

DIVOKÝ SEN O MĚŘENÍ

Jan Klaschka, Psychiatrické centrum Praha

Danovi s omluvami: Neumím jinak a neumím líp.

Dvakrát měř

Také jste to určitě někdy četli nebo slyšeli: "Mám-li jedny hodinky, vím, kolik je hodin, mám-li dvoje, nejsem si už jist." Tento vtip je obzvláště oblíbený mezi statistiky - snad proto, že jim dává pocítit převahu nad laiky, kteří potřebují takto drastický příklad, aby si uvědomili rozdíl mezi měřením a měřeným. Statistickí si jistě tyto pojmy pletou zřídka a iluze, že výsledek jediného měření je přesně tím číslem "o které jde", je u nich také vzácná. V něčem si ale přece bude leckterý statistik s laikem roven: Má-li k dispozici jediné měření nějaké veličiny, nenapadne ho na otázku, jaké hodnoty tato veličina nabývá, lepší odpověď než právě výsledek měření. (Pokud se k tomu nikdo nehlasí, týká se to alespoň autora před nějakým časem.)

Jiná odpověď by však statistika napadnout mohla. Odhad měřeného z měření představuje statistickou úlohu, která má smysl a řešení i v případě, že měření je jen jedno.

Uvažujme nejběžnější model měření X veličiny ξ s aditivní chybou ε

$$\begin{aligned} X &= \xi + \varepsilon, \\ E\xi &= \mu, \text{ var}\xi = \sigma_{\xi}^2, E\varepsilon = 0, \text{ var}\varepsilon = \sigma_{\varepsilon}^2, E\xi\varepsilon = 0. \end{aligned} \quad (1)$$

Veličina ξ se chápe jako náhodná proto, že měřené objekty se pokládají za výběr z nějaké populace objektů. Hodnota veličiny ξ u daného objektu v daném okamžiku - tzv. skutečná hodnota - je pevná.

Měření X je sice nestranným odhadem veličiny ξ , tj. $E(X | \xi) = \xi$, lze ale sestavit odhad $\hat{\xi} = f(X)$ s menší střední kvadratickou chybou $E(X - \hat{\xi})^2$. Jak je dobře známo ([4], str. 302), tuto střední kvadratickou chybu minimalizuje podmíněná střední hodnota $E(\xi | X)$.

Je-li sdružené rozdělení veličin ξ a ε normální, platí

$$E(\xi | X) = \mu + r(X - \xi) = (1 - r)\mu + rX,$$

$$r = \sigma_{\xi}^2 / (\sigma_{\xi}^2 + \sigma_{\varepsilon}^2) .$$

Pro ne-normální dvojici ξ , ε může podmíněná střední hodnota $E(\xi | X)$ mít jiný tvar, odhad

$$\hat{\xi} = \mu + r(X - \mu) = (1 - r)\mu + rX \quad (2)$$

ovšem i tehdy minimalizuje střední kvadratickou chybu alespoň ve třídě lineárních odhadů, tj. odhadů tvaru $\hat{\xi} = aX + b$.

Odhad (2) se vcelku nepříčí intuici: Odchylku měření X od střední hodnoty μ je třeba přičíst na vrub chyby měření z tím větší částí, čím větší tato odchylka je a čím větší je rozptyl chyby měření ve srovnání s rozptylem skutečných hodnot. Parametr r , pro který si z psychometrie vypůjčíme označení *reliabilita*, udává de facto, v jaké míře lze hodnotám X jakožto informaci o ξ věřit. Je-li $r = 1$, měření je bezchybné a $\hat{\xi} = X$. Je-li naopak reliabilita nulová, jsou veškeré odchylky X od μ způsobeny jen chybou měření a $\hat{\xi} = \mu$.

Odhad (2) je funkcí parametrů μ a r , jež v praktických situacích budou zpravidla neznámé. V dalším textu nicméně budeme o μ a r uvažovat jako o známých hodnotách, kdykoli budou k dispozici data, na základě kterých lze tyto parametry dostatečně přesně odhadnout. Důsledné rozlišování odhadu (2) a jeho modifikace, kde místo μ a r figurují jejich odhady, by bylo korektnější a vedlo by k bohatší a těžší teorii, ale spíše by zatemnilo než zviditelnilo jádro sdělení.

