


6/2009

FORUM STATISTICUM SLOVACUM



ISSN 1336-7420



9 771336 742001



**Slovenská štatistická a demografická
spoločnosť Miletičova 3, 824 67
Bratislava
www.ssds.sk**



Naše najbližšie akcie:

(pozri tiež www.ssds.sk, blok Poriadané akcie)

18. Medzinárodný seminár VÝPOČTOVÁ ŠTATISTIKA,

3. – 4. 12. 2009, Bratislava, Infostat

Prehliadka prác mladých štatistikov a demografov

3. 12. 2009, Bratislava, Infostat

NITRIANSKE ŠTATISTICKÉ DNI 2010

4. - 5. február 2010, Nitra

Pohl'ady na ekonomiku Slovenska 2010

13. 4. 2010, Bratislava, Aula EU

EKOMSTAT 2010, 24. škola štatistiky

tematické zameranie: *Štatistické metódy vo vedecko-výskumnej, odbornej
a hospodárskej praxi.*

jún 2010, Trenčianske Teplice

Aplikácie metód na podporu rozhodovania vo vedeckej, technickej a spoločenskej praxi

jún 2010, STU Bratislava

15. SLOVENSKÁ ŠTATISTICKÁ KONFERENCIA

2010, SLOVENSKO

Regiónálne akcie

priebežne

Pokyny pre autorov

Jednotlivé čísla vedeckého časopisu FORUM STATISTICUM SLOVACUM sú prevažne tematicky zamerané zhodne s tematickým zameraním akcií SŠDS. Príspevky v elektronickej podobe prijíma zástupca redakčnej rady na elektronickej adrese uvedenej v pozvánke na konkrétne odborné podujatie Slovenskej štatistickej a demografickej spoločnosti. Názov word-súboru uvádzajte a posielajte v tvare: **priezvisko_nazovakcie.doc**

Forma: Príspevky písané výlučne len v textovom editore MS WORD, verzia 6 a vyššia do verzie 2003, písmo Times New Roman CE 12, riadkovanie jednoduché (1), formát strany A4, všetky okraje 2,5 cm, strany nečíslovať. Tabuľky a grafy v čierno-bielom prevedení zaradiť priamo do textu článku a označiť podľa šablony. Bibliografické odkazy uvádzať v súlade s normou STN ISO 690 a v súlade s medzinárodnými štandardami. Citácie s poradovým číslom z bibliografického zoznamu uvádzať priamo v texte.

Rozsah: Maximálny rozsah príspevku je 6 strán.

Príspevky sú recenzované. Redakčná rada zabezpečí posúdenie príspevku členom redakčnej rady alebo externým oponentom.

Štruktúra príspevku: (Pri písaní príspevku využite elektronickú šablónu: <http://www.ssds.sk/> v časti Vedecký časopis, Pokyny pre autorov.)

Názov príspevku v slovenskom jazyku (štýl Názov: Time New Roman 14, Bold, centrovať)

Názov príspevku v anglickom jazyku (štýl Názov: Time New Roman 14, Bold, centrovať)

Vynechať riadok

Meno1 Priezvisko1, Meno2 Priezvisko2 (štýl normálny: Time New Roman 12, centrovať)

Vynechať riadok

Abstract: Text abstraktu v anglickom jazyku, max. 10 riadkov (štýl normálny: Time New Roman 12).

Vynechať riadok

Key words: Kľúčové slová v anglickom jazyku, max. 2 riadky (štýl normálny: Time New Roman 12).

Vynechať riadok

Kľúčové slová: Kľúčové slová v jazyku v akom je napísaný príspevok, max. 2 riadky (štýl normálny: Time New Roman 12).

Vynechať riadok

Vlastný text príspevku v členení:

1. **Úvod** (štýl Nadpis 1: Time New Roman 12, bold, zarovnať vľavo, číslovať)
2. **Názov časti 1** (štýl Nadpis 1: Time New Roman 12, bold, zarovnať vľavo, číslovať)
3. **Názov časti 1. . .**
4. **Záver** (štýl Nadpis 1: Time New Roman 12, bold, zarovnať vľavo, číslovať)

Vlastný text jednotlivých častí je písaný štýlom Normal: písmo Time New Roman 12, prvý riadok odseku je odsadený vždy na 1 cm, odsek je zarovnaný s pevným okrajom. Riadky medzi časťami nevynechávajúte.

5. **Literatúra** (štýl Nadpis 1: Time New Roman 12, bold, zarovnať vľavo, číslovať)

[1] Písať podľa normy STN ISO 690

[2] GRANGER, C.W. – NEWBOLD, P. 1974. Spurious Regression in Econometrics. In: Journal of Econometrics, č. 2, 1974, s. 111 – 120.

Adresa autora (-ov) (štýl Nadpis 1: Time New Roman 12, bold, zarovnať vľavo, adresy vpísať do tabuľky bez orámovania s potrebným počtom stĺpcov a s 1 riadkom):

Meno1 Priezvisko1, tituly1
Ulica1
970 00 Mesto1
meno1.priezvisko1@mail.sk

Meno2 Priezvisko2, tituly2
Ulica2
970 00 Mesto2
meno2.priezvisko2@mail.sk

FORUM STATISTICUM SLOVACUM

vedecký recenzovaný časopis Slovenskej štatistickej a demografickej spoločnosti

Vydavateľ

Slovenská štatistická a demografická
spoločnosť
Miletičova 3
824 67 Bratislava 24
Slovenská republika

Redakcia

Miletičova 3
824 67 Bratislava 24
Slovenská republika

Fax

02/39004009

e-mail

chajdiak@statis.biz
jan.luha@fmed.uniba.sk

Registráciu vykonalo

Ministerstvo kultúry Slovenskej republiky

Registračné číslo

3416/2005

Evidenčné číslo

EV 3287/09

Tematická skupina

B1

Dátum registrácie

22. 7. 2005

Objednávky

Slovenská štatistická a demografická
spoločnosť
Miletičova 3, 824 67 Bratislava 24
Slovenská republika
IČO: 178764
DIČ: 2021504276
Číslo účtu: 0011469672/0900

ISSN 1336-7420

Redakčná rada

RNDr. Peter Mach – *predseda*

Doc. Ing. Jozef Chajdiak, CSc. – *šéfredaktor*

RNDr. Ján Luha, CSc. – *tajomník*

členovia:

Ing. František Bernadič
Mgr. Branislav Bleha, PhD.
Ing. Mikuláš Cár, CSc.
Ing. Ján Cuper
Ing. Pavel Flák, DrSc.
Ing. Edita Holičková
Doc. RNDr. Ivan Janiga, CSc.
Ing. Anna Janusová
RNDr. PaedDr. Stanislav Katina, PhD.
Prof. RNDr. Jozef Komorník, DrSc.
RNDr. Samuel Koróny, PhD.
Doc. Ing. Milan Kovačka, CSc.
Doc. RNDr. Bohdan Linda, CSc.
Prof. RNDr. Jozef Mládek, DrSc.
Doc. RNDr. Oľga Nánásiová, CSc.
Doc. RNDr. Karol Pastor, CSc.
Prof. RNDr. Rastislav Potocký, CSc.
Doc. RNDr. Viliam Páleník, PhD.
Ing. Iveta Stankovičová, PhD.
Prof. RNDr. Beata Stehlíková, CSc.
Prof. RNDr. Anna Tirpáková, CSc.
Prof. RNDr. Michal Tkáč, CSc.
Ing. Vladimír Úradníček, PhD.
Ing. Boris Vaňo
Doc. MUDr. Anna Volná, CSc., MBA.
Ing. Mária Vojtková, PhD.
Prof. RNDr. Gejza Wimmer, DrSc.
Mgr. Milan Žirko

Ročník

V.

Číslo

6/2009

Cena výtlačku 20 EUR

Ročné predplatné 80 EUR

ÚVOD

Šieste číslo piateho ročníka vedeckého časopisu Slovenskej štatistickej a demografickej spoločnosti je zostavené z príspevkov, ktoré sú obsahovo orientované v súlade s tematikou VI. ročníka Medzinárodnej konferencie aplikovanej štatistiky FernStat 2009. Táto konferencia sa uskutočnila v dňoch 1. a 2. októbra 2009. Tradičné tematické okruhy konferencie sú: Aplikovaná štatistika, Demografická štatistika, Matematická štatistika, Štatistické riadenie kvality.

Akciu z poverenia Výboru SŠDS, zorganizoval Organizačný a programový výbor: Ing. Vladimír Úradníček, Ph.D. – predseda, Ing. Mária Kanderová, PhD.– tajomník, RNDr. Ján Luha, CSc., doc. Ing. Jozef Chajdiak, CSc., doc. RNDr. Bohdan Linda, CSc., doc. Dr. Jana Kubanová, PhD., RNDr. Peter Mach, Ing. Iveta Stankovičová PhD., Ing. Martin Boďa.

Na príprave a zostavení tohto čísla FORUM STATISTICUM SLOVACUM participovali: Ing. Vladimír Úradníček, Ph.D, Ing. Mária Kanderová PhD., doc. Ing. Jozef Chajdiak, CSc., RNDr. Ján Luha, CSc.

Recenziu príspevkov zabezpečili: Ing. Vladimír Úradníček, Ph.D, Ing. Mária Kanderová PhD., doc. Ing. Jozef Chajdiak, CSc., RNDr. Ján Luha, CSc., doc. RNDr. Bohdan Linda, CSc., doc. Dr. Jana Kubanová, PhD.

Výbor SŠDS

Predicting bankruptcy of Slovak enterprises by an artificial neural network

Martin Bod'a

Abstract: The paper as an output of VEGA project No. 1/4634/07 inquires into a possibility of employment of an artificial neural network (of multilayer perceptron topology) in the task of bankruptcy prediction in the business environment of the Slovak Republic.

Key words: bankruptcy, Slovak enterprises, financial ratios, multilayer perceptron

1. The introductory notes

The paper, prepared under the framework of VEGA project No. 1/4634/07 „Variant methods of prediction of small and medium sized enterprises development after introducing single European currency in the Slovak Republic”, strives to apply an artificial neural network to the prediction of business failures in the environment of the Slovak Republic.

Much literature has been committed to the topic of business failure prediction, in the world or even in the Slovak Republic. The possibilities of business failure modelling are broad, ranging from standard (multivariate) statistical techniques to data mining procedures; yet, none of them has been so far established firmly and convincingly in practical applications. They all together build upon an array of financial ratio indicators from which they attempt to extract information as to whether the enterprise given is liable to go bankrupt or apt to survive in the competitive environment. This formulation of the task is tied up with the underlying and incontestable assumption of faithful representation of economic information in financial statements. This assumption is not challenged in the paper and it is premised that all financial ratios available contain information about the prospects of the enterprise given. It is then possible to utilize the previous results on business failure modelling for the case of the Slovak Republic. Hiadlovský and Král' (2005, 2006, 2007) operated with 36 financial ratio indicators and utilized factor analysis to search for latent relationships within the indicators. For the purpose of prediction, they employed discriminant analysis and binary logistic regression and concluded that only 18 indicators are of relevant discriminant capacity. Gavliak (2006, 2007) extended their studies by use of linear probability models. Hiadlovský and Král' (2009) recently considered the application of fuzzy sets theory to this end. There still remains room for further investigations in this area, which serves as the motivation for this paper.

2. The database

In the construction of an artificial neural network, a set of data on 851 Slovak enterprises active in divers industries across the economy was available, of which 12 were declared bankrupt and 839 were considered financially healthy. The data date back to the time span of 2002 until 2005; and despite being relatively older, they are not afflicted by the impacts of on-going economic crisis. For each enterprise 36 financial ratios one year and two years before going bankrupt were known; however, for the sake of modelling, only 18 of them, those recommended by Hiadlovský and Král' (2006), were employed. Thus, effectively each enterprise was described by 36 attributes, 18 financial ratios one year prior to bankruptcy and 18 financial ratios two years prior to bankruptcy. The ratios employed are presented in table 1. The criteria for bankruptcy were chosen in compliance with Slovak bankruptcy act (zákon č. 328/1991 Zb. o konkurze a vyrovnaní v zn. n. p. and/or zákon č. 7/2005 Z. z. o konkurze a reštrukturalizácii a o zmene a doplnení niektorých zákonov v zn. n. p.). The data were obtained from the agency INFIN, s. r. o., and intermediated by Rudolf Gavliak, to whom the author hereby expresses gratitude.

Table 1. The financial ratios utilized in the construction of a neural network

(Source: Adjusted according to Gavliak (2006, 2007).)

Label	Financial ratio	Label	Financial ratio
BU_CZ	Banking loans / Total debt	KKZOM	Current assets / Short term liabilities
CZA	Total debt / Total assets	KZ_MC	Current assets / Total assets
DOZ	Inventory / Daily sales	L_CF	Liquidity calculated with cash flow
DZA	Long term debt / Total assets	L1	Cash ratio
EBIT_CK	EBIT / Total assets	L2	Quick ratio
FP1	Financial leverage measure	L3	Current ratio
HVB_KZ	EBT / Short term liabilities	OA	Assets turnover ratio
KCZBCF	Cash flow / Total debt	STZ	Total assets / Total debt
KCZOM	Current assets / Total debt	UZA	Loans / Total assets

Before proceeding to the development of a neural network, it needs be remarked the following:

1. The considered 18 financial ratios as data attributes are by their definition dependent and prone to high correlation.
2. The enterprises whose data enter the modelling are located in about 250 statistically different branches of economic activity throughout the entire economy. This, amongst others, results in high variability in financial ratios between industries. Though it might have been expected, it was discovered upon the inspection of the data that in both years they heavily suffer from extreme values and obviously cannot be found, even with abounding optimism, normal. Some attributes are of such high variability that 5 % values came as extreme or outlying.

These two points themselves invalidate multivariate analysis techniques, though possibly based upon robust estimation, and are restrictive to the subsequent processing of the data, though it may be meditated over the transformation of the attributes (such as taking the logarithm or effecting the Cox-Box transformation in hope that it would remedy correlation, notwithstanding striking dependence) or over the limitation of values (and their substitution by the mean, e. g.). As to the possibility of use of robust techniques, usual data mining procedures (such as decision trees and artificial neural networks) rank to them.

3. Out of 851 cases, only 12 (1.41 %) are marked as bankrupt, which is a serious hindrance to statistical modelling.

Taking under advisement the third point, there were three possible actions to increase the proportion of bankrupt companies in the sample: Either (a.) to make a random drawing from amongst the cases marked as non-bankrupt and model with all the cases marked as bankrupt and with some marked as non-bankrupt, or (b.) to replicate the cases marked as bankrupt and model with all the cases marked as non-bankrupt and with the repeated cases marked as bankrupt, or (c.) to combine (a.) and (b.). For the purpose of this paper, option (b.) was employed and the cases the cases marked as bankrupt were “multiplied by six” and in the modelling $6 \times 12 = 72$ cases marked as bankrupt and all the 839 cases marked as non-bankrupt were employed, totalling 921 cases.

3. The set-up of the network and modelling issues

A multilayer perceptron with its usual topology and the sigmoidal activation function was chosen for an artificial neural network and the entire estimation was carried out in Weka version 3.6.0's Explorer. Four models were confronted, in a 2×2 matrix scheme:

- two simpler models without the hidden layer and two more flexible models with one hidden layer, and
- two models with 18 financial ratio attributes related to the financial condition of the enterprises one year before the declaration of bankruptcy and two models with 36

financial ratio attributes, of which 18 were calculated out of one-year-before-bankruptcy financial statements and 18 were related to the two-years-before-bankruptcy financial condition.

The criterion of making a distinction between a set of indicators related to just one year before going bankrupt and a set of indicators related to two years preceding bankruptcy is motivated by a belief of many researchers in this area that traces of inevitable bankruptcy to come are detectable in financial statements several years before failure.

As for the settings, the training of the networks was accomplished in accord with the pre-sets of Weka (learning rate 0.3, momentum 0.2, normalization of inputs, 500 epochs and validation threshold 20). The models were estimated and evaluated under the 10-fold cross-validation option. The results for, and a brief overview of, the considered 4 models are presented in table 2.

Table 2. The overview of the competitive models and the results

(Source: The author.)

MULTILAYER PERCEPTRON	18 ATTRIBUTES (FINANCIAL RATIOS ONE YEAR BEFORE BANKRUPTCY ONLY)	36 ATTRIBUTES (FINANCIAL RATIOS TWO YEARS PRIOR DECLARING BANKRUPTCY)																		
NO HIDDEN LAYER	Number of input nodes: 18 Number of hidden notes: 0 Number of output nodes : 2 Number of estimated parameters: 38 Transformation: sigmoidal Correctly classified instances: 864 (93.81 %) Incorrectly classified instances: 57 (6.19 %) Mean absolute error: 0.1138 Root mean squared error: 0.2432 Relative absolute error: 78.47 % Root relative squared error: 90.57 % ----- Confusion matrix ----- <table><tr><td>Non-bankrupt</td><td>846</td><td>3</td></tr><tr><td>Bankrupt</td><td>54</td><td>18</td></tr><tr><td>classified as --></td><td>Non-bankrupt</td><td>Bankrupt</td></tr></table>	Non-bankrupt	846	3	Bankrupt	54	18	classified as -->	Non-bankrupt	Bankrupt	Number of input nodes: 36 Number of hidden notes: 0 Number of output nodes : 2 Number of estimated parameters: 74 Transformation: sigmoidal Correctly classified instances: 859 (93.27 %) Incorrectly classified instances: 62 (6.73 %) Mean absolute error: 0.1122 Root mean squared error: 0.253 Relative absolute error: 77.42 % Root relative squared error: 94.23 % ----- Confusion matrix ----- <table><tr><td>Non-bankrupt</td><td>840</td><td>9</td></tr><tr><td>Bankrupt</td><td>53</td><td>19</td></tr><tr><td>classified as --></td><td>Non-bankrupt</td><td>Bankrupt</td></tr></table>	Non-bankrupt	840	9	Bankrupt	53	19	classified as -->	Non-bankrupt	Bankrupt
	Non-bankrupt	846	3																	
	Bankrupt	54	18																	
classified as -->	Non-bankrupt	Bankrupt																		
Non-bankrupt	840	9																		
Bankrupt	53	19																		
classified as -->	Non-bankrupt	Bankrupt																		
ONE HIDDEN LAYER	Number of input nodes: 18 Number of hidden notes: 10 Number of output nodes : 2 Number of estimated parameters: 212 Transformation: sigmoidal Correctly classified instances: 866 (94.03 %) Incorrectly classified instances: 55 (5.97 %) Mean absolute error: 0.1178 Root mean squared error: 0.2354 Relative absolute error: 81.26 % Root relative squared error: 87.68 % ----- Confusion matrix ----- <table><tr><td>Non-bankrupt</td><td>848</td><td>1</td></tr><tr><td>Bankrupt</td><td>54</td><td>18</td></tr><tr><td>classified as --></td><td>Non-bankrupt</td><td>Bankrupt</td></tr></table>	Non-bankrupt	848	1	Bankrupt	54	18	classified as -->	Non-bankrupt	Bankrupt	Number of input nodes: 36 Number of hidden notes: 19 Number of output nodes : 2 Number of estimated parameters: 743 Transformation: sigmoidal Correctly classified instances: 863 (93.70 %) Incorrectly classified instances: 58 (6.30 %) Mean absolute error: 0.1076 Root mean squared error: 0.2367 Relative absolute error: 74.21 % Root relative squared error: 88.16 % ----- Confusion matrix ----- <table><tr><td>Non-bankrupt</td><td>843</td><td>6</td></tr><tr><td>Bankrupt</td><td>52</td><td>20</td></tr><tr><td>classified as --></td><td>Non-bankrupt</td><td>Bankrupt</td></tr></table>	Non-bankrupt	843	6	Bankrupt	52	20	classified as -->	Non-bankrupt	Bankrupt
	Non-bankrupt	848	1																	
	Bankrupt	54	18																	
classified as -->	Non-bankrupt	Bankrupt																		
Non-bankrupt	843	6																		
Bankrupt	52	20																		
classified as -->	Non-bankrupt	Bankrupt																		

It is obvious that the results are virtually uniform, which is not case with the complexity of the individual models. The simplest model is the multilayer perceptron without the hidden layer based on one-year-before-bankruptcy financial ratios. This model economizes the number of parameters to estimate on the hidden layer (which is none) and on the number of inputs (which is 18); and yet its predictive capability is comparable. Having stated that, it

must be noted that all the models are impotent to predict bankruptcy and that it seems sufficient to base the modelling purely upon the financial information one year before possible bankruptcy to be predicted. The former statement results from the fact that of 72 bankrupting enterprises (of course, after the replication) about 75 % were predicted as non-bankrupting in the following year. This finding is suggestive that no the replication by 6 was insufficient to accommodate the modelling. The latter argument is supported by the fact that the models basing upon the information only one year before bankruptcy do not differ in terms of performance from the models building upon the information two years before bankruptcy. The results clearly indicate the necessity to procure a better database with a relevant proportion of bankrupting enterprises.

4. The conclusive remarks

The paper attempts to develop a multilayer perceptron neural network with a view to predicting bankruptcy of Slovak enterprises, and therein arrives at unsatisfactory results. The vice in the results stems from a very small proportion of bankrupt enterprises in the sample; even so, it is observed that financial ratios one year before bankruptcy are sufficient to the end pursued and that it is not necessary to utilize financial ratios two year before going bankrupt.

5. The references

- [1.] BERRY, M. J. A., LINOFF, G. S. 2004. Data mining techniques for marketing, sales and customer relationship management. 2nd ed. Wiley : Indianapolis 2004. 643 pp. ISBN 978-0-471-47064-9.
- [2.] GAVLIAK, R. 2006. Bankruptcy prediction in Slovak companies using linear probability models. In: Forum Statisticum Slovaca. 2006. Vol. 2 No. 5. Pp. 65-70. ISSN 1336-7420.
- [3.] GAVLIAK, R. 2007. Využitie lineárnych pravdepodobnostných modelov pri tvorbe bonitného modelu v slovenských podmienkach. In: Evropské finanční systémy 2007. Sborník příspěvků z mezinárodní vědecké konference. Brno : Masarykova univerzita v Brně. 2007 Pp. 69-75. ISBN 978-80-210-4319-0.
- [4.] HIADLOVSKÝ, V., KRÁL, P. 2005. Využitie diskriminačnej analýzy na predikovanie finančnej situácie podnikov v SR. In: Forum Statisticum Slovaca. 2005. Vol. 1 No. 1. Pp. 44-50. ISSN 1336-7420.
- [5.] HIADLOVSKÝ, V., KRÁL, P. 2006. Možnosti predikovania finančnej situácie podnikov v SR s využitím SPSS. In: Forum Statisticum Slovaca. 2006. Vol. 2 No. 4. Pp. 90-95. ISSN 1336-7420.
- [6.] HIADLOVSKÝ, V., KRÁL, P. 2007. Predicting financial distress of Slovak companies. Contribution held at AMSE 2007 (Applications of Mathematics and Statistics in Economy) conference in Poprad, Slovakia, 2006. Unpublished.
- [7.] HIADLOVSKÝ, V., KRÁL, P. 2009. Predicting financial distress of Slovak companies using fuzzy sets theory. Contribution held at AMSE 2009 (Applications of Mathematics and Statistics in Economy) conference in Uherské Hradiště, the Czech Republic, 2009. Publishing under way.
- [8.] WITTEN, I. H., FRANK, E. 2005. Data mining. Practical machine learning tools and techniques. 2nd ed. Morgan Kaufmann : Amsterdam, 2005. 524 pp. ISBN 978-0-12-088407-0.

