

Viacrozmerné hodnotenie vo finančno-ekonomickej analýze

Multidimensional evaluation in financial and economic analysis

Sylvia JENČOVÁ - Igor PETRUŠKA - Eva LITAVCOVÁ

Abstrakt:

Cieľom príspevku je analýza viacrozmerných štatistických metód. V rámci viacrozmerných štatistických metód je príspevok orientovaný na aplikáciu metódy hlavných komponentov – PCA (*Principal Components Analysis*) a faktorovej analýzy – FA (*Factor Analysis*). Výskumnú vzorku tvorí 138 nefinančných korporácií (objektov) v odvetví podľa SK NACE. Hodnotiace ukazovatele, ktorými sú pomerové finančné metriky jednotlivých nefinančných korporácií boli skonštruované na základe absolútnych stavových ukazovateľov, ktoré boli získané z Registra účtovných záznamov Slovenskej republiky.

Kľúčové slová: viacrozmerné hodnotenie, metóda hlavných komponentov, faktorová analýza.

Abstract:

The aim of the paper is to evaluate multidimensional statistical methods. Within multidimensional statistical methods is a contribution from the application of the main components method – PCA (*Principal Components Analysis*) and Factor Analysis. The research sample consists of 138 non-financial corporations (objects) in the SK NACE sector. The rating indicators are the relative financial metrics of individual non-financial corporations. They were constructed on the basis of the absolute values of indicators obtained from the Registry of Financial Statements of the Slovak Republic for the years 2013-2016.

Key words: Principal Components Analysis, Factor Analysis, Financial Analysis.

JEL Classification: C59, G39

Úvod

Jedným zo zámerov každého finančného analytika je snaha o uskutočnenie štatistického rozboru viacrozmerných údajov vo finančnej analýze. „Cieľom všetkých metód

multikriteriálneho hodnotenia je transformácia a syntetizácia hodnôt rôznych ukazovateľov do jedného – integrálneho ukazovateľa, komplexne vyjadrujúcej úroveň jednotlivých podnikov v súbore skúmaných hodnôt“, (Zalai a kol. 2013, s. 353). V podnikovej praxi sa môžeme stretnúť s viacerými metódami viacrozmerného hodnotenia. Využívané sú predovšetkým metódy, metóda poradia, bodovacia metóda, metóda vzdialenosti od fiktívneho objektu, komponentná analýza, faktorová analýza, zhuková analýza, pyramídová analýza. Multikriteriálne metódy aplikované na údaje nefinančných korporácií elektrotechnického priemyslu analyzujú vo svojich prácach Jenčová, Litavcová, Vašaničová, Košíková, (2017). Viackriteriálne metódy boli analyzované a aplikované na údaje v rámci sektoru zdravotníctva v práci Jenčová, Litavcová, a Vašaničová (2017). Viacaspektovým metódam sa venuje vo svojej práci pre oblasť turizmu Petruška (2017). Synek, Kopkáně, Kubálková (2009) vo svojej práci poukazujú na hlavné problémy pri praktickej aplikácii PCA, ktorými je najmä interpretácia jednotlivých komponentov. Na rozdiel od metódy hlavných komponentov, pri ktorej hlavné komponenty vysvetľujú maximum rozptylu pôvodných premenných, pri faktorovej analýze spoločné faktory predovšetkým vysvetľujú vzájomné súvislosti medzi premennými. Podrobnú metodiku pre všetky viacrozmerné metódy a podrobnú aplikáciu PCA a FA, ktorej sa venuje tento príspevok uvádzajú vo svojich prácach autori, Stankovičová, Vojtková (2007), Meloun, Militký, Hill (2005, 2012), Litavcová (2010), Hebák, Hustopecký (1987, 2005) a i. Porovnanie týchto dvoch metód je uvedené v práci napr. Stankovičová, Vojtková (2007, s. 93).

