

Neke dvojbe u primjeni faktorske analize u području istraživanja odgoja i obrazovanja (pedagogiji)

UDK: 37.012-303.722.2

Pregledni članak

Primljeno: 14. 6. 2012.

Prihvaćeno: 20. 10. 2012.

Sažetak: *Cilj je rada rasvijetliti neke dvojbe u primjeni faktorske analize, poput: razlika između faktorske analize i analize glavnih komponentata, odabir odgovarajuće veličine i omjera uzorka i broja varijabla, razlika između ortogonalnih i kosokutnih rotacija, odabir odgovarajućeg kriterija za zaustavljanje ekstrakcije faktora (Guttman-Kaiserov kriterij i Cattellov „scree test“), te odabir odgovarajuće matrice za interpretaciju faktora (matrica sklopa i matrica strukture). Navedene dvojbe u istraživanjima odgoja i obrazovanja (naglasak je na pedagogiji) potkrjepljenje su preglednim stajalištima i deskripcijama raznih autora te čitatelju pružaju samostalan zaključak o odabiru određenih interpretacija, odnosno stajališta, a sukladno ulaznim parametrima vlastitog istraživanja. Kompleksnost faktorske analize naglašava upitnost jednoznačnih stajališta, odnosno propitivanje odabira odgovarajućih statističkih parametara.*

Ključne riječi: *faktorska analiza, rotacija, varijanca, metoda glavnih komponentata, matrica sklopa, matrica strukture.*

Sinisa Opic*

Some Doubts about the Use of Factor Analysis in the Field of Research Education (Pedagogy)

UDC: 37.012-303.722.2
Review article

Accepted: 14th June 2012
Confirmed: 20th October 2012

Summary: *The aim of this article is to clarify some doubts regarding the application of factor analysis. Some of these problems dealt with here are: the difference between factor analysis and principal component analysis, the selection of proper size and aspect ratio of the sample and the number of variables, the difference between the orthogonal and oblique rotation, the selection of the appropriate criteria for stopping the extraction of factors (Guttman-Kaiser criteria and Cattell screening test), and the selection of the appropriate matrix for the interpretation of factors (the pattern matrix and the structure matrix). These dilemmas in research education (emphasis on pedagogy) are extremely important and descriptions of various authors provide readers with an independent conclusion regarding the selection of a specific interpretation or point of view, in accordance with the input parameters of one's own research. The complexity of factor analysis highlights questionability of unambiguous positions, that is, it highlights questioning the selection of appropriate statistical parameters.*

Keywords: *factor analysis, rotation, variance, the method of principal components (PCA), pattern matrix, structure matrix.*

1. Uvod

Faktorska analiza svoje začetke i razvoj sažima početkom 20. stoljeća unutar psihologije, i to matematičkim postupcima kojima je cilj reducirati dimenzionalnost interkoleriranog manifestnog prostora seta varijabla na manji set varijabla koje čine faktore (interpretabilne). Iako faktorska analiza ima provobitan primat korištenja unutar psihologije, sve više se upotrebljava i u drugim društvenim znanostima s ciljem zadovoljenja načela parsimoničnosti, odnosno objašnjenja većeg broja varijabla s manjim brojem ekstrahiranih faktora. Razvojem pedagogije kao kritičke i stvaralačke znanosti o odgoju, pojave koje se opisuju manifestnim varijablama sve su opsežnije te je korištenje faktorske analize postala česta praksa u navednim istraživanjima. Za razliku od drugih multivarijantnih metoda obrade

podataka, faktorska analiza izuzetno je široko područje, štoviše većina drugih metoda njihova je izvedenica; regresijska analiza, kanoničko-korelacijska i druge srodne analize. Ta širina i kompleksnost faktorske analize nameće istraživačima oprez u njezinu korištenju. Iz navedene kompleksnosti istraživači ponekad iz vlastite paradigme ili dubinskog nerazumijevanja određenih postupaka višeznačno tumače određene postupke s većom ili manjom statističkom opravdanošću. U radu su elaborirane neke dvojbe unutar faktorske analize, poput: razlika između faktorske analize i metode glavnih komponentata, odnos veličine uzorka i varijabli, Guttman-Kaiserov kriterij i Cattelov *scree* test, razlike između ortogonalnih i kosokutnih rotacija te interpretabilnosti matrice sklopa i matrice struktura unutar kosokutnih rotacija. Navedene dvojbe često su primjer svojevrstnih statističkih neopravdanih postupaka unutar korištenja faktorske analize, ali i krivo donesenih zaključaka. U tekstu se ne daju konačni odgovori, već sustavan pregled stajališta stranih (i domaćih) autora o navedenim dvojbama te se čitatelj treba odlučiti za određeno stajalište, a naravno ovisno o specifičnosti istraživanja koje provodi.

2. Faktorska analiza nasuprot metodi glavnih komponentata

Česta je pojava da istraživači koriste termin faktorska analiza, a da zapravo koriste metodu glavnih komponentata. Eksplanatorna faktorska analiza i analiza glavnih komponentata nisu istoznačnice te se u mnogim parametrima razlikuju. Važnu nedoumicu istraživačima stvara statistički paket SPSS (novije verzije) jer se pod faktorsku analizu ubraja metoda glavnih komponentata kao metoda ekstrakcije faktora.