The author's address

Martin Bod'a, Ing. et Bc.
Univerzita Mateja Bela v Banskej Bystrici
Ekonomická fakulta
Katedra kvantitatívnych metód a informačných systémov
Tajovského 10
975 90 Banská Bystrica
martin.boda@umb.sk

Charakteristika stavebného priemyslu v Slovenskej republike za rok 2007 Building industry characterization in Slovak republic in 2007

Mária Bolcárová, Ján Samuhel

Abstract: The main aim of this work is to characterize building industry in the Slovak Republic in 2007 with appropriate analytical procedures in hope of a possibility of their application to new building companies, eventually for next periods. We used some methods of multidimensional statistical and unstatistical data processing of financial ratios of 50 Slovak building companies. By principal component analysis and factor analysis we created six new indicators describing industry better and found objects which lie out. We also created a good model of neural network which can divide companies into those where sales increase and those where they decrease.

Key words: Principal Component Analysis, Exploratory Analysis, Multidimensional Scaling, Factor Analysis, Canonical Correlation, Discriminant Analysis, Neural Networks

Kľúčové slová: Analýza hlavných komponentov, Exploratórna analýza, Viacrozmerné škálovanie, Faktorová analýza, Kanonické korelácie, Diskriminačná analýza, Neurónové siete

1. Úvod

Cieľom práce je charakterizovať vhodnými analytickými postupmi odvetvie stavebníctva v Slovenskej republike za rok 2007 v nádeji, že ich bude možné využiť aj pre iné stavebné firmy neuvažované v článku, prípadne budúce obdobia. Pri plnení cieľa sme použili niektoré metódy viacrozmerného štatistického a neštatistického spracovania dát – ukazovateľov finančnej analýzy. Na tento účel sme analyzovali ukazovatele popisujúce činnosť päťdesiatich stavebných podnikov, ktoré boli získané z časopisu TREND. Dáta sme následne štandardizovali, aby sme tak dosiahli porovnateľnosť všetkých premenných a s takto upravenými mohli ďalej pracovať. Na spracovanie analýz sme využili programy SPSS 13.0, Weka 3.6, STATISTICA 7, NCSS a štandardné programy balíka Microsoft Office.


2. Analýza hlavných komponentov

Aby mala analýza hlavných komponentov zmysel, zvolené premenné (pozri tabuľka 3) musia byť vzájomne čo najviac korelované. To sa nám potvrdilo jednak tým, že determinant kovariančnej matice je blízky nule a že p-hodnota Barlettovho testu sféricity sa prakticky rovná nule na všetkých bežných hladinách významnosti, čo nám podľa tohto testu umožňuje zamietnuť nulovú hypotézu o jednotkovej korelačnej matici.

Tabuľka 1: Vlastné čísla

Komponent	Vlastné čísla	% z rozptylu	Kumulatívne %
1	3,401	26,167	26,167
2	2,459	18,919	45,086
3	1,933	14,867	59,953
4	1,586	12,202	72,155
5	1,261	9,704	81,859
6	1,136	8,737	90,596
7	0,674	5,184	95,780
8	0,342	2,633	98,413
9	0,089	0,687	99,100
10	0,046	0,351	99,451
11	0,034	0,260	99,711
12	0,027	0,207	99,918
13	0,011	0,083	100,000

Zdroj: vlastné spracovanie



Graf 1: Cattelov indexový graf úpätia vlastných čísel

Zdroj: vlastné spracovanie

Z dát sme vytvorili 13 hlavných komponentov a ďalej pracujeme už len s tými, ktorých vlastné čísla vysvetľujú spolu aspoň 90% variability a tiež sú väčšie ako jedna, t. z. každá z nich vysvetľuje viac variability ako jednotlivé premenné samostatne, preto má zmysel s nimi ďalej pracovať. Zhodli sme sa teda na šiestich komponentoch. Cattelov indexový graf úpätia vlastných čísel podporuje rozhodnutie.

Hodnoty komunalít sú v našom prípade v priemere 0,93 (+0,06), pričom neuvažujeme s premennou obrátka majetku rovnajúca sa 0,559. Zvolené komponenty teda postačujúco vysvetľujú každú z pôvodných premenných.

Ďalej bolo našou snahou zistiť, čo orientačne vyjadrujú jednotlivé komponenty. Premenné sme preto za pomoci komponentnej skórovej matice koeficientov zaradili do jedného zo šiestich komponentov podľa toho, ktoré sa najviac podieľali na vysvetlení jednotlivých komponentov. Pre lepšiu predstavivosť a názornosť sme každý komponent charakteristicky pomenovali a nasledujúca tabuľka zobrazuje toto rozdelenie.

Tabuľka 3: Komponentná skórová matica koeficientov

Ozn.	Názov ukazovateľa	Komponenty					
		Zdroje do budúcnosti	Efektivita využitia zdrojov	Ukazovateľ zamestnaneckej činnosti	Tvorba hodnoty	Ukazovateľ zadlženosti	Ukazovateľ vývoja činnosti
Y1	Zmena pridanej hodnoty (%)	-0,104	0,145	0,158	-0,031	-0,242	0,569
Y2	Zisk po zdanení (tis. Sk)	0,239	0,042	0,216	-0,221	0,059	-0,010
x3	Produktivita práce	-0,060	-0,210	0,362	0,234	0,132	-0,055
x4	Celková zadlženosť majetku	-0,102	-0,030	-0,051	-0,155	0,672	0,154
x5	Podiel pridanej hodnoty v tržbách	0,136	0,189	-0,076	0,443	0,142	0,025
x6	ROE	-0,111	0,206	0,213	-0,154	0,206	-0,319
x7	Zmena tržieb (%)	-0,107	0,195	0,220	0,043	-0,009	0,454
x8	Obrátka majetku	-0,151	0,155	0,018	-0,157	0,221	-0,075
x9	Pridaná hodnota/majetok	0,069	0,278	-0,062	0,380	0,210	-0,051
x10	ROA	-0,049	0,242	0,247	-0,042	-0,266	-0,436
x11	Vybavenosť pracovníkov	-0,036	-0,245	0,336	0,261	0,092	-0,034
x12	Vlastné imanie	0,272	0,013	0,138	-0,069	0,032	0,082
x13	Priemerný počet zamestnancov	0,254	0,044	0,126	-0,192	0,159	0,123

Zdroj: vlastné spracovanie

Hlavné komponenty sme využili aj na overenie viacrozmerného normálneho rozdelenia dát a to vytvorením scatter plot-ov. Dáta pravdepodobne pochádzajú z normálneho rozdelenia pretože vytvárajú elipsy. Výnimkou je šiesty komponent (ukazovateľ vývoja činnosti), pretože v kombinácii s ostatnými komponentmi nevytvára jasné obrázce.


Touto analýzou sme začali ako prvou, pretože zvolené komponenty využijeme v niektorých nasledujúcich analýzach a pomôžu nám ich zjednodušiť a sprehládniť.

3. Exploratórna analýza

V tejto časti práce sme na dátach vykonali niekoľko grafických procedúr, aby sme názorne zobrazili štruktúru dát s ktorými sme pracovali a identifikovali v dátach abnormality.

3.1 Box plot analýza

Na obrázku 1 box ploty predstavujú jednotlivé komponenty, pričom rozpätie jednotlivých box plot-ov pomáha indikovať stupeň rozptylu. Symbol hviezda znázorňuje objekty, ktoré predstavujú „outliere“ a preto by sa mali bezpodmienečne z ďalších analýz vylúčiť, a to Doprastav, a.s., Bratislava (1); Tchas, s.r.o., o.z., Bratislava (17) a ZIPP, s.r.o., Bratislava (3). Symbol kruh znázorňuje objekty, ktorých vylúčenie sa môže ďalej zvážiť. My navrhujeme okrem už spomenutých vylúčiť Termotav – Mráz, s.r.o., Košice (33), keďže je „outlier“-om v druhom aj šiestom komponente.



Obrázok 1: Box ploty

Zdroj: vlastné spracovanie

Na obrázku 1 vidieť, že objekt 1 (Doprastav, a.s., Bratislava) má najvyššiu hodnotu prvého komponentu. Znamená to, že firma má absolútne najviac zdrojov do budúcnosti a na trhu stavebníctva je teda najväčšia. Hodnota štvrtého komponentu je zase najnižšia, teda spoločnosť dokáže tvoriť len malú pridanú hodnotu a pravdepodobne nakupuje drahé vstupné náklady ako materiál a energie. To, že hodnota štvrtého komponentu je najnižšia, nie je spôsobené nízkymi tržbami, pretože hodnota tretieho komponentu je najvyššia. Priemerný počet zamestnancov je tiež vysoký, čo čítame z prvého komponentu.

3.2 Chernoffove tváre

Objekty sme analyzovali aj pomocou Chernoffových tvárí charakterizovaných šiestimi znakmi, ktoré predstavujú jednotlivé hlavné komponenty popísané v tabuľke 3. Tvár objektu Doprastav, a.s., Bratislava (1) je oproti ostatným relatívne širšia, čo predstavuje komponent vyjadrujúci budúce zdroje, pričom v danom prípade predpokladáme ich dostatok. Ďalším vybočujúcim objektom sa javí byť ZIPP, s.r.o., Bratislava (3) pre jeho širokú a nízku tvár v porovnaní s ostatnými tvármi. To naznačuje silnú pozíciu objektu v oblasti budúcich zdrojov, ale naopak nízku produktivitu práce a vybavenosť zamestnancov. Objekt Tchas, s.r.o., o.z., Bratislava (17) je v opačnej pozícii ako predchádzajúci objekt, nakoľko jeho tvár prejavuje známky vysokej produktivity práce a vybavenosti zamestnancov, ale naznačuje problém v oblasti budúcich vlastných zdrojov. Tvár objektu Prefa, a.s., Sučany (26) nízko položenými ušami naznačuje slabú efektivitu využívania vložených zdrojov z pohľadu vlastníkov ako aj všetkých zúčastnených. Termostav - Mráz, s.r.o., Košice (33) sa vyčleňuje pred ostatné objekty pre vysokú dynamiku rastu tržieb a pridanej hodnoty. Odporúčame zváženie možnosti uvedené objekty vylúčiť z ďalších analýz.

3.3 Záver exploratórnej analýzy

Okrem už popísaných častí exploratórnej analýzy sme použili aj niektoré jej ďalšie metódy. V tabuľke 4 sú označené krížikom objekty, ktoré boli jednotlivými analýzami navrhnuté na vylúčenie.

Tabuľka 4: Výsledky exploratórnej analýzy

Ozn.	Názov objektu	Scatter plot analýza	Andrewsové krivky	Profily	Box plot analýza	Chernoffove tváre
1	Doprastav, a.s., Bratislava	x	x	x	x	x
3	ZIPP, s.r.o., Bratislava	x	x	x	x	x
17	Tchas, s.r.o., o.z., Bratislava	x	x	x	x	x
26	Prefa, a.s., Sučany	x				x
27	Stamart, s.r.o., Martin	x				
33	Termostav-Mráz, s.r.o., Košice	x	x		x	x
37	Mijas, s.r.o., Banská Bystrica	x				


Zdroj: vlastné spracovanie

Dohodli sme sa, že objekty označené aspoň štyri krát odstránime z dát a v nasledujúcich analýzach už s nimi nebudeme pracovať. Ide o objekty s číslami 1, 3, 17 a 33.

Na Andrewsových krivkách a profiloch badať znaky protichodného vývoja minimálne dvoch skupín objektov, teda existuje predpoklad pre použitie diskriminačnej analýzy. Taktiež z analýzy scatter plot-ov predpokladáme existenciu ukazovateľov, ktoré sú tieto skupiny schopné rozlíšiť. V článku však nie sú grafické prezentácie týchto metód uvedené.


4. Viacrozmerné škálovanie

Na výpočet relatívnych vzdialeností objektov a premenných sme využili euklidovskú metriku. Pôvodné vzdialenosti medzi premennými, resp. objektmi sme transformovali pri minimalizácii mierky stress za využitia metódy PROXSCAL. Pri hľadaní vzdialeností medzi objektmi je stress 0,037 a medzi premennými 0,013, čiže transformované vzdialenosti pravdepodobne veľmi vhodne opisujú skutočné vzdialenosti. Oba nasledujúce grafy znázorňujú postavenie koordinátov v dvojdimenzionálnom priestore.



Graf 2: Relačná mapa

Zdroj: vlastné spracovanie



Graf 3: Graf vzťahov premenných

Zdroj: vlastné spracovanie

Každý z objektov na relačnej mape má úsečkou označenú vzdialenosť od centroidu objektov. Tie, ktoré sme označili za odlahlé sú na tejto mape najvzdialenejšie od centroidu. Na grafe vzťahov premenných sa výrazne zlučujú premenné x12, x13 a Y2, tiež x3 a x11, ktoré sme aj v analýze hlavných komponentov označili za tvoriace jednotlivé komponenty. Premenná x4 sa výrazne líši od ostatných a aj v analýze hlavných komponentov bola označená za premennú, ktorá vysvetľuje hlavnú časť variability jedného z komponentov. Legenda k premenným je v tabuľke 3.

5. Faktorová analýza

Pri určení počtu faktorov sme vychádzali z analýzy hlavných komponentov. Na extrakciu faktorových zátŕaží bola použitá metóda maximálnej vierohodnosti (dáta sa ukazujú byť normálne rozdelené, pozri záver časti 2), pričom na ortogonálnu transformáciu faktorového riešenia bola použitá metóda rotácie varimax. Na základe vzniknutej matice faktorových zátŕaží sme určili 6 faktorov, pri ktorých predpokladáme interpretácie znázornené v tabuľke 5.

Treba upozorniť, že na vyextrahované faktory treba nazerať s veľkou mierou opatrnosti. V prvom rade sa javí sledovaný výber dát ako nevhodný na použitie faktorovej analýzy, čomu nasvedčuje pomerne nízka hodnota miery vhodnosti výberu dát ($KMO = 0,455$). Problémom je tiež nedostatočný počet pozorovaní (iba 46 objektov). Determinant korelačnej matice pôvodných premenných je blízky nule, čo je dobré.

Tabuľka 5: Štruktúra a interpretácia výsledných faktorov

Faktor	Zahnuté premenné	Interpretácia
F1	Priemerný počet zamestnancov; Zisk po zdanení; Vlastné imanie.	Vyjadruje potenciál objektu z hľadiska vlastných finančných zdrojov a pracovnej sily, do istej miery aj veľkosť objektu
F2	Vybavenosť pracovníkov; Produktivita práce.	Odráža pracovné podmienky zamestnancov, pričom zároveň zohľadňuje produktivitu ich činnosti.
F3	ROA; ROE.	Zohľadňuje zhodnotenie zdrojov, s ktorými objekt pracuje.
F4	Závázky/majetok.	Triviálny, nemá zmysel s ním ďalej pracovať.
F5	Pridaná hodnota/tržby; Pridaná hodnota/majetok.	Vyjadruje relatívnu schopnosť objektu tvoriť pridanú hodnotu vzhľadom na jeho veľkosť. Hovorí tak o technologickej vyspelosti činnosti objektu.
F6	Tržby/majetok; Pridaná hodnota/majetok.	Indikátor rýchlosti a efektivity využívania majetku.

Zdroj: vlastné spracovanie

Komunalita naznačujú, že väčšina pôvodných premenných je vo veľkej miere vysvetlená odhadnutými faktormi. Avšak „zmena tržieb“ a „zmena pridanej hodnoty“ sú týmito faktormi vysvetlené slabšie (komunalita 0,23, resp. 0,09). Počas iteratívneho procesu dosiahli niektoré komunalita hodnotu vyššiu ako 1, čo tiež nabáda k opatrnému využitiu týchto faktorov.

Z dôvodu prítomnosti triviálneho faktora, bol iteratívny proces zopakovaný s piatimi faktormi. Pravdepodobne pre nevhodné dáta a ich nízky rozsah však nebolo možné extrahovať nové faktory a to ani pri použití iných metód extrakcie. Výstupom analýzy teda ostáva 6 faktorov, hoci jeden z nich chápeme ako triviálny. Počet faktorov je v súlade s „testom správnosti odhadu“ (goodness-of-fit test), pretože na 5-percentnej hladine významnosti sa nepodarilo vyvrátiť platnosť nulovej hypotézy o správnom počte extrahovaných faktorov.

Apelujeme na to, aby výsledky faktorovej analýzy boli chápané ako veľmi hrubé vysvetlenie vzťahov medzi pôvodnými premennými, a to nielen z dôvodu všeobecne známej nejednoznačnosti faktorového riešenia, ale aj pre

vyššie popísané problémy. Dávame tiež do pozornosti obsahovú podobnosť niektorých faktorov s hlavnými komponentmi.

6. Kanonické korelácie

Pri tvorbe kanonických premenných sme dve premenné označili za závislé (zmena pridanej hodnoty (%) a zisk po zdanení (tis. Sk)) a zvyšné za nezávislé. Korelácie medzi kanonickými premennými sú potom po zaokrúhlení 0,972 a 0,680 a p-hodnoty F-testov sú takmer nulové, teda na všetkých bežných hladinách významnosti sa podľa tohto testu dá povedať, že závislé kanonické premenné sú dostatočne vysvetľované nezávislými premennými. Hodnota skupinového korelačného koeficienta je po zaokrúhlení 0,970, čo je tiež pozitívne.

Avšak za nedostatok považujeme to, že nezávislé kanonické premenné vysvetľujú spolu len 26,8 % variability pôvodných premenných. Závislé premenné sú vysvetľované nezávislými na 70,7 %, čo by bolo postačujúce, keby kanonická analýza dokázala vytvoriť takú premennú, ktorá dostatočne vyčerpáva variabilitu pôvodných nezávislých premenných. Riešením by bolo iné prerozdelenie pôvodných premenných na závislé a nezávislé, a to stanovením nižšieho počtu nezávisle premenných, avšak my sme iné rozdelenie nepokladali za vhodné a potrebné.

7. Diskriminačná analýza

Hľadáme kritériá pre klasifikáciu ľubovoľného objektu do jednej z dvoch disjunktných skupín, z ktorých jedna predstavuje objekty s rastúcimi tržbami (1) a druhá skupina je tvorená objektmi s klesajúcimi tržbami (0).


Na tento účel sme odhadli kanonickú diskriminačnú funkciu (CDF). Hodnoty všetkých použitých premenných majú v celom sledovanom výbere ako aj v oboch skupinách vysokú smerodajnú odchýlku, ktorá pri viacerých ukazovateľoch prevyšuje ich priemernú hodnotu. Finálne klasifikačné kritéria spolu s koeficientmi CDF sú zapísané vo vzťahu (1):

$$d_i^2(o_j) = \left[0,007 + 0,122(Zisk / majetok_j - \overline{Zisk / majetok_i}) + 0,71(ROE_j - \overline{ROE_i}) + \right. \\ \left. + 0,503(ZmenaPH_j - \overline{ZmenaPH_i}) + 0,29(Trzby / majetok_j - \overline{Trzby / majetok_i}) \right]^2 \quad (1)$$

$$i \in \{0,1\}, o_j - j\text{-ty objekt}$$

Na hladine významnosti 0.05 sa podarilo spochybníť nulovú hypotézu o nepoužiteľnosti uvedenej kanonickej premennej na diskrimináciu (p-hodnota = 0,02).

Na riešenie rovnakej úlohy bola použitá aj umelá neurónová sieť typu „multilayer perceptron“ s metódou učenia sa „backpropagation“. Jej architektúra je znázornená na obrázku 2. Pri odhade boli objekty náhodne rozdelené na tréningové (31) a testovacie (15).



Obrázok 2: Neurónové siete

Zdroj: vlastné spracovanie

Z tabuľky 6 vidíme, že neurónový model zaradil 84,78 % objektov zo sledovaného výberu do správnej skupiny, čo je v porovnaní s výslednou CDF o viac ako 8 percentuálnych bodov lepší výsledok. Nie je potešiteľné, že z hľadiska štruktúry je vyššie percento nesprávne zaradených objektov s reálne klesajúcimi tržbami do skupiny s rastúcimi tržbami v porovnaní s opačným prípadom chybného zaradenia (potenciálne negatívne dôsledky pre používateľa), pričom táto situácia nastáva pri oboch metódach. Aj v tomto smere ale dosiahol neurónový model o 12 percentuálnych bodov lepší výsledok a pre relatívne lepšie výsledky pri klasifikácii objektov z daného výberu ho odporúčame preferovať pred odhadnutou CDF.

Tabuľka 6: Zaradenie pri CDF a neurónovej sieti

Metóda	Správne zaradené (%)	Chybné zaradenie do skupiny 0 (%)	Chybné zaradenie do skupiny 1 (%)
CDF	76,1	20,7	29,4
Neurónová sieť	84,78	13,8	17,6

Zdroj: vlastné spracovanie

Problém analýzy je v slabej rozlišovacej schopnosti všetkých premenných meraných na objektoch. Odporúčame opatrnú interpretáciu a použitie oboch odhadnutých modelov len na prvotné zaradenie objektu do niektorej zo skupín, pričom výsledok by mal byť verifikovaný ďalšími analýzami a nástrojmi.

8. Záver

V práci sme sa snažili držať stanoveného cieľa, avšak úloha bola značne skomplikovaná nízkym počtom objektov v sledovanom výbere, napriek tomu však môžeme zhrnúť zistené skutočnosti. Metódou hlavných komponentov sa podarilo vytvoriť šesť hlavných komponentov, ktoré považujeme za správnejší rozmer dát. Pomocou faktorovej analýzy sme dospeli k obsahovo podobným faktorom, preto predpokladáme že stavebníctvo je možné charakterizovať týmito novými premennými. Z nich prikladáme najväčší význam hlavne komponentom s názvami efektivita využitia zdrojov (pc2), tvorba hodnoty (pc4) a ukazovateľ vývoja činnosti (pc6). Tieto tri informujú používateľa v globále o zhodnotení zdrojov vložených do firmy, efektivite výroby a vývoji odbytu v čase. Tento predpoklad potvrdilo aj viacrozmerné škálovanie. Hlavné komponenty sme následne použili v niektorých nástrojoch exploratórnej analýzy, čím sa podarilo nájsť tie stavebné podniky, ktoré sa nejakým spôsobom výraznejšie odlišujú od ostatných. Jedná sa o nasledovné firmy: Doprastav, a.s. Bratislava, ZIPP, s.r.o., Bratislava, Tchas, s.r.o., o.z., Bratislava, Termotav - Mráz, s.r.o., Košice. Podotýkame, že kým prvé dve menované firmy patria medzi päť najväčších stavebných firiem na Slovensku, tak posledná menovaná prislúcha skôr k menším až malým firmám. Tiež sme pomocou nich overili viacrozmerné normálne rozdelenie sledovaného výberu. Napriek náznakom v exploratórnej analýze diskriminovať sa nepotvrdila výrazná diskriminačná schopnosť použitých ukazovateľov najmä z dôvodu vysokej smerodajnej odchýlky často vyššej ako priemer. Podarilo sa však vytvoriť obstojný model neurónovej siete, ktorý slúži na rozlíšenie stavebných podnikov na tie, ktorých tržby rastú a na tie, ktorým tržby naopak klesajú. Uvedomujeme si určité nedostatky niektorých analýz popísaných v práci, avšak veríme, že dosiahnuté výsledky tvoria solídny základ pre ďalšie skúmania.