Metódy

Cieľom každej viacrozmernej analýzy je spracovať údaje tak, aby sa zreteľne indikoval model a tak odkryl skrytý jav. V mnohých výskumných úlohách sa stretávame so situáciou, kde východiskový počet premenných skúmaných javov je značný a pre interpretáciu neprehľadný. Pre zjednodušenie analýzy a ľahšie hodnotenie výsledkov je často vhodné skúmať, či by študované vlastnosti pozorovaných objektov nebolo možné nahradiť menším počtom iných (hoci aj umelých) premenných, čiže znížiť dimenziu, bez toho aby pri tom došlo k strate informácií. Pre účely rozboru vstupovali viackriteriálnych metód finančné pomerové metriky, rentabilita vlastného kapitálu (*ROE*), rentabilita majetku (*ROA*), rentabilita tržieb (*ROS*), rentabilita celkového investovaného kapitálu (*ROI*), obrat celkových aktív (*OA*), obrat obežných aktív (*OOA*), doba obratu pohľadávok (*DOP*), doba splatnosti záväzkov (*DOZ*), doba obratu krátkodobých záväzkov (*DOKZ*), doba obratu obežných aktív (*DOOM*),


celková likvidita (*CL*), finančná páka (*FP*), celková zadlženosť (*CZ*), ukazovateľ samostatnosti (*USA*), miera zadlženosti (*MZ*), daňová redukcia zisku (*DRZ*), úroková redukcia zisku (*ÚRZ*), ziskový účinok finančnej páky (*ZÚFP*), podiel osobných nákladov na tržbách (*ONT*) a finančná produktivita práce (*FPP*).

Viacrozmerné štatistické metódy metóda hlavných komponentov (*PCA*) a faktorová analýza (*FA*) patria do skupiny metód slúžiacich na analýzu skrytých vzťahov medzi premennými. Premenné nie sú apriórne rozdelené do dvoch skupín na závislé a nezávislé. Zámerom je pochopiť a identifikovať, ako sú premenné prepojené, Stankovičová, Vojtková (2007).

Metóda hlavných komponentov bola pôvodne navrhnutá v roku 1901 Karlom Pearsonom. V roku 1933 H. Hotelling jej postup zovšeobecnil a navrhol použitie na analýzu kovariačnej štruktúry premenných. *PCA* a *FA* sa pokúšajú nájsť v pozadí stojace a teda skryté (umelé, nemerateľné, latentné) veličiny označované za hlavné komponenty, alebo faktory vysvetľujúce variabilitu a závislosť uvažovaných premenných. Tieto novo vytvorené premenné sú lineárnou kombináciou pôvodných premenných, Meloun, Militký, Hill (2005, 2012). Od nových premenných sa v oboch metódach požaduje, aby čo najlepšie reprezentovali pôvodné premenné. Konkretizácia tejto požiadavky však nie je v oboch metódach rovnaká. Ak požadujeme, aby nové premenné čo najviac vysvetľovali variabilitu pôvodných premenných, dochádzame k metóde hlavných komponent. Ak požadujeme, aby súbor vytvorených premenných čo najlepšie reprodukoval vzájomné lineárne vzťahy pôvodných premenných, dochádzame k metóde faktorovej analýzy. Základným predpokladom analýzy údajov je sledovanie rozptylu, pretože nájdené smery maximálneho rozptylu, sú viac či menej späté s týmito skrytými javmi, (Meloun, Militký, Hill 2012, s. 69). Podrobnú metodiku a aplikáciu *PCA* a *FA* uvádzajú vo svojich prácach viacerí autori Stankovičová, Vojtková (2007), Meloun, Militký, Hill (2005, 2012), Litavcová (2010), Hebák, Hustopecký (1987) a i.

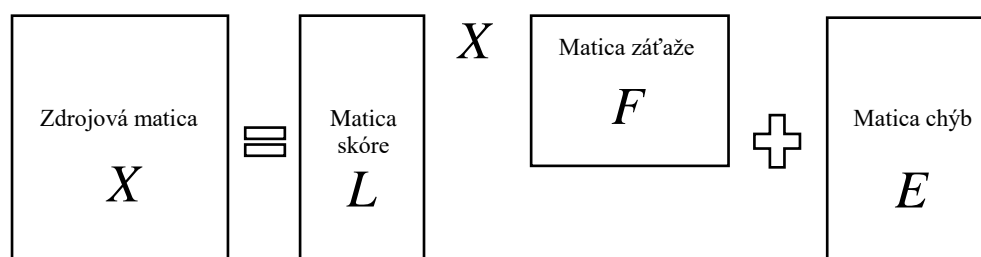
Obrázok 1 Maticový výpočet metódou PCA

Zdroj: [Meloun, Militký, Hill, 2012, s.70]



Obrázok 2 Maticový výpočet metódou FA

Zdroj: [Meloun, Militký, Hill, 2012, s.115]