Reliabilita r se (na rozdíl od střední hodnoty μ) nedá odhadnout na základě jediného měření náhodně vybraných objektů. V psychometrii je běžná technika odhadu reliability pomocí opakovaného měření, tj. dvojice měření $X = \xi + \varepsilon$, $X' = \xi + \varepsilon'$, jež se vzájemně liší pouze chybou. (Ponechme stranou, že právě v psychologii je dosti obtížné takové opakování uskutečnit.) Pokud se obě trojice (X, ξ, ε) i (X', ξ, ε') řídí modelem (1) a chyby ε , ε' mají stejné rozptyly a nulovou korelaci, je reliabilita měření X (stejně jako X') rovna korelačnímu koeficientu mezi X a X' . Reliabilitu r lze tedy odhadnout výběrovým korelačním koeficientem vypočteným z dostatečného počtu dvojic měření X_i , X'_i , $i = 1, 2, \dots, N$ získaných u N náhodně vybraných objektů.

Jak se ukazuje, úloha odhadu skutečné hodnoty z jediného měření je v podstatě triviální a není divu, že řešení je v literatuře dávno popsáno (viz např. [3]). Dále se touto věcí zabývat by bylo nudné a uspávající...

Zeměměřič K. sestrojil přístroj, kterým mohl změřit hodnotu každé věci na světě. Provedl množství měření, která zaznamenal. Když zestárl, nechtělo se mu už běhat po světě a měřit, i pustil se do teoretické práce, jejíž výsledky shrnul ve spisu "Závět zeměměřiče". Doporučil tu budoucímu zeměměřiči změřit dříve, než se pustí do díla, určité množství věcí (snad 1000) dvakrát, vypočítat z těchto měření aritmetický průměr μ a výběrový korelační koeficient r , a hodnotu věcí ξ pak odhadovat z měření X podle vzorce (2).

Zeměměřič K. odkázal svým synům dva shodné exempláře svého přístroje. V rodině prvního syna se pak přístroj dále dědil z otce na syna a po celé generace se prováděla a zaznamenávala měření. Z těchto záznamů dosti jasně vyplývalo, že hodnota věcí na světě si zachovává dlouhodobě stále stejné rozložení.

Druhému synovi - označme jej K_1 - odkázal starý zeměměřič kromě přístroje také své zápisky a především spis "Závět zeměměřiče". Pamětliv otcova odkazu, vypočítal K_1 z posloupnosti opakovaných měření průměr μ a korelaci r . Otcův přístroj P pak zabudoval do přístroje P_1 , který výstupní hodnoty X přístroje P používal jako vstup a na výstupu poskytoval transformované hodnoty $\hat{\xi} = \mu + r(X - \mu) = (1 - r)\mu + rX$. Celý život pak K_1 měřil a zaznamenával hodnoty $\hat{\xi}$. Nakonec přístroj P_1 , své a otcovy záznamy a také "Závět zeměměřiče" odkázal synovi K_2 .

Také K_2 byl pamětliv dědova teoretického odkazu, i pustil se nejdříve do opakovaných měření věcí přístrojem P_1 . Co zjistil?

1.) Výstup $\hat{\xi}$ z přístroje je zřejmě roven součtu skutečné hodnoty ξ a chyby měření c .

2.) Aritmetický průměr z naměřených hodnot $\hat{\xi}$ je roven μ ($= E\hat{\xi} = EX$).

3.) Korelační koeficient mezi opakovanými měřeními $\hat{\xi}$ a $\hat{\xi}'$ je roven r (neboť $\hat{\xi} = aX + b$, $\hat{\xi}' = aX' + b$, kde $a \neq 0$, takže $\text{cor}(\hat{\xi}, \hat{\xi}') = \text{cor}(X, X')$).

Vzhledem k těmto poznatkům vložil K_2 přístroj P_1 do nitra přístroje P_2 , který výstupní hodnoty $\hat{\xi} = \hat{\xi}^{(1)}$ přístroje P_1 používal jako vstup a na výstupu poskytoval transformované hodnoty $\hat{\xi}^{(2)} = \mu + r(\hat{\xi}^{(1)} - \mu) = (1 - r)\mu + r\hat{\xi}^{(1)} = \mu + r^2(X - \mu) = (1 - r^2)\mu + r^2X$. Celý život pak K_2 měřil a zaznamenával hodnoty $\hat{\xi}^{(2)}$. Nakonec přístroj P_2 , své, otcovy a dědovy záznamy a také "Závět zeměměřiče" odkázal synovi K_3 .

Zbytek historie je už nasnadě. Každý další potomek K_i vždy nejdříve vypočítal z měření zděděným přístrojem P_{i-1} střední hodnotu μ a reliabilitu r , načež sestrojil přístroj P_i , kterým pak celý život měřil hodnoty $\hat{\xi}^{(i)} = \mu + r(\hat{\xi}^{(i-1)} - \mu) = (1 - r)\mu + r\hat{\xi}^{(i-1)} =$

$$\mu + r^i(X - \mu) = (1 - r^i)\mu + r^i X.$$

Srovnání záznamů různých generací čím dál tím jasněji prozrazovalo nezadržitelný trend "glajchšaltování" světa. Rozptyl naměřených hodnot věcí byl stále menší, až se posléze přestaly vyskytovat jakékoli pozorovatelné odchylky od hodnoty μ .

Zeměměřič K. měl ještě třetího syna. Ten však neměl o měření valný zájem, a tak mu otec odkázal jen dřevěný model přístroje P. Starobylá maketa byla v rodu tohoto syna po generace hrdě oprašována. Nestálo by to za zmínku, nebýt zvláštního kontrastu: Zatímco ručička dřevěného modelu, ukazující jednou provždy hodnotu μ nikdy nikoho nevyvedla z duševní rovnováhy, byli zeměměřiči K_i obdobnými projevy přístrojů P_i s rostoucím i stále více deptáni. Spíše než měření se pak věnovali návštěvě pražských hostinců, kde posléze jejich empiricky podložená filosofie vyznačující se paušálními soudy typu "Teď už stojí všechno za μ " měla velký ohlas a zapustila pevné kořeny.

Výklad snu

Z celého pokolení K_i , $i = 1, 2, 3, \dots$ jen K_1 opravou podle vzorce (2) skutečně minimalizoval střední kvadratickou chybu odhadu veličiny ξ . Všichni ostatní vzorec (2) aplikovali v situaci, kdy byly porušeny předpoklady modelu (1). Měření pořízená přístrojem P_i pro $i \geq 1$ lze sice vyjádřit jako součet skutečné hodnoty ξ a chyby měření, ale chyba měření není nekorelovaná se skutečnou hodnotou.

Porušení předpokladů (1), s nímž se zeměměřiči K_i , $i \geq 2$ setkali, bychom nicméně mohli nazvat porušením skrytým. Výstupy přístroje P_{i-1} , $i \geq 2$ byly jen lineární transformací výstupů vevnitř ukrytého původního přístroje P, takže nesoulad s modelem (1) nemohl být odhalen, pokud by jej neindikoval také samotný přístroj P. (Býval by pomohl např. etalon, tj. objekt u nějž je známa skutečná hodnota, nebo znalost rozptylu σ_ξ^2 .)

Počínání zeměměřičů K_i , $i \geq 2$ tedy můžeme interpretovat více způsoby. Možná byli prostě slepě poslušní instrukcí, o jejichž smyslu nepřemýšleli. Spíše ale si byli teoretického pozadí odhadu (2) vědomi, jenže dostupná měření jim neumožňovala platnost předpokladů (1) ověřit. Jednali tedy dále, jako by model (1) platil - obdobně, jako nám (prosím, některým z nás) mnohdy v aplikacích k přijetí předpokladu normality stačí, že není porušen příliš zjevně.

Konec konců se dá úsilí potomků K_i zhodnotit i tak, že opravdu úspěšně minimalizovali střední kvadratickou chybu lineárního odhadu skutečné hodnoty, pouze se jednalo o skutečnou hodnotu jiné veličiny

než ξ , totiž $\mu + r^{-1}(\xi - \mu)$. Z tohoto pohledu se pak jako omyl nejeví samotná měření, ale jen snaha srovnávat mezi sebou záznamy různých generací.

V praxi naštěstí snad spuštění série oprav, jaké jsme byli svědky, nehrozí. Při fyzikálním měření lze zpravidla pomocí etalonů porušení modelu (1) odhalit. A v psychologii, kde je přeci jen obtížnější uchovávat neměnný vzorek v Sèvres při teplotě 0°C , se odhad (2) (pokud jsem si všiml) příliš nepoužívá a není ani v literatuře často doporučován. Důvod bude spočívat asi v tom, že $\hat{\xi}$ je jen lineární transformací X , takže volba mezi X a $\hat{\xi}$ je v podstatě jen volbou jednotky a jako taková je do značné míry lhostejná. Nasvědčuje tomu fakt, že se o vzorci (2) v literatuře mluví převážně jen v souvislosti s psychometrickým hodnocením změny v čase: Rozdíl $Y - X$ dvou postupných měření má různé nepříjemné vlastnosti, které lze částečně oslabit nahrazením počátečního měření X odhadem $\hat{\xi}$ (viz [2]). Na rozdíl od "jednoduchého" měření ovšem korigovaná hodnota $Y - \hat{\xi}$ není funkcí (tím méně funkcí lineární) nekorigované difference $Y - X$.