9. Literatúra

- [1] JOHNSON, E. D. 1998. Applied Multivariate Methods for Data Analysis. Massachusetts: Duxbury Pr, 1998, s. 55 – 275. ISBN 0-534-23796-7.
- [2] MELOUN, M. – MILITKÝ, J. 2002. Kompendium statistického zpracování dat. Praha: Academia, 2002. 764 s. ISBN 80-200-1008-4.
- [3] STANKOVIČOVÁ, I. – VOJTKOVÁ, M. 2007. Viacrozmerné štatistické metódy s aplikáciami. Bratislava: Iura Edition, 2007. 261 s. ISBN 978-80-8078-152-1.
- [4] TREND TOP 2008: Príloha k časopisu TREND. Zodp. red. Martin Jaroš, 2008. Bratislava: TREND Holding, s. r. o., roč. 45/2008.

Adresy autorov:

Mária Bolcárová, Bc.
Ekonomická fakulta UMB
Tajovského 10
975 90 Banská Bystrica
bolcarova.maria@student.umb.sk

Ján Samuhel', Bc.
Ekonomická fakulta UMB
Tajovského 10
975 90 Banská Bystrica
jan.samuhel@student.umb.sk

Tradingové stratégie s opciami Trading strategies with options

Paula Bolcárová

Abstract: This work demonstrates the option strategies approach to investing. Under an assumption of diversification in portfolio we follow the results of correlation analysis of share prices volatility and we chose three underlying assets for option strategies. With this selection, we predict the price of the shares at the day of expiration upon which the option strategies are modeled. The power of a portfolio is closely related to the type of data to which it is applied. Using the options currently traded on Chicago Board Option Exchange we face opportunities to modify the widely recognized patterns of strategies in order to extend the field of expected profit and decrease the probable loss. Moreover, we compute optimal proportion of strategies to create a sample portfolio which is both risk minimizing and profitable.

Key words: Option strategies. Portfolio construction. Price of option. Volatility

Kľúčová slová: Stratégie s opciami. Tvorba portfólia. Opčná prémia. Volatilita

Úvod


Investori po celom svete, v snahe znásobiť svoje bohatstvo, čoraz viac upierajú zrak k odborným knihám, brožúram alebo internetu. Väčšina odborných informácií z oblasti kapitálových trhov konverguje ku grafom a vzorcom, ktorých zložitosť je priamo úmerná presnosti i práci. Mnohé zo záverov z nich plynúcich pritom nie je možné aplikovať do praxe pre nesplniteľné podmienky. V prípade tradingových stratégií s opciami napríklad vzniká problém s neexistenciou výberu realizačných cien zodpovedajúcich nami načrtnutému modelu. Podobne nízka obchodovateľnosť niektorých opcií tvoriaca cenu, ktorá nie vždy zodpovedá reálnej či teoretickej hodnote opcie, alebo nepriama úmera medzi maturitou a množstvom uzavretých obchodov prispievajú k tomu, že namodelovanú stratégiu nie je možné na trhu uplatniť, prípadne ju včas opustiť. Každá kombinácia opcií sa tak stáva originálnou stratégiou nie vždy dokonale zodpovedajúcou požiadavkám investora. Cieľom tejto práce je načrtnúť reálnu tvorbu portfólia stratégií s opciami na akcie, ktoré sa bežne obchodujú na amerických burzách, s inklúziou vyššie spomenutých obmedzení. Informácie o zobchodovaných objemoch, kusoch, resp. lótoch a priemerných cenách akcií i opcií a volatilitách akcií sa pravidelne aktualizujú na internete. Pre účely tejto práce sme použili dáta zo stránok <http://finance.yahoo.com/> a <http://www.cboe.com/>.

Výber skupiny akcií

Základná podmienka pri tvorbe portfólia je požiadavka diverzifikácie. Podľa výroku Miguela de Cervantesa: „Patrí k múdremu mužovi nevkladať všetky vajíčka do jedného košíka.“ neinvestujeme všetky peňažné prostriedky do jedného typu akcie, resp. opcie, ani do jedného odvetvia. Diverzifikácia spočíva v rozložení rizika plynúceho z volatility výnosov, formou zvýšenia počtu akcií, medzi ktorými neexistuje priama lineárna závislosť. Výhodou v obchodovaní s opciami oproti obchodovaniu s akciami je, že dokážeme profitovať z akéhokoľvek pohybu ceny podkladového aktíva. Teda ak očakávame prudký rast akcie A, opčná stratégia na akciu B, ktorá je negatívne korelovaná s akciou A, bude založená na poklese hodnoty aktíva. Preto nás viac ako korelácia výnosov akcií zaujíma ich volatilita a korelácia týchto volatilit v našej skupine. Následne v prípade udalosti, ktorá vyvolá

volatilitu vo vývoji hodnoty akcie A, teda cena v čase expirácie sa nebude približovať hodnote, ktorú sme predpokladali, neovplyvni to vývoj stratégie na akciu B.

Vybrali sme deväť firiem pôsobiacich v štyroch odvetviach, ktorých opcie sa obchodujú na chicagskej burze. Z finančného sektora Bank of America, JP Morgan a Goldman Sachs, spoločnosti zaoberajúce sa výpočtovou technikou Microsoft Corp a IBM Corp a spoločnosti pôsobiace v oblasti internetu a správy informácií Google Inc a Yahoo! Inc. Ďalej za chemické odvetvie Avon Products a za odvetvie bielej techniky firmu Whirlpool. Získané údaje o volatilitě týchto akcií za posledných dvadsaťšesť mesiacov okrem marca roku 2008, za ktorý dáta neboli uverejnené, ukazuje graf 1. Volatilita akcií reprezentujúcich finančný sektor je vyznačená čiarami.



Graf 1: Historická volatilita cien vybraných akcií

Zdroj: vlastné spracovanie podľa údajov zo stránky <http://www.cboe.com/>

Z grafu vidíme, že od júla roku 2008 je najvyššia volatilita práve vo finančnom sektore, ktorý spôsobil krízu, pričom v predošlom období takýto trend nevykazovala. Táto volatilita sa od septembra preniesla aj do ostatných odvetví ekonomiky.

Analýzu výberu akcií sme rozdelili na dva kroky. V prvom zisťujeme koreláciu volatility ceny akcií za obdobie sedemnástich mesiacov pred vypuknutím finančnej krízy. V druhom kroku komparujeme naše zistenia s výsledkami rovnakej analýzy za obdobie ôsmich mesiacov od júla roku 2008. Pomocou korelačných koeficientov medzi dvojicami akcií sme za podkladové aktíva zvolili kombináciu týchto troch akcií, pri ktorých bola splnená podmienka minimálnej korelovanosti a teda maximálnej diverzifikácie vo volatilitě. Akcie spoločností Avon Products, Bank of America Corp, a Yahoo! Inc. Opčné kontrakty hypoteticky uzatvárame k 27. marcu 2009. pričom expirujú 15. mája toho istého roku.

Definovanie očakávaní

Akcie firmy Avon Products Inc sú kótované na trhu dvadsaťsedem rokov. Vydávané boli pri cene zhruba jeden dolár a od roku 1995 zaznamenávali prudký a volatilný rast s výnimkou rokov 1999 a 2005, kedy sa hodnota akcií prepádla približne o 55% a 45%. Okrem toho tieto prepady sú nasledované prudkým rastom v priebehu niekoľkých mesiacov. Môžeme zhodnotiť, že firma zvládla prípady veľkých strát na hodnotách akcií a teda existuje predpoklad, že je schopná a vďaka veľkej volatilitě v uplynulých rokoch aj pripravená prekonať súčasný pokles ceny akcií o takmer 60% na hodnotu 19,9 USD. Naše očakávanie pre akcie firmy Avon Products je: Hodnota akcie v horizonte jeden a pol mesiaca vzrastie.

Akcie korporácie Bank of America sa obchodujú na trhu už viac ako dvadsaťpäť rokov pričom začínali na hodnote asi osem dolárov za akciu. Ich cena prudko vzrástla po roku 1995 a po roku 2001. Vyššiu volatilitu zaznamenala najmä v období rokov 1998 až 2001. Začiatok prepady ceny akcie na súčasných asi sedem dolárov môžeme datovať na október roku 2008. Cena akcie dosahuje úroveň, ktorá nezabezpečuje manažmentu dostatočný kapitál na riadenie banky a teda je v súčasnosti neudržateľná. Naše očakávania pre hodnotu tejto akcie v čase

expirácie vyzerajú asi takto: Banka sa dostane do konkurzu z dôvodu problémov vyplývajúcich z vlastníctva toxických aktív v portfóliu banky, alebo hodnota akcie výrazne vzrastie, vďaka svojej dlhodobej histórii a širokého portfólia klientov, od čoho sa odvíja relatívna sila spoločnosti v porovnaní s konkurenciou. Do úvahy prichádza aj možné poskytnutie záchranného balíčka americkou vládou.


Akcie spoločnosti Yahoo! Inc sú obchodovateľné na trhu trinásť rokov. V prvej emisii sa predávali za jeden a pol dolára. V prvých troch rokoch zažívali akcie prudký rast, ktorý sa v roku 2000 vplyvom prasknutia tzv. dotcom bubliny zastavil na hodnote približne sto dolárov. Nasledoval prudký prepád o 80%, s ktorým sa firma dokázala vyrovnáť v časovom horizonte troch rokov. Následný stabilný vývoj počas štyroch rokov pred krízou, môže prispieť k väčším problémom s vyrovnaním sa so súčasnou krízou. Cena akcií Yahoo! v poslednom roku klesala s posunutím troch mesiacov oproti trhu. Následne sa stabilizovala na úrovni približne trinásť dolárov za akciu s nízkou volatilitou a mierne rastúcou rezistenciou. Naše očakávania pre túto akciu sú: Hodnota akcií ostane stabilná do doby vypršania opcií, pričom môžeme očakávať, že hladinu podpory neprerazí.

Tvorba opčných stratégií

V tejto časti vytvoríme jednotlivé opčné stratégie, podľa definovaných očakávaní v kapitole 3, pričom naším cieľom bude maximalizovať zisk a súčasne minimalizovať riziko. Na spracovanie dát a tvorbu stratégií nám posluží rozšírený a jednoduchý softvér MS Excel.

Avon Products


Pri predpoklade rastu hodnoty akcie uvažujeme stratégiu long call, pričom potenciálny zisk môžeme zvýšiť pomocou short put stratégie. Na grafe 2 a) a b) vidíme diagramy zisku a straty opcií, ktoré sa k 27. marcu predávajú na trhu.



Graf 2: Stratégie na akcie AVP a) long call b) short put

Zdroj: vlastné spracovanie

Pri výbere vhodnej dvojice opcií nás v súvislosti so zmenou realizačnej ceny zaujímajú predovšetkým dva parametre ziskovosti stratégie. Po prvé ide o zmenu výšky opčnej prémie a po druhé o posun BEPu. Hodnotu BEPu, z anglického breakeven price, máme v snahe minimalizovať aj pri kúpe call opcie aj pri predaji put opcie. Naopak rozdiel hodnôt opčných prémii sa snažíme maximalizovať. V prípade put opcie vidíme, že pri zmene realizačnej ceny (K) z 20 USD na 25 USD sa zvýšila opčná prémie (OP) predstavujúca pozitívny cash flow stratégie v čase uzatvárania obchodu, ale BEP sa nezmenil. Je teda pre nás výhodnejšie predat' put opciu s realizačnou cenou 25 USD. V prípade call opcie vidíme podobný efekt pre realizačné ceny 25 USD a 23 USD. Ďalšie zníženie realizačnej ceny na 20 USD spôsobí posun BEPu väčší ako je zmena ceny opcie a je len na investorovi, do akej miery je ochotný akceptovať pomer marginálnej potenciálnej straty a posunu BEPu. My sme si zvolili výslednú stratégiu s realizačnými cenami pre call opciu 20 USD a pre put opciu 25 USD. Diagram zisku a straty stratégie je znázornený na grafe 3.




Graf 3: Opčná stratégia na akciu firmy Avon Products

Zdroj: vlastné spracovanie


Bank of America Corp

Ak predpokladáme volatilný vývoj ceny akcie, ale nepoznáme jej budúce smerovanie, je vhodné zabezpečiť sa voči strate a naopak zaujať pozíciu s neobmedzeným potenciálnym ziskom. Príkladom takejto stratégie je long straddle. Uvažujme však aj stratégiu long strangle, kedy sa rozpätie BEPov rozšíri pri súčasnom znížení maximálnej straty. Nakoľko naše očakávania o cene akcie v čase expirácie zhodnej so súčasnou hodnotou konvergujú k nule, uprednostníme maximálne zúženie BEPov na úkor rastu straty. Na akcie firmy Bank of America sme tak aplikovali stratégiu long straddle, ktorej rozpätie BEPov sa rovná dvojnásobku maximálnej straty. Jej výška závisí od cien opcií, preto našou úlohou bude minimalizovať funkciu súčtu opčných prémie (graf 4), čím zároveň minimalizujeme oblasť straty stratégie. Za tejto podmienky sme vybrali dvojicu call a put opcie s realizačnými cenami 6 USD. Diagram zisku a straty stratégie long straddle vidíme na grafe 5.



Graf 4: Cena opcií na akcie Bank of America Corp

Zdroj: vlastné spracovanie podľa údajov z <http://finance.yahoo.com/>




Graf 5: Opčná stratégia na akciu Bank of America Corp

Zdroj: vlastné spracovanie

Yahoo! Inc

Nízko volatilný vývoj kurzu akcie spoločnosti Yahoo v relatívne dlhom období evokuje pomalý a stabilný návrat ceny akcie na hodnoty z pred finančnej krízy. Z grafu 1 tiež vidíme, že vypuknutie krízy nemalo výraznejší vplyv na rast volatility ceny akcie a teda je vhodným doplnkom na diverzifikáciu nášho portfólia. Zároveň dodávame, že pri málo obchodovaných akciách, resp. opciách na ne, čoho príkladom je práve spoločnosť Yahoo, je vhodné obmedziť maximálnu stratu, pre prípad, že by nebolo možné stratégiu opustiť pre jej nízku likvidnosť. Berúc do úvahy všetky spomenuté informácie i očakávania o podkladovom aktíve, volíme ako vhodnú stratégiu long butterfly.



Graf 6: Opčná stratégia na akciu Yahoo! Inc

Zdroj: vlastné spracovanie

Stratégiu sme zložili s put opcií, ktorých likvidnosť v čase uzatvárania kontraktov je približne o 20% nižšia a pár dní pred expiráciou takmer 40% nižšia ako pri call opciách, z hľadiska obmedzenia straty sú však pre túto stratégiu vhodnejšie. Ďalej sme modifikovali symetrický tvar stratégie zakúpením put opcie pri realizačnej cene 17 USD namiesto 18 USD tak, aby sa minimalizovala oblasť straty pri súbežnej maximalizácii zisku. Takúto kombináciu dôsledkov teória efektívneho oceňovania opcií odmieta, pre reálny trh však nie je nezvyčajnou. Zároveň sa z pravej strany otvorila oblasť dosiahnutia zisku. Cítíme však zodpovednosť uviesť, že túto stratégiu považujeme za zložitejšiu podľa počtu uzatváraných kontraktov, čo nám zároveň zvyšuje náklady na jej obstaranie.

Kontrola portfólia

Faktory ako veľkosť emisie akcií, resp. opcií, likvidnosť opcií vyjadrenú počtom obchodov, volatilita a očakávania vývoja podkladového aktíva, ako aj pravdepodobnosť straty, sa berú do úvahy pri konštrukcii stratégií alebo sú obsiahnuté priamo v cene opcií. Preto pre vyčíslenie podielu jednotlivých stratégií v portfóliu sa obchodník koncentruje predovšetkým na svoj okamžitý a potenciálny stav na účte, čo je vyjadrením jeho solventnosti. Marginálna zmena vnútornej hodnoty opcie je plne závislá na marginálnej zmene hodnoty akcie. Čím drahšia je akcia, tým vyššia je aj opčná prémie, a teda na dosiahnutie rovnakého zisku, pre menej hodnotné akcie, je potrebné obstarat' väčšie množstvo opcií do portfólia. Priama závislosť platí aj v prípade volatility a výšky opčnej prémie, pričom zvýšená volatilita, akej v súčasnosti pri doznievaní finančnej krízy, podliehajú aj naše akcie v portfóliu, akcentuje význam časovej hodnoty opcie a teda opčná prémie je citlivejšia na zmenu maturity. Následne nevyužitie stratégie dnes môže znamenať nenávratne premrhanú šancu a naopak, uzavretú stratégiu môžeme po niekoľkých dňoch predat' s výrazným ziskom.

Zakomponovanie absolútnej hodnoty akcie a jej volatility do vyjadrenia podielu stratégie v portfóliu realizujeme nasledovným spôsobom. Vyjadríme si jednopercenčné zmeny cien akcií v USD, pre násobíme ich volatilitami, čím dostaneme jednotku očakávaných zmien na

našom účte pri nastatí udalosti, ktorá ovplyvní všetky akcie. Následne ich recipročné hodnoty sčítame a vyjadríme podiel týchto hodnôt na celkovom súčte. Takýmto postupom sme dospeli k nasledovnej skladbe portfólia: 26% stratégií na akcie Avon Products, 34% stratégií na akcie Bank of America Corp a 40% stratégií na akcie spoločnosti Yahoo! Inc. Teraz je už len na nás, aké množstvo finančných prostriedkov sme ochotní a pripravení reálne investovať, resp. zabezpečiť na krytie strát. Z celkového počtu, napríklad tisíc stratégií, po vysporiadaní opčných prémie z uzatvorených kontraktov, je počiatočná hodnota na účte 685 USD. Považujeme však za nutné zdôrazniť, že abstrahovanie od nákladov, plynúcich z uzatvárania kontraktov ovplyvňuje celkovú výnosnosť aj zloženie portfólia.

Vytvorením a uzatvorením opčných stratégií v portfóliu sa naša činnosť neskončila. Predovšetkým v prípadoch, ak máme stratégie s neobmedzenou stratou, ako v prípade stratégie na akcie Avon Products. Portfólio opcií budeme sledovať a prípadne revidovať až po deň expirácie.

Záver

Na záver môžeme zhodnotiť, že opčné stratégie nám ponúkli možnosť zarobiť na vyplnení našich očakávaní o cene akcie v budúcnosti a to bez reálneho investovania do týchto akcií. Počas celej maturity kurz akcie Avon Products neklesol pod hranicu BEPu, stanovenú na 19 USD, preto sme nemali dôvod na revidenciu stratégie. V prípade stratégie na akcie Bank of America bol BEP určený na hodnote 3 USD a 9 USD. Kurz akcie sa pohyboval v rozmedzí 7 USD až 14 USD, pričom v deň expirácie sa nachádzal v oblasti zisku. Potvrdil sa predpoklad volatilného vývoja, oceňujeme preto, že stratégia podáva informáciu o maximálnej potenciálnej strate. Pre stratégiu na akcie spoločnosti Yahoo sme stanovili BEP na 12 USD a maximálny zisk pri hodnote akcie 15 USD. Počas celej doby maturity sa cena akcie pohybovala v rozmedzí 12,5 USD a 15,5 USD, opäť sme teda nemali dôvod na predaj stratégie.

Počiatočný stav na účte investora ostal kladný, čo mu dáva priestor na úpravu alebo doplnenie stratégií. Keďže kurzy akcií sa vyvíjali v náš prospech, predaj ktorejkoľvek stratégie vo vhodnom čase pred expiráciou by priniesol zisk väčší ako je zmena časovej hodnoty opcie. Uzavreté pozície sme však počas maturity neopúšťali, a preto zisk plynúci zo stratégií sa rovná potenciálnemu zisku podľa jednotlivých diagramov.

Použitá literatúra

- [1] AMBROŽ, L. 2002. Oceňování opcí. Praha : C.H.Beck, 2002. 313 s. ISBN 80-7179-531-3
- [2] JÍLEK, J. 2002. Finanční a komoditní deriváty. Praha : GRADA Publishing, 2002. 624 s. ISBN 80-247-0342-4
- [3] KOHOUT, P. 2001. Investiční strategie pro třetí tisíciletí. Praha : GRADA Publishing, 2001. 230 s. ISBN 80-247-0074-3
- [4] MELICHERČÍK, I., OLŠAROVÁ, L., ÚRADNÍČEK, V. 2005. Kapitoly z finančnej matematiky. Bratislava : Epos, 2005. 242 s. ISBN 80-8057-651-3
- [5] NIEMIRA, M. P., ZUKOWSKY, G. F. 1994. Trading the fundamentals. USA : Irwin Professional Publishing, 1994. 260 s. ISBN 1-55738-450-9
- [6] PINDA, Ľ. 2001. Deriváty cenných papierov. Bratislava : Edícia Ekonómia, 2001. 118 s. ISBN 80-88715-98-9

Adresa autora:

Paula Bolcárová, Bc.
Ekonomická fakulta UMB
Tajovského 10
975 90 Banská Bystrica, paula.bolcarova@yahoo.com .

Analýza procesu opráv Analysis of the process of repairing

Zuzana Hajduová, Marek Andrejkovič

Abstract:

Historically, the quality was required especially for tangible products. But in this time the quality is important also for intangible services. Therefore, this article focused on the issue of processes in the repair of machinery and their improvement. This article aims to describe the processes that take place in the enterprise and then, based on the analysis we determine measures to improve these processes. For a description and analysis of processes in the enterprise will use procedural maps. The data analyzed in the article are from the company in Košice dealing with the repair machinery.

Key words: Process Maps. Repairing.

Kľúčové slová: Procesné mapy. Opravy.

Úvod

Kvalita je v poslednom období jedným z možností, ako môžu podniky získavať konkurenčnú výhodu. Z toho dôvodu dosahovanie najvyššej kvality je veľmi dôležité. Za týmto účelom manažéri využívajú rozličné štatistické a manažérske nástroje, ktoré majú podporiť ich rozhodovanie. Jedným z takýchto nástrojov sú aj procesné mapy. Tieto mapy využijeme na identifikáciu možností zlepšenia procesu opravy v podniku ABC servis. Tento názov je pritom fiktívny, aj keď sa jedná o reálnu spoločnosť, ktorá sa zaoberá servisom ručného elektrického náradia v Košiciach.

1. Kvalita a jej zlepšovanie

Gitlow [3] definuje kvalitu ako „posúdenie produktu alebo služby zákazníkom alebo používateľom.“ El-Haik a Yang [2] definujú kvalitu ako pomer vlastností, ktorými daný produkt alebo služba disponuje a našimi očakávaniami, ktoré na produkt alebo službu máme. Z toho dôvodu je potrebné poukázať na Juranovu definíciu kvality, ktorá hovorí, že kvalitou je vhodnosť pre použitie.