Vzťahy (1) – (16) predstavujú podstatu faktorovej analýzy, Melon a kol. (2007, 2012). Faktorová analýza na príklade dvoch znakov x_1, x_2 , ktoré sú determinované spoločným faktorom a každý je samostatne determinovaný faktorom e_1, e_2 má tvar (1). Faktory e_i a faktor F sú vzájomne nekorelované (2). Rozptyl je daný podľa vzťahu (3). Pri kovariácii (korelácii) medzi x_i a F platí (4) a medzi x_1, x_2 platí (5). *Varimaxová rotácia* maximalizuje rozptyl záťaží v každom stĺpci vektorovej matice, maximalizuje sa výraz (7). Alternatívou je *quartimanová rotácia*, pri ktorej sa maximalizuje rozptyl záťaže v každom riadku (8). Autori popisujú členenie faktorovej analýzy na dve kategórie:

- model klasickej faktorovej analýzy daný vzťahom podľa (9)
- analýza hlavných komponentov podľa vzťahu (10), b_{ij} predstavujú záťaž, y_1, y_2, \dots, y_p - hlavné komponenty

Namiesto pôvodných znakov v rade viacrozmerných štatistických metód sa používa veličina F_j faktorové skóre podľa (11).

$$x_i = a_i \cdot F + b_i \cdot e_i, i = 1, 2, \dots, \quad (1)$$

$$\text{cov}(e_1 \cdot e_2) = 0, \text{cov}(e_i \cdot F) = 0, i = 1, 2, \dots, \quad (2)$$

$$\sigma^2 = a_i^2 + b_i^2 = 0, \quad (3)$$

$$\text{cov}(x_i, F) = a_i, \quad (4)$$

$$\text{cov}(x_1, x_2) = a_1 \cdot a_2, \quad (5)$$

$$\sigma^2(x_i) = \sum_{j=1}^p a_{ij}^2 = 1, \quad (6)$$

$$C_j = \frac{1}{m} \cdot \sum_{i=1}^m (a_{ij}^2 - a_j^{-2}), j = 1, \dots, p, \quad (7)$$

$$d_i = \frac{1}{p} \cdot \sum_{j=1}^p (a_{ij}^2 - a_j^{-2}), j = 1, \dots, m, \quad (8)$$

$$x_i = \sum_{j=1}^m a_{ij} \cdot F_j + b_i \cdot e_i, \quad (9)$$

$$x_i = \sum_{j=1}^m b_{ij} \cdot y_j, \quad (10)$$

$$F_j = \sum_{i=1}^m a_{ij} \cdot x_j, \quad (11)$$

Objekt v modeli faktorovej analýzy je kvantifikovaný podľa vzťahu (12), pričom F_1, F_2, \dots, F_p je p vybraných spoločných faktorov, ktoré vyvolávajú korelácie medzi m pôvodnými znakmi, e_1, e_2, \dots, e_m sú špecifické chybové faktory. Maticový tvar pre n -ticu objektov má regresný model faktorovej analýzy tvar podľa (13), pričom matica \mathbf{X} má rozmer $n \times m$, \mathbf{F} má rozmer $n \times p$, \mathbf{A} má rozmer $m \times p$, \mathbf{E}^* má rozmer $n \times m$. Všeobecne je rozptyl pre i -tý znak daný podľa (14). V prípade, že $\mathbf{M} = \mathbf{E}$ sú faktory ortogonálne a všetky prvky, ktoré sú mimo diagonály sú rovné nule, potom rozptyl i -tého znaku je v tvare podľa (15), pričom h_i^2 je objasnená časť rozptylu, u_i^2 časť rozptylu prislúchajúca chybovým členom, ktorá sa delí na u_{si}^2 , ktorú nie je možné vysvetliť a nespoľahlivosť u_{Ni}^2 , ktorá kvantifikuje experimentálnu chybu merania, viac Meloun Militký, Hill (2012, s.114-115).