Tablica 1 – Diferencijalni prikaz metode glavnih komponentata i faktorske analize

Metoda glavnih komponentata	Faktorska analiza
analizira cjelokupnu varijancu	analizira samo zajedničku varijancu; manje je osjetljiva na <i>noise</i> – „šum“ podataka!
broj komponentata (ili faktora) teoretski je jednak broju manifestnih varijabli	broj faktora mora biti unaprijed određen
pretpostavke za korištenje više su konceptualne naravi	statističke pretpostavke za korištenje
manje osjetljiva na homogenost varijance, kolineranost i normalnost	osjetljivija na navedene parametre
koncentrira se na varijancu (Jolliffe, 2002.: 2.)	koncentrira se na korelacije i kovarijance

Kao što je vidljivo iz Tablice 1, metoda glavnih komponenta i faktorska analiza značajno se razlikuju u svom zadanom cilju, parametrima, ali i ishodišnim rezultatima. U tom smjeru, od samog razvoja faktorske analize, Thomson (1939.) ukazuje da je cilj faktorske analize objasniti izvandijagonalne korelacije između manifestnih varijabli prisutnošću jedne ili više latentnih varijabla koje predstavljaju korelaciju između manifestnih varijabla. Tijekom faktorske ekstrakcije zajednička varijanca varijable podijeljena je svojom jedinstvenom varijancom (*unique*) i varijancom pogreške (*error*) kako bi se otkrio temeljni faktor strukture. Odnosno, u faktorskoj analizi samo se zajednička varijanca pojavljuje u soluciji dok kod metode glavnih komponenta to nije slučaj (ne razlikuje se zajednička i jedinstvena varijanca). Metoda glavnih komponenta ima za cilj smanjiti dimenzionalnost prostora skupa podataka na način da konstruira ortogonalne latentne dimenzije (komponente) koje nisu u međusobnoj korelaciji. Glavne su komponente linearne kombinacije izvornih manifestnih varijabla, što implicira da je broj glavnih komponenata teoretski moguć broju manifestnih varijabla dok kod faktorske analize to nije slučaj. Jedan od argumenata u korist preferenciji faktorske analize jest da istraživači *a priori* određuju broj latentnih dimenzija, odnosno faktora, dok kod metode glavnih komponenata on je najčešće zadan prema Guttman-Kaiserovu kriteriju, Cattelovu *scree* testu te rjeđe prema PB kriteriju, Bartletovu kriteriju, *Image* analizi, 5%-tnom kriteriju, arbitrarnom i drugim kriterijima. Osim nekih navedenih razlika (Tablica 1) pomutnju stvara statistički paket SPSS gdje se upravo metoda glavnih komponenata podrazumijeva kao model ekstrakcije faktora u faktorskoj analizi. Međutim, iako se u literaturi navode prednosti korištenja faktorske analize nad metodom glavnih komponenata (Bentler i Kano, 1990.; Mulaik, 1990.), ipak se u novije vrijeme pojavljuju radovi autora koji nastoje nivelirati, izjednačiti njihovu važnost i semantiku. U tom smjeru npr. Field (2005.) ističe da, ako je riječ o istraživanju koje ima veći broj varijabli (>30), a komunaliteti su visoki (>0.7), ne očekuju se različite solucije između faktorske analize i analize glavnih komponenata. Analogno tome, Velicer i Jackson (1990.), Fava i Velicer (1992.), sugeriraju da rezultati dobiveni faktorskom analizom i metodom glavnih komponenata nisu značajno različiti, već su u mnogim slučajevima slični (s obzirom na usporedbu vrijednosti faktorskih solucija). Naravno da ova debata istraživačima stvara nedoumicu prilikom odabira navedenih dviju metoda.

3. Veličina uzorka i varijabla

Veličina uzorka koji je u minimalnoj mjeri potreban da bi faktorska analiza bila metodološki opravdana u literaturi nije jednoznačno određena. Ona iznosi:

- najmanje 300 (Tabachnick i Fidell, 2001., 2007.; Field, 2005.; Kass i Tinsley, 1979.; Baiyin, 2005.)
- više od 100 (Hair et al., 1995.; Fulgozi, 1979., 331.)
- 50 – premalo; 100 – slabo; 200 – zadovoljavajuće; 300 – optimalno, a 1000 – izvrsno (Comrey i Lee, 1992.).