V začiatkoch dochádza pri zlepšovaní kvality k využívaniu základných nástrojov zlepšovania, ktoré sú histogram, vývojové diagramy, korelačný diagram, pareto diagram, Ishikawov diagram, regulačné diagramy a kontrolné hárky. História moderného zlepšovania kvality pritom začína práve Sherwarthovými regulačnými diagramami. [3] Následne sa mu podarilo vytvoriť cyklus PDCA, ktorého úspech bol až neskôr. Postupne sa v praxi zaužíval systém zlepšovania kvality TQM. Najnovším prístupom k zlepšovaniu kvality je metóda Six Sigma, ktorej kľúčovým aspektom úspechu je schopnosť implementovať do hodnotenia projektov aj ekonomické a iné charakteristiky okrem kvality. [2]

2. Procesné mapy a vývojové diagramy

V teórii sa stretávame s pojmami procesné mapy a vývojové diagramy. Podľa viacerých autorov sa pritom jedná priamo o synonymá. Gitlow definuje vývojový diagram ako „grafické (obrazové) zobrazenie toku rozličných operácií procesu používaný k zdokumentovaniu tohto procesu.“ [3] Konštrukcia vývojového diagramu môže poskytnúť dôležité informácie o procese, ktoré môžu pomôcť ostatným zainteresovaným osobám k pochopeniu, modifikovaniu alebo zlepšeniu procesu. Na konštrukciu vývojových diagramov využívame štandardné symboly zavedené Americkým národným inštitútom štandardizácie. [5]

Fitzgerald et al. pritom definuje dva typy používaných vývojových diagramov: [4]


- *Systémový vývojový diagram* – graficky vyjadruje postupnosť operácií vytvárajúcich proces.
- *Projektový vývojový diagram* – pritom znázorňuje plán oblasti, obyčajne vrátane toku práce a tovarov, rozloženia vybavenia (equipment), odkladacích priestorov a skladov a iných.

Gitlow uvádza nasledovné výhody využívania vývojových diagramov oproti využívaniu písaných alebo slovných opisov. Podľa nich majú funkcie nástroja komunikácie, nástroja plánovania, poskytujú systémový nadhľad, definujú úlohy, zobrazujú vnútorné vzťahy, podporujú logickú správnosť, uľahčujú odstraňovanie chýb a dokumentujú systém. [3]

3. Analýza procesu opráv

Celý proces opráv budeme analyzovať z pohľadu prístupu procesných máp, prostredníctvom ktorých sa budeme snažiť identifikovať subprocesy, ktoré sú duplicitné, respektíve môžu navzájom protikladne pôsobiť na kvalitu opravy.

Proces opravy stroja rozdeľujeme do piatich samostatných podprocesov. Každý z týchto podprocesov ešte následne delíme na samostatné podriadené procesy. Celý proces opravy stroja sa začína jeho prijatím do opravy. Tento proces prijatia je pritom veľmi dôležitý z toho dôvodu, že obsahuje okrem iného aj prvú diagnostiku problému. V tomto prípade zákazník dostáva doklad o odovzdaní stroja, ktorý preukazuje záväzok firmy, že tento stroj má v dočasnej držbe. Druhým podprocesom je diagnostika chyby stroja. V tomto procese priamo školený opravár spoločnosti prezrie uvedený prístroj. Opravár pritom vychádza zo záznamov z príjmu stroja, kde je uvedený aj výsledok predbežnej diagnostiky. V prípade, ak je táto predbežná diagnostika chybná, dochádza k predĺženiu tohto procesu diagnostiky chyby stroja, keďže opravár musí zisťovať možné zdroje chýb rôznymi variantmi. Na tento proces diagnostiky stroja nadväzuje proces zabezpečenia náhradných dielov. Po zabezpečení náhradných dielov potrebných k oprave stroja dôjde k vykonaniu samotnej opravy. Oprava stroja taktiež obsahuje aj vyskúšanie stroja, či reálne došlo k odstráneniu určenej poruchy. Celý proces opravy je ukončený odovzdaním stroja zákazníkovi, ktorý následne pri pozáručnom servise uhradza faktúru, respektíve pri záručnom servise iba potvrdí prevzatie stroja a úhrada nákladov spojených s opravou znáša predajca, respektíve dovozca uvedeného druhu strojov, keďže spoločnosť ABC servis je zmluvným servisom pre viacero značiek ručného náradia.



Obrázok 1 Procesná mapa opráv

Zdroj: vlastné spracovanie

Prvý podproces predstavuje príjem stroja do opravy. Tento podproces začína procesom spísania prijímacieho protokolu. Tento protokol obsahuje identifikačné údaje zákazníka. Tieto identifikačné údaje pritom slúžia iba na kontakt zákazníka po oprave stroja. Tieto údaje servis nijak ďalej podrobne nespracúva. Ďalšou položkou tohto protokolu sú informácie o stroji, ktorý má byť opravený. V ňom sa uvádzajú základné identifikačné znaky stroja ako jeho výrobné číslo, rok výroby, bežný opis stavu stroja (výbava a podobne). Druhým krokom je zaevidovanie stroja do elektronického systému, keďže všetky servisy majú centralizovaný evidenčný systém. Tento systém má plné využitie však iba v prípade strojov Bosch. Na základe tohto systému potom ľubovoľné servisné stredisko našej firmy môže pristupovať k celej histórii uvedeného stroja a jeho minulým opravám realizovaným v našej spoločnosti. Táto časť zahŕňa tiež aj označenie stroja vizuálnym označením (visačkou) s registračným číslom, pod ktorým je uvedený stroj evidovaný. Tieto visačky sú pritom vyrobené z kartónu, pričom nie sú farebne rozlišované. V ďalšom kroku prijímajúci zamestnanec poskytne zákazníkovi základné všeobecné informácie ohľadom hodinovej ceny opravy, garantovanej doby opravy stroja ako aj platobným podmienkam. Posledným krokom tohto podprocesu je vydanie potvrdenia o prijatí stroja. Toto potvrdenie pritom zákazník bude musieť predložiť pri preberaní stroja na preukázanie vlastníckeho práva k uvedenému stroju a záväzku servisu, že má v držbe stroj uvedeného klienta.

Tento podproces diagnostiky chyby stroja je rozdelený do troch samostatných procesných krokov. Prvým krokom je prehľad protokolu, do ktorého zamestnanec pri prijíme stroja zapísal predpokladanú príčinu chýb, ktoré by sa mali odstrániť. Ďalej opravár vykoná na základe protokolu overenie určenej príčiny chýb. V prípade potvrdenia predpokladaných zdrojov chýb prebieha tento proces v priebehu približne 10-20 min. V prípade, že predbežná diagnostika nebola vhodne spravená, táto časť prebieha omnoho dlhšie v závislosti od

zložitosti chyby. Na konci dôjde k porovnaniu oboch diagnostík a k vystaveniu konečnej diagnostickej správy, ktorá určí presný druh opravy, ktorý je potrebné na danom stroji uskutočniť.

Po vykonaní diagnostiky a určenia toho, čo je potrebné opraviť dochádza k určeniu potrebných náhradných súčiastok. Administratívny pracovník na základe zoznamu, ktorý vypracujú opravári dvakrát denne skontroluje obsah príručného skladu, ktorý je pridelený k servisu. V ňom hľadá uvedené súčiastky. V prípade, ak sú uvedené súčiastky na sklade, presunie ich do miestnosti, v ktorej sú uskladnené stroje pripravené na opravu. Stroj, ktorý prešiel diagnostikou je umiestnený v debničke z plastu, do ktorej vloží tento pracovník zvolené náhradné diely. V opačnom prípade, vystaví objednávku na zvolené náhradné diely. Zvolené náhradné diely sú objednávané buď z centrálneho skladu spoločnosti v Sučanoch, alebo zo skladu dovozcov uvedených súčiastok priamo od ich výrobcu. V prípade potreby sú na prepravu náhradných dielov využívané buď vlastné dopravné možnosti spoločnosti, alebo dovoz prostredníctvom prepravných organizácií ako je UPS, Ten-Expres alebo ďalšie. Po dodaní náhradného dielu, ten je vložený do debny, v ktorej je umiestnený aj opravovaný stroj.

Servisný technik na začiatku opravy opätovne preskúša stroj. Následne dochádza k rozobratiu stroja za účelom vybratia chybnej súčiastky. Po vybratí chybnej súčiastky, táto je ihneď nahradená novou súčiastkou. Servisný technik opätovne zhodnotí, či je táto výmena dostatočná. Túto výmenu zaznamená do priloženého protokolu o oprave. V prípade, ak dôjde k záveru, že je potrebné uskutočniť aj inú opravu, proces opravy stroja sa vracia do podprocesu č. 3, teda určenia či je zvolená súčiastka opäť k dispozícii. Následne dôjde k dokončeniu opravy. Po úspešnej výmene chybných súčiastok je uvedený stroj vyskúšaný, aby bolo overené, či oprava bola úspešná.

Posledným podprocesom, ktorý je zahrnutý v procese opravy stroja je podproces odovzdania stroja klientovi. Tento podproces je zložený z piatich samostatných procesných krokov. V prvom kroku administratívny zamestnanec servisu telefonicky oznámi zákazníkovi, že jeho stroj bol úspešne opravený a je možné si ho vyzdvihnúť. K tomu je potrebné, aby si klient doniesol aj potvrdenie o prevzatí stroja. Zamestnanec stroj priamo pred klientom vyskúša, aby deklaroval úspešnosť opravy. Následne je vystavená faktúra. Zákazník potvrdzuje svojim podpisom, že preberá stroj nepoškodený a opravený. Úhrada faktúry je v prípade, ak sa jedná o pozáručný servis, v hotovosti alebo elektronicky prostredníctvom POS terminálu. Táto skutočnosť je z dôvodu, že v minulosti mal podnik zlé skúsenosti s oddialenou splatnosťou na faktúru, kedy niektorí klienti uhrádzali faktúry s výrazným meškaním. Z toho dôvodu pri takýchto individuálnych klientoch používa takýto systém platby. Naproti tomu pre stálych klientov umožňuje oddialenie platby faktúry do doby 2 týždňov. V prípade záručných opráv, náklady na opravu hradí dodávateľ stroja, respektíve jeho výrobca. V takomto prípade je splatnosť týchto faktúr 2 týždne.

Záver

Analýzou sme zistili, že proces diagnostiky je veľmi neštandardná. Odporúčame odstrániť duplicitné vykonávanie diagnostiky. Je vhodné, ak diagnostika sa vykoná pri prijatí stroja do opravy. V takom prípade budú odstránené podprocesy P1.3, P2.1 a P2.3. Uvedené podprocesy budú pokryté prostredníctvom podprocesu P2.2. Na základe toho dôjde k úspore času z dôvodu zníženia počtu procesov. Taktiež dôjde k odstráneniu možných zdrojov nesprávnej diagnostiky, ak by nebola vykonávaná profesionálnym servisným pracovníkom. Z toho dôvodu je prínosné, ak dôjde k odstráneniu predbežnej diagnostiky.

Literatúra

- [1] DEMING, W.E. 1993. The new Economics for Industry. Massachusetts : MIT, Center for Advanced Engineering Study. ISBN 978-0911378951.
- [2] EL-HAIK, B. – YANG, K. 2003. Design for Six Sigma: A Roadmap For Product Development. New York : McGraw Hill ISBN 0071412085.
- [3] GITLOW, H. ET AL. 1989. Tools and Methods for the Improvement of Quality. Boston : Irwin. ISBN 0-256-05680-3.
- [4] FITZGERALD, J. M. – FITZGERALD, A. F.: *Fundamentals of Systems Analysis*. New York : John Wiley & Sons, 1973.
- [5] SILVER, G. A. – SILVER, J. B.: *Introduction to Systems Analysis*. Englewood Cliffs, N.J. : Prentice-Hall, 1976.

Adresa autorov:

Zuzana Hajduová, RNDr.
Ekonomická univerzita v Bratislave
Podnikovohospodárska fakulta v Košiciach
Tajovského 13
040 01 Košice
zuzana.hajduova@tuke.sk

Marek Andrejkovič, Ing.
Ekonomická univerzita v Bratislave
Podnikovohospodárska fakulta v Košiciach
Tajovského 13
040 01 Košice
andrejkovic.marek@gmail.com

Faktory pro detekci problematických mikro-regionů Factors for Detection of Problematic Micro Regions

Karel Hrach, Jana Gabčanová

Abstract: The initiative for this contribution was at the request of the Komunitní nadace (Community Foundation) in Ústí nad Labem. The demand was to examine problematic micro regions mathematically, the size of town-districts, where these non-profit organizations and state institutions focus their resources and activities. There exist many socio-economic indicators of deprivation (SESDI) abroad, their main disadvantage is that no relevant data is available at the level of the Czech town-districts. This contribution reports on the results of our own survey. Respondents had to compare districts of city Ústí nad Labem and to assess factors, influencing their evaluation. Subsequently, relevant data was obtained from the state administration and municipal governments, to assess the city districts. The results are compared also with the results of the so called Gabal's report.

Key words: Composite indicator, SESDI, Regional analysis, Gabal's report.

Klíčová slova: Souhrnný ukazatel, SESDI, Regionální analýza, Gabalova zpráva.

1. ÚVOD – STRUČNÝ PŘEHLED SESDI V ZAHRANIČÍ

K měření individuální i regionální deprivace se používají různé indexy socio-ekonomické úrovně. Běžně používanou zkratkou je SESDI (socio-economic status deprivation index). Rozdíly mezi jednotlivými typy SESDI spočívají v tom, které ukazatele jsou do něj zahrnuty. SESDI používaný k měření individuální deprivace obvykle zahrnuje informaci o nezaměstnanosti, výši příjmu, dosaženém vzdělání, životní úrovni, zdravotním stavu, apod.; SESDI používaný k měření regionální deprivace popisuje socio-ekonomickou strukturu obyvatelstva v dané oblasti, často jako podíl deprivovaných jedinců. Regionální SESDI se kromě jiného dá využít jako objektivní zdůvodnění alokace různých finančních podpor pro danou oblast. Připomeňme alespoň jeden z historicky nejznámějších způsobů měření nerovností v příjmech, tzv. GINI coefficient, který počítá relativní vzdálenost od hypotetického stavu ideálních rovností, přičemž hodnota 0 odpovídá dokonalé rovnosti a naopak hodnota 1 představuje stav plné nerovnosti.

SESDI jsou běžně používány např. ve Velké Británii. Přehled používaných indexů sestavili Morris and Carstairs v roce 1991. Jak již bylo výše konstatováno, každý typ SESDI vyžaduje svou specifickou množinu ukazatelů, ale také metodiku jejich sumarizace. Např. SESDI Townsend (TOWN) používá údaje o rodinách; Carstairs's SESDI (SCOTDEP) je založen na hustotě obyvatelstva, sociální struktuře, vlastnictví automobilů a zaměstnanosti; Department of the Environment's SESDI (DoE) shrnuje údaje o sociální, ekonomické a životní úrovni; Scottish Development Department's SESDI (SDD) je konstruován z údajů o životní úrovni, dlouhodobé nemocnosti, nezaměstnanosti a nedostatku sociálních potřeb [6]. Velmi podrobný (co do množství zahrnutých ukazatelů) je též Scottish Index of Multiple Deprivation (IMD), založený na 38 ukazatelích pro 7 socio-ekonomických aspektů [8].

2. POTŘEBA SESDI V ČR

Tento příspěvek shrnuje některé výsledky diplomové práce [1], která vznikla na základě požadavku Komunitní nadace v Ústí nad Labem. Hlavním úkolem bylo detekovat statistickými metodami problematické mikro-regiony (zde míněny oblasti o velikosti

městských částí) a tím objektivně zdůvodnit, proč právě těmto mikro-regionům budou následně neziskové organizace či jiné instituce alokovat své podpůrné prostředky.

Zásadním důvodem, proč k tomuto účelu nelze automaticky aplikovat v zahraničí používané SESDI, je nedostatek relevantních dat na úrovni městských částí v ČR. Dalším, neméně závažným argumentem proti automatické aplikaci zahraničních SESDI, je nutnost reflektovat rozdíly mezi situací v ČR a tam, kde původní SESDI vznikl. Typickým, tradičně zmiňovaným rozdílem, je stále výrazně menší třídní diferencovanost v ČR oproti zemím západní Evropy. Např. analýza Večerníka a Matějů [7] ukazuje stále poměrně malou provázanost mezi dosaženým vzděláním a výší příjmů v ČR, byť během období jejich průzkumu se tato závislost postupně zvyšovala.

Absenci vhodné metodiky pro určování SESDI na úrovni malých oblastí v ČR se snaží odstranit různé analýzy, projekty a podobně. Několik SESDI bylo sestrojeno na regionální úrovni (NUTS 3), ať již za účelem porovnání jednotlivých regionů mezi sebou, nebo analýzy sub-regionů uvnitř některého z nich. Tak např. české Ministerstvo pro místní rozvoj podpořilo projekt na vytvoření metodologie na identifikaci strukturálně postižených regionů [5]. Ministerstvo práce a sociálních věcí podpořilo projekt na výzkum problematických regionů, jehož výsledkem je tzv. Gabalova zpráva, resp. mapa [3] problematických romských lokalit. Porovnání regionů lze najít také např. v [4]. Kromě indexů sociální a ekonomické úrovně jsou v ČR konstruovány také indexy popisující úroveň zdravotní péče či ekologické aspekty, příkladem je Ministerstvem zdravotnictví podpořený projekt ostravského pracoviště [6].

3. ANKETA O PROBLEMATICE ROZDÍLŮ MEZI MIKRO-REGIONY V ÚSTÍ N.L.

V rámci našeho vlastního průzkumu bylo (převážně) mezi studenty kombinovaného studia naší fakulty distribuováno 200 dotazníků, týkajících se jednak toho, jaké ukazatele obecně jsou podle respondentů důležité při vnímání problematických lokalit, a dále toho, které konkrétní lokality města oni sami považují za problematické. Navráčeno bylo 180 dotazníků. Co se týče obecného hodnocení důležitosti jednotlivých ukazatelů, kompletně vyplněny byly 153 dotazníky. Z toho 34 dotazníků vyplnili muži, 119 ženy. Průměrný věk respondenta činil 32,9 roku. Co se týče konkrétního hodnocení jednotlivých částí města, kompletních bylo 88 dotazníků (ne všichni studenti kombinovaného studia znali město tak dobře, aby se k tomuto vyjádřili).

Tabulka 1: Význam jednotlivých faktorů pro vnímání kvality života, vlastní průzkum

(nižší hodnota odpovídá větší důležitosti)	průměr	medián
úroveň kriminality	3,58	3
občanská vybavenost	3,59	3
dopravní dostupnost	3,80	3
převažující typ zástavby	3,86	4
úroveň znečištění	4,07	4
sociální složení	4,48	5
množství zeleně	4,59	5

Respondenti měli nejprve za úkol seřadit sedm faktorů podle toho, jakou roli hrají při hodnocení kvality života (pořadí 1 pro nejdůležitější faktor, pořadí 7 pro nejméně důležitý faktor) obecně, tedy ne v nějaké konkrétní lokalitě. Jednalo se o faktory: občanská vybavenost, dopravní dostupnost, úroveň znečištění, množství zeleně, sociální složení, převažující typ zástavby a úroveň kriminality. Průměr a medián pro každý faktor jsou uvedeny v tabulce 1. Nejdůležitějšími faktory se ukázaly úroveň kriminality a občanská vybavenost. Tento výsledek je v souladu s tím, že míra kriminality bývá zahrnuta ve většině

regionálních SESDI. Na druhou stranu, sociální složení obyvatel a množství zeleně byly hodnoceny jako faktory nejméně důležité, respondenti je většinou zařadili na 4.-6. místo.

Tabulka 2: Hodnocení jednotlivých částí města Ústí n.L., vlastní průzkum

městská část (nižší hodnota odpovídá atraktivněji vnímané lokalitě)	průměr	medián	příslušný úřad městského obvodu
Klíše	1,57	1	ÚMO Ústí n.L. město
Brná	1,78	2	ÚMO Střekov
Božtěšice, Skorotice	1,81	2	ÚMO Ústí n.L. město
Skřivánek	1,97	2	ÚMO Ústí n.L. město
Severní Terasa / Stříbrníky	2,18	2	ÚMO Severní Terasa
Bukov	2,31	2	ÚMO Ústí n.L. město
Všebořice	2,48	2	ÚMO Ústí n.L. město
Dobětice	2,76	3	ÚMO Severní Terasa
Střekov	2,88	3	ÚMO Střekov
Vaňov	2,92	3	ÚMO Ústí n.L. město
Ústí n.L.- centrum	3,05	3	ÚMO Ústí n.L. město
Krásné Březno	4,24	4	ÚMO Neštětice
Mojžíř / Neštětice	4,48	5	ÚMO Neštětice
Předlice	4,82	5	ÚMO Ústí n.L. město

Dalším úkolem pro respondenty bylo označkovat 14 městských částí známkami 1 (ideální lokalita k bydlení) až 5 (nevhodná lokalita k bydlení), výsledky viz tabulka 2. Nejprestižnější lokalitou je Klíše, klidná obytná čtvrť poblíž centra a sídlo univerzitního kampusu. Následující lokality (s mediánem 2) jsou také klidné čtvrti, buď rodinných domů na okraji města (Brná, Božtěšice, Skorotice), nebo čtvrti, v nichž je kombinovaná zástavba rodinných a panelových domů (Skřivánek, Bukov, Všebořice). Výjimkou jsou sídliště Severní Terasa a Stříbrníky, kde panelová zástavba převažuje, ale je to kompenzováno jinými nadstandardními aspekty (parkový charakter, pěší zóny, školy, hřiště, nákupní centra). Všechny tyto lokality (včetně okrajových) přitom mají dobrou dopravní dostupnost a prakticky se v nich nevyskytují průmyslové objekty. Třetí skupina (s mediánem 3) je velmi různorodá. Patří sem typické panelové sídliště (Dobětice), již ne tak vybavené jako ta dvě výše uvedená, ovšem alespoň v jejich bezprostředním sousedství; dále velká pravobřežní čtvrť (Střekov) – kombinace staré zástavby, menších panelových sídlišť i rodinných domů, ale také sídlo jedné z největších továren ve městě; čtvrť rodinných domů na levém břehu Labe (Vaňov), jejímuž lepšímu hodnocení zřejmě brání množství malých a většinou opuštěných průmyslových objektů podél hlavního silničního tahu na Lovosice a Prahu; a konečně střed města, považovaný obvykle za hlučný a prašný. V poslední skupině (s mediánem 4 nebo 5) se umístila velká panelová sídliště (Krásné Březno, Mojžíř, Neštětice) a čtvrť staré zástavby (Předlice). Společná jim je horší dopravní dostupnost (větší vzdálenost od centra) a množství továren. Zároveň se v nich nacházejí tři ze čtyř ústeckých problematických lokalit podle Gabalovy zprávy.