$$x_i = a_{i1} \cdot F_1 + a_{i2} \cdot F_2 + \dots + a_{ip} \cdot F_p + e_i, \quad (12)$$

$$x_2 = a_{21} \cdot F_1 + a_{22} \cdot F_2 + \dots + a_{2p} \cdot F_p + e_2,$$

$$x_m = a_{m1} \cdot F_1 + a_{m2} \cdot F_2 + \dots + a_{mp} \cdot F_p + e_m,$$

$$X = F \cdot A^T + E^*, \quad (13)$$

$$s_i^2 = \sum_{j=1}^p a_{ij}^2 + \sum_{j \neq k}^p \sum_{j \neq k}^p a_{ij} \cdot a_{ik} \cdot M_{jk} + N_i, i = 1, \dots, m., \quad (14)$$

$$s_i^2 = \sum_{j=1}^p a_{ij}^2 + N_i = h_i^2 + u_i^2, \quad (15)$$

Výsledky a diskusia

Aby sme zabezpečili vzájomnú súmeriteľnosť veličín, vynechali sme z pôvodne 20 skúmaných finančných pomerových ukazovateľov ukazovatele aktivity, t. j. DOP, DOZ, DOKZ, DOOM. Pre zabezpečenie ortonormality latentných premenných sme použili analýzu hlavných komponentov (PCA) a faktorovú analýzu (FA).

Korelačná matica pre skúmaných 16 finančných pomerových ukazovateľov je uvedená v tabuľke 1.

Tabuľka 1 Korelačná matica (Correlation Matrix)

	ROE	ROA	ROS	ROI	OA	OOM	CL	FP	CZ	USA	MZ	DRZ	ÚRZ	ZÚFP	ON/T	FPP	
Correlation	ROE	1,00	0,22	0,05	0,24	0,11	0,00	0,01	-0,30	-0,09	0,08	-0,31	-0,03	0,00	-0,28	-0,11	0,04
	ROA	0,22	1,00	0,31	0,98	0,16	-0,04	0,06	-0,05	-0,28	0,21	-0,05	-0,04	0,01	-0,01	-0,18	0,13
	ROS	0,05	0,31	1,00	0,32	0,05	-0,01	0,65	-0,01	-0,05	0,04	-0,01	-0,02	0,00	0,00	0,23	0,06
	ROI	0,24	0,98	0,32	1,00	0,14	-0,06	0,06	-0,05	-0,30	0,23	-0,05	-0,07	0,00	-0,01	-0,18	0,12
	OA	0,11	0,16	0,05	0,14	1,00	0,63	-0,15	-0,04	0,31	-0,26	-0,04	-0,03	0,04	-0,14	-0,42	0,02
	OOM	0,00	-0,04	-0,01	-0,06	0,63	1,00	-0,16	0,05	0,28	-0,24	0,05	-0,02	0,02	-0,05	-0,20	0,08
	CL	0,01	0,06	0,65	0,06	-0,15	-0,16	1,00	-0,02	-0,24	0,19	-0,02	0,00	-0,01	0,00	0,38	-0,05
	FP	-0,30	-0,05	-0,01	-0,05	-0,04	0,05	-0,02	1,00	0,10	-0,09	1,00	0,00	-0,03	0,56	0,00	-0,02
	CZ	-0,09	-0,28	-0,05	-0,30	0,31	0,28	-0,24	0,10	1,00	-0,83	0,10	-0,03	0,03	0,00	-0,32	0,12
	USA	0,08	0,21	0,04	0,23	-0,26	-0,24	0,19	-0,09	-0,83	1,00	-0,09	0,02	-0,04	-0,01	0,26	-0,10
	MZ	-0,31	-0,05	-0,01	-0,05	-0,04	0,05	-0,02	1,00	0,10	-0,09	1,00	0,00	-0,03	0,56	0,00	-0,02
	DRZ	-0,03	-0,04	-0,02	-0,07	-0,03	-0,02	0,00	0,00	-0,03	0,02	0,00	1,00	0,06	0,01	0,07	-0,06
	ÚRZ	0,00	0,01	0,00	0,00	0,04	0,02	-0,01	-0,03	0,03	-0,04	-0,03	0,06	1,00	0,16	-0,03	0,00
	ZÚFP	-0,28	-0,01	0,00	-0,01	-0,14	-0,05	0,00	0,56	0,00	-0,01	0,56	0,01	0,16	1,00	0,04	-0,01
	ON/T	-0,11	-0,18	0,23	-0,18	-0,42	-0,20	0,38	0,00	-0,32	0,26	0,00	0,07	-0,03	0,04	1,00	-0,18
	FPP	0,04	0,13	0,06	0,12	0,02	0,08	-0,05	-0,02	0,12	-0,10	-0,02	-0,06	0,00	-0,01	-0,18	1,00
Sig. (1-tailed)	ROE		0,00	0,11	0,00	0,01	0,48	0,42	0,00	0,02	0,04	0,00	0,25	0,49	0,00	0,01	0,19
	ROA	0,00		0,00	0,00	0,00	0,17	0,10	0,11	0,00	0,00	0,12	0,17	0,42	0,38	0,00	0,00
	ROS	0,11	0,00		0,00	0,11	0,42	0,00	0,43	0,14	0,21	0,43	0,33	0,48	0,47	0,00	0,08
	ROI	0,00	0,00	0,00		0,00	0,09	0,09	0,11	0,00	0,00	0,11	0,04	0,49	0,38	0,00	0,00
	OA	0,01	0,00	0,11	0,00		0,00	0,00	0,16	0,00	0,00	0,17	0,26	0,20	0,00	0,00	0,29
	OOM	0,48	0,17	0,42	0,09	0,00		0,00	0,14	0,00	0,00	0,14	0,36	0,29	0,11	0,00	0,03
	CL	0,42	0,10	0,00	0,09	0,00	0,00		0,34	0,00	0,00	0,32	0,47	0,45	0,49	0,00	0,12
	FP	0,00	0,11	0,43	0,11	0,16	0,14	0,34		0,01	0,02	0,00	0,47	0,24	0,00	0,48	0,34
	CZ	0,02	0,00	0,14	0,00	0,00	0,00	0,00	0,01		0,00	0,01	0,28	0,22	0,47	0,00	0,00
	USA	0,04	0,00	0,21	0,00	0,00	0,00	0,00	0,02	0,00		0,02	0,33	0,19	0,45	0,00	0,01
	MZ	0,00	0,12	0,43	0,11	0,17	0,14	0,32	0,00	0,01	0,02		0,46	0,24	0,00	0,49	0,34
	DRZ	0,25	0,17	0,33	0,04	0,26	0,36	0,47	0,47	0,28	0,33	0,46		0,10	0,45	0,07	0,07
	ÚRZ	0,49	0,42	0,48	0,49	0,20	0,29	0,45	0,24	0,22	0,19	0,24	0,10		0,00	0,25	0,47
	ZÚFP	0,00	0,38	0,47	0,38	0,00	0,11	0,49	0,00	0,47	0,45	0,00	0,45	0,00		0,17	0,42
	ON/T	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,48	0,00	0,00	0,49	0,07	0,25	0,17		0,00
	FPP	0,19	0,00	0,08	0,00	0,29	0,03	0,12	0,34	0,00	0,01	0,34	0,07	0,47	0,42	0,00	