Kao što je vidljivo, autori se jednoznačno ne slažu u donjoj granici veličine uzorka koja je potrebna za korištenje faktorske analize. Međutim, razmatranja o veličini uzorka nisu samo jednoznačno određena, već su u odnosu s faktorskim opterećenjima i komunalitetima. Tako npr. ako faktor ima 4 ili više opterećenja većih od 0,60, veličina uzorka pouzdana je, dok za faktor s 10 ili više opterećenja većih od 0,40 uzorak treba biti veći od 150. Konačno, faktor sa samo nekoliko opterećenja nije potrebno interpretirati ako uzorak nije veći od 300 (Guadagnoli i Velicer, 1988.). Veličinu uzorka možemo promatrati u odnosu s komunalitetima odnosno s onim dijelom totalne varijance koja je uvjetovana zajedničkim faktorima, tj. onim dijelom varijance koji varijabla dijeli s drugim varijablama. U tom smjeru MacCallum et al. (1999.) ističu da, ako su svi komunaliteti veći od 0,60, tada je i uzorak manji od 100 adekvatan, dok, ako su komunaliteti oko 0,50, veličina je adekvatnog uzorka između 100 i 200. Kada su komunaliteti daleko manji od 0,50 i kada je mnogo determiniranih faktora, veličina uzorka treba biti viša od 500. Isto tako, preduvjet za korištenje faktorske analize sažima odnos varijabli i ispitanika. Prema Fulgozi (1979.: 331.) odnos varijabli i ispitanika mora biti najmanje 1:5, dok Everitt (1975.) zahtijeva da taj omjer treba biti najmanje 1:10, odnosno 1:5 – 10 (Baiyin, 2005.). Međutim, taj omjer kod mnogih istraživača značajno je veći pa se proteže do omjera 1:20 (Costello i Osborne, 2005.).

Iz navedenih razmatranja možemo sugerirati da bi optimalna veličina uzorka za primjenu faktorske analize trebala težiti najmanje 300 ispitanika s odnosom varijabla i ispitanika najmanje 1:5.

Adekvatnost uzorka s obzirom na broj varijabla neizostavno se testira Kaiser-Meyer-Olkin testom (KMO). KMO bazira se na omjeru suma parcijalnih i opaženih korelacija u matrici, odnosno testira se podobnost matrice korelacija za faktorizaciju.

4. Pravokutne nasuprot kosokutnim rotacijama

U faktorskoj analizi rotacije se primjenjuju kako bismo poboljšali interpretabilnost faktora. Rotacija povećava opterećenje svake varijable na jednom od ekstrahiranih faktora, a umanjuje opterećenje na svim drugim faktorima. Proces rotacije omogućava uvid u to koje se varijable odnose na koje faktore (ili komponente). Korištenje rotacija metodološki su elaborirali Thurstone (1947.) i Cattell (1978.), želeći pojednostaviti faktorsku strukturu i njihovu interpretabilnost. Osnovni je cilj rotacija stvaranje jednostavne strukture koja olakšava interpretaciju i njezinu pouzdanost. Rotacije su gotovo neizostavan postupak u faktorskoj analizi i gotovo da se podrazumijeva da je bez provedbe rotacije faktorska analiza nedovršena. Zorni prikaz razlika u dimenzionalnom prostoru nerotirane i rotirane strukture predočuje Child (2006.):



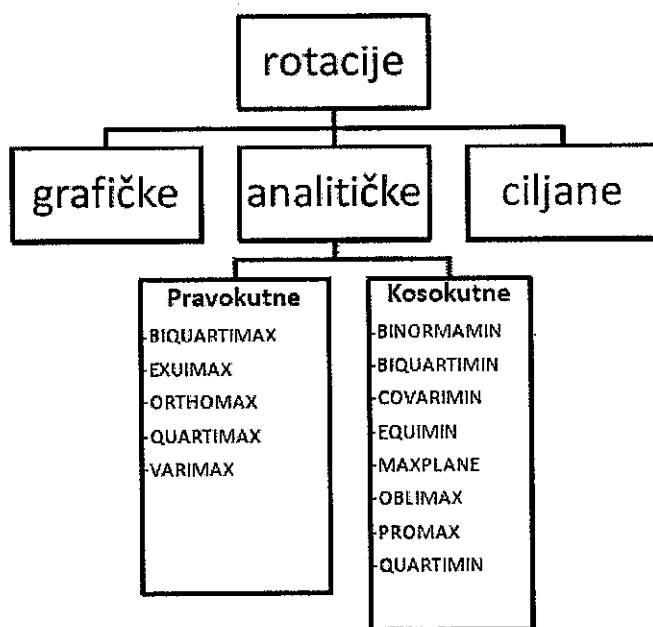
Slika 1 – Diferencije između nerotirane i rotirane strukture

Kao što je vidljivo na Slici 1, ako rotiramo osi oko ishodišta 0 za 30 u smjeru kazaljke na satu, one ostaju u međusobnom odnosu pod 90 (pravokutna rotacija). Međutim, vrijednosti su se promijenile na način da se početna os A(+0,80, +0,40) rotirala u nove vrijednosti B(+0,75) i C(+0,50). Ovo je grafička simulacija jer se prave vrijednosti analitički rješavaju trigonometrijskim jednadžbama.