Záměrem autorů bylo následně získat o jednotlivých městských částech (z tabulky 2) data, zohledňující důležité faktory (podle tabulky 1) a jejich souhrnnou analýzou potvrdit, zda se také tímto „objektivnějším“ způsobem seřadí městské části do pořadí, určeného v tabulce 2 „jen“ na základě subjektivního hodnocení respondentů. Bohužel oficiální data na úrovni městských částí nejsou sledována. Autoři se museli spokojit s daty na úrovni čtyř úřadů městských obvodů (ÚMO), a to Ústí nad Labem město, Neštětice, Severní Terasa a Střekov (viz též poslední sloupec tabulky 2). Je zřejmé, že takto definované mikro-regiony zahrnují i

značně odlišně vnímané lokality – např. pod ÚMO Ústí n.L. město patří jak nejlépe, tak nejhůře vnímané čtvrti (Klíše a Předlice). Pokud výsledky průzkumu z tabulky 2 převedeme na hodnocení jednotlivých ÚMO (viz tabulka 3), zjistíme, že respondenty byl nejlépe hodnocen obvod Střekov, ale výsledné celkové ohodnocení obvodů Severní Terasa a Ústí n.L. město dopadlo číselně velmi podobně. S výrazným odstupem od nich je hodnocen pouze vůbec celkově nejhůř vnímaný obvod Neštětice.

Tabulka 3: Hodnocení částí města Ústí n.L. shrnuté podle příslušnosti k úřadu městského obvodu ÚMO, vlastní průzkum

ÚMO	Střekov	Severní Terasa	Ústí n.L.město	Neštětice
průměr	2,32	2,47	2,62	4,36

4. KONSTRUKCE SOUHRNNÉHO UKAZATELE PRO MIKRO-REGIONY V ÚSTÍ N.L.

Jak vyplývá z dosud uvedeného, autoři při konstrukci souhrnného ukazatele použili data na úrovni čtyř ústeckých městských obvodů, a to data od Magistrátu města, Policejního ředitelství a Českého statistického úřadu v Ústí n.L. (Nepodařilo se získat data od Úřadu práce a od Dopravního podniku.) Ukazatele byly voleny tak, aby reflektovaly zjištěnou důležitost faktorů (viz tabulka 1). Z nabídnutých ukazatelů za jednotlivé obvody byly použity, případně přepočteny tyto: počet vloupání, počet deliktů spáchaných mladistvými, počet krádeží, počet obyvatel, počet obyvatel na jedno dětské hřiště, průměrný věk, podíl obyvatel se základním vzděláním, podíl ekonomicky aktivního obyvatelstva, podíl panelových domů z celkového počtu domů a počet dětí na jedno místo ve škole. Ukazatele viz tabulka 4.

Tabulka 4: Vybrané ukazatele za jednotlivé městské obvody (ÚMO), vlastní šetření

ÚMO	počet vloupání	počet deliktů mladistvých	počet krádeží	počet obyvatel na 1 dět.hřiště	počet obyvatel	průměrný věk	obyv. se zákl. vzděl.(%)	ekonomicky aktivních (%)	panel. domů (%)	počet dětí na 1 místo ve škole	SOUHRNNÝ UKAZATEL
Severní Terasa	632	0	921	536,32	21 989	39	55	55	97	1,05	15
Střekov	304	10	693	794,94	13 514	40	60	53	39	0,94	16
Ústí n.L. město	1 204	8	2 134	780,84	35 138	40	56	51	39	0,78	19
Neštětice	654	3	1 415	708,43	24 795	34	67	53	87	0,99	20
CELKEM	2 794	21	5 163	691,57	95 436	38	59	53	64	0,91	X

Z mnoha možných technik agregace ukazatelů (viz např. [2]) byla použita jedna z nejjednodušších: obvody byly seřazeny podle každého ukazatele (1 značí nejlepší pozici daného obvodu; ukazatelé, u nichž nešlo jednoznačně specifikovat, co je „nejlepší pozice“, však musely být z agregace vyloučeny). Součet získaných pořadí je uveden v posledním sloupci tabulky 4. Víceméně v souladu s výsledky „subjektivního“ hodnocení (viz tabulka 3) se nejlépe umístily obvody Severní Terasa a Střekov (souhrnný ukazatel s hodnotou 15, resp. 16). Naopak nejhůře hodnoceným je opět obvod Neštětice (souhrnný ukazatel s hodnotou 20). Jediným výraznějším rozdílem oproti „subjektivnímu“ pořadí obvodů je tak hodnocení obvodu Ústí n.L. město, jehož hodnota se přesunula blíže k hodnocení Neštětice.

5. SHRUTÍ

Příspěvek potvrzuje, že „subjektivní“ vnímání kvality života v jednotlivých lokalitách je skutečně možno „objektivně“ potvrdit pomocí souhrnných ukazatelů. Oběma přístupy byl na příkladu města Ústí nad Labem detekován jako nejhorší městský obvod Neštětice. Zajímavá je shoda tohoto zjištění i v kontextu Gabalovy zprávy, podle níž se právě v tomto obvodu nacházejí dvě ze čtyř problematických ústeckých lokalit. Na druhou stranu však nutno připomenout, že v Gabalově mapě nejsou činěny rozdíly ve velikosti problematické lokality, takže někdy se jedná o celou čtvrť a někdy o jedinou ulici – v tom případě ještě nemusí být celý příslušný obvod nutně vnímán jako problematický. Toto je pravděpodobně jedním (byť ne jediným) z důvodů, proč obvody Střekov a Ústí n.L. město dopadly rozdílně, přestože podle Gabalovy zprávy se v každém z těchto obvodů nachází jedna problematická lokalita: v obvodu Střekov, který byl hodnocen spíše pozitivně, jde víceméně pouze o ojedinělé problematické domy, zatímco v obvodu Ústí n.L. město, který byl celkově hodnocen spíše negativně, o celou problematickou čtvrť (Předlice).

Současné ale také příspěvek ukazuje, jak obtížné je provést skutečně objektivní a komplexní zhodnocení. Výsledek vždy závisí jak na volbě velikosti hodnocených mikroregionů, tak na volbě použitých ukazatelů. Obojí je přitom podmíněno „technickými“ možnostmi, tedy tím, jaká data je vůbec reálné získat. Při jakékoli interpretaci je pak samozřejmě nutná obezřetnost v tom smyslu, že souhrnný ukazatel je především pouze shrnujícím údajem vytvořeným z vybraných ukazatelů.

LITERATURA

- [1] GABČANOVÁ, J. 2009. Detekce problematických mikroregionů. Diplomová práce. Ústí n.L.: FSE UJEP, 2009. 67 s.
- [2] HRACH, K. – MIHOLA, J. 2006. Metodické přístupy ke konstrukci souhrnných ukazatelů. In: Statistika, č.5, 2006, s.398-418. ISSN 0322-788x.
- [3] <http://www.esfcr.cz/mapa> (“Gabalova zpráva”)
- [4] MARTINČÍK, D. 2008. Ekonomicko-sociální úroveň krajů – komplexní srovnávací analýza. In: E+M Ekonomie a Management, č.1, 2008, s.14-25. ISSN 1212-3609.
- [5] PRSKAVCOVÁ, M. – ŘEHOŘOVÁ, P. 2008. Metodika šetření hospodářské výkonnosti obcí České republiky. In: E+M Ekonomie a Management, č.4, 2008, s. 77-83. ISSN 1212-3609.
- [6] ŠLACHTOVÁ, H., at all.: Socioekonomické deprivací indexy – teoretická východiska a možnosti aplikace ve veřejném zdraví. www.zuova.cz/projekty/sesindexy/sesindexy006clanek.pdf.
- [7] VEČERNÍK, J. – MATĚJŮ, P. et al. 1998. Zpráva o vývoji české společnosti 1989 – 1998. Praha: Academia, 1998. 364 s. ISBN 80-200-0703-2.
- [8] www.scotland.gov.uk, www.communities.gov.uk

ADRESA AUTORŮ:

Karel Hrach, RNDr., Ph.D.
Jana Gabčanová, Mgr. Ing.
FSE UJEP, Moskevská 54
40096 Ústí n.L., ČR
karel.hrach@ujep.cz

Prognóza spotreby mias v Slovenskej republike Forecast consumption of the meat in the Slovak republic

Jozef Chajdiak

Abstract: Paper includes comparison past forecast consumption of the meat with new estimate consumption of the meat in the Slovak republic.

Príspevok obsahuje porovnanie predchádzajúcej prognózy mias so skutočnosťou a nový odhad spotreby mias v Slovenskej republike.

Key words: meat, forecast, consupction, comparison.

Kľúčové slová: mäso, prognóza spotreba, porovnanie.

1. Úvod

Na FERNSTAT-e v roku 2006 bola prezentovaná prognóza spotreby mias v Slovenskej republike (tabuľka 1).

Tabuľka 2: Spotreba mias (skutočnosť a prognóza 2006)

ROK	HOV	HOVF1	BRAV	BRAVF1	HYD	HYDF1
1990	22,1		44,5		15,2	
1991	16,6		42,1		16,8	
1992	14,6		39,9		13,3	
1993	15,6		36,2		11,8	
1994	14,3		36,4		11,9	
1995	12,2		36,8		13,4	
1996	12		37,3		14,4	
1997	12,2		37,2		15,5	
1998	11,8		36,9		16	
1999	10,4		35,9		17,4	
2000	9,3		33,1		17,1	
2001	7		31,8		18,5	
2002	6,8		31,3		20,1	
2003	6,9		32,3		20,7	
2004	6,4		31,9		20,4	
2005	6,2	6,22	32,9	31,06	21,1	20,69
2006	5,3	6,03	32,2	29,95	22,3	20,95
2007	5,4	5,84	32,2	28,66	19,9	21,08
2008	5	5,65	32,3	27,38	19,3	21,42
2009		5,46		26,18		21,66
2010		5,27		24,88		21,91


Prameň: Slovstat a [3]

Tabuľka osahuje údaje o spotrebe hovädzieho mäsa (HOV, BRAV a HYD) v kg na jedného obyvateľa SR a realizovanú prognózu v roku 2006 (HOVF1, BRAVF1 a HYDF1). Vykázaná skutočnosť za rok 2005 bola 6,1; 31,1 a 20,3 kg mäsa na obyvateľa oproti súčasnej verzii 6,2; 32,9 a 21,1. Súčasná verzia Slovstatu poskytla aj údaje za roky 1990, 1991 a 1992.


Z pohľadu na kvalitu mäsa autori vyslovili predpoklad, že spotreba hovädzieho mäsa porastie, bravčového poklesne a hydínového bude mať stagnujúci charakter. Pohľad na skutočnosť hovädzieho mäsa ukazuje pokles, bravčové mäso stagnuje a hydínové mäso klesá.

2. Grafická prezentácia skutočnosti a prognóz


Na grafoch 1, 2 a 3 je prezentácia vývoja spotreby príslušného mäsa. Plnou čiarou je zobrazená dosiahnutá skutočnosť, bodkovanou čiarou prognóza podľa [3] a čiarkovanou čiarou súčasný nový odhad budúcej spotreby. V pravom hornom rohu je zobrazený použitý model pre odhad ($x=1$ v roku 1990).



Graf 1 Výsledky za hovädzie mäso



Graf 2 Výsledky za bravčové mäso



Graf 3 Výsledky za hydinové mäso

3. Záver

Podľa novej verzie odhadov môžeme v najbližších rokoch očakávať pokles spotreby hovädzieho mäsa, stagnáciu v spotrebe bravčového mäsa a rast spotreby hydinového mäsa.

Literatúra

- [1] CHAJDIK, J. 2003. Štatistika jednoducho. Bratislava: Statis 2003. 194 s. ISBN 80-85659-28-X.
- [2] CHAJDIK, J. 2003. Štatistické úlohy a ich riešenie v Exceli. Bratislava: Statis 2005. 262 s. ISBN 80-85659-39-5.
- [3] KRÍŽOVÁ, S. – CHAJDIK, J.: Vývoj spotreby vybraných mias v Slovenskej republike z pohľadu sociálno-ekonomických aspektov. In. Forum Statisticum Slovaccum, 4/2006. Bratislava: SSDŠ 2006. Str. 96-105

Adresa autorov:

Jozef Chajdiak, Doc., Ing., CSc.

Ústav manažmentu STU

810 00 Bratislava

chajdiak@statis.biz

Aplikácia štatistických metód pri hodnotení poistných podvodov

The application of statistical methods in evaluating claims of fraud

Jaroslav Ivor, Beáta Stehlíková, Anna Tirpáková

Abstract: In this contribution we describe and analyse insurance fraud by using statistical methods in Slovakia.

Key words: insurance fraud, spatial autocorrelation

Kľúčové slová: poistný podvod, priestorová autokorelácia

1. Úvod

Hospodárska kriminalita je v ekonomicky vyspelých štátoch závažný spoločensko-politický problém. Spôsobuje spoločnosti vysoké materiálne a morálne škody. Poist'ovacie podvody však patria medzi trestné činy, ktoré nie sú odmietané spoločnosťou do takej miery, ako ostatné trestné činy. Je to tým, že na strane poškodeného sú poisťovne a ľudia samotných sa táto trestná činnosť nedotýka tak osobne, konštatuje Košťálová (2007). V súlade s odporúčaním Európskeho poisťovacieho výboru (European Insurance Committee - CEA) iniciovala Slovenská asociácia poisťovní pri novelizácii Trestného zákona doplnenie o špeciálnu skutkovú podstatu poisťovacieho podvodu. Skutková podstata trestného činu podvodu v starom Trestnom zákone zahŕňala len konanie, keď už vznikla majetková ujma. Skutkové podstaty trestného činu poisťovacieho podvodu vymedzuje zákon č. 300/2005 Zb. v platnom znení – Trestný zákon Slovenskej republiky v štvrtej hlave Trestné činy proti majetku.

2. Materiál a metódy

Na posúdenie priestorovej autokorelácie sa použil Moranov koeficient

$$I = \frac{n}{2A} \frac{\sum_{i=1}^n \sum_{j=1; j \neq i}^n \delta_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

kde n je počet oblastí, A je počet hraníc, $\delta_{ij} = 1$, ak oblasti i a j susedia, $\delta_{ij} = 0$ inak ($i, j = 1, 2, \dots, n$), x_i ($i = 1, 2, \dots, n$) je hodnota skúmaného javu v oblasti i , $\bar{x}$ je priemerná hodnota hodnôt x_i . Ak sa hodnota I blíži k hodnote $+1$, skúmaný jav je silne pozitívne autokorelovaný. Ak hodnota I sa blíži k hodnote -1 , skúmaný jav je silne negatívne autokorelovaný. Ak hodnota I sa blíži k hodnote $1/(n-1)$, skúmaný jav je v priestore rozložený náhodne. Pre testovanie štatistickej významnosti pomocou metód Monte Carlo sa použil softvér GeoDa.

Údaje poskytl Prezídium Policajného zboru Slovenskej republiky.


3. Výsledky a diskusia

Trestný čin poistný podvod má špecifickú právnu úpravu, takže záleží aj na tom, ako posúdia trestný čin orgány činné v trestnom konaní. T.j. či ho z hľadiska klasifikácie posúdia ako poistný podvod alebo bude klasifikovaný ako podvod vo všeobecnom zmysle. Základný rozdiel spočíva v tom, že podmienkou dokonania trestného činu podvodu je obohatenie páchateľa alebo inej osoby. Naproti tomu u poisťovacieho podvodu nie je potrebný k

dokonaniu trestného činu vznik škody, a to ako majetkovej, tak prípadne nemajetkovej povahy. Preto ani úmysel páchatel'a nemusí k takejto škode spočívajúcej hlavne vo vylákaní poistného plnenia smerovať, aj keď spravidla tomu tak je.

Trestný čin poistný podvod je úmyselným trestným činom spočívajúcim v úmyselnom vyvolaní poistnej udalosti, ktoré vyvolá páchatel' tak, že spôsobí konkrétnu skutočnosť, z ktorej vzniká povinnosť poistiteľa poskytnúť poistné plnenie (napríklad zámerne havaruje s poisteným vozidlom), alebo úmyselnom udržiavaní stavu vyvolaného poistnou udalosťou, ktoré spôsobí páchatel' tak, že predlžuje alebo rozvíja poistnú udalosť, ktorá nastala bez jeho pričinenia alebo jeho nedbalostným jednaním. Udržiavanie takéhoto stavu páchatel' vykonáva s úmyslom zvýšiť vzniknutú škodu. Týmto úmyselným konaním je trestný čin poistný podvod dokonaný, aj keď ku škode na cudzom majetku nemuselo dôjsť.


Na obrázku 1 sú znázornené počty zistených a objasnených poistných podvodov v rokoch 2000-2008.



Zdroj údajov: PPZ SR

Obrázok 2: Počet zistených a objasnených poistných podvodov v roku 2008


Z hľadiska priestorového rozloženia poistných podvodov je vhodnejšie ako s absolútnymi počtami pracovať s ukazovateľom počet poistných podvodov na 100 000 obyvateľov.



Zdroj údajov: PPZ SR

Obrázok 2: Počet poistných podvodov na 100 000 obyvateľov v roku 2008

Priemerná výška škody na jeden poistný podvod s nenulovou škodou bola 95,5 tisíc korún so smerodajnou odchýlkou 79,0 Sk. Medián dosiahol hodnotu 78,3 tisíc Sk. Priemerná výška škody na jeden poistný podvod 26,6 tisíc korún.



Zdroj údajov: PPZ SR

Obrázok 3: Veľkosť škody na jeden poistný podvod v roku 2008

Najvyšší počet poistných podvodov na 100 000 obyvateľov vykazuje Bratislavský (4,3) a Nitriansky kraj (4,0). Variabilita v rámci okresov SR je mimoriadne veľká. Extrémnu hodnotu vykazuje okres Bratislava III – až 20,9 podvodov na 100 000 obyvateľov avšak s pomerne nízkou (siedmou najnižšou hodnotou) spôsobenou škodou na jeden poistný podvod (33,5 tisíc Sk). V okresoch Bratislava IV, Pezinok, Senec, Hlohovec, Skalica, B8novce nad Bebravou, Ilava, Myjava, Partizánske, Púchov, Zlaté Moravce, Bytča, Čadca, Dolný Kubí, Kysucké Nové Mesto, Námestovo, Ružomberok, Turčianske Teplice, Banská Štiavnica, Detva, Krupina, Poltár, Revúca, Veľký Krtíš, Zvolen, Humenné, Kežmarok, Levoča, Medzilaborce, Poprad, Sabinov, Snina, Stará Ľubovňa, Stropkov, Svidník, Vranov nad Topľou, Košice II, Košice III, Košice IV, Košice – okolie, Gelnica, Michalovce, Rožňava, Sobrance, Trebišov nebol v roku 2008 zistený žiadny poistný podvod. V okresoch Bratislava I, Bratislava V, Trnava, Senica, Považská Bystrica, Prievidza, Nové zámky, Topoľčany, Liptovský Mikuláš, Brezno, Žarnovica, Prešov bol zistený aspoň jeden poistný podvod, ale spôsobená škoda bola vyčíslená vo výške 0 Sk. V 22 okresoch SR bola priemerná spôsobená škoda na jeden poistný podvod vo výške od 6,7 tisíc (okres Komárno) do 265,0 tisíc Sk (okres Trenčín). V deviatich okresoch - Martin (100,0), BA II (123,6), Rimavská Sobota (124,0), Nitra (125,5), Banská Bystrica (155,2), Žiar nad Hronom (157,0), Dunajská Streda (245,0), Piešťany (249,5), Trenčín (265,0) bola priemerná škoda na jeden poistný podvod vyššia ako sto tisíc korún.

Hodnota Moranovho koeficienta pre počet poistných podvodov na 100 000 obyvateľov je 0,1424. Príslušná P hodnota je 0,0168. Znamená to, že na hladine významnosti 0,05 existuje priestorová autokorelácia. Z obrázku 2 je vidno, že ju spôsobujú predovšetkým okresy na východe Slovenska, kde je počet poistných podvodov na 100 000 obyvateľov vo viacerých navzájom susediacich okresoch nízky.

Hodnota Moranovho koeficienta pre veľkosť škody na jeden poistný podvod je 0,00158. Príslušná P hodnota je 0,2988. Znamená to, že neexistuje priestorová autokorelácia, teda hodnota veľkosti škody na jeden poistný podvod na úrovni okresov je náhodná.

4. Záver

Najdôležitejšie príčiny vzniku poistných podvodov spočívajú v zmene spôsobu života obyvateľstva. Ľudia vo svojom konzumnom spôsobe života hľadajú ľahké zisky a snažia sa vyťažiť maximum z každej situácie. Okrem týchto príčin existuje aj určité mylné vedomie, že takáto činnosť nebude odhalená a hlavne páchatelia necítia vinu za svoje konanie. U poistných podvodov došlo k profesionalizácii a špeciálnemu zameraniu sa na určitú oblasť. Podsvetie sa sústreďuje najmä na štátne peniaze a eurofondy (Domeová, 2007). Poistný podvod v posledných rokoch narastá do medzinárodných dimenzií, hlavne z dôvodu voľného pohybu osôb a tovaru a bezbariérového poistovania rizík v rámci Európskej únie.

5. Literatúra

- [1]ARLINGHAUS, S.L.: Spatial Statistics. Boca Raton: CRC Press, 1996
- [2]DOMEOVÁ, A.: Zločin priťahuje ženy. 22.2.2007 Dostupné na internete: http://hnonline.sk/c4-10142110-20494500-k00000_d
- [3]CHALKA, R., HOLCR, K., HOLOMEK, J.: Prognóza vývoja kriminality v Slovenskej republike. Bratislava, A PZ 2000
- [4]CLIF, A.D. - ORD, J.K.: Spatial Autocorrelation. London: Pion, 1993
- [5] KOŠŤALOVÁ, A.: Poisťovacie podvody. Pošta, Telekomunikácie a Elektronický obchod, 2007 ISSN 1336-8281 Dostupné na internete: <http://ks.utc.sk/casopis/pdf/II2007/kostalova.pdf>
- [6] MALÁ, D. – MALÝ, V.: Prenikanie IKT do vzdelávacieho procesuIntroduction of ICT into education In: 10 rokov technológie vzdelávania. Zborník referátov z medzinárodnej vedeckej konferencie. Bešeňová, 7.-8. novembra 2002. - Nitra: Slovdidac, 2002. - ISBN 80-967746-6-2. - (2002) s. 177-180

Adresa autorov:

Jaroslav Ivor, Prof. JUDr., CSc.

Fakulta práva BVŠP

Tomášiková 20

851 05 Bratislava

dekan.fp@uninova.sk

Beáta Stehlíková, prof. RNDr., CSc.

Fakulta ekonómie a podnikania BVŠP

Tematínska 10

851 05 Bratislava

stehlikovab@gmail.com

Anna Tirpáková, Doc. RNDr., CSc.

Katedra matematiky UKF

Tr. A. Hlinku 1

949 01 Nitra

atirpakova@ukf.sk

MATEMATICKÝ SOFTVÉR AKO POMÔCKA PRI RIEŠENÍ NIEKTORÝCH TYPOV ZÁVISLOSTÍ

MATHEMATICAL SOFTWARE AS A HELP SOLVING SOME TYPES OF DEPENDENCES

Gabriela Ižaríková

Abstract: Statistical methods allow us to measure dependent between qualitative and quantitative variables. It is very important to find out the dependent between the variables and how they dependent. Contingention coefficients measure dependence of two variables.