Medzi viacerými použitými finančnými pomerovými ukazovateľmi existuje silná korelácia. Korelačný koeficient sa pohybuje od -0,83 do 0,98. Korelačná matica umožňuje pre potreby PCA posúdiť stupeň vzájomnej lineárnej závislosti sledovaných 16 premenných a zároveň naznačuje skupiny vzájomne korelovaných dvojíc. Veľké rozdiely medzi odpovedajúcimi si parciálnymi a jednoduchými korelačnými koeficientami indikujú silné vzájomné závislosti v skupinách premenných. Na testovanie vzájomnej závislosti skupiny premenných sa používa

kritérium *KMO* (Kaiser-Meyer-Olkin) a kritérium Bartletta, (tabuľka 2).

Miera *KMO* podľa vzťahu (16) je index k porovnaniu veľkosti experimentálnych korelačných koeficientov voči veľkostiam parciálnych korelačných koeficientov.

$$KMO = \frac{\sum_{i \neq j}^m \sum_{j \neq i}^m r_{ij}^2}{\sum_{i \neq j}^m \sum_{j \neq i}^m r_{ij}^2 + \sum_{i \neq j}^m \sum_{j \neq i}^m a_{ij}^2}, \quad (16)$$

Tabuľka 2 Kritérium *KMO* a Bartlett

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,595
Bartlett's Test of Sphericity	Approx. Chi-Square	7152,714
	df	120
	Sig.	0,000

Hodnota *KMO* 0,595 ukazuje na vzájomnú lineárnu závislosť uvažovaných premenných. (podľa odporúčaní pre adekvátnosť výberových dát na FA hodnota štatistiky *KMO* v intervale <0,5;0,6) vyjadruje slabé odporúčanie, viac Stankovičová, Vojtková (2007, s. 91)).