Prvobitno su korištene grafičke rotacije čiji je cilj bio prepoznavanje jednostavne strukture iz faktorske matrice. Thurstone (1947.) predložio je prvobitno tri, a kasnije pet kriterija za prepoznavanje jednostavne strukture. Prema ovim kriterijima faktorska matrica (matrica opterećenja) ima jednostavnu strukturu u sljedećim slučajevima:

- ako svaki redak u faktorskoj matrici sadrži najmanje jednu nulu (0)
- ako postoji r zajedničkih faktora, tada u svakom stupcu faktorske matrice mora biti najmanje r nula (0)
- u svakom paru stupaca faktorske matrice mora postojati nekoliko varijabli koje će imati nule (0) u jednom, ali ne u drugom stupcu
- kad je broj faktora veći od 4, onda u svakom paru stupaca faktorske matrice velika većina varijabli mora imati nestajuće ili nulte projekcije
- u svakom paru stupaca faktorske matrice postoji samo mali broj varijabli s projekcijama koje ne nestaju na obama stupcima.

Rotacije se dijele na 3 osnovne skupine (Slika 2): grafičke, analitičke i ciljane (Frank i Todeschini, 1994.).



Slika 2 – Vrste rotacija

Danas se koriste analitičke rotacije koje su značajno pouzdanije i točnije za razliku od prvobitnih grafičkih. Izuzetno je važno istaknuti da niti jedna rotacija ne može promijeniti količinu varijance ekstrahiranu iz pojedinih stavaka.

Kosokutne rotacije metodološki su opravdanije za korištenje u društvenim znanostima jer pružaju realističniji prikaz kako su faktori međusobno povezani. Ako su faktori nepovezani, ili vrlo slabo povezani, kosokutna će rotacija kreirati

solucije koje su virtualno iste kao kod pravokutne rotacije. Mejovšek (2008.: 246.) ukazuje na prednost kosokutnih rotacija jer se može potpunije zadovoljiti Thurstonov kriterij jednostavne strukture i to zbog veće fleksibilnosti u određivanju pojedinog faktora. Isto tako ukazuje na jednostavnost ortogonalnih rotacija jer se kosokutne rotacije interpretiraju na tri matrice: matricu sklopa, matricu strukture i matricu korelacija faktora, dok se ortogonalne interpretiraju samo na jednoj: matrici strukture.

Osnovne razlike između pravokutnih i kosokutnih rotacija možemo svesti na sljedeće (Tablica 2):

Tablica 2 – Razlike između pravokutnih i kosokutnih rotacija u faktorskoj analizi

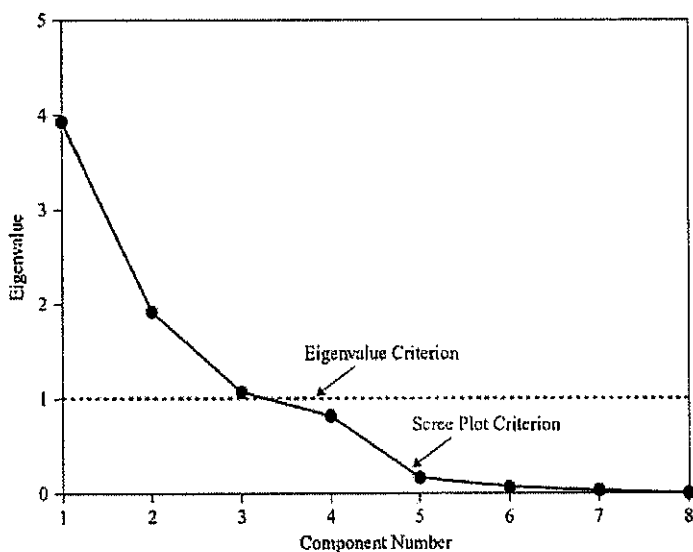
pravokutne rotacije	kosokutne rotacije
faktori su u položaju da ne mogu korelirati ($\cos 90^\circ=0$)	faktorima se omogućuje da koreliraju: kosinus kuta može proizvesti korelacije faktora između 0 i 1
faktori su pod kutom od 90°	kut faktorske osi manji je ili veći od 90°
rotirane faktorske solucije lakše je interpretirati	otežana interpretabilnost rotiranih faktorskih solucija
linearno nezavisni faktori	linerno zavisni faktori
rotira se cijela faktorska struktura u krutom okviru oko izvorne strukture	rotira se svaki faktor zasebno

5. Guttman-Kaiserov kriterij nasuprot Cattelovu *scree* testu

Osnovni je cilj faktorske analize parsimoničnost, odnosno kreiranje latentnih dimnezija; faktora (komponenata) iz prostora većeg broja manifestnih varijabli (njihove kolinearnosti). Bilo da se radi o modelu zajedničkih faktora ili o metodi glavnih komponenata, moramo se odlučiti prema kojem ćemo kriteriju određene faktore (komponente) zadržati, odnosno odbaciti. Najučestaliji Guttman-Kaiserov kriterij nalaže da se zadrže komponente čija je svojstvena vrijednost veća od 1. Međutim, to često dovodi do hiperfaktorizacije čime se onemogućava smisljena interpretacija faktora (čak i nakon rotacije). Osim hiperfaktorizacije Larose (2006.) ukazuje na još dva problema Guttman-Kaiserova kriterija. Prvi razlog očituje se u u arbitrarnosti jer svojstvene vrijednosti koje su npr. 1,01 značajne su i tvore ekstrahirani faktor, dok vrijednosti od npr. 0,99 ne zadovoljavaju navedeni

kriterij. Tu proizlazi svojevrсни problem jer se svaki statistički parametar računa s određenim stupnjem pogreške i ako bismo ponovili istraživanje, ti stupnjevi pogreške mogu promijeniti različite solucije. Drugi problem autor sažima u činjenici da navedeni kriterij ima metodološko opravdanje u analizi glavnih komponenta gdje se komunaliteti računaju počevši od maksimalne vrijednosti 1, dok su kod modela zajedničkih faktora komunaliteti reducirani.

S obzirom na navedene diskutabilnosti/ograničenja Guttman-Kaiserova kriterija, često istraživači vide rješenje u Cattellovu *scree* testu (Slika 3).



Slika 3 – Catellov „scree plot“ (prema: Larose 2006.)

Cattelov *scree test* (test odrona) koristi se kad prema Gutman-Kaiserovu kriteriju imamo prevelik broj značajnih faktora. Tada se kao granica do kada ćemo uzeti određene statistički značajne komponente uzima mjesto na grafičkom prikazu gdje dolazi do naglog smanjenja u opadanju svojstvenih vrijednosti (korjenova). To se može odnositi i na slučaj kada imamo premali broj glavnih komponenta koje se nalaze iznad granične vrijednosti od 1 (Slika 3), što je u istraživanju odgoja i obrazovanja (pedagogiji) rjeđi slučaj. Međutim, Cattellovu *scree testu* zamjera se subjektivnost, odnosno arbitrarnost (Crawford i Koopman, 1979.). Isto tako, npr. Streiner (1998.) sumnjičavo se odnosi prema navedenom kriteriju zbog vizualnog ograničenja kompjutorskih *softweara* koji za razliku od prijašnjeg grafičkog odnosa prikazanih vrijednosti na osi x i y navedene vrijednosti „izravnavaju“ te istraživaču vizualno onemogućuju uvid u kritičnu točku odabira značajnih faktora za razliku od prijašnjeg grafičkog „ručnog“

računanja. Cattelov test zapravo bismo trebali koristiti samo kao sekundarni izbor kriterija, odnosno kao dodatak drugim kriterijima za zaustavljanje ekstrakcije faktora (Velicer, Eaton i Fava, 2000.). Iako, npr. Stevens (2002.) smatra da se kad je uzorak preko 200, Cattelov *scree test* smatra pouzdanim kriterijem za zaustavljanje ekstrakcije faktora.

Navedena dva kriterija imaju značajna ograničenja te su često istraživači u dvojbi koliko značajnih komponenata uzeti, odnosno koji kriterij koristiti. Za rješenje te dvojbe treba imati u vidu koliko *a priori* značajnih faktora očekujemo i koliko su zapravo oni smisleni i interpretabilni. Poboljšanje Cattelova *scree testa* s obzirom na poboljšanje preciznosti jest paralelna forma/analiza.

Osim navedenih testova postoji cijeli niz kriterija za zastavljanje ekstrakcije faktora s obzirom na određene zadane parametre (Tablica 3).

Tablica 3 – Testovi za zaustavljanje ekstrakcije faktora


<i>kriterij</i>	<i>karakteristike</i>	<i>prednosti /nedostatci</i>
Bartlettov kriterij	Bazira se na <i>hi</i> kvadratu (<i>goodness of fit</i>), kad se ekstrahirana varijanca statistički ne razlikuje od prethodne ekstrakcija koja je gotova.	Hiperfaktorizacija; ekstrakcija trivijalnih faktora; nije podoban za mali uzorak (Gorsuch, 1973.).
Plum-Brandyjev (PB) kriterij	Kriterij 95%-tne valjane varijance; bazira se na varijanci <i>image</i> koja je jednaka sumi kvadriranih multiplih korelacija.	Prestrog kriterij; čest slučaj premalo faktora; premalo poznat na međunarodnoj razini.
kriterij NUM numerus	<i>A priori</i> se određuje broj faktora; sugestija je da se započne s kriterijem od maksimalnog do minimalnog broja faktora dok se ne vidi gdje su najbolje interpretabilne solucije (Hakstian, Rogers, Cattel, 1986.).	Previše dugotrajan postupak, iteracija svih mogućnosti; mogućnost izostavljanja određenog broja faktora koji mogu imati najbolje solucije.
paralelna analiza	Uspoređuju se svojstvene vrijednosti dobivene iz uzorka podataka s onima koji se očekuje kod sasvim slučajnih podataka; kriterij se određuje kao broj stvarnih svojstvenih vrijednosti koje su veće od očekivanih svojstvenih vrijednosti dobivenih na slučajnim podacima.	Polučuju vrlo točan broj faktora; uz zajednu provedbu sa <i>scree testom</i> najbolja metoda za zaustavljanje ekstrakcije faktora (Ford, MacCallum i Tait, 1986.: 295.).