Key words: dependent of variables, CHI TEST, contingency coefficients

Kľúčové slová: závislosť medzi kvalitatívnymi znakmi, chí-kvadrát test, kontingenčné koeficienty

1. Úvod

Posledné obdobie sa vyznačuje aj masívnym poklesom matematických vedomostí a zručností u študentov nastupujúcich do vyšších stupňov vzdelávania. Je nutné spôsob výučby podporiť novými, inými vyučovacími metódami, napr. rozšírením používania matematických softvérov. Je veľmi dôležité, aby študenti mali dostatočné matematické vedomosti, ktoré im umožnia stať sa užívateľmi softvérov, majúcimi schopnosť rozumieť a kontrolovať výsledky. Študenti by sa mali naučiť ako používať matematický softvér, riešiť úlohy, ktoré sa dajú jednoducho a efektívne riešiť pomocou počítačov, ale nesmú sa naučiť iba príkazy dostupné v softvérových balíkoch. Tieto balíky sa musia učiť používať súdne a kriticky, musia uplatňovať matematické vedomosti pomocou, ktorých zistia, kedy počítačové riešenie nemusí byť spoľahlivé. V predošlých rokoch sme zaznamenali rýchle zmeny v informačných technológiách, rast počítačového výkonu a komplexnosť prístupného matematického softvéru (Maple, Mathematica, MATLAB, MuPad, Derive, EXCEL Octave a pod.). Absolventi, ktorí ukončia štúdium, využijú možno iba časť znalostí z matematiky, ktoré získali na vysokej škole, avšak logické myslenie, ktoré nadobudnú práve učením sa matematiky, využijú znamenito.

Jednou z charakteristických črt súčasného obdobia je čoraz širšie uplatňovanie matematických metód v mnohých spoločenských a technických vedeckých disciplínach. Dôsledkom tohto trendu je skúmanie ekonomických javov a procesov z pozície pravdepodobnosti a matematickej štatistiky. Pomocou týchto metód sa odhaľujú štatistické zákonitosti vývoja javov a procesov, vzájomne vzťahy, ktoré charakterizujú ich kvantitatívnu a kvalitatívnu stránku.

Štatistika je vedný odbor, ktorý skúma stav a vývoj číselne premenlivých premenných a hromadne sa vyskytujúcich javov, ktoré sa tykajú dostatočne veľkého počtu jednotiek, tvoriacich sa na základe toho, že majú niektoré spoločné vlastnosti.

2. Využitie Excelu pri zisťovaní závislosti - χ^2 - test o nezávislosti kvalitatívnych znakov

Pri každom štatistickom výskume sa v súbore určitých jednotiek sledujú údaje o väčšom počte premenných, číselných a slovných. Z teoretických a praktických dôvodov je často dôležité zistiť či sú niektoré z týchto premenných závislé a ako sú závislé.

Ak sledujeme len dve premenné tak prvú informáciu o ich závislosti dostaneme už usporiadaním zistených údajov do dvojrozmernej tabuľky. V hlavičke tabuľky sú hodnoty jednej premennej, v legende hodnoty druhej premennej a v jednotlivých kolónkach tabuľky sú početnosti kombinácii hodnôt oboch premenných. Sú to združené početnosti a obyčajne ich značíme n_{ij} . V poslednom riadku sú stĺpcové súčty združených početností $n_{.j}$, a v poslednom stĺpci tabuľky sú ich riadkové súčty $n_{i.}$.

Dvojrozmerná tabuľka so slovnými premennými sa nazýva kontingenčná tabuľka, tabuľka numerických premenných sa nazýva korelačná tabuľka.

Závislosť medzi kvalitatívnymi znakmi môžeme skúmať pomocou χ^2 - testu o nezávislosti kvalitatívnych znakov (chí-kvadrát test), ktorý je založený na porovnaní empirických a teoretických početností pre každú kategóriu sledovaných znakov. Nulová hypotéza H_0 predpokladá nezávislosť kvalitatívnych znakov, alternatívna hypotéza H_1 predpokladá závislosť kvalitatívnych znakov. Testovacie kritérium pre overenie nulovej hypotézy H_0 o nezávislosti medzi kvalitatívnymi znakmi vypočítame podľa nasledovného vzťahu:

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^s \frac{(Q_{ij} - E_{ij})^2}{E_{ij}}, \quad \text{kde } E_{ij} = \frac{n_{i.} \cdot n_{.j}}{n} - \text{teoretické početnosti,}$$

Q_{ij} - empirické početnosti,
 r - počet riadkov, s - počet stĺpcov

Hodnotu testovacieho kritéria χ^2 porovnáme s tabuľkovou hodnotou χ_α^2 , pre $(r-1) \cdot (s-1)$ stupňov voľnosti, kde α je hladina významnosti, na ktorej sa test realizuje. Ak $\chi^2 > \chi_\alpha^2$, tak nulovú hypotézu o nezávislosti zamietneme.

Pri zisťovaní závislosti použijeme funkcie Excelu: CHIINV, CHITEST.

Úloha: Zistiť, či výsledok zo skúšky z matematiky závisí od typu absolvovanej strednej školy, tzn. otestovať, či existuje štatistická závislosť medzi kvalitatívnymi štatistickými znakmi, výsledkom zo skúšky a typom ukončenej SŠ na hladine významnosti 5%. Závery by mohla príslušná škola využiť pri prijímacom konaní, napr. stanovením koeficientov pre jednotlivé typy stredných škôl.

Tabuľka 3: Počet respondentov podľa ukončeného stredoškolského vzdelania a úspešnosti na skúške

Druh SŠ	Úspešnosť skúšky						Súčty početnosti $n_{i.}$
	A	B	C	D	E	F	
Gymn.	3	5	8	4	3	0	23
SPŠ	2	4	24	27	45	5	107
Iné	1	1	14	15	38	8	77
Súčty početnosti $n_{.j}$	6	10	46	46	86	13	207

Úlohou je overiť, či existuje závislosť medzi sledovanými dvoma kvalitatívnymi znakmi, ak áno, tak potom je potrebné zistiť aká je intenzita tejto závislosti.

Hypotézy môžeme formulovať takto:

H_0 : medzi typom ukončeného stredoškolského vzdelania a úspešnosťou na skúške nie je štatistická závislosť.

H_1 : medzi typom ukončeného stredoškolského vzdelania a úspešnosťou na skúške existuje štatistická závislosť.

Najprv vypočítame teoretické početnosti $E_{ij} = \frac{n_{i.} \cdot n_{.j}}{n}$, t.j. príslušná riadková suma* príslušná stĺpcová suma / celková suma.

Tabuľka 2: Teoretické početnosti

Druh SŠ	Úspešnosť skúšky						Súčty početnosti $n_{i.}$
	A	B	C	D	E	F	
Gymn.	0,67	1,11	5,11	5,11	9,56	1,44	23
SPŠ	3,10	5,17	23,78	23,78	44,45	6,72	107
Iné	2,23	3,72	17,11	17,11	31,99	4,84	77
Súčty početnosti $n_{.j}$	6	10	46	46	86	13	207

Po dosadení do vzorca je hodnota testovacieho kritéria:

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^s \frac{(Q_{ij} - E_{ij})^2}{E_{ij}} = 37,83$$

Hodnotu testovacieho kritéria môžeme jednoduchšie a rýchlejšie vypočítať pomocou Excelu:

CHITEST (B3:G5;B11:G13)

Aktuální - B3:G5 – označíme empirické početnosti

Očekávané – B11:G13 – označíme teoretické početnosti

Argumenty funkce

CHITEST

Aktuální B3:G5 = {3;5;8;4;3;0|2;4;24

Očekávané B11:G13 = {0,666666666666666

= 4,06366E-05

Vrátí test nezávislosti: hodnota ze statistického rozdělení chí-kvadrát a příslušné stupně volnosti.

Očekávané je oblast dat obsahující podíl součinu součtů řádků a sloupců a celkového součtu.

Výsledek = 4,06366E-05

[Nápověda k této funkci](#) OK Storno

Argumenty funkce

CHIIINV

Prst: 0.9 = 4,06366E-05

Volnost: 10 = 10

= 37,82937428

Vrátí hodnotu funkce inverzní k distribuční funkci jednostranné pravděpodobnosti rozdělení chí-kvadrát.

Volnost je počet stupňů volnosti. Argument je číslo mezi 1 a 10¹⁰ kromě čísla 10¹⁰.

Výsledek = 37,82937428

[Nápověda k této funkci](#)

OK Storno

Výsledek $\chi^2 = 37,83$ porovnáme s 95 percentilom χ^2 -rozdelenia s $(r-1) \cdot (s-1) = (3-1) \cdot (6-1) = 10$ stupňami voľnosti - $\chi^2_{0,95}(10) = 18,3$.

Argumenty funkce

CHIIINV

Prst: 0,05 = 0,05

Volnost: 2*5 = 10

= 18,30703805

Vrátí hodnotu funkce inverzní k distribuční funkci jednostranné pravděpodobnosti rozdělení chí-kvadrát.

Volnost je počet stupňů volnosti. Argument je číslo mezi 1 a 10¹⁰ kromě čísla 10¹⁰.

Výsledek = 18,30703805

[Nápověda k této funkci](#)

OK Storno

Hodnota testovacieho kritéria je väčšia ako kritická hodnota na hladine významnosti 5%, to znamená, že zamietneme nulovú hypotézu o nezávislosti medzi typom ukončeného stredoškolského vzdelania a úspešnosťou na skúške, t.j., medzi typom ukončeného stredoškolského vzdelania a úspešnosťou na skúške existuje štatistická závislosť.

3. Meranie tesnosti závislosti

Kontingenčné koeficienty merajú závislosť dvoch slovných premenných. Najpoužívanjšie koeficienty sú Cramerov kontingenčný koeficient C_{cr} a Pearsonov kontingenčný koeficient C_p .

$$C_{cr} = \sqrt{\frac{\chi^2}{n \cdot h}}, \quad C_{cr} \in \langle 0, 1 \rangle, \quad (\text{závislosť je tým silnejšia, čím je hodnota koeficientu bližšia ku 1})$$

$$C_p = \sqrt{\frac{\chi^2}{\chi^2 + n}}, \quad C_p \in \langle 0, 1 \rangle, \quad (\text{jeho horná hranica závisí od počtu riadkov a stĺpcov, napr. pre}$$

$$r = 3, s \geq 3 \text{ je } 0.816)$$

kde h je $\min.(r-1, s-1)$, n je celková suma - rozsah súboru.

V predchádzajúcej časti sme výpočtom zistili, že medzi typom ukončeného stredoškolského vzdelania a úspešnosťou na skúške existuje štatistická závislosť, čiže ďalšou úlohou je analýza intenzity tejto závislosti. O akú silnú závislosť ide, zistíme pomocou niektorého z kontingenčných koeficientov. Po dosadení do vzorcov dostaneme:

$$C_{cr} = \sqrt{\frac{\chi^2}{n \cdot h}} = \sqrt{\frac{37,83}{207,2}} = 0,60 \qquad C_p = \sqrt{\frac{\chi^2}{\chi^2 + n}} = \sqrt{\frac{37,83}{37,83 + 207}} = 0,39$$

Hodnoty týchto koeficientov naznačujú, že medzi analyzovanými štatistickými znakmi je silná závislosť, t.j. známka zo skúšky z matematiky závisí aj od typu ukončenej strednej školy,

4. Záver

Pri analýze závislosti premenných sa používajú rôzne štatistické postupy a metódy. Niektoré z nich slúžia len na posúdenie, či sú určité premenné závislé alebo nie. Iné využívame na konkrétnu špecifikáciu závislosti, ktorá je predpokladom ich praktického využitia. Pri analýze závislosti premenných je výhodne použiť matematický softvér, kvôli zjednodušeniu a najmä na zrýchlenie výpočtov napr. spomínaný Excel, ale aj Maple, Mathematica, MATLAB, Octavu a pod..

5. Literatúra

- [1] HINDLS R., KAŇOKOVÁ J.: Metódy statisticke analýzy pro ekonómy. Management Press, Praha 1997
- [2] Amird d ACZEL: Complete Business Statistics. Irwin, Boston 1989
- [3] PENJAK V., DOBOŠ J., HERETOVÁ Z., PAVLISKOVÁ A., RAISOVÁ: Matematika IV
- [4] PACÁKOVÁ V.: Štatistika pre ekonómov. Bratislava 2003
- [5] CHAJDIK J.: Štatistické riadenie kvality. Statis Bratislava 1998

Adresa autora:

Mgr. Gabriela Ižaríková, PhD.
Letná 9
040 01 Košice
gabriela.izarikova@tuke.sk

Optimalizace využití lesnického těžebního zařízení s ohledem na ochranu půdy

Optimization of logging machinery use considering soil preservation restriction

Jitka Janová

Abstract: The stochastic programming problem of tree harvesting planning in a medium size logging company in Czech Republic is treated. The mathematical programming model of the optimal utilisation of machine harvesters and manual operators for cutting, and horses, tractors, lift and specialized trucks for transporting, when minimum total costs are required, is formulated based on the real cost characteristics of the machine and human resources. The environmental restriction concerning the soil preservation- currently not fully taken into account by logging companies - is considered, the respective constraint is developed and incorporated into the model. The solution of the optimization model considering the environmental restriction is compared to the solution of the model without soil preservation constraint and the applicability of the results in the decision making of small and medium logging companies is discussed.

Key words: optimization in forestry, stochastic programming, linear programming, logging machinery, soil preservation

1. Introduction

The decision support systems commonly used in industry and economy managerial practice for optimizing the processes are based on algorithmization of the typical decision problems. In Czech forestry business, there is a lack of developed decision support systems, which could be easily used in daily practice. This stems from the fact, that the application of optimization methods is less successful in forestry decision making than in industry or economy due to inherent complexity of the forestry decision problems. There is worldwide ongoing research on optimization models applicable in forestry decision making (see [1]). The logging machinery use is studied e.g. in [4], [7], [9], [10], the impact of ecological issues on the logging optimization is considered in [5], [8], [11], [12]. The linear programming models are intensively used in forestry applications. Apart from the machinery use planning the linear programming approach can be typically found in wood transportation problems (see e.g. [3]) or the forest stand rotation (see e.g. [2], [13]).

The results of world wide research in the area of forestry optimization are not globally applicable and moreover the costs of possibly arising software tools are indispensable. Especially small and medium forestry companies in Czech Republic can not afford such additional costs, although the results of optimization could positively influence not only the business itself but also the impact of forestry business on the environment. Hence there is a need for user friendly optimization models for forestry decision making in the area of Czech Republic, which could be easily solved in commonly available software, and whose results would be both, realistic and easily applicable in the daily decision making.

The aim of this paper is to develop the optimization model for the machinery use planning in Czech logging firm in such a way, that the results can be obtained using MS EXCEL. The goal is to identify the integer number of particular machines which should be outsourced for the next period, when the total cost minimization is required. In Section 2 the problem is formulated and the stochastic programming model is designed covering the typical

restrictions on available machinery and total volume of trees to be cut and transported. The randomness of particular parameters is discussed and the stochastic programming model is transformed into the deterministic linear programming model, which is solved for concrete data of medium Czech logging company. In Section 3 the soil preservation constraint is designed and incorporated into the linear programming model and the problem is solved using MS EXCEL. In the Conclusion the results together with its applicability in real life practice are discussed.

2. Stochastic programming model without restriction of soil preservation

Czech logging companies are forced to minimize their costs due to the system of placing the harvest orders. In Czech republic the majority of forests are the property of the state and the state company, which manages the state forests, announces tenders for harvesting in forests. The only criterion for choosing the winner is the lowest price of performing the logging. Hence, the company, which is able to supply the lowest price per particular logging, wins the tender and gets the job. Often the logging company does not own the necessary machinery, and the machinery is outsourced from local small firms and individual workers. Although planning the machinery use in advance with respect to minimizing the total costs of outsourcing is crucial not only for maximizing the profit of the firm but even for getting the job, no decision support systems are generally used in Czech logging companies. Typical restrictions, which have to be taken into account when planning the machinery use for particular logging order are limits on available machinery and volume of wood to be harvested.

The aim of the optimization is to provide a support for typical decision making in logging company, which is planning the numbers of cutting and transporting machines needed for particular harvest in particular area. The company must minimize the cost of outsourced machinery in order to be able to supply the lowest price per the harvest work.

There are two types of logging machinery to be planned: harvest and transport machinery. The first type is used to cut trees at harvest area and the second type serves for trees transportation to place close to forest roads, which are accessible by logging trucks.

As for the harvest machinery we can employ chain saws and harvesters and as for the transport machinery horses, forest tractors, rope lifts or specialized small forest trucks can be used (for the numbers of machinery available see table 1).

Table 4: Numbers of machines available for the logging

Chain saw	30
Harvester	10
Horse	15
Tractor	10
Rope lift	10
Forest truck	10

Assume that the detailed description of the harvest area is known concerning the total amount of tree volumes in different age classes, which are to be harvested. The concrete volumes of particular tree types for our problem can be seen in table 2, where p denotes the tree type characterized by tree age and L_p denotes the volume of wood of type p which is to be harvested in the area.

The decision variables x_{ip} in the optimization problem have the meaning of numbers of the machines i cutting or transporting the trees of type p . Denote a_i the volume of wood cut or transported per one day by machine i and c_{ip} the cost per one cubic meter of trees of type p cut or transported by machine i . The number of machines i which can be outsourced, i.e. which

are available in the given area is denoted by X_i and by d we denote number of days during which the logging job must be done.

Table 2: Volume of wood in particular tree classes to be harvested

p	$L_p [m^3]$
3	1375
4	675
5	14200
6	375
7	2300
8	1875
9	800
10	575
11	1050
12	450
13	200

The mathematical programming model for the problem takes the form

$$z^* = \min \left\{ \sum_{i=1}^2 \sum_{p=3}^{13} x_{ip} a_i c_{ip} + \sum_{i=3}^6 \sum_{p=3}^{13} x_{ip} a_i \left(c_{ip} + \sum_{r=1}^3 \rho_{pr} Q_{ri} \right) \right\},$$

$$\sum_{p=3}^{13} x_{ip} \leq X_i, \quad y_i = \sum_{p=3}^{13} x_{ip}$$

$$(1)$$

$$d \sum_{i=1}^2 a_i x_{ip} \geq L_p, \quad d \sum_{i=3}^6 a_i x_{ip} \geq L_p,$$

$$x_{ip} \geq 0, \quad y_i \geq 0,$$

where y_i must be integer. We minimize the total costs of outsourcing: the first term in the objective function are the costs per harvest machinery and the second term per the transport machinery. The additional term $\rho_{pr} Q_{ri}$ represents additional costs of transportation of tree type p by the machine i due to the distance of the area r from the road accessible by trucks. The constraints reflect the limited sources of machines and the requirement on harvesting certain amount of particular tree types. The total number of machines must be integer and therefore additional decision variables y enters the problem.

The model (1) is the stochastic programming problem due to the randomness of parameters a_i . Adopting the approach in which the stochastic parameters are replaced by its means, the problem is transformed into linear programming problem easily solvable in the solver application of MS EXCEL (for values of parameters ρ_{pr} , Q_{ri} , a_i and c_{ip} in our problem and other details see [6]). By solving the LP model for the case, when the harvest takes 40 days, we get the total number of machines to be outsourced (see table 3) and we get also the optimal distribution of machines to work with particular tree types (see figure 1 and 2).

Table 3: The optimal solution: total number of machines to be outsourced

Chain saw	29
Harvester	5
Horse	13
Tractor	1
Rope lift	0
Forest truck	10

For example chain saw should be employed on cutting young trees, while the harvesters on cutting the areas grown by the older ones. For transportation of the trees to the road we should not use the expensive rope lift and the only one employed forest tractor should operate at the harvest area where the trees are 60 to 70 years old. On harvest areas, where younger

trees grow, especially horses should be used, while for transportation of the older trees the small forest trucks are optimal.




Figure 3: Optimal distribution of cutting machinery




Figure 2: Optimal distribution of transporting machinery

3. Linear programming model with restriction of soil preservation

The model (1) solved the real decision problem commonly arising in Czech logging companies when typically no special care to ecological impact of the work in the forest is considered. The following model solves the decision problem when the operating of heavy machines in the forest is limited in order to reduce soil damage. Hence, we will add a restriction on soil preservation. The model with the restriction of soil preservation takes form

$$\begin{aligned}
 z^* = \min & \left\{ \sum_{i=1}^2 \sum_{j=1}^4 \sum_{p=3}^8 c_{ip} a_i x_{ijp} + \right. \\
 & \left. + \sum_{i=3}^6 \sum_{j=1}^4 \sum_{p=3}^8 (c_{ip} + \sum_{r=1}^3 \rho_{pr} Q_{ri}) a_i x_{ijp} \right\} \\
 & \sum_{j=1}^4 \sum_{p=3}^8 x_{ijp} \leq X_i, \\
 & d \cdot \sum_{i=1}^2 x_{ijp} a_i \geq L_{jp}, \quad d \cdot \sum_{i=3}^6 x_{ijp} a_i \geq L_{jp}, \\
 & \sum_{j=1}^4 \sum_{p=3}^8 x_{ijp} s_j \frac{L_{jp}}{k_i} \leq D_i \\
 & y_i \equiv \sum_{j=1}^4 \sum_{p=3}^8 x_{ijp} : \text{integer}, \quad x_{ijp} \geq 0.
 \end{aligned} \tag{2}$$

The harvest area is split into several sub-areas, which are denoted by index j . These sub-areas differ one from another by the average distance which must be covered by transport machines operating in the sub-area in order to reach the place accessible by trucks.

The decision variables x_{ijp} in the model (2) have the meaning of number of machines (type i) cutting/transporting the trees (type p) from the area j . Similarly the index j arise in all the parameters of the model with appropriate meaning.

The model (2) is quite similar to the (1) up to the new constraint (2.1), which restricts the total distance D_i covered by particular transport machine i in the harvest area during the whole harvest period (in our problem we have restricted only the tractors and forest trucks by

the total distance of 15000 m). In (2.1) we denote s_j the average distance of the sub-area j from the place accessible by trucks and k_i the capacity of the machine i .

In our problem we have four sub-areas A, B, C, D, i.e. $j=1,2,3,4$ and to reduce number of variables we decrease the types of trees from 11 to 6, which is possible thanks to similar cost coefficients characteristics of operating last six types of trees.

By solving this LP problem in MS EXCEL we get the solution which differs from the previous one in eliminating the use of tractors for transportation (see table 4). In figures 3 and 4 we can see how the cutting and transporting machinery should be employed to minimize the outsourcing costs. The machines are distributed with respect not only to the age of the harvested stand but also to the sub-area, where the machines operate.

Table 4: The optimal solution: total number of machines to be outsourced

Chain saw	29
Harvester	5
Horse	15
Tractor	0
Rope lift	0
Forest truck	10




Figure 3: Optimal distribution of cutting machinery




Figure 4: Optimal distribution of transporting machinery

4. Conclusion

Both models are using linear programming and are solvable via EXCEL. The results obtained from the models represent the total numbers of machines to be outsourced and the allocation of machines, which is represented by a fraction of work time during which the machine should cut or transport the particular tree type in order to minimize total outsourcing costs. The first model covers the restrictions on total volume of different types of wood to be harvested and on available machinery, while the second model considers also the soil preservation restriction. The models are applicable only in case, that the terrain and other harvest area conditions allow to substitute cutting machines one with another (and similarly the transporting machines), the harvest area must be known precisely and only one specie in the harvest area is considered, which is correct for Czech forests, where spruce is almost the only one harvested tree specie.

