neodradili od dalších dílů. V nich přineseme jasné návody, jaké testy aplikovat v různých situacích. Přesto se nám téma velikosti účinku bude neustále vracet a budeme ho rozebírat především v případech, kdy výsledky vyjdou statisticky nejasně. Kritické posouzení věcného významu výsledků totiž nelze čekat od statistického software, je to úkol experimentátorů a v klinickém výzkumu lé-

$$\text{Vzorec: } (\bar{x}_1 - \bar{x}_2) \pm t_{(\alpha/2, \nu)} SE(\bar{x}_1 - \bar{x}_2) = (\bar{x}_1 - \bar{x}_2) \pm t_{(\alpha/2, \nu)} \sqrt{s^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}$$

Kde: \bar{x}_1, \bar{x}_2 – odhady průměru skupin 1 a 2

s_1, s_2 – odhady směrodatné odchylky skupin 1 a 2

n_1, n_2 – počet hodnot ve výběrových skupinách 1 a 2

SE – standardní chyba odhadu rozdílu průměrů 1 a 2

s^2 – vážený odhad rozptylu obou skupin

t – kvantil Studentova rozdělení

ν – stupně volnosti

$$s^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$$

$$\nu = n_1 + n_2 - 2$$

Příklad 1

Kontrola	Pokus		Kontrola	Pokus
49,0	69,0	průměr	48,2	68,2
42,2	62,2	směr. odch.	6,6	6,6
47,3	67,3	N	10	10
43,9	63,9			
42,4	62,4	rozdíl průměrů (SE)	20,0 (2,9)	
49,0	69,0			
48,4	68,4	95% IS:		
59,7	79,7	dolní/horní mez	13,9–26,1	
51,2	71,2			
51,4	71,4			

Příklad 2

Kontrola	Pokus		Kontrola	Pokus
49,3	50,3	průměr	50,7	51,7
54,5	55,5	směr. odch.	4,9	4,9
40,0	41,0	N	10	10
56,3	57,3			
46,8	47,8	rozdíl průměrů (SE)	1,0 (2,2)	
55,6	56,6			
50,8	51,8	95% IS:		
48,7	49,7	dolní/horní mez	-3,6–5,6	
53,1	54,1			
51,7	52,7			

Obr. 2. Příklad výpočtu intervalu spolehlivosti (IS) pro rozdíl odhadů aritmetického průměru.

Tab. 2. Sumarizace naměřených hodnot.

Sumarizace naměřených hodnot

Experiment (E)	Kontrola (K)	Rozdíl (E – K)	Velikost účinku	Statistický test
výběrový odhad průměru doplněný standardní chybou	výběrový odhad průměru doplněný standardní chybou	rozdíl odhadů průměru (E a K) doplněný 95 % int. spolehlivosti	Cohenovo <i>d</i> , odhad <i>d</i> doplněný 95% int. spolehlivosti	výsledek vhodného statistického testu ověřujícího platnost hypotézy E = K

Tabulka končí políčkem o provedení statistického testu a právě této problematice se bude věnovat další díl našeho seriálu

kažů. Věříme, že po pročtení tohoto dílu bude čtenář souhlasit s následujícím zlatým pravidlem prezentace vědeckých výsledků: vedle statistické významnosti by měla být vždy doložena i velikost dosaženého účinku a ta doplněná intervalem spolehlivosti. Ačkoli to vypadá jako samozřejmost, zdaleka ne vždy je toto pravidlo dodržováno. I proto zde na závěr dokládáme ukázkou výsledkové tabulky (tab. 2), která vyčerpávajícím způsobem dokumentuje význam a spolehlivost naměřených rozdílů mezi dvěma výběrovými průměry.

Literatura

1. Blahuš P. Statistická významnost proti vědecké průkaznosti výsledků výzkumu. *Čes Kinantropologie* 2000; 4(2): 53–72.
2. Cohen J. *Statistical power analysis for the behavioral sciences*. 2nd ed. Hillsdale, NJ: Earlbaum 1998.
3. Hedges L, Olkin I. *Statistical Methods for Meta-Analysis*. New York: Academic Press 1985.
4. Hoenig JM, Heisey DM. The abuse of power: the pervasive fallacy of power calculations for data analysis. *Am Stat* 2001; 55: 19–24.

5. Ives B. Effect size use in studies of learning disabilities. *J Learn Disabil* 2003; 36(6): 490–504.
6. Johnson DH. The insignificance of statistical significance testing. *J Wildl Manage* 1999; 63(3): 763–772.
7. Lipsey MW, Wilson DB. The efficacy of psychological, educational, and behavioral treatment: Confirmation from meta-analysis. *Am Psychol* 1993; 48(12): 1181–1209.
8. Thompson B. Statistical significance and effect size reporting: portrait of a possible future. *Research in the Schools* 1995; 5(2): 33–38.

www.epsychieatrie.cz