6. Matrica sklopa (*Pattern Matrix*) nasuprot matrici strukture (*Structure Matrix*)

U ortogonalnim rotacijama iz matrice strukture koja predstavlja koeficijente korelacija manifestnih varijabli s faktorima određuju se (prema određenom kriteriju) varijable koje čine faktorska opterećenja. Uobičajeno je u području društvenih znanosti kriterij koeficijenta $r \geq 0,40$. Međutim, kad je riječ o kosokutnim rotacijama, imamo uz matricu strukture i matricu sklopa. Česta je pojava da su istraživači u području odgoja i obrazovanja kod kosokutnih rotacija u faktorskoj analizi u dvojbi koja je matrica temeljna za interpretaciju faktorskih opterećenja, odnosno za interperataciju faktora. Faktorska opterećenja u matrici sklopa predstavljaju jedinstvenu povezanost između faktora i manifestnih varijabli (parcijalna korelacija), odnosno poput jedinstvenih parcijalnih regresijskih koeficijenata u multiploj regresiji, dok je u matrici strukture osim jedinstvene varijance obuhvaćena i povezanost između varijabli i zajedničke varijance između faktora. Drugim riječima, opterećenja u matrici strukture predstavljaju korelacije nultog reda između varijabla i faktora, ali bez utjecaja drugih faktora (prema: Brown, 2006.: 32.). Iz tog razloga vrijednosti faktorskih opterećenja u matrici sklopa i matrici strukture ponekad se ne podudaraju jer ako su korelacije između faktora niske, tada će faktorska opterećenja u matrici strukture biti veća nego u matrici sklopa.

Mejovšek (2008.) ukazuje na to da su paralelne projekcije u matrici sklopa „osjetljivije“, odnosno da određuju bolju pripadnost varijable faktoru. Autor grafički ukazuje na svojevrstu vektorsku „pogrješku“ kod ortogonalnih projekcija (matrica strukture) jer je pripadnost određene varijable specifičnom vektoru iskazana većom razlikom paralelnih projekcija nego kod ortogonalnih projekcija.

U društvenim znanostima matrica sklopa kod kosokutnih rotacija temeljna je za interpretaciju dobivenih faktora (Hair et al., 1995.; Field, 2000.; Tabachnick i Fidell, 2001.; Munro, 2005.; Brown, 2006.), iako se u literaturi nalaze i drugačija mišljenja (Kline, 1994.; Giles, 2002.; Pett, Lackey i Sullivan, 2003.). Tako npr. Pett, Lackey i Sullivan (2003.) ukazuju na to da je matrica strukture stabilnija zbog činjenice da se vrijednosti ne mijenjaju s povećanjem korelacija između faktora, što nije slučaj kod matrice sklopa. Potkrjepljenje navedenog zaključka vidljivo je na grafičkom prikazu (Slika 4):



4. A – visoko korelirani faktori

4. B – nisko korelirani faktori

Slika 4 – Grafički primjer razlika između faktorskih opterećenja u matrici strukture i matrici sklopa s obzirom na razinu korelacija između faktora (prema: Pett, Lackey i Sullivan, 2003.: 151.)

Na primjeru (Slika 4. A) korelacija između faktora $r(F_1 F_2 \dots F_n) = 0.43$, $\Phi = 64^\circ$. S obzirom na visinu korelacije opterećenja u matrici strukture i sklopa relativno su različita. Međutim, u prikazu 4. B., gdje je $r(F_1 F_2 \dots F_n) = -0.18$, $\Phi = 101^\circ$, vrijednosti faktorskih opterećenja u matrici i sklopa i strukture približavaju se, odnosno gotovo se podudaraju. Naravno, kad su faktori međusobno ortogonalni, matrica strukture i matrica sklopa identične su (nema korelacija između faktora).

Iz navedenog autori zaključuju da je matrica strukture neopterećena težinom razine korelacija između faktora temeljna za interpretaciju faktora.

Kao što je vidljivo, postoje oprječna stajališta koja je matrica ključna za interpretaciju faktora. Smatram da je iz gore navedenih stajališta matrica sklopa temeljna za interpretaciju, ali uz uvjet da se usporede vrijednosti s matricom strukture (korelacije), koje se najčešće i podudaraju, i razina korelacija između faktora, jer se s povećanjem razine korelacija između faktora povećavaju i razlike vrijednosti između matrice strukture i matrice sklopa.

Zapravo, kod kosokutnih rotacija prilikom interpretacija treba uzeti u obzir vrijednosti svih triju matrica; matrice sklopa, matrice strukture i matrice korelacija između faktora. Ako postoji niska korelacija između faktora, tada se vrijednosti unutar matrica strukture i matrice sklopa neće bitno razlikovati. U suprotnom, razlike u vrijednostima postojat će ponekad i s obrnutim predznakom.

7. Umjesto zaključka

Kao skup statističkih postupaka faktorska analiza široko je korištena u području psihologije ali i u drugim društvenim znanostima. Posebice ističem sve učestalije korištenje faktorske analize u području pedagogije, jer suvremeno društvo nameće nove izazove i pojave unutar odgoja i obrazovanja na koje pedagogija unutar svog stručnog i znanstvenog habitusa nastoji iznaći odgovore. Kao dominantna multivarijantna metoda faktorska analiza svojom kompleksnošću stvara određene dvojbe istraživačima koje se mogu sažeti kroz dva načina. Prvi način obuhvaća nedovoljno razumijevanje faktorske analize te njezina neodgovarajuća primjena i tumačenje implicira krive zaključke. Posebice mladim istraživačima na poslijediplomskim studijima izučavanje metodologije i primijenjene statistike svojevrsni je imperativ za istraživački rad, a upravo faktorska analiza dominantna je multivarijantna analiza. Drugi način odnosi se na svojevrsnu paradigmu istraživača te dosljednost u provedbi i odabiru određenih statističkih parametara faktorske analize. Međutim, česta je pojava da svojevrsna paradigma istraživača u određenim slučajevima implicira odabir neodgovarajućih postupaka unutar faktorske analize. Stoga je i cilj ovog rada bio rasvijetliti neke dvojbe u primjeni faktorske analize, poput: razlika između faktorske analize i analize glavnih komponenata, odabir odgovarajuće veličine i omjera uzorka i broja varijabla, razlika između ortogonalnih i kosokutnih rotacija, odabir odgovarajućeg kriterija za zaustavljanje ekstrakcije faktora (Guttman-Kaiserov kriterij i Cattelov *scree test*), te odabir odgovarajuće matrice za interpretaciju faktora (matrica sklopa i matrica strukture). Navedene dvojbe u istraživanjima odgoja i obrazovanja (naglasak je na pedagogiji) potkrjepljenje su preglednim stajalištima i deskripcijama raznih autora te čitatelju pružaju samostalan zaključak o odabiru određenih interpretacija, odnosno stajališta, a sukladno ulaznim parametrima vlastitog istraživanja.

Literatura

1. Baiyin, Y. (2005.): Factor Analysis Methods, u: Swanson, R. A., Holton, E. F. (Ed.), *Research in organization* (181. – 200.). San Francisco: Berrett-Koehler Publishers.
2. Bentler, P. M., Kano, Y. (1990.): On the Equivalence of Factors and Components. *Multivariate Behavioral Research*, 25(1), 67. – 74.
3. Brown, T. A. (2006.): *Confirmatory Factor Analyses for Applied Research*. New York: The Guilford Press.
4. Child, D. (2006.): *The Essential of Factor Analyses* (3rd edition). New York: Continuum, International Publishing Group.

5. Comrey, A. L.; Lee, H. B. (1992.): *A First Course in Factor Analysis* (2nd edition). Hillsdale, NJ: Lawrence Erlbaum Associates.
6. Costello, A. B.; Osborne, J. W. (2005.): Best Practices in Exploratory Factor Analysis: Four Recommendations for Getting the Most From Your Analysis. *Practical Assessment, Research & Evaluation*, Vol.10, No 7. <<http://pareonline.net/pdf/v10n7.pdf>>
7. Crawford, C. B.; Koopman, P. (1979.): Inter-rater reliability of scree test and mean square ratio test of number of factors. *Perceptual Motor Skills*, 49, 223. – 226.
8. Everitt, B. S., (1975.), Multivariate analysis: the need for data and other problems, *British Journal of Psychiatry*, 126, 237. – 240.
9. Fava, J. L.; Velicer, W. F. (1992.): An empirical comparison of factor, image, component, and scale scores. *Multivariate Behavioral Research*, 27, 301. – 322.
10. Field, A. (2000.): *Discovering Statistics Using SPSS for Windows*. London: Sage Publication.
11. Field, A. (2005.): *Discovering Statistics Using SPSS* (2nd edition). London: SAGE.
12. Ford, J. K.; MacCallum, R. C.; Tait, M. (1986.): The Application of Explanatory Factor Analysis in Applied Psychology: A Critical Review and Analysis, 39, 291. – 314.
13. Frank, I. E.; Todeschini, R. (1994.): *The Data Analyses Handbook: Data Handling in the Science in Technology* (14). Amsterdam: Elsevier.
14. Fulgozi, A. (1979.): *Faktorska analiza*. Zagreb: Školska knjiga.
15. Giles, D. C. (2002.): *Advanced Research Methods in Psychology*. Hove: Routledge.
16. Gorsuch, R. L. (1973.): Using Bartlett's Significance Test to Determine the Number of Factor to Extract. *Education and Psychological Measurement*, 33, 361. – 364.
17. Guadagnoli, E.; Velicer W. F. (1988.): Relation of sample size to the stability of component patterns. *Psychological Bulletin* 103(2), 265. – 275.
18. Hair, Jr., J. F.; Anderson, R. E.; Tatham, R. L.; Black, W. C. (1995.): *Multivariate Data Analysis with Readings* (4th edition). New Jersey: Prentice-Hall, Englewood Cliffs.
19. Hakstian, A. R.; Rogers, W. T.; Cattell, R. B. (1986.): The Behavior of Number-of-Factors Rules With Simulated Data. *Multivariate Behavioral Research*, 17, 193. – 219.
20. Jolliffe, I. T. (2002.): *Principal Component Analyses* (2nd edition). Springer Series in Statistics. New York – Springer.
21. Kass, R. A.; Tinsley, H. E. A. (1979.): Factor analysis. *Journal of Leisure Research*, 11, 120. – 138.
22. Kline, P. (1994.): *An Easy Guide to Factor Analysis*. London: Routledge.
23. Larose, D. T. (2006.): *Data Mining Methods and Models*. New Jersey: John Wiley and Sons.
24. MacCallum, R. C.; Widaman, K. F.; Zhang, S.; Hong, S. (1999.). Sample size in factor analysis. *Psychological Methods*, 4, 84. – 99.

25. Mejovšek, M. (2008.): Metode znanstvenog istraživanja: u društvenim i humanističkim znanostima. Jastrebarsko: Naklada Slap.
26. Mulaik, S. A. (1990.): Blurring the Distinctions between Component Analysis and Common Factor-Analysis. *Multivariate Behavioral Research*, 25(1), 53. – 59.
27. Munro, B. H. (2005.): *Statistical Methods for Health Care Research* (5th edition). Philadelphia (PA): Lippincott Williams & Wilkins.
28. Pett, M, A.; Lackey, N.; Sullivan, J. J. (2003.): *Making Sense of Factor Analyses: The Use of Factor Analyses for Instrument Development in Health Care Research*. California: Sage Publication.
29. Stevens, J. P. (2002.): *Applied multivariate statistics for the social science* (4th edition). Hillsdale, NJ: Erbaum.
30. Streiner, D. L. (1998.): Factors affecting reliability of interpretations of scree plots. *Psychological Reports*, 83, 687. – 694.
31. Tabachnick, B. G.; Fidell, L. S. (2001.): *Using Multivariate Statistics* (4th edition). Needham Heights, MA: Allyn and Bacon.
32. Tabachnick B. G.; Fidell L. S. (2007.): *Using Multivariate Statistics*. Boston: Pearson Education Inc.
33. Thomson, G. H. (1939.): *The factorial analysis of human ability*. London: University of London Press.
34. Velicer, W. F.; Jackson, D. N. (1990.): Component analysis vs. common factor analysis: Some further observations. *Multivariate Behavioral Research*, 25, 95. – 112.
35. Velicer, W. F.; Eaton, C. A.; Fava, J. L. (2000.): Construct Explication Through Factor or Component Analysis: A Review and Evaluation of Alternative Procedures for Determining the Number of Factor or Components, u: Goffin, R. D., Helmes, E. (Ed.), *Problems and Solutions in Human Assessments* (41. – 72.). Norwel, Massachusetts: Kluwer Academic Publisher.

Siniša Opić*

Alcuni dubbi circa l'applicazione dell'analisi fattoriale nel campo delle ricerche pedagogiche

UDK: 37.012 303.722.2
Articolo compilativo

Ricevuto: 14.6.2012.
Accettato per la stampa: 20.10. 2012.

Riassunto: L'obiettivo del presente lavoro consiste nel fugare alcuni dubbi nell'applicazione dell'analisi fattoriale quali: la differenza tra l'analisi fattoriale e l'analisi delle componenti principali, della scelta della misura adatta e il rapporto tra il campione e il numero delle variabili, la differenza tra le rotazioni ortogonali e quelle all'angolo acuto, la scelta del criterio adeguato nell'arresto dell'estrazione dei fattori (il criterio di Guttman Kaiser e lo screen test di Cattell), nonché la scelta della matrice adatta per l'interpretazione dei fattori (la matrice del complesso e la matrice della struttura). Le ambiguità appena elencate nelle ricerche pedagogiche vengono accompagnate dalla rassegna di teorie dei vari autori e al lettore viene data la possibilità di trarre le conclusioni in maniera del tutto autonoma (in base, cioè, ai parametri delle proprie ricerche) in merito alla scelta di determinate interpretazioni o posizioni. La complessità dell'analisi fattoriale accentua i limiti delle posizioni univoche e sottolinea la necessità della scelta di parametri statistici adeguati.

Parole chiave: analisi fattoriale, rotazione, variazioni, metodo delle componenti principali, la matrice del complesso, la matrice della struttura.

*doc. dr. sc. Siniša Opić
Učiteljski Fakultet
Sveučilišta u Zagrebu
10000 Zagreb
Sinisa.opic@ufzg.hr

*Sinisa Opić, PhD,
Assistant Professor
Faculty of Teacher Education
University of Zagreb
10000 Zagreb
Sinisa.opic@ufzg.hr

*doc. dr. sc. Siniša Opić
Facoltà di Scienze della
Formazione dell'Università
degli Studi di Zagabria
10000 Zagreb
Sinisa.opic@ufzg.hr