

INFORMAČNÍ ÚČINNOST DIDAKTICKÉHO TESTU S VOLBOU Z NABÍDNUTÝCH ODPOVĚDÍ

STANISLAV KOMENDA, JANA ZAPLETALOVÁ

Test typu multiple-choice

Didaktický test s volbou správné odpovědi z předložených nabídek zprostředkovává zpětnou vazbu mezi učitelem a žákem v procesu učení. K hlavním přednostem dobře sestaveného testu zmíněného typu patří jeho objektivnost a také ekonomičnost při měření, jaké úrovně znalostí o daném tématu bylo opravdu dosaženo.

Struktura testové položky, jejichž soubor pak tvoří test, zahrnuje tzv. kmen, což je tvrzení nebo otázka či úloha, týkající se zkoušené znalosti. Spolu s otázkou se pak zkoušenému subjektu předkládá několik nabídek odpovědi, z nichž zpravidla právě jediná bývá správná a ostatní hrají roli distraktorů.

Úkolem zkoušeného subjektu je vybrat z nabídek odpovědi tu, kterou považuje za správnou. Pokud se jeho volba shoduje se záměrem examinátora, je položka skórována hodnotou 1 (jedním bodem), což je její příspěvek k testovému skóre správných odpovědí v testu. V případě nesprávného řešení položky je její příspěvek k testovému skóre nulový. Existují však i určité modifikace těchto zásad skórování v testu.

Konstrukce testových položek vyžaduje, vedle dobré znalosti zkoušeného tématu, i určitý důvtip a znalost zásad tvorby testu. Způsob formulace problému rozhoduje nejen o zkoušeném tématu, ale i o tom, jak hluboké mají být znalosti, na něž je dotazováno. To souvisí s tzv. taxonomií výukových cílů, např. v pojetí Bloomově.

Hlavním problémem bývá při konstrukci testové položky formulace distraktorů. Požaduje se, aby tyto plně fungovaly - v tom smyslu, že žádná není pro subjekt triviální a subjekt bez znalosti zkoušeného tématu volí mezi nabídkami odpovědi podle zásad náhodného výběru. Protože vyšší počet nabídek snižuje, při zachování jejich kvality - možnost dosažení správného řešení náhodným uhádnutím, bývá na straně examinátora snaha formulovat nabídek (tj. vlastně distraktorů) s danou položkou co nejvíce. To však bývá velmi obtížné - což

examinátor někdy překonává tím, že jako distraktory nabízí odpovědi z různých „dimenzí“ zkoušeného tématu. Tímto způsobem lze, samozřejmě, zvyšovat počet distraktorů prakticky bez omezení - dá se však pochybovat, že by přitom zůstal respektován požadavek rovnocennosti všech nabídnutých odpovědí.

Tomuto problému se budeme později věnovat hlouběji a ukážeme, že z hlediska jistého rozumně zvoleného kritéria informační účinnosti jsou rozsáhlejší testy s jednoduššími položkami ekvivalentní testům méně rozsáhlým, užívajícím položky s vyšším počtem distraktorů.

Pravděpodobnostní model didaktického testu

Uvažujme situaci, kdy je test aplikován na subjekt se záměrem zjišťovat, jakou část sledovaného tématu tento opravdu zná resp. nezná.

Test je složen z n položek považovaných za vzájemně nezávislé. Tím se rozumí, že znalost správného řešení dané položky subjektem nijak neovlivňuje schopnost subjektu správně řešit kteroukoliv z dalších $n-1$ testových položek.

Spolu s položkou se subjektu předkládá q nabídek odpovědi, z nichž jedna je správná a $q-1$ představuje distraktory. O tom je zkoušený subjekt informován, spolu se žádostí, aby jednu z q nabídek - totiž tu, kterou považuje za řešení položky - označil za správnou (a tím současně prohlásil zbylých $q-1$ položek za nesprávné). Podle instrukce má subjekt jednu z nabídek označit za správnou i tehdy, není-li si správným řešením úlohy jist; tím využije možnosti dosáhnout správné odpovědi náhodným uhádnutím.

Test má tedy dva parametry: rozsah n (počet položek) a q (počet nabídek odpovědi s každou položkou).

Vedle toho uvažuje model testu další parametr π ($0 \leq \pi \leq 1$), totiž podíl látky zkoušeného tématu, který subjekt neovládá. Přitom platí, že zatímco parametry n a q jsou kontrolovány examínátorem, je parametr π pod kontrolou zkoušeného subjektu. Veličina $1-\pi$ tak představuje podíl látky, kterou zkoušený subjekt ovládá.

Parametr π bude objektem statistického odhadování, využívajícího naměřených údajů o chování subjektu.

Odhad parametru π modelu testu

Za předpokladu, že naši evidenci je dostupná informace o počtu chyb k , kterých se subjekt dopustil v testu (k je skóre nesprávných odpovědí subjektu), lze odhadovat číselnou hodnotu parametru π metodou maximální věrohodnosti. Tímto způsobem nás výsledek testu dokáže informovat o tom, jaký podíl zkoušené látky subjekt ve skutečnosti neovládá či ovládá.

Odhady získané metodou maximální věrohodnosti mají dobré vlastnosti, žádoucí ve smyslu požadavků teorie statistického odhadování. Jsou asymptoticky nevyčýlené, asymptoticky eficientní a jejich rozdělení se blíží k rozdělení normálnímu – s rostoucím rozsahem testu n .

Maximálně věrohodný odhad $\hat{\pi}$ parametru π tedy je dán výrazem

$$\hat{\pi} = \frac{k}{n} \frac{q}{q-1}, \text{ jestliže } k \leq n \frac{q-1}{q}$$

$$\hat{\pi} = 1, \text{ jestliže } k > n \frac{q-1}{q}.$$

Střední hodnota odhadu

Za předpokladu, že π je skutečná hodnota parametru, lze odvodit střední hodnotu odhadu. Platí přitom

$$E(\hat{\pi}|\pi) = B\left(\left[n \frac{q-1}{q}\right] - 1 | n-1, \pi \frac{q-1}{q}\right) + \\ + 1 - B\left(\left[n \frac{q-1}{q}\right] | n, \pi \frac{q-1}{q}\right),$$

kde $[x]$ označuje celou část čísla x a

$$B(x|n, p) = \sum_{k=0}^x \binom{n}{k} p^k (1-p)^{n-k}$$

je distribuční funkce binomického rozdělení s parametry n a p , v bodě x .

Odhad (3) je vychýlený; jeho střední hodnota se liší od odhadované skutečné hodnoty parametru, a to tak, že očekávaná (střední) hodnota $E(\hat{\pi})$ odhadu parametru π je nižší nežli skutečná hodnota parametru π . Odhadem $\hat{\pi}$ je tedy odhadovaná hodnota parametru π v průměru podceňována.

Odchylka činí

$$\begin{aligned} \pi - E(\hat{\pi}|\pi) &= \\ &= \pi \left\{ 1 - B \left(\left[n \frac{q-1}{q} \right] - 1 \mid n-1, \pi \frac{q-1}{q} \right) \right\} - \\ &\quad - \left\{ 1 - B \left(\left[n \frac{q-1}{q} \right] \mid n, \pi \frac{q-1}{q} \right) \right\}. \end{aligned}$$

Rozdíl postupně mizí k nule s rostoucím q , tak, že v případě (hypotetického) testu s volně formulovanou odpovědí vymizí docela.

Rozptyl odhadu

Pro rozptyl $D(\hat{\pi}|\pi)$ odhadu tak dostáváme

$$\begin{aligned} D(\hat{\pi}|\pi) &= \\ &= \frac{n-1}{n} \pi^2 B \left(\left[n \frac{q-1}{q} \right] - 2 \mid n-2, \pi \frac{q-1}{q} \right) + \\ &\quad + \frac{1}{n} \frac{q}{q-1} \pi B \left(\left[n \frac{q-1}{q} \right] - 1 \mid n-1, \pi \frac{q-1}{q} \right) + \end{aligned}$$

$$\begin{aligned}
& + 1 - B \left(\left[n \frac{q-1}{q} \right] \middle| n, \pi \frac{q-1}{q} \right) - \\
& - \left\{ \pi B \left(\left[n \frac{q-1}{q} \right] - 1 \middle| n-1, \pi \frac{q-1}{q} \right) + \right. \\
& \left. + 1 - B \left(\left[n \frac{q-1}{q} \right] \middle| n, \pi \frac{q-1}{q} \right) \right\}^2.
\end{aligned}$$

Ve speciálním případě testu s volně tvořenou odpovědí ($q = \infty$) se rozptyl odhadu redukuje do podstatně jednoduššího tvaru

$$D(\mathfrak{H}|\pi) = \frac{1}{n} \pi(1-\pi).$$

Testy stejné informační účinnosti

Rozptyl $D(\mathfrak{H}|\pi)$ odhadu \mathfrak{H} je mírou informační účinnosti (vlastně spíše neúčinnosti) testu. Při daném π (skutečné, neznámé hodnotě parametru) závisí rozptyl dále na vnějších parametrech n a q . To nabízí možnost hledat takové kombinace hodnot (n, q) , které vedou ke shodným hodnotám rozptylu – a tedy kvantifikovat představu, která se zcela přirozeně nabízí: rozsáhlý test (s velkým počtem položek n) s jednoduchými položkami (o malém počtu nabídek odpovědi q) může být stejně účinný jako poměrně malý test (s nízkým n) se složitějšími položkami (o větším počtu nabídek odpovědi q).

Hodnotou rozptylu $D(\mathfrak{H}|\pi)$ jsou tedy zaváděny určité skupiny testů (n, q) dané úrovně ekvivalence informační účinnosti. Vyhledávání ekvivalentních testů je poměrně jednoduché. Pro zvolenou hodnotu parametru π a danou hodnotu rozptylu $D(\mathfrak{H}|\pi)$ se najdou pro dané hodnoty q příslušné rozsahy testů n . Hodnotu π je třeba volit na základě předběžné zkušenosti s úrovní znalostí subjektů ve zkoušené tematické oblasti.

Tak například, pro $\pi = 0,4$ (předpokládá se, že subjekty neovládají asi 40% zkoušené látky) zjišťujeme, že téže úrovně rozptylu odhadu ve výši 0,010 dosahují testy ($n = 64, q = 2$),

($n = 44, q = 3$), ($n = 37, q = 4$), ($n = 34, q = 5$) a ($n = 24, q = \infty$). Podobně můžeme postupovat také při jiných volbách π a $D(\mathcal{S}|\pi)$.

Grafickou modifikací postupu představují soustavy křivek na grafech. Pro zvolenou úroveň neznalosti a zvolenou kvalitu odhadu (na svislé ose) se odečítají souřadnice (na vodorovné ose) průsečíků této kvality odhadu s křivkami pro jednotlivé počty distraktorů q . Uvažována je úroveň neznalosti $\pi = 0,25$ a $\pi = 0,50$.