Výsledok Bartlettovho testu je veľmi priaznivý pre použitie PCA.


Tabuľka 3 Charakteristické čísla získané z korelačnej matice.

Component	Eigenvalues		
	Total	% of Variance	Cumulative %
1	2,985	18,653	18,653
2	2,637	16,484	35,137
3	2,232	13,952	49,089
4	1,556	9,726	58,815
5	1,137	7,107	65,922
6	1,084	6,776	72,698
7	,945	5,907	78,606
8	,879	5,497	84,102
9	,771	4,819	88,921
10	,559	3,491	92,412
11	,489	3,058	95,470
12	,291	1,817	97,287
13	,263	1,644	98,931
14	,150	,935	99,866
15	,021	,129	99,996
16	,001	,004	100,000

V ďalšej analýze je určený počet hlavných komponent, ktoré by spoľahlivo vysvetlili celkový rozptyl. Cieľom je nájsť čo najmenšie číslo dominantných faktorov tak, aby vysvetlili väčšinu

rozptylu premenných, (tabuľka 3). Vlastné hodnoty (*eigenvalues*) sa využívajú ako meradlo rozptylu vysvetľovaného faktorom. Ako dominantné vyberieme tie faktory, kde vlastná hodnota je väčšia než 1. Ostatné faktory vysvetľujú menej rozptylu než pôvodné premenné. Prvých 6 faktorov má vlastnú hodnotu väčšiu než 1 a vysvetľujú spolu 72 % rozptylu. Výber vhodného počtu faktorov uvádza scree plot (obrázok 3).

Obrázok 3 Scree plot



Celkový rozptyl vo faktorovej analýze je zložený zo spoločnej časti (*Communality*) prislúchajúcej faktorom (tabuľka 4), špecifickej časti prislúchajúcej premennej a časti Error, viac (Meloun Militký, Hill 2012, s.115).

Tabuľka 4 Spoločná časť rozptylu premenných

	Extraction		Extraction
ROE	,317	CZ	,850
ROA	,907	USAM	,792
ROS	,862	MZ	,921
ROI	,920	DRZ	,337
OA	,821	ÚRZ	,762
OOM	,718	ZÚFP	,642
CL	,805	ON/T	,626
FP	,918	FPP	,432

Model s faktormi, kde vlastná hodnota je väčšie ako 1 vysvetľuje iba 31,7 % rozptylu ROE, 33,7 % DRZ a 43,2 % FPP. Interpretáciu pre jednotlivé faktory dostávame z korelácie premenných s faktormi po rotácii metódou Varimax, (tabuľka 5).

Tabuľka 5 Korelácie premenných s faktormi po rotácii metódou Varimax

Rotated Component Matrix ^a						
	Component					
	1	2	3	4	5	6
ROE	-,467	,308	-,021	-,031	,056	-,020
ROA	-,038	,941	-,091	,090	,056	-,013
ROS	-,003	,284	,098	,875	,077	-,009
ROI	-,041	,947	-,105	,093	,038	-,036
OA	-,092	,176	,157	-,068	,867	,027
OOM	,022	-,056	,094	-,045	,839	,011
CL	-,014	,004	-,125	,881	-,110	,001
FP	,951	-,002	,016	-,009	,064	-,095
CZ	,071	-,290	,811	-,080	,310	,008
USAM	-,063	,246	-,811	,038	-,262	-,021
MZ	,952	-,001	,016	-,009	,064	-,096
DRZ	,002	-,125	-,188	,010	,086	,528
ÚRZ	,024	,090	,151	-,012	-,063	,852
ZÚFP	,749	,065	,023	-,016	-,147	,234
ON/T	,036	-,338	-,382	,517	-,311	,022
FPP	-,038	,303	,531	-,032	-,206	-,117

Extraction Method: Principal Component Analysis.
Rotation Method: Varimax with Kaiser Normalization.

Jednotlivé faktory reprezentujú tie premenné, kde absolútna hodnota korelácie sa blíži k jednej. Na základe vyššie uvedeného model vysvetľuje len malú časť rozptylu ukazovateľov ROE, DRZ, FPP, (v ďalšej analýze sú vynechané). Na testovanie vzájomnej závislosti skupiny premenných podľa kritérií KMO a Bartletta (tabuľka 6), dostávame podobné výsledky ako v tabuľke 2. Hodnoty v tabuľke 7 kvantifikujú, že model lepšie popisuje spoločnú časť rozptylu premenných. Prvých 5 faktorov vysvetľuje 78 % rozptylu pôvodných premenných, (tabuľka 8).

Tabuľka 6 Kritérium KMO a Bartlett

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,590
Bartlett's Test of Sphericity	Approx. Chi-Square	7179,714
	df	78
	Sig.	0,000

Tabuľka 7 Spoločná časť rozptylu premenných


	Extraction		Extraction
ROA	,924	CZ	,798
ROS	,857	USAM	,724
ROI	,932	MZ	,947
OA	,703	ÚRZ	,693
OOM	,568	ZÚFP	,637

CL	,806	ON/T	,609
FP	,947		

Tabuľka 8 Charakteristické čísla získané z korelačnej matice.

Component	Eigenvalues		
	Total	% of Variance	Cumulative %
1	2,890	22,234	22,234
2	2,447	18,821	41,055
3	2,194	16,876	57,931
4	1,554	11,952	69,883
5	1,059	8,149	78,032
6	1,012	7,783	85,815
7	,579	4,453	90,269
8	,503	3,866	94,135
9	,304	2,341	96,476
10	,269	2,069	98,545
11	,166	1,278	99,823
12	,022	,172	99,994
13	,001	,006	100,000

Obrázok 4 Scree plot



Scree plot (obrázok 4) má podobný priebeh ako na obrázku 3. Najvyššie hodnoty korelácií premenných s faktormi nám pomôžu pri interpretácii jednotlivých faktorov, (tabuľka 9).

Faktor 1 zahŕňa premenné – OA, OOM, CZ, USAM. Vzhľadom na premenné, ktoré sítia faktor 1 je obtiažne tento faktor jednoznačne pomenovať.

Faktor 2 zahŕňa premenné – FP, MZ, ZÚFP. Vhodnou interpretáciou pre druhý faktor je faktor zadlženosti.

Faktor 3 zahŕňa premenné – ROA, ROI. Vhodnou interpretáciou pre tretí faktor je faktor rentability.

Faktor 4 zahŕňa premenné – ROS, CL. Vhodnou interpretáciou pre tretí faktor je faktor likvidity.

Faktor 5 predstavuje jediná premenná – ÚRZ. Vhodnou interpretáciou pre piaty faktor je faktor produktívnosti.

Tabuľka 9 Korelácie premenných s faktormi po rotácii metódou Varimax

Rotated Component Matrix ^a					
	Component				
	1	2	3	4	5
ROA	-,039	-,016	,956	,083	,026
ROS	,110	,000	,290	,872	,042
ROI	-,061	-,015	,959	,085	,028
OA	,744	-,101	,293	-,076	-,217
OOM	,682	,005	,051	-,050	-,313
CL	-,171	-,016	,006	,881	-,018
FP	,066	,965	-,032	,000	-,097
CZ	,792	,078	-,326	-,068	,232
USAM	-,744	-,071	,290	,017	-,284
MZ	,066	,965	-,031	-,001	-,098
ÚRZ	-,009	,012	,058	-,018	,830
ZÚFP	-,100	,751	,013	-,009	,250
ON/T	-,467	,018	-,331	,517	-,116

Záver

Cieľom autorov v rámci viacrozmerných štatistických metód bola aplikácia metódy hlavných komponentov – PCA (*Principal Components Analysis*) a faktorovej analýzy (*Factor Analysis*), ktorá je považovaná za rozšírenie PCA a zároveň odstraňuje jej nedostatky.

Zámerom príspevku bolo poukázať na možnosti použitia hlavných komponentov vo finančno-ekonomickej analýze a vo finančnom riadení podnikateľských subjektov. Výsledkom je zredukovanie 13 vzájomne závislých manifestných premenných finančných ukazovateľov do piatich ortonormálnych, teda vzájomne nezávislých latentných faktorov. S týmito faktormi je možné ďalej pracovať. Chápeme ich ako vstupné údaje do analýz ďalších pripravovaných článkov.

Použitá literatúra

[1] GROS, I., 2003. *Kvantitatívni metódy v manažérskom rozhodovaní*. Praha: Grada Publishing, ISBN 80-247-0421-8.

[2] HEBÁK, P., - HUSTOPECKÝ, J., 1987. Vícerozměrné statistické metody s aplikacemi. Praha: Alfa, SNTL.

[3] HEBÁK, P. a kol., 2005. Vícerozměrné statistické metody (2). Praha: Informatorium ISBN 80-7333-039-3.

[4] JENČOVÁ, S., - LITAVCOVÁ, E., - VAŠANIČOVÁ, P. 2017. Aplikácia viacerozmerných metód v odvetví zdravotníctva. Nitrianske štatistické dni 2017: zborník abstraktov a príspevkov z konferencie Nitrianske štatistické dni 2017 konanej v dňoch 16.-17. marca 2017 v Nitre. Bratislava: Slovenská štatistická a demografická spoločnosť, s.17-23. ISBN 978-80-88946-75-5.

[5] JENČOVÁ, S., - LITAVCOVÁ, E., - VAŠANIČOVÁ, P., - KOŠÍKOVÁ, M. 2017. Implementation of multidimensional analytic methods to compare performance between corporations. In: Strategic management and its support by information systems. Proceedings of the 12th international conference. Ostrava, VŠB - Technical university of Ostrava, Faculty of economic. p. 21-29. ISBN 978-80-248-4046-8. ISSN 2570-5776.

[6] LITAVCOVÁ, E., 2010. Výskum vybraných marketingových cenových stratégií predajcov a vnímanie hodnoty eura a cien vybraných tovarov v čase svetovej hospodárskej krízy v rôznych sociálnych vrstvách v regióne. Prešov: Prešovská univerzita v Prešove, FM. ISBN 978-80-555-0322-6.

[7] MOLINERO. M. C. – EZZAMEL, M., 1991 *Multidimensional Scalling Applied to Corporate Failure*. Manchester: University of Manchester

[8] MELOUN, M., - MILITKÝ, J., - HILL, M., 2005. Počítačová analýza vícerozměrných dat v příkladech. Praha: Academia. ISBN 80-200-1335-0.

[9] MELOUN, M., - MILITKÝ, J., - HILL, M., 2012. Štatistická analýza vícerozměrných dat v příkladech. Praha: Academia. ISBN 80-200-1335-0.

[10] STANKOVIČOVÁ, I., VOJTKOVÁ., M, (2007). Viacrozmerné štatistické metódy s aplikáciami. Bratislava: Iura Edion. ISBN 978-80-8078-152-1.

[11] SYNEK, M., - KOPKÁNĚ, H., - KUBÁLKOVÁ, M., 2009. Manažérske výpočty a ekonomická analýza. Praha: C. H. Beck. ISBN 978-80-7400-154-3.

[12] PETRUŠKA, I., (2017). Analýza ukazovateľov cestovného ruchu krajín EÚ pomocou multidimenzionálneho škálovania. s. 117-125. In: Ekonomická aktivita turizmu. Prešov: BookMan, s. r. o. ISBN 978-80-8165-264-6.

[13] ZALAI, Karol a kol., 2013. Finančno-ekonomická analýza. BRATISLAVA: SPRINT DVA. ISBN 978-80-89393-80-0.

Príspevok je jedným z výstupov projektu:

VEGA 1/0945/17 Výskum ekonomickej kvantifikácie marketingových procesov zameraných na zvyšovanie hodnoty pre pacienta, viacdimenzionálne analýzy marketingového mixu zdravotníckych zariadení a kvantifikácia ich významu v procese tvorby systému na meranie kvality a efektivity v zdravotníctve SR

VEGA 1/0470/18 Ekonomická aktivita turizmu v európskom priestore

Kontaktné údaje

Ing. Sylvia Jenčová, PhD.
Katedra financií
Fakulta manažmentu Prešovská univerzity v Prešove
Prešovská univerzita v Prešove
Konštantínova 16,08001 Prešov, Slovensko
tel.: +421 917 637 341
sylvia.jencova@unipo.sk

doc. Mgr. Eva Litavcová, PhD.
Katedra matematických metód a manažérskej informatiky
Fakulta manažmentu Prešovská univerzity v Prešove
Prešovská univerzita v Prešove
Konštantínova 16,08001 Prešov, Slovensko
tel.: +421 51 4880 559
eva.litavcova@unipo.sk

Ing. Igor Petruška, PhD.
Katedra matematických metód a manažérskej informatiky
Fakulta manažmentu Prešovská univerzity v Prešove
Prešovská univerzita v Prešove
Konštantínova 16,08001 Prešov, Slovensko
tel.: +421 51 4880 559
igor.petruska@unipo.sk