Second helping

Můžeme poznatky o odhadu (2) nějak zužitkovat v situaci, kdy se měření X veličiny ξ řídí modelem (1), ale reliabilitu r (ani její dostatečně přesný odhad) neznáme? Svým způsobem ano, pokud víme alespoň, že $r \leq r^*$ pro nějaké $r^* < 1$. Odhad

$$\hat{\xi}(\rho) = \mu + \rho(X - \mu) \quad (3)$$

má totiž menší střední kvadratickou chybu než X pro $2r - 1 < \rho < 1$. Lepší než spokojit se s neupravenou hodnotou X je tedy, zdá se, použít odhad (3) a zvolit kteroukoli hodnotu ρ mezi $2r^* - 1$ a 1.

Podívejme se, jak bude tato metoda fungovat v životě. Představte si, že se ucházíte v konkursu o místo vedoucího pracoviště. Jediným konkurentem je váš velmi neoblíbený kolega. Výsledky jsou zatím vyrovnané a o všem má rozhodnout test schopnosti rychlého učení. Na rozdíl od svého soupeře jste pochopil(-a), že důležitým předpokladem úspěchu v tomto testu je nízká naměřená úroveň vstupních znalostí, proto veškeré vstupní znalosti zatajíte. A ejhle - vychází vám, že jste se naučil(-a) 150 jednotek, zatímco váš kolega, sláva, jen 50. Už se těšíte, jakými úkoly ho v nejbližší době pověříte... Reliabilita rozdílu mezi výsledky dvou testů (vstupního a výstupního) je bohužel obecně dosti malá (viz [1]), v případě daného testu učení není větší

než 0,4. Lze tedy volit třeba $\rho = -0,1$ ($> 2 \cdot 0,4 - 1 = -0,2$). Střední výsledek uchazečů v obdobných konkurech je 100 bodů. I přepočítá konkursní komise výsledky testu takto: váš ze 150 na $100 - 0,1 \cdot (150 - 100) = 95$, kolegův z 50 na $100 - 0,1 \cdot (50 - 100) = 105$. Je to sice těsné, ale komisi to k určení vítěze stačí. Když se zajímáte, kdo si takový způsob hodnocení vymyslel, dozvíte se, že metodika byla vyvinuta v Psychiatrickém centru v Bohnicích a že tamní statistik dokázal, že to je tak lepší než výsledky testu vůbec nekorigovat. Chcete si na celou záležitost ještě pořádně posvítit, ale nějak to stále odkládáte - dostáváte teď v práci moc úkolů...

Závěr

nechť si utvoří každý sám. Osobně jsem si z překvapení vlastnostmi odhadů (2) a (3) odnesl hlavně trochu nedůvěry - možná iracionální - k odhadům s nejmenší střední kvadratickou chybou (obecně, ne jen v modelu (1)).

Nezbytnou vlastností kvalitní metody měření je bezpochyby značná shoda pořadí naměřených hodnot podle velikosti s pořadím hodnot skutečných. Odhad $\hat{\xi}(\rho)$ dle (3) pro ρ záporné je z tohoto hlediska katastrofa. Nemuseli bychom tyto patologické případy brát vážně, vždyť optimální hodnota ρ (rovná reliabilitě měření) záporná nikdy není, takže v praxi není důvod záporné ρ volit. A odhad $\hat{\xi}$ podle (2) není podle uvedeného kritéria horší (i když není ani lepší) než nekorigované měření X.

Ale: Je-li nejlepší usilovat o nejmenší čtverce chyb, očekával bych také, že bude dobré je jakkoli zmenšovat. Toto očekávání se nesplnilo. Reflexy praktického statistika velí zamítnout hypotézu.

Literatura

- [1] Bereiter, C.: Some persisting dilemmas in the measurement of change. In: Harris, Ch. W. (ed.): Problems in measuring change. Univ. of Wisconsin Press, Madison 1963.
- [2] Cronbach, L. J. - Furby, L.: How we should measure "change" - or should we? Psychological Bulletin 74 (1970), 68 - 80.
- [3] Kelley, T. L.: Fundamentals of statistics. Harvard Univ. Press, Cambridge, MA 1948.
- [4] Rao, R. C.: Lineární metody statistické indukce a jejich aplikace. Academia, Praha 1978.