Compared to real decision made by logging firm the optimal total numbers of machines obtained from the first model without ecological constraint correspond to the real decision, but the optimization model provides also an additional result: the correct allocation of machines to particular trees, which could decrease total outsourcing costs.

There are many others aspects, that are to be taken into account during harvesting planning and the suggested models could be used as a help for the complex decision making for harvesting planning.

5. References

- [1] DIAZ-BALTEIRO, L., ROMERO, C., 2008: *Making forestry decisions with multiple criteria: A review and an assessment*, Forest Ecology and Management, 255, 8-9:3222-3241. ISSN 0378-1127.
- [2] EID, T. HOEN, H., F., OKSETER, P., 2002: *Timber production possibilities of the Norwegian forest area and measures for a sustainable forestry*, Forest Policy and Economics, 4, 3:187-200. ISSN 1389-9341.
- [3] FLISBERG, P., LIDEN, B., RONNQVIST, M., 2009: *A hybrid method based on linear programming and tabu search for routing of logging trucks*, Computers & Operations Research, 36, 4:1122-1144. ISSN 0305-0548.
- [4] GOMEZ, T., HERNANDEZ, M., LEON, M.A., CABALLERO, R., 2006: *A forest planning problem solved via a linear fractional goal programming model*, Forest Ecology and Management, 227, 1-2:79-88. ISSN 0378-1127.
- [5] GUTIERREZ, V. H., ZAPATA, M., SIERRA, C., LAGUADO, W., SANTACRUZ, A., 2006: *Maximizing the profitability of forestry projects under the Clean Development Mechanism using a forest management optimization model*, Forest Ecology and Management, 226, 1-3: 341-350. ISSN 0378-1127.
- [6] JANOVÁ, J., LINDNEROVÁ, M., *Optimalizační model využití těžebního zařízení v lesnické praxi*. to appear in Acta Agriculturae et Silviculturae Mendeliana Brunensis.
- [7] MARTIN-FERNANDEZ, S., GARCIA-ABRIL, A., 2005: *Optimisation of spatial allocation of forestry activities within a forest stand*, Computers and Electronics in Agriculture, 49, 1: 159-174. ISSN 0168-1699.
- [8] OLSCHESKI, R., BENITEZ, P. C., 2009 *Optimizing joint production of timber and carbon sequestration of afforestation projects*, Journal of Forest Economics, In Press, ISSN 1104-6899, DOI: 10.1016/j.jfe.2009.03.002.
- [9] SPINELLI, R., WARD, S., M., OWENDE, P. M., 2009: *A harvest and transport cost model for Eucalyptus spp. fast-growing short rotation plantations*, Biomass and Bioenergy, In Press, ISSN 0961-9534, DOI: 10.1016/j.biombioe.2009.05.010.
- [10] TIERNAN, D., NIEUWENHUIS, M., 2005: *Financial optimisation of forest-level harvest scheduling in Ireland - A case study*, Journal of Forest Economics, 11, 1: 21-43. ISSN 1104-6899.
- [11] TORRES ROJO, J. M., SANCHEZ OROIS, S., 2005: *A decision support system for optimizing the conversion of rotation forest stands to continuous cover forest stands*, Forest Ecology and Management, 207, 1-2: 109-120. ISSN 0378-1127.
- [12] VENEMA, H. D., CALAMAI, P. H., FIEGUTH, P., 2005: *Forest structure optimization using evolutionary programming and landscape ecology metrics*, European Journal of Operational Research, 164, 2: 423-439. ISSN 0377-2217.
- [13] ZHOU, W., GONG, P., 2004: *Economic effects of environmental concerns in forest management: an analysis of the cost of achieving environmental goals*, Journal of Forest Economics, 10, 2:97-113. ISSN 1104-6899.

Corresponding adress:

Janová Jitka, Mgr. Ph.D,
PEF, MZLU v Brně
Zemědělská 1
61300 Brno
janova@mendelu.cz

On a stochastic programming approach to production planning in agriculture

Využití stochastického programování k plánování produkce v zemědělství

Jitka Janová

Abstract: The real world problem of the sowing design under uncertainty in the small Czech agriculture co-operative is presented; the stochastic programming model is designed and several optimal solutions are found using different uncertainty treatment. The choice of the goal function and its impact on optimal solution is presented and the specificity of the agriculture data collection is discussed. Comparison of the optimization results to those achieved by real manager decision in agricultural co-operative is performed and the benefits of the stochastic programming application are shown. The optimization routine presented can easily be repeated by practitioners in the agricultural management (where, especially in small and medium farms, application of operations research methods is infrequent) with no additional needs on SW equipment or data collection.

Key words: production planning, stochastic programming, optimization in agriculture

Klíčová slova: plánování produkce, stochastické programování, optimalizace v zemědělství

1. Introduction

Planning problems in forestry and agriculture cover all aspects from the production planning: planting, irrigation, harvesting, transportation, building roads to the wood and food supply chain and lead to optimization problems with specific goals and restrictions coming from the environmental issues impact. Probably due to the complexity of the optimization problems in agriculture and forestry the application of the operations research models is less successful here than in other industries. There has, however, been steady development in this branch over several last years as can be seen e.g. in [1], [2], [3].

Currently a number of distinct optimization problems in the area of planting and harvesting is solved; e.g. recently in [4] the optimization problem of wine grape harvesting scheduling is studied, in [5] optimal forest replanting of the recently harvested area is analyzed, and in [6] a forest harvest model with specific constraints is presented. The water scarcity is often concerned in optimization problems of Mediterranean countries (see e.g. [7], [8], [9]), whereas in northern Europe countries mainly specific optimization problems of forest industry are extensively solved, see e.g. [10], [11]).

As for the production planning in agriculture, many large- and medium- companies have implemented computerized production planning systems in the past decades. In most cases, these are based on maintaining up-to-date procurement and production information on each item and on recording and distributing planning decisions. Significantly superior results can, however, be obtained when changing these tools for optimization planning systems. The first step towards the improvement of production planning is usually utilization of linear programming methods and considerable savings achieved by the companies with linear programming optimization planning system are reported (see e.g. [12]).

In the linear programming approach the planning model is constrained by severe restrictions, which often oblige to revise the optimization results, in order to obtain feasible plans. This means that the linear programming models used need to be improved to allow for full optimization of short term productivity. Currently, the general mathematical programming models applicable in agriculture and forestry are under research (see e.g. [6] for integer programming, [4] for robust optimization approach to mathematical programming under uncertainty, [7] for a stochastic goal programming and [12], [13] for integer programming applications).

During production planning in agriculture the optimization models are designed using data which are subject to uncertainty and measurement errors – e.g. volume of the future crop or future purchase prices of the crop-plants. There are different approaches for dealing with uncertainty, first of them being simply to ignore it and use average values instead of respective stochastic variables. This may lead to both very realistic or, on the other hand, completely distort results, depending on the characteristics of the particular problem. Second, concerning mathematical programming models, the stochastic approach implements the uncertainty into both the objective function and the restrictions and represents in general more realistic modeling of the problem than previous simple deterministic programming. Such a treatment of uncertainty with mathematical programming is addressed by the whole field of stochastic programming (see e.g. [14], [15], and for recent applications see e.g. [16], [17], [18]).

In this paper we introduce a real world problem of the sowing design under uncertainty in the Czech agriculture co-operative farming on 1284 ha of arable land in the southern region of Czech Republic. The major part of the management decisions in small and medium agriculture companies is based on the passed years experience only, which, when concerning the sowing design decision making, ordinarily produces satisfactory gains. There is, hence, no need felt towards radical change in the decision processes. Moreover, the methods of operations research are considered to be too complicated to be applied by ordinal farmer and outsourcing an expert or purchasing a specialised SW to find a solution of the optimization problem seems for a small farm or agricultural co-operative too costly, although the benefits of the operations research methods application can be essential. The aim of this paper is to:

- present and model a case study on optimization of sowing design under uncertainty in the future crop volume using real Czech agriculture co-operative data.
- make accessible the optimization model of the sowing design based on the application of the stochastic programming method to the smaller and medium farmers by means of simplification the method into the easily applicable form, which can be solved by frequent SW tools.

The stochastic programming model is designed and several optimal solutions are found using different uncertainty treatments. The choice of the goal function and its impact on optimal solution is presented and the specificity of agriculture data collection is discussed. Comparison of the optimal solutions and estimated profit to real sowing design and final gains realized in the agricultural co-operative together with the easy SW application of the described method may serve as a motivation for middle and small agriculture companies and co-operatives, whose utilization of optimization methods is generally infrequent. In Section 2 a brief summary of the chosen stochastic programming approaches is given, in Section 3 the respective mathematical programming models are designed and optimal solution for each approach is derived and conclusions together with discussion are presented in the last Section 4.

2. The stochastic programming model

Consider the following problem:

$$z^* = \max c^T x \quad (1)$$

$$Ax \leq b, x \geq 0, \quad (2)$$

where c is the random variables vector, A is the matrix of known parameters, b is the vector of known restrictions of the resources. We are, hence, searching for an optimal solution of the linear stochastic programming problem with the random variables included in the objective function.

The first problem is to recognize the distribution functions of the random variables. As we shall see in the next section, the random variables will correspond to the future crop volume of the crop-plants – we can, hence, assume (according to [19]) that all the stochastic variables have normal distribution. Denote μ and Σ the vector of respective means and covariance matrix of the random variables c , respectively.

There are many ways of designing the deterministic equivalent of the stochastic programming model. Let us consider four different approaches based on modification of the objective function (for details see e.g. [15]):

1. Mean value approach is the intuitive one. All of the random variables are replaced by their respective means. We, hence, get the linear programming model

$$z^{*,1} = \max \mu^T x, Ax \leq b, x \geq 0. \quad (3)$$

Omitting most of the random variables' information, this model is suitable for problems where unfeasibility of derived optimal solution could easily be recognized.

2. Minimum variance approach changes the objective of the optimization. Instead of maximization of the objective function (1) the minimization of its variance together with minimum feasible value z_0 of the objective function (1) mean value is required. The optimization model is modified into the form of quadratic programming model:

$$\begin{aligned} z^{*,2} &= \min x^T \Sigma x \\ Ax &\leq b, \mu^T x \geq z_0, x \geq 0. \end{aligned} \quad (4)$$

3. Probability approach minimizes the probability, that the objective function (1) value will decrease under certain level z_0 . We, hence, postulate $\min P\{c^T x \leq z_0\}$. Considering $c \sim N(\mu, \Sigma)$ (N being the multivariate normal distribution), the model (1) is replaced by the non-linear programming problem:

$$\begin{aligned} z^{*,3} &= \min \left(\frac{z_0 - \mu^T x}{\sqrt{x^T \Sigma x}} \right) \\ Ax &\leq b, x \geq 0. \end{aligned} \quad (5)$$

4. Utility approach requires maximization of the mean value of the utility function $u(t) = 1 - e^{-at}$,

with $t \equiv c^T x$ being the random variable with normal distribution $N(\mu^T x, x^T \Sigma x)$ and $a > 0$ being the risk aversion coefficient. The objective function of the utility approach, hence, takes the form: $z = \max \langle 1 - e^{-ac^T x} \rangle$, which after the mean value computation leads to

$$z = \max \left\langle 1 - e^{\left(\frac{a}{2} x^T \Sigma x - \mu^T x\right)} \right\rangle \quad (6)$$

and the problem of maximizing the objective function (6) on the feasible area can be replaced by an equivalent model:

$$\begin{aligned} z^{*,4} &= \min \left(\frac{a}{2} x^T \Sigma x - \mu^T x \right) \\ Ax &\leq b, x \geq 0. \end{aligned} \quad (7)$$

3. Planning the sowing design of the agricultural co-operative

The sowing design problem is described by the manager of the agriculture co-operative as follows: The area of 1284 ha of the arable land is to be split into five parts, each of them planted with one of the crop-plants: winter wheat, winter barley, spring barley, maize, winter rape. Apart the arable land area available there is a restriction on available capital in amount $19 \cdot 10^6$ CZK per year. For the detail cost data in base year 2007 prices see Table 1: each of the crop-plants is characterized by number of particular sub-costs per 1 ha of arable land planted

with respective crop-plant, but crucial for the optimization model is only the total costs parameter N_i , because there is only one capital source for every outcome in the given agricultural co-operative. In the last column of the table, there is a purchase price P_i offered to the farmers for each ton of respective crop-plant. Both N_i and P_i are considered to be constant.

Table 1: Crop-plant characteristics: costs per hectare and selling prices per ton

i	Costs and prices (CZK)	Costs per 1 ha						Total costs N_i per 1 t	Price P_i
		Material	Services	Staff	Insurance	Other			
1	winter wheat	6 711						13	3 000
2	winter barley	3 826	480	59	96	878	723	8	2 400
3	spring barley	3 427	248	24	54		938 990	8	3 200
4	maize	7 165	251	69	18		030 296	17	2 400
5	winter rape	7 952	158	35	52		258 568	14	7 000
			901	36	02	844	836		

The enterprise goal of the agriculture co-operative is simply a maximization of the profit, which together with the above mentioned cost restrictions, can be formulated as a stochastic programming problem:

$$\begin{aligned}
 z^* &= \max \sum_{i=1}^5 c_i x_i \\
 \sum_{i=1}^5 x_i &\leq 1284, \\
 \sum_{i=1}^5 N_i x_i &\leq 1,9 \cdot 10^6, \\
 x_i &\geq 0, 1 \leq i \leq 5,
 \end{aligned} \tag{8}$$

where decision variables x_i stand for areas of arable land planted with the crop i ; and c_i are the random variables of *total profit* per 1 ha of planted crop i defined as follows:

$$c_i = P_i q_i - N_i,$$

q_i being the random variable of the *volume of harvest* of respective crop-plant i (see Table 2 and Table 3 for the volumes of the harvests and profits, respectively, as realized by the agriculture co-operative during last 11 years).

Table 2: Crop-plant harvest history

i	Harvest history (t/ha)	q_i										
		1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007
1	winter wheat	4.30	4.80	4.30	5.10	5.10	5.20	3.60	5.60	5.20	4.40	4.90
2	winter barley	5.40	4.90	4.10	3.30	4.30	3.00	4.00	5.20	4.70	4.40	4.50
3	spring barley	3.60	4.00	4.00	0.00	0.00	0.00	3.70	3.40	3.00	2.90	3.70
4	maize	7.50	6.00	7.30	7.20	7.10	5.40	4.40	6.80	6.70	6.10	7.50
5	winter rape	1.70	2.70	2.10	2.60	2.70	2.40	0.90	3.40	3.20	2.50	2.90

Table 3: Profit per hectare history

	Profit per ha (CZK)	c_i										
		1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007
1	winter wheat	-823	677	-823	1577	1577	1877	-2923	3077	1877	-523	977
2	winter barley	3970	2770	850	-1070	1330	-1790	610	3490	2290	1570	1810
3	spring barley	3224	4504	4504	-8296	-8296	-8296	3544	2584	1304	984	3544
4	maize	432	-3168	-48	-288	-528	-4608	-7008	-1248	-1488	-2928	432
5	winter rape	-2936	4064	-136	3364	4064	1964	-8536	8964	7564	2664	5464

As already mentioned above, the random variables vector c is considered to have the multivariate normal distribution with the mean values vector μ and the covariance matrix Σ

(see Table **Error! Reference source not found.**4 for calculated values using time series from Table 3).

Table 4: Mean value vector μ and covariance matrix Σ of random variable vector c .

μ	Σ				
594	2652397	-23802	-3786050	1416198	6870992
1439	-23802	2820972	5902175	1302426	1555041
-63	-3786050	5902175	26532602	-67279	-3932033
-1859	1416198	1302426	-67279	5041190	4991405
2409	6870992	1555041	-3932033	4991405	21851570

To treat the stochastic programming model (8) we use four approaches described in Sec. 2, which transform the problem into deterministic mathematical programming problems solvable in ordinarily available SW tools.

Using μ and Σ introduced in Table 4 and setting the minimum feasible value of the mean expected profit in models (4) and (5) to $z_0 = 1,5 \cdot 10^5$ and risk aversion parameter in model (6) to $a = \frac{1}{2500}$ we get an optimal solution of the problem (**Error! Reference source not found.**) by the mean value, minimum variance, probability and utility approach model as can be seen in Table 5.

Table 5: Optimal sowing design solution with respect to different stochastic programming models

	Mean value a	Min. variance	Probability	Utility
Sowing plan (ha)	approach			
winter wheat	0	274	0	734
winter barley	316	529	987	475
spring barley	0	235	0	63
maize	0	0	0	10
winter rape	968	245	297	0
Estimated surplus (CZK)	2 786 929	1 500 00	2 135 718	1 097 222

As we can see, the results of the particular approaches are fundamentally different. The first approach does not suit to the problem of the sowing design due to omitting all of the random characteristics of the expected profit. According to high mean value of the profit per hectare, the winter rape is suggested to be the main crop to be planted. Comparing this result to the three others, which take into account the random characteristics of the harvest (resp. profits), we realize, that the main role is shifted to other crop-plants, whose harvests varied during last years less.

The final decision, which of the other three approaches is the most suitable for the respective problem of the sowing design, depends on the decision maker: whether the guarantee of certain level of the profit is preferred (minimum variance approach, probability approach) or more complex solution, which minimizes the difference between measure of the profit variance – as weighted by the risk aversion parameter – and mean value of expected profit, (utility criterion) fits better the desired goal. Nevertheless, the real decision of the sowing design made by the manager of the agriculture co-operative in 2008 (see Table 6), is worse (in terms of expected mean value of the profit) than any of the results of the optimization approaches suggested above.

Table 6: The real sowing design in 2008

	Real sowing plan (ha)
winter wheat	710
winter barley	64
spring barley	167
Maize	141
winter rape	200
Estimated surplus (CZK)	723 578

4. Conclusion

The real world problem of the sowing design optimization was solved by means of several simple stochastic programming approaches. The optimization routine suggested can easily be repeated by practitioners in the agricultural management with no additional needs of SW equipment or data collection. As for the data, it should be pointed out that the data processing is crucial for the correct optimal solution. In Table 2, e.g., there are zero harvests of spring barley during 2000-2002 due to contrary natural conditions in the area. Including the zero values into the analysis depends on the possibility of repeating the same cause of the poor crops. If the cause of the bad crops, hence, were severe floods in 2000-2002 and the flood protection works were made, there is no need to retain the respective data in data file.

Note, that the essential value of the precise methods of mathematical programming in agricultural decision making is to be of even greater importance in Czech Republic due to current or upcoming restrictions of the agricultural business by the environment issues (not necessarily comprehended in decision making up to now), which will make the optimization problem more complex and difficult to be correctly solved by intuitive decision approach. Therefore, the simplified effective methods of operations research easily applicable in agriculture business should be of great importance for managers and agricultural practitioners.

Acknowledgement: The research is supported by the Grant MSM6215648904 of the Ministry of Education, Youth and Sports of Czech Republic.

5. References

- [1] SEPPELT R., VOINOV A., Landscape Optimization: Application of a Spatial Ecosystem Model Modelling Dynamic System, Springer, New York, 2004
- [2] CAMPOS P. et al. Modeling Multifunctional Agroforestry Systems with Environmental Values: Dehesa in Spain and Woodland Ranches in California, Handbook Of Operations Research In Natural Resources, Springer US, 2007
- [3] AHUMADA, O., VILLALOBOS, J, Applications of planning models in the agri-food supply chain: A review, Eur. J. Oper. Res. 195, (1-20) 2009
- [4] BOHLE C., MATURANA S., VERA J., A robust optimization approach to wine grape harvesting scheduling Eur. J. Oper. Res. (2009), doi: 10.1016/j.ejor.2008.12.003
- [5] LIEN, G., STORDAL, S., HARDAKER, J.B., ASHEIM, L.J Risk aversion and optimal forest replanting: A stochastic efficiency study Eur. J. Oper. Res.(3) 181, (1584-1592) 2007
- [6] MARTINS, I., CONSTANTINO, M., JOSE G. BORGES, A column generation approach for solving a non-temporal forest harvest model with spatial structure constraints Eur. J. Oper. Res.(2) 161, (478-498) 2005
- [7] BRAVO M., GONZALES I., Applying stochastic goal programming: A case study on water use planning, Eur. J. Oper. Res. (2008), doi: 10.1016/j.ejor.2008.04.034
- [8] LIZHONG WANG, LIPING FANG, KEITH W. HIPEL, Basin-wide cooperative water resources allocation Eur. J. Oper. Res. (3) 190, (798-817) 2008
- [9] REJANI R., JHA M. K., PANDA S. N., Simulation-optimization modelling for sustainable groundwater management in coastal basin of Orissa, India, Water Resource Management (2008), doi: 10.1007/s11269-008-9273-5
- [10] RONNQVIST M., Optimization in forestry, Math. Program., Ser. B 97, (267-284) 2003
- [11] VENEMA, H. D., CALAMAI, P.H., FIEGUTH, P., Forest structure optimization using evolutionary programming and landscape ecology metrics Eur. J. Oper. Res.(2) 164, (423-439) 2003
- [12] POCHET Y, WOLSEY L.A. Production Planning by Mixed Integer Programming ,Springer Series in Operations Research and Financial Engineering Springer, 2006

- [13] SATYAVEER S. et al, Multi-commodity supply network planning in the forest supply chain Eur. J. Oper. Res. (2009), doi:10.1016/j.ejor.2008.03.024
- [14] BIRGE J., LOUVEAUX F., Introduction to Stochastic programming, Springer-Verlag, New York, 1997
- [15] DUPACOVA J., Stochastic programming (in czech), Praha 1986
- [16] FLETTEN SE., KRISTOFFERSEN T. K., Short-term hydropower production planning by stochastic programming, Comput. Oper. Res. 35, (2656-2671) 2008
- [17] LADURANTAYE D., GENDREAU M., POTVIN JY., Optimizing profits from hydroelectricity production, Comput. Oper. Res. 36, (499-529) 2009
- [18] WEI WANG, Shabbir Ahmed, Sample average approximation of expected value constrained stochastic programs, Oper. Res. Lett. 36, (515-519) 2008
- [19] FREUND R. J., The introduction of risk into a programming model. Econometrica 24, (253-263), 1956

Corresponding adress:

Janová Jitka, Mgr. Ph.D, PEF, MZLU v Brně, Zemědělská 1, 61300 Brno, janova@mendelu.cz

Aplikácia faktorovej analýzy na finančné ukazovatele platobnej schopnosti podnikov*

Application of factor analysis to liquidity ratio determination in Slovak corporations

Mária Kanderová, Jana Stašová

Abstract: The paper focuses on revealing the hidden relations between financial ratios that affect the liquidity of a corporation. Factor analysis is employed to convert the original list of variables into a shorter list of latent variables that contain information about original variables. The analysed data is drawn from a selected sample of Slovak businesses.

Key words: latent variables, communalities, eigenvalues, factor matrix, factor extraction, orthogonal rotation.

Kľúčové slová: latentné premenné, komunality, vlastné čísla, faktorová matica, extrakcia faktorov, ortogonálna rotácia.

1. Úvod

Cieľové správanie podnikov tvorí ucelenú hierarchickú sústavu strategických a finančných cieľov. Väčšina podnikov riadi svoje konanie s dlhodobou perspektívou. Z hľadiska času kľúčovým parametrom pre dlhodobé fungovanie podniku je peňažný tok a s ním spojený pojem platobnej schopnosti podniku. Udržanie platobnej schopnosti je dôležitou súčasťou finančného riadenia podniku, predstavuje základnú podmienku fungovania podniku v trhovej ekonomike a je výrazným indikátorom zdravej finančnej pozície podniku pre veriteľov, banky, dodávateľov, akcionárov a ostatných investorov.

2. Teoretické východiská

Finančná analýza predstavuje významnú súčasť finančného riadenia podniku. Metódy finančnej analýzy zvyšujú vypovedaciu schopnosť spracovaných údajov, pretože kvantifikujú vzťahy medzi analyzovanými údajmi, hľadajú kauzálne súvislosti a určujú ich vývoj. Pri hodnotení finančnej situácie podniku metódami finančnej analýzy nepoznáme jednotný systém finančných ukazovateľov pre hodnotenie platobnej schopnosti podniku. Pre hodnotenie platobnej schopnosti podniku sa využívajú predovšetkým pomerové ukazovatele: z krátkodobého hľadiska ukazovatele likvidity a aktivity; z dlhodobého hľadiska ukazovatele zadlženosti. Úroveň a vývoj likvidity, aktivity aj zadlženosti sa premieta do výšky a vývoja syntetického ukazovateľa finančnej situácie podniku – rentability. Naším cieľom je pomocou faktorovej analýzy zredukovať počet finančných ukazovateľov, ktoré sú navzájom skorelované a získať nové, navzájom nezávislé premenné, v ktorých sú obsiahnuté informácie z pôvodných premenných. Takéto nové premenné sa potom dajú využiť v ďalších štatistických analýzach, ktoré si vyžadujú nekorelovanosť vstupných údajov.

Faktorová analýza patrí k viacrozmerným štatistickým metódam, ktorá umožňuje vytvorenie nových premenných zo súboru pôvodných premenných. Umožňuje nájsť skryté príčiny, ktoré sú zdrojom variability dát. Pomocou latentných premenných - faktorov, ktoré charakterizujú príčiny, a tie sú zdrojom variability, je možné redukovať počet premenných pri zachovaní maximálnej informácie a nájsť súvislosť medzi pozorovateľnými (merateľnými)

* Tento príspevok bol spracovaný v rámci riešenia projektu VEGA 1/4634/07 – Variantné metódy predikovania finančného vývoja malých a stredných podnikov po zavedení spoločnej európskej meny v SR.

príčinami a novými premennými (faktormi). Faktorová analýza predpokladá, že vstupné premenné sú dôsledkom spoločných príčin, ktoré nie sú známe, nie sú známe väzby medzi faktormi, ani ich štruktúra. Ak predpokladáme, že vstupné premenné sú navzájom korelované, potom je možné popísať rovnaký objem informácií menším počtom premenných. Údaje vstupujúce do faktorovej analýzy musia byť číselné. Pri voľbe počtu vstupujúcich premenných musíme zohľadňovať aj počet pozorovaní. Platí pravidlo, že na jednu vstupnú premennú by malo byť aspoň 10 pozorovaní.

Posúdenie vhodnosti dát je možné začať analýzou korelačnej matice vstupných premenných. Na hodnotenie vzájomnej závislosti vstupných premenných sa používa KMO kritérium (Kaiser-Meyer-Olkin), ktoré je založené na porovnávaní jednoduchých a parciálnych koeficientov korelácie. KMO kritérium nadobúda hodnoty od 0 do 1. Podľa odporúčaní Kaisera a Ricea (1974), ak hodnoty KMO kritéria sú nižšie ako 0,6 výberové dáta nie sú vhodné pre faktorovú analýzu. SPSS ponúka aj Bartlettov test (Bartlett's Test of Sphericity), ktorý testuje hypotézu, že korelačná matica je jednotková matica. Ak sa nepodari zamietnuť nulovú hypotézu, vstupné dáta nie sú vhodné pre použitie faktorovej analýzy.

Kritéria pre určenie počtu spoločných faktorov sú založené na tom, že s najskôr pre pôvodný počet premenných získa taká kombinácia premenných, ktorá vysvetľuje najväčšiu časť rozptylu a potom sa hľadajú také kombinácie premenných, ktoré postupne vysvetľujú menšiu a menšiu časť rozptylu.

Odhad parametrov modelu spočíva v nájdení matice faktorových saturácií. Pri odhade sa použije jedna z metód na extrakciu faktorov. Výsledkom je nerotovaná faktorová matica, ktorá predstavuje najlepšiu lineárnu kombináciu pôvodných vstupných premenných v tom zmysle, že pokrýva čo najväčšiu variabilitu pôvodných premenných. V prípade, že nie je dosiahnutá jednoduchá štruktúra v zmysle pravidiel podľa Thurstona (bližšie pozri Hebák, 2005, s. 96), je potrebná rotácia faktorov. Pred samotnou rotáciou je vhodné analyzovať komunality. Ak komunalita príslušného indikátora je menšia ako 0,5, je vhodné vylúčiť daný indikátor z analýzy a zopakovať faktorovú analýzu.

Rotácia faktorov vedie k zjednodušeniu faktorovej štruktúry a tým aj k jednoduchšej interpretácii faktorov. Každý stĺpec vo faktorovej matici predstavuje jeden faktor a hodnoty v každom stĺpci vyjadrujú faktorovú saturáciu pre každú premennú s daným faktorom. Faktorová saturácia predstavuje koreláciu medzi pôvodnou premennou a daným faktorom.

3. Empirické výsledky

Faktorovú analýzu sme robili pomocou štatistického softvéru SPSS. Analyzovali sme súbor ukazovateľov, ktoré ovplyvňujú platobnú schopnosť podniku. K dispozícii máme údaje 144 podnikov 52. oddielu podľa OKEČ - maloobchod za rok 2006. Údaje sú anonymné a boli poskytnuté Daňovým úradom SR. Vo vybraných podnikoch sme sledovali 11 finančno-ekonomických ukazovateľov, ktoré sú definované nasledovne:

PK_A – pomer čistého pracovného kapitálu k majetku ako podiel (obežný majetok - krátkodobé záväzky)/majetok,

FRT – finančná rentabilita tržieb ako podiel cash flow/tržby,

FRM – finančná rentabilita majetku ako podiel cash flow/majetok,

PP – stupeň prevádzkovej páky ako podiel percentuálna zmena EBIT /percentuálna zmena tržieb,

FP - stupeň finančnej páky ako podiel percentuálna zmena EBT/percentuálna zmena EBIT,

STUP_DLH – stupeň zadlženia ako podiel záväzky/vlastné imanie,

CELK_DLH – celková zadlženosť ako podiel záväzky/majetok,

STUP_ODDL – stupeň oddlženia ako podiel cash flow/záväzky,

SOLV – solventnosť ako podiel cash flow/ ((dlhodobé + krátkodobé záväzky)-finančné účty),

lnA – prirodzený logaritmus majetku,

lnT – prirodzený logaritmus tržieb.

Výstup riešenia faktorovej analýzy pred rotáciou ponúka tabuľku KMO kritéria a Bartlettovho testu, tabuľky odhadnutých komunalít, tabuľku vysvetlenej variability a maticu faktorových saturácií pred rotáciou.

Na základe KMO štatistiky a taktiež na základe Bartlettovho testu môžeme vstupné dáta považovať za vhodné pre použitie faktorovej analýzy.

Tabuľka 1: Výsledky KMO štatistiky a Bartlettovho testu sféricity

KMO and Bartlett's Test			
Kaiser-Meyer-Olkin Measure of Sampling Adequacy.			.595
Bartlett's Test of Sphericity	Approx. Chi-Square	931.821	
	df	55	
	Sig.	.000	

V tabuľke 2 sú vypočítané hodnoty komunalít pre jednotlivé vstupné premenné. Indikátor STUP_DLH má veľmi nízku hodnotu komunality, preto bol z ďalšej analýzy vylúčený.

Tabuľka 2: Komunality vstupných premenných

Communalities		
	Initial	Extraction
PK_A	1.000	.878
FRT	1.000	.828
FRM	1.000	.943
PP	1.000	.452
FP	1.000	.504
STUP_DLH	1.000	.264
CELK_DLH	1.000	.881
ST_ODDLH	1.000	.896
SOLV	1.000	.348
lnA	1.000	.915
lnT	1.000	.918

Extraction Method: Principal Component Analysis.

Zopakovali sme faktorovú analýzu vynechaním indikátora s najnižšou komunalitou. Hodnota KMO štatistiky sa zvýšila z 0,595 na 0,605, percento vysvetlenej variability sa zvýšilo z 71,14 % na 77,31%. Na základe kritéria vlastných čísel a vysvetlenej variability boli vybrané štyri významné faktory.

Tabuľka 3: Vlastné čísla a podiel vysvetlenej variability s pôvodným počtom premenných

Total Variance Explained									
Component	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	3.004	27.306	27.306	3.004	27.306	27.306	2.961	26.916	26.916
2	2.250	20.451	47.757	2.250	20.451	47.757	2.003	18.208	45.125
3	1.499	13.631	61.388	1.499	13.631	61.388	1.778	16.160	61.285
4	1.073	9.756	71.144	1.073	9.756	71.144	1.085	9.859	71.144
5	.953	8.665	79.809						
6	.936	8.506	88.315						
7	.713	6.486	94.801						
8	.264	2.400	97.200						
9	.181	1.644	98.844						
10	.084	.763	99.607						
11	.043	.393	100.000						

Extraction Method: Principal Component Analysis.

Tabuľka 4: Vlastné čísla a podiel vysvetlenej variability s vynechanou premennou

Total Variance Explained									
Component	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	3.004	30.035	30.035	3.004	30.035	30.035	2.959	29.587	29.587
2	2.201	22.006	52.041	2.201	22.006	52.041	1.939	19.388	48.974
3	1.468	14.680	66.721	1.468	14.680	66.721	1.766	17.658	66.632
4	1.059	10.593	77.314	1.059	10.593	77.314	1.068	10.682	77.314
5	.938	9.376	86.690						
6	.743	7.428	94.119						
7	.265	2.647	96.765						
8	.195	1.951	98.716						
9	.085	.847	99.563						
10	.044	.437	100.000						

Extraction Method: Principal Component Analysis.

V tabuľke 5 je nerotovaná matica faktorových saturácií. V nerotovanej matici je niekoľko indikátorov, ktoré nie sú faktorovo čisté, to znamená, že sú spojené s dvoma až tromi faktormi. Napríklad indikátory lnT, lnA, PK_A a CELK_DLH majú vysokú faktorovú saturáciu s druhým a tretím faktorom. Z toho dôvodu je potrebné urobiť rotáciu faktorov.

Tabuľka 5: Nerotovaná faktorová matica

Component Matrix ^a				
	Component			
	1	2	3	4
FRM	.951	-.174	.067	.035
ST_ODDLH	.921	-.194	.090	.027
FRT	.892	-.173	.020	.032
SOLV	.559	.122	.125	-.043
lnT	.078	.852	.462	-.009
lnA	.108	.787	.553	-.040
PK_A	.289	.570	-.690	.038
CELK_DLH	-.199	-.617	.665	.115
FP	-.020	-.021	.006	.773
PP	-.045	.190	-.043	.664

Extraction Method: Principal Component Analysis.
a. 4 components extracted.

Tabuľka 6: Rotovaná faktorová matica

Rotated Component Matrix ^a				
	Component			
	1	2	3	4
FRM	.969	-.042	.027	-.003
ST_ODDLH	.944	-.046	-.008	-.012
FRT	.905	-.072	.054	-.003
SOLV	.540	.209	.082	-.049
lnA	.041	.967	.038	.009
lnT	-.007	.961	.140	.049
PK_A	.111	.058	.928	.094
CELK_DLH	-.013	-.113	.927	.053
FP	.014	-.053	-.068	.768
PP	-.055	.090	.094	.679

Extraction Method: Principal Component Analysis.
Rotation Method: Varimax with Kaiser Normalization.
a. Rotation converged in 4 iterations.

Rotáciou faktorov sme získali jednoduchú štruktúru. Prvý faktor je vysoko saturovaný indikátormi FRM (finančná rentabilita majetku), ST_ODDLH (stupeň oddlženosti), FRT (finančná rentabilita tržieb) a SOLV (solventnosť). Všetky indikátory v prvom faktore považujeme za faktorovo čisté. Uvedené finančné ukazovatele v prvom faktore sú definované ako podiel cash flow k tržbám, majetku resp. k vlastnému imaniu. Prvý faktor odráža cash flow ako determinant platobnej schopnosti. Premenné lnA (logaritmus aktív) a lnT (logaritmus tržieb) majú vysokú saturáciu s druhým faktorom. Týmto indikátormi sa dá charakterizovať veľkosť podniku. Druhý faktor predstavuje veľkosť podniku ako ďalší z determinantov platobnej schopnosti. Tretí faktor je spojený s indikátormi PK_A (pomer pracovného kapitálu k majetku) a CELK_DLH (celková zadlženosť). Faktorové saturácie majú opačné znamienka, čo je vzhľadom na definíciu týchto ukazovateľov logické. Tretí faktor odráža zadlženosť podniku. S posledným faktorom sú zviazané ukazovatele FP (stupeň finančnej páky) a PP (stupeň prevádzkovej páky). Tieto ukazovatele sú počítané z výsledku hospodárenia podniku. Z toho dôvodu je aj logická ich zviazanosť s jedným faktorom. Tento faktor môžeme nazvať ziskovosť.

4. Záver

Na základe hodnoty KMO kritéria a výsledku Bartlettovho testu sme usúdili, že analyzované údaje sú vhodné pre použitie faktorovej analýzy. Do riešenia vstupovalo pôvodne 11 premenných, z ktorých sme vylúčili jednu premennú s najnižšou komunalitou. Parametre sme odhadovali metódou hlavných komponentov. Pri určení počtu významných faktorov sme vychádzali z kritéria vysvetlenej variability a z kritéria vlastných čísel. Na základe uvedených kritérií sme zvolili štyri významné faktory, ktoré vysvetľujú 77 % percent celkovej variability. V nerotovanej matici faktorových saturácií mali niektoré indikátory vysoké faktorové saturácie pri dvoch faktoroch. Pre lepšiu interpretovateľnosť sme pôvodnú maticu rotovali metódou Varimax. V rotovej matici sme získali faktorovo čisté riešenie, kde každý indikátor mal významnú faktorovú saturáciu práve pri jednom faktore. Z pôvodných 10 premenných sme získali štyri nové premenné. Vzhľadom na vecnú povahu pôvodných premenných zlúčených do jednotlivých faktorov môžeme nové hypotetické premenné interpretovať nasledovne:

- 1.faktor – cash flow podniku,
2. faktor – veľkosť podniku,
3. faktor – zadlženosť podniku,
4. faktor - ziskovosť podniku.

Faktorovou analýzou sme znížili počet vstupných premenných, ktoré boli korelované. Nové premenné sú lineárne nezávislé a preto sú vhodné pre ďalšie použitie v iných viacrozmerných metódach, ktoré vyžadujú lineárnu nezávislosť vstupných premenných.

5. Literatúra

- [1] ANDĚL, J. 1985. Matematická statistika. Praha : SNTL/ALFA, 1985. s. 489 s. ISBN 1-58488-308-1.
- [2] HEBÁK, P. a kol. 2005. Vícerozměrné statistické metody (3). Praha : Informatorium, 2005. 241 s. ISBN 80-7333-039-3.
- [3] MELOUN, M.- MILITKÝ, J.- HILL, M. 2005. Počítačová analýza vícerozměrných dat v příkladech. Praha : Academia, 2005. 954 s. ISBN 80-200-1335-0.
- [4] STANKOVIČOVÁ, I. - VOJTKOVÁ, M. 2007. Viacrozmerné štatistické metódy s aplikáciami. Bratislava : IURA Edition, 2007. 261 s. ISBN 978-80-8078-152-1
- [5] TABACHNICK, B.,G. – FIDELL, L., S. 2007. Using Multivariate Statistics. Boston : Pearson Education, 2007. 980 s. ISBN 0- 205-46525-0.
- [6] FICZOVÁ, I. – SEDLÁČEK, J. – ÚRADNÍČEK, V. 2002. *Finančno-ekonomická analýza podniku – I. časť*. Banská Bystrica : OZ Financ, 2002. 185 s. ISBN: 80-968702-1-1
- [7] FICZOVÁ, I. – SEDLÁČEK, J. – ÚRADNÍČEK, V. 2002. *Finančno-ekonomická analýza podniku – II. časť*. Banská Bystrica : OZ Financ, 2002. 177 s. ISBN: 80-968702-5-4

Adresa autorov:

Mária Kanderová, Ing., PhD.
KKMaIS, Ekonomická fakulta UMB
Tajovského 10
975 90 Banská Bystrica
maria.kanderova@umb.sk

Jana Stašová, Ing.
KFÚ, Ekonomická fakulta UMB
Tajovského 10
975 90 Banská Bystrica
jana.stasova@umb.sk

Modelovanie pravdepodobnosti podnikania študentmi slovenských vysokých škôl

Modeling of Probability to Run a Business by Slovak University Students

Alena Kaščáková, Gabriela Nedelová

Abstract. The aim of the paper is to analyze the affective factors to enterprise of the Slovak University students. Reliable data were obtained by means of questionnaire. Questions were divided into three parts – desire for the enterprising, the education and the support for establishing enterprising and the background (profile) of respondent. For identification the most affective factors to the probability of enterprising was used the logistic regression. The self-confidence, own experiences and enterprising successfulness of the close relatives and friends were found as the most important factors influencing the probability of enterprising.

Key words: Slovak University students, economic activity, questionnaire, enterprising, logistic regression.

Kľúčové slová: Študenti slovenských vysokých škôl, ekonomická aktivita, dotazník, podnikanie, logistická regresia.

1. Úvod

Pre fungovanie každej ekonomiky, osobitne trhovej je nenahraditeľné podnikanie a podnikateľské schopnosti, pričom motívy k podnikaniu majú v nej nezastupiteľnú úlohu aktivizujúceho prvku.

Podnik bol od svojho vzniku základným článkom chodu národného hospodárstva a jeho fungovaniu prikladala ekonomická teória vždy veľkú pozornosť. Poznatky z vykonaných analýz podnikania mali veľký vplyv na tvorbu a využívanie nástrojov hospodárskej politiky v zmysle smerovania ekonomiky.

Podnikateľské prostredie na Slovensku ako aj v iných postkomunistických krajinách prešlo v transformačnom období dynamickým rozvojom a viacerými modifikáciami, najmä pokiaľ ide o jeho legislatívny a právny rámec. V súčasnej dobe ostáva stále aktuálnou otázka budovania optimálnej podnikovej štruktúry a potreba budovania malého a stredného podnikania. Z tohto pohľadu má zakladanie podnikov mladými ľuďmi nespochybniteľný význam, rovnako vážne treba brať aj ich úmysel podnikat', názory, ktoré majú na podnikanie a skutočnosti, ktoré tieto názory ovplyvňujú.

2. Názory na podnikateľské prostredie na Slovensku

Problematica zapájania mladých ľudí, predovšetkým vysokoškolských študentov do podnikateľského prostredia bola predmetom analýzy výskumného projektu VEGA 1/0795/08 „Potenciál mladých ľudí v podnikateľskom prostredí na Slovensku i v širšom európskom regióne a možnosti jeho využitia“. Zameraním projektu bola sociálno-ekonomická analýza hospodárskeho života, podpora podnikania zo strany štátu a porovnanie pôsobenia týchto faktorov s inými európskymi krajinami, predovšetkým Vyšehradskej štvorky (Horehárová, Marasová, 2009). Projekt nadviazal na prieskum, organizovaný v rámci medzinárodného vedecko-výskumného projektu „Sensibilité a la création d'entreprise“, ktorého jedným z výstupov je databáza údajov z dotazníkov. Tieto boli v roku 2007 distribuované a zozbierané na slovenských vysokých školách.

Otázky v dotazníku boli tematicky rozčlenené na tri časti: chuť podnikat', vzdelanie a pomoc pri zakladaní podniku a profil.

V prvej skupine boli otázky zameraná na určenie dôležitosti niektorých aspektov pre profesionálny život (napr. mať istotu zamestnania, mať stály príjem, nemať príliš veľa práce, a pod.), ďalej zistenie názoru, čo by respondentovi prinieslo vlastné podnikanie, schopnosť vysporiadať sa s problémami, ktoré by priniesol začiatok podnikania, postoj a názory okolia na rozhodnutie o podnikaní, úmysel respondenta podnikat' či skôr zamestnať sa po skončení štúdia, dôvera vo vlastné schopnosti a príťažlivosť myšlienky o podnikaní. Odpoveď na každú otázku bolo možné vybrať zo sedem stupňovej škály hodnotiacej škály.

Druhá skupina otázok smerovala k overeniu názorov respondentov - študentov na možnosť pomoci vo forme podnikateľského kurzu pri úmysle podnikat' po skončení štúdia.

Tretia skupina otázok bola zameraná na profil respondenta, jeho rodičov a blízkeho okolia a ich aktivity pri podnikaní.

Celkovo bolo k dispozícii 299 platných dotazníkov s odpoveďami na 73 otázok v prvej skupine, 13 otázok v druhej skupine a 15 profilových otázok, teda databáza viac ako 20 000 údajov.

Pre analýzu získaných údajov bol použitý programový balík SPSS.

3. Modelovanie pravdepodobnosti podnikania

Ťažiskové otázky, týkajúce sa tendencie študentov vysokých škôl na Slovensku podnikat', sa zamerali na zistenie intenzity tohto úmyslu, príťažlivosti myšlienky na podnikanie a dôvery vo vlastné schopnosti podnikat'. Prirodzene vyústili v otázku na to, aká je pravdepodobnosť, že študent – respondent začne vlastné podnikanie po skončení štúdia. Rozhodovanie o vlastnom podnikaní je u každého jednotlivca ovplyvnené množstvom faktorov, ktoré rôznou intenzitou pôsobia na konečné rozhodnutie. Sú to faktory ekonomické (veľkosť trhu, daňová a odvodová politika štátu, podpora podnikania, a pod.), vzdelanostné (odborná pripravenosť, skúsenosti a zručnosti získané počas štúdia), psychologické (dôvera vo vlastné schopnosti, schopnosť rozhodovať a riadiť podnikanie, a pod.), prípadne poznatky a skúsenosti ostatných podnikateľov a ďalšie.

Vytvorenie modelu pravdepodobnosti podnikania študentov vysokých škôl na Slovensku, zahŕňajúceho faktory, ktoré naň významne vplyvajú umožňuje logistickú regresiu. Metóda vyžaduje binárnu vysvetľujúcu premennú, preto bolo potrebné prekódovať 7 úrovňovú škálu odpovedí (od veľmi nepravdepodobné až po veľmi pravdepodobné) na dvojicu hodnôt vyjadrujúcich pravdepodobnosť, že študent bude po skončení štúdia podