 Kineziologija, Vol. 13 (1982.) str. 23—27

KONSTANTIN MOMIROVIĆ, LEO PAVIČIĆ i ANKICA HOŠEK
Fakultet za fizičku kulturu Sveučilišta u Zagrebu

Primljeno 24. 5. 1982.

NEKI POSTUPCI ZA PROCJENU POUZDANOSTI NA TEMELJU UNIKNE VARIJANCE ČESTICA KOMPOZITNIH MJERNIH INSTRUMENATA

SAŽETAK

Predložene su dvije grupe postupaka za procjenu pouzdanosti kompozitnih mjernih instrumenata. U prvoj je grupi varijanca pogreške svake čestice definirana kao unikna varijanca te čestice, procjenjena na temelju sustava preostalih čestica. U drugoj grupi varijanca pogreške svake čestice definirana je na temelju jednofaktorskog kanoničkog modela.

0. UVOD

Primjena elektroničkih računala omogućila je da se pouzdanost kompozitnih mjernih instrumenata (tj. testova sačinjenih od većeg broja čestica) procijeni efikasnijim postupcima od onih koji su se nekada primjenjivali u tu svrhu. Tako je na temelju klasičnog modela pouzdanosti virtualno (ili samo intencionalno) jednodimenzionalnih psihologijskih mjernih instrumenata Momirović (Momirović, 1974) predložio da se pouzdanost procijeni na temelju omjera maksimalne varijance sustava čestica transformiranih u image oblik i maksimalne varijance normaliziranih i standardiziranih čestica. Ovaj postupak, koji u stvari daje donju granicu pouzdanosti određene na temelju interne konzistencije primijenjen je u većm broju analiza kognitivnih, konativnih i motoričkih tstova (Momirović, Džamonja, Hošek, Wolf i Gredelj, 1980).

Pod modelom koji image varijable tretira kao prave varijable, a antiimage varijable kao varijable pogreške, moguće je, minimiziranjem varijance pogreške, ili maksimiziranjem prave varijance testa, procijeniti samo donju i gornju granicu pouzdanosti (Momirović i Dobrić, 1977; Momirović, Dobrić i Gredelj, 1978; Momirović, Gredelj i Dobrić, 1981; Momirović i Gredelj, 1980).

Mjere pouzdanosti, izvedene pod ovim modelom, imaju neka pogodna svojstva, od kojih je najvažnija mogućnost izračunavanja varijance pogreške čestica. Međutim, posebno pod vidom praktične primjene rezultata ovaj model nije uvijek superioran klasičnom modelu.

Iako klasični model pouzdanosti vjerojatno nije uvijek prikladan za određivanje točnosti mjerenja psihologijskih i kineziologijskih mjernih instrumenata[1], zbog njegove opće prihvaćenosti, a vjeroajtno i zbog njegove logičke jednostavnosti, čini se opravdanim njegova uistinu konsekventna primjena pod uvjetom da se veličina varijance pogreške procijeni bez nepotrebnih restrikcija i aproksimacija karakterističnih za postupke koje su predložili Kuder i Richardson, Host, Cronbach, Spearman i Browne i drugi autori dobro poznatih i danas već klasičnih postupaka za procjenu pouzdanosti na temelju interne konzistencije kompozitnih testova.

Ako se pouzdanost definira kao omjer »prave« i ukupne varijance testa, vrijednost različitih postupaka za procjenu pouzdanosti ovisi od dva faktora:

(1) od toga na koji je način definirana varijanca pogreške testa, dakle varijanca pogreške svake pojedine njegove čestice,

(2) od toga kako su definirane kvadratne forme interprtirane ako komponente ukupne varijance testa, pa prema tome i od toga kako je definirana ukupna varijanca testa.

Ovdje će biti predloženo nekoliko postupaka kojih je zajedničko obilježje da su varijanca i različite njene komponente definirane kao kvadratne forme dobijene pomoću vektora normiranih na 1. U nekim slučajevima ovakva standardizacija ukupne varijance testa i različitih njenih komponenata ne mijenja bitno, ili ne mijenja uopće, vrijednost procijenjene pouzdanosti, ali u nekim slučajevima ovako definirane varijance vode do procjena suštinski različitih od onih koje bi se mogle dobiti drugačije definiranim kvadratnim formama. Većina predloženih postupaka, uz ovaj uvjet temelji se i na uvjetu da je ukupna varijanca testa maksimizirana i/ili da su maksimizirane komponente te varijance.

Predložene metode razlikuju se prema tome kako je definirana varijanca pogreške čestica. Obzirom na tu definiciju sve se metode mogu podijeliti u dvije velike grupe:

(1) u grupu metoda kod kojih je varijanca pogreške čestica definirana kao maksimalna unikna varijanca u okviru sustava čestica koji predstavlja određeni mjerni instrument,

(2) u grupu metoda kod kojih je varijanca pogreška čestica definirana na temelju jednofaktorskog kanoničkog modela.

[1] Lordov model (Lord i Novick, 1968) u mnogim slučajevima je bliži realnosti i zato podesniji za procjenu pouzdanosti.

Zajedničko je obilježje obje grupe predloženih metoda da ne maksimiziraju mjere pouzdanosti, već samo komponente ukupne varijance testa. Po ovome se te metode i razlikuju od onih koje su bile ranije predložene u okviru image ili generaliziranog image modela (Momirović i Dobrić, 1977; Zakrajšek, Momirović i Dobrić, 1977; Momirović, Gredelj i Dobrić, 1981) i modela koji se temelji na jednom jedinom značajnom predmetu mjerenja (Momirović i Dobrić, 1982).

1. DEFINICIJE

Neka je $Z=(z_{ij})$; $i=1,\ldots n$; $j = 1,\ldots, m$ matrica rezultata, u standardiziranom i normaliziranom obliku[2], što ih n subjekata postiglo u m čestica nekog kompozitnog mjernog instrumenta.

Matrica interkoleracija bit će, u tom slučaju

$$R = Z^T Z \frac{1}{n},$$

a dijagonalna matrica maksimalnih unikviteta (Guttman, 1953)

$$U^1 = (\mathrm{diag}\, R^{-1})^{-1},$$

gdje je R^{-1} inverz matrice interkorelacija.

Matrica rezultata, transformirnih u image oblik, bit će

$$\Psi = Z\,(I - R^{-1} U^2),$$

a matrica kovarijanci tako transformiranih čestica

$$C = \Psi^T \Psi \frac{1}{n} = R + U^2 R^{-1} U^2 - 2U^2 .$$

Matrica kovarijanci standardiziranih čestica i tih čestica transformiranih u image oblik bit će

$$Z^T \Psi \frac{1}{n} = R - U^2,$$

tj. dobro poznata »reducirana« matrica korelacija. Ova matrica definira zajednički potprostor čestica i njihove image transformacije.

Neka je X_1 prvi svojstveni vektor matrice R, normiran na 1, tako da je

$$X_1^T R X_1 = \lambda_1$$

prva svojstvena vrijednost te matrice. λ_1 je, očito, maksimalna varijanca kompozitnog mjernog instrumenta, i, prema tome, točna i nepristrasna procjena njegove ukupne varijance.

Neka je Y_1 prvi karakteristični vektor matrice $(R - U^2)$, tako da je

$$Y_1^T (R - U^2)\, Y_1 = \delta_1$$

prva svojstvena vrijednost te matrice. δ_1 se može smatrati varijancom testa oslobođenom udjela unikne varijance čestica, ako se takva varijanca odredi u zajedničkom prostoru čestica i njihovih image transformacija. Prema tome, δ_1 je jedna od mogućih procjena »prave« varijance testa.[3]

Pretpostavimo sada da test dopušta primjenu jednofaktorskog kanoničkog modela, tj. da barem aproksimativno vrijedi

$$R = L_1 L_1^T + S^2_1 ,$$

gdje je L_1 prvi kanonički faktor, a S_1 dijagonalna matrica unikviteta, određena na temelju Lawley-Raovog kanoničkog modela. Neka su matrice L_1 i S^2_1 procijenjene Rao-Maxwellovim iterativnim postupkom, tj. slijedećim algoritmom:

$$S^2_{10} = \mathrm{diag}\,(R - X_1 \Lambda_1 X_1^T)$$

$$P_1 = S^{-1}_{10} (R - S^2_{10})\, S^{-1}_{10}$$

$$\eta_{11}^T P_1 \eta_{11} = \phi_{11}$$

$$L_{11} = S_{10}\, \eta_{11}\, (\phi_1 - 1)^{1/2}$$

$$S^2_{11} = \mathrm{diag}\,(R - L_{11} L^T_{11})$$

$$P_2 = S^{-1}_{11}\, (R - S^2_{11})\, S^{-1}_{11}$$

$$\eta^T_{12}\, P_2\, \eta_{12} = \Phi_{12}$$

$$L_{1a} = S_{1a}\, \eta_{1a}\, (\phi_{1a} - 1)^{1/2}$$

$$S^2_{1a} = \mathrm{diag}\,(R - L_{1a} L^T_{1a})$$

$$P_{a+1} = S_{1a}^{-1}\, (R - S^2_{1a})\, S_{1a}^{-1}$$

$$\eta^T_{1,a+1} P_{a+1} \eta_{1,a+1} = \Phi_{1,a+1}$$

gdje je a oznaka iteracije. Matrica S^2_{11} dobijena u posljednjoj iteraciji, tj. kada uz neku proizvoljno malu pogrešku vrijedi $S^2_{1a} = S^2_{1,a+1}$, sadrži unikvitete čestica definirane u okviru jednofaktorskog kanoničkog modela. Svojstvena vrijednost ϕ_1, dobijena u posljednjoj iteraciji, je varijanca sustava čestica transformiranih u kanoničku Harrisovu formu (Harris, 1962), pa je, otuda, maksimalna varijanca sustava čestica u okviru jednodimenzionalnog kanoničkog modela $(\phi_1 - 1)$.

Naravno, matrica rezultata ispitanika u česticama, transformiranim u antiimage oblik, bit će

$$A = Z\,U^{-1},$$

a matrica kovarijanci tako transformiranih čestica

$$C = U^{-1} R\, U^{-1}.$$

Neka je V_1 prvi svojstveni vektor matrice C, tako da je

$$V^T_1\, C\, V_1 = \alpha_1$$

prva svojstvena vrijednost te matrice. U tom će slučaju

---

[2] Operacija normalizacije i standardizacije presudna je za razborito određivanje pouzdanosti psihologijskih mjernih instrumenata, kao uostalom i za razboritu primjenu psihologijskih testova. U tu se svrhu može primijeniti dobro poznati Abramowitzev algoritam, koji je u obliku potprograma NORMALISATION sastavni dio programskog sistema SS.

[3] Naravno, pravom se varijancom može smatrati i prva svojstvena vrijednost matrice kovarijanci čestica, transformiranih u image oblik (ξ_1, recimo). Na temelju tako definirane prave varijance je i izveden spomenuti Momirovićev koeficijent pouzdanosti koji je, očito, ξ_1/λ_1

V_1 biti i prvi svojstveni vektor Harrisove transformacije reducirane matrice interkorelacije čestica, tako da će

$$V^T_1 U^{-1} (R - U^2) U^{-1} V_1 = \alpha_1 - 1$$

biti maksimalna varijanca testa, čije su čestice, pod ovim modelom, oslobođene unikne varijance. $\alpha_1 - 1$ je otuda također jedna od mogućih procjena »prave'« varijance testa.

Definirajmo još, zbog notacionih pogodnosti, ω kao vektor jedinica reda m, i $\omega\, m^{-1/2} = \beta$ kao normirani vektor, pogodan za izračunavanje kvadratnih formi u slučaju kad se ne može odbaciti hipoteza da je neki karakteristični vektor jednak β[4].

2. ODREĐIVANJE POUZDANOSTI NA TEMELJU MAKSIMALNE VELIČINE UNIKVITETA ČESTICA

Ako se »prava« varijanca testa definira u potprostoru koji je zajednički česticama i njihovoj image transformaciji, i ako se dopusti da čestice mogu biti nejednako saturirane prvim glavnim predmetom mjerenja testa, pouzdanost se može definirati kao

$$\mu_1 = \delta_1 / \lambda_1 \,.$$

Uočimo da je

$$(X^T_1 R X_1) = (Y^T_1 R Y_1 - \mu_1 = (Y^T_1 (R - U^2) Y_1) \;/\; -Y^T_1 U^2 Y_1)$$
$$/ \;\lambda_1 = Y^T_1 R Y_1 \lambda_1^{-1} - Y^T_1 U^2 Y_1 \lambda_1^{-1} \,,$$

pa je prema tome pouzdanost testa proporcionalna ponderiranom zbiru koeficijenata determinacije čestica na temelju subsistema od (m—1) preostalih, tj. varijancama varijabli transformiranih u image oblik. Kako su koeficijenti u Y_1 direkcionalni kosinusi vektora čestica i prve glavne osovine reducirane matrice korelacija, one čestice koje najviše sudjeluju u određivanju ukupnog rezultata u testu u najvećoj mjeri doprinose pouzdanosti testa.

Ako ima valjana razloga za pretpostavku $X_1 = Y_1 = \beta$[5] pouzdanost se može procijeniti aproksimativnim postupkom

$$\mu_2 = (\beta^T (R - U^2) \beta) \;/\; (\beta^T R \beta)$$
$$= (m^{-1/2} \omega^T (R - U^2) \omega\, m^{-1/2}) \;/\; (m^{-1/2} \omega^T R\, \omega\, m^{-1/2})$$
$$= (\omega^T (R - U^2) \omega) \;/\; (\omega^T R \omega)$$
$$= \omega^T R \omega - \omega^T U^2 \omega) \;/\; (\omega^T R \omega)$$
$$= 1 - (\omega^T U^2 \omega) \;/\; (\omega^T R \omega) \,.$$

[4] Andersonov test te hipoteze (Anderson, 1958) vidi i u Morrison, 1976.

[5] Psiholozi se, doduše, gotovo uvijek ponašaju kao da je ova hipoteza ispravna, dakle, kao da sve čestice nekog testa jednako doprinose određivanju predmeta mjerenja tog testa. Međutim, najmanje što se može učiniti je da se ova hipoteza provjeri s pomoću Andersonova testa; ako se na temelju tog testa ta hipoteza ne može odbaciti, može se u određivanju pouzdanosti smatrati da je ispravna, iako, naravno, nemogućnost odbacivanja te hipoteze još i nije dokaz njene ispravnosti.

U ovom je, dakle, slučaju pouzdanost testa inverzno proporcionalna zbroju unikviteta čestica, i upravo proporcionalna zbroju koeficijenata korelacija između svih parova čestica. Lako je pokazati da ovdje (a i inače) vrijedi Sperman-Browneovo pravilo, tj. da je pri jednakim vrijednostima prosječne varijance pogreške čestica, i jednakim vrijednostima prosječnog koeficijenta korelacije čestica, test utoliko pouzdaniji ukoliko sadrži veći broj čestica.

Zaista, ako definiramo $\sum_j^m u_j / m = u^{-2}$ kao prosjek unikviteta, i $r = \sum_j^m \sum_k^m r_{jk} / m^2$ kao prosjek koeficijenata interkorelacija čestica,

$$\mu_2 = 1 - u^2 / m \cdot r$$

pa, uz konstantne vrijednosti u^2 i r, μ_2 raste proporcionalno broju čestica.

Izražavanje testovnih rezultata u antiimage metrici omogućuje još jedan način za procjenu pouzdanosti testa na temelju maksimalne unikne varijance njegovih čestica. Ako su rezultati pretvoreni u Harrisov oblik α_1 je ukupna varijanca testovnih rezultata. a $(\alpha_1 - 1)$ varijanca »pravog« testovnog rezultata, pa je pouzdanost

$$\mu_3 = (\alpha_1 - 1) \;/\; \alpha_1 = 1 - 1/\alpha_1 \,,$$

što odgovara Guttman-Nicewanderovoj mjeri λ_6.

Prema tome, pouzdanost testa je proporcionalna varijanci prve glavne komponente čestica transformiranih u Harrisov oblik. Zbog toga što vrijedi (vidi o tome, npr. u Morrison, 1967) da je gornja granica najveće svojstvene vrijednosti jednaka maksimalnom zbroju kovarijanci neke varijable sa svima ostalima, i ovdje vrijedi da od dva testa koji imaju jednake prosječne unikvitete i jednaku prosječnu korelaciju čestica, veću pouzdanost ima onaj koji sadrži veći broj čestica.

To se direktno vidi iz aproksimativne meotde za određivanje pouzdanosti testa u Harrisovom prostoru, izvedene uz pretpostavku da vrijedi $V_1 = \beta$. U tom slučaju,

$$\mu_4 = (\omega^T_1 (U^{-1} R U^{-1} - I) \omega) \;/\; (\omega^T_1 (U^{-1} R U^{-1}) \omega_1)$$
$$= (\omega^T_1 U^{-1} R U^{-1} \omega_1 - \omega^T_1 I\, \omega_1) \;/\; (\omega^T_1 U^{-1} R U^{-1} \omega_1)$$
$$= 1 - m \;/\; (\omega^T_1 U^{-1} R U^{-1} \omega_1)$$
$$= 1 - m \,/\, (\omega^T_1 C \omega_1) \,.$$

Zbog toga što uvijek vrijedi $\alpha_1 > \lambda_1 > \delta_1$, $\mu_3 > \mu_1$ μ_3 se (ili njegova aproksimacija μ_4) može tretirati kao procjena gornje granice pouzdanosti.

3. ODREĐIVANJE POUZDANOSTI NA TEMELJU UNIKVITETA DEFINIRANIH JEDNOFAKTORSKIM KANONIČKIM MODELOM

Varijanca glavnog predmeta mjerenja testa u jednofaktorskom kanoničkom modelu je, u originalnoj matrici,

$$\chi_1 = L^T_1 L_1 = (\phi_1 - 1)^{1/2} \eta^T_1 S^2_1 \eta_1 (\phi - 1)^{1/2}$$

i može se tretirati kao procjena prave varijance testa. Otuda je pouzdanost moguće definirati kao

$$\sigma_1 = \chi_1 / \lambda_1$$

Međutim, iako je u okviru kanoničkog modela

$$R = L_1 L^T_1 + S^2_1 ,$$

χ_1 nije maksimalna varijanca sustava $R - S^2_1$. Zbog toga, analogno koeficijentu μ_1, može se definirati jedan koeficijent pouzdanosti na temelju najveće svojstvene vrijednosti $R - S^2_1$, za koju je lako pokazati da je, u stvari, matrica korelacija originalnih varijabli i njihove aproksimacije sukladne jednofaktorskom kanoničkom modelu.

Zbog toga što je S^2_1 matrica kovarijanci varijabli pogreške čestica,

$$\Omega = Z\,(I - R^{-1} S^2_1)$$

je matrica rezultata ispitanika u ovako definiranim varijablama. Očito,

$$Z'^T \Omega \frac{1}{n} = R - S^2_1$$

je matrica korelacija čestica i njihove kanoničke transformacije, pa njeni vektori definiraju potprostor koji je zajednički originalnim vektorima čestica i onom dijelu tih vektora koji je ortogonalan na kanonički definiran prostor pogreške. Ako je γ_1 prvi svojstveni vektor matrice $R - S^2_1$,

$$\gamma'_1 (R - S^2_1) \gamma_1 = \gamma^T_1 R \gamma_1 - \gamma^{T_1} S^2_1 \gamma_1 = \tau$$

je prva svojstvena vrijednost te matrice. Koeficijent

$$\sigma_2 = \tau_1 / \lambda_1$$

može se, dakle, također tretirati kao koeficijent pouzdanosti. Očigledno je da, zbog toga što je $\tau_1 > \chi_1$, vrijedi $\sigma_1 < \sigma_2$

Donja granica pouzdanosti u okviru jednofaktorskog kanoničkog modela može se dobiti ako se »prava« varijanca definira kao varijanca prve glavne komponente rezultata transformiranih u kanonički image oblik. Matrica kovarijanci ovako definiranih image čestica bit će

$$\Omega^T \Omega \frac{1}{n} = R + S^2_1 R^{-1} S^2_1 - 2S^2_1 .$$

Neka je W_1 prv svojstveni vektor te matrice;

$$W^T_1 \,\Theta\, W_1 = \eta_1$$

dati će procjenu minimalne »prave« varijance, pa je koeficijent

$$\sigma_3 = \eta_1 / \lambda_1$$

procjena donje granice pouzdanosti, analogan koeficijentu $\xi_1 / \lambda_1 = \tau_1$, tj. procjeni donje granice pouzdanosti na temelju maksimalnih unikviteta.

Analogno koeficijentu μ_3, gornja se granica pouzdanosti može procijeniti nakon transformacije rezultata u kanonički antiimage oblik. U tom slučaju, za jednodimenzionalni kanonički model,

$$\sigma_4 = (\phi_1 - 1) / \phi_1 = 1 - 1 / \phi_1$$

biti će mjera gornje granice pouzdanosti testa.

4. PROGRAMSKA IMPLEMENTACIJA PREDLOŽENIH MJERA POUZDANOSTI

Neke od predloženih mjera pouzdanosti implementirane su u program RTT*MARK FFK L. Pavičića. U ovom programu predloženi koeficijenti označeni su ovim imenima:

μ_1 = MI1
μ_2 = MI2
μ_3 = MI3
μ_4 = MI4.

U ovom programu su i neki koeficijenti pouzdanosti, opisani u ranijim radovima. SA ALPHAMIN označen je koeficijent τ_1 (Momirović, 1975), sa SPEARMAN-BROWN 2 generalizirani Spearman-Browneov koeficijent pouzdanosti, sa SPEARMAN-BROWN 1 koeficijent pouzdanosti definiran jednadžbom $(m^* r^*) / (1 + (m-1) r^*)$, gdje je

$$r^* = \left(\left(\sum_j^m \sum_k^m r^2_{jk} - m \right) / (m^2 - m) \right)^{1/2},$$

a sa INDEX OF RELIABILTY koeficijent $\left((m / (m-1)) \right) \left(1 - \sum^m w_j \right))^{1/2}$, gdje su w_j elementi vektora $W = (U^{-1} - R^{-1} U) V_1 \alpha^{1/2} /$ (Kaiser i Rice, 1974).

5. ZAKLJUČAK

Predložene su dvije grupe postupaka za procjenu pouzdanosti kompozitnih mjernih instrumenata. U prvoj je grupi varijanca pogreške svake čestice definirana kao unikna varijanca te čestice, procijenjena na temelju sustava preostalih čestica. U drugoj grupi varijanca pogreške svake čestice definirana je na temelju jednofaktorskog kanoničkog modela.

Ukupna varijanca testa definirana je kao varijanca prve glavne komponente normaliziranih i standrdizirnih čestica, ili kao varijanca prve glavne komponente čestica reskaliranih na generaliziranu antiimage metriku. Prava varijanca testa definirana je (a) kao prva svojstvena vrijednost reducirane matrice interkorelacija, (b) kao prva svojstvena vrijednost reducirane matrice interkorelacija reskalirane na antiimage metriku, (c) kao varijanca prvog kanoničkog faktora i (d) kao varijanca prvog kanoničkog faktora u antiimage metrici.

6. LITERATURA

1. Anderson, T. W.: An introduction to multivariate statistical analysis. Wiley, New York, 1958.
2. Harris, C. W.: Some Rao-Guttman relationships, Psychometrika, 1962, 27, 247—263.
3. Kaiser, H. F. and J. Rice: Little Jiffy, Mark IV. Educational and Psychological measurements, 1974, 34, 1.
4. Lord, F. M. and M. Novick: Statistical theory of mental test scores, Addison-Wesley, Readino, 1968.
5. Momirović, K.: Određivanje donje granice pouzdanosti kompozitnih testova, Materijali V Kongresa psihologa

SRJ, Društvo psihologa SR Makedonije, Skopje, 1975, 258—261.
6. Momirović, K. i V. Dobrić: Jedna mjera donje granice pouzdanosti pod modelom koji dopušta nenulte kovarijance varijabli pogreške. Zbornik skupa psihologa »Dani Ramira Bujasa« 1978, Društvo psihologa SR Hrvatske, Zagreb, 1977, 135—144.
7. Momirović, K., Z. Džamonja, A. Hošek, B. Wolf i M. Gredelj: Struktura antropoloških dimenzija vojnika JNA. Odelenje za psihologiju Vojno-medicinske akademije, Beograd, 1980.
8. Momirović, K., V. Dobrić i M. Gredelj: Mjera reprezentativnosti nekog uzorka varijabli. Radovi sa znanstvenog skupa »Istraživanja na području defektologije«, Fakultet za defektologiju, Zagreb, 1978, 31—37.
9. Momirović, K., M. Gredelj i V. Dobrić: Mirror image analysis and its application to reliability theory. III International Symposium »Computer at the University«, Cavtat, 1981, 305, 1—3.
10. Momirović, K. i M. Gredelj: Primjena elektroničkih računala u određivanju metrijskih karakteristika i izračunavanju testovnih rezultata. Društvo psihologa Hrvatske, Zagreb, 1980.
11. Momirović, K. i V. Dobrić: Procjena pouzdanosti kompozitnih mjernih instrumenata na temelju iterativnog postupka za procjenu varijance pogreške čestica. VI psihologijski skup »Dani Ramira Bujasa«, Zagreb, 1981.
12. Morrison, D. F.: Multivariate statistical methods. McGraw-Hill, New York, 1976.
13. Zakrajšek, E., K. Momirović i V. Dobrić: Alternativna definicija mjera pouzdanosti pod modelom koji dopušta nenulte kovarijance varijabli pogreške. Kineziologija, 1—2, 157—160.

SOME PROCEDURES FOR ASSESSMENT OF RELIABILITY ON THE BASIS OF THE UNIQUE VARIANCE OF ITEMS OF THE COMPOSITE MEASURING INSTRUMENTS

Two groups of procedures for assessment of reliability of the composite measuring instruments were proposed. In the first group the error variance of each item was defined as the unique variance of that item, assessed on the basis of the system of the remaining items. In the second group the error variance of each item was defined on the basis of a uni-factor canonic model.

The total variance of a test defined as the variance of the first principal component of the normalized and standardized items, or as the variance of the first principal component of items re-scaled on the generalized anti-image metrics. The true variance of a test was defined (a) as the first characteristics value of the reduced intercorrelation matrix, (b) as the first characteristic value of the reduced intercorrelation matrix re-scaled on the anti-image metrics, (c) as variance of the first canonic factor and (d) as variance of the first canonic factor in the anti-image metrics.

Константин Момирович, Лео Павичич, Анкица Хошек

НЕКОТОРЫЕ ПРИЕМЫ ДЛЯ ОЦЕНКИ ДОСТОВЕРНОСТИ НА ОСОНОВАНИИ УНИКНОЙ ВАРИАНЦЫ ЗАДАНИЙ КОМПЛЕКСНЫХ ИЗМЕРИТЕЛЬНЫХ ИНСТРУМЕНТОВ

Предлагаются два вида приемов для оценки достоверности комплексных измерительных инструментов. В первом виде варианца ошибки каждого задания определяется как уникная варианца этого задания, которая оценивается на основании системы остальных заданий. Во втором виде варианца ошибки каждого задания определяется на основании однофакторной канонической модели.

Общая варианца теста определена как варианца первого главного компонента нормализованных и стандартизованных заданий, или как варианца первого главного компонента заданий рескалированных на генерализованную антиимаж метрику. Действительная варианца теста определена: (а) как первая характерная величина редуцированной матрицы интеркорреляций, (б) как первая характерная величина редуцированной матрицы интеркорреляций, рескалированной на антиимаж метрику, (в) как варианца первого канонического фактора и (г) как варианца первого канонического фактора в антиимаж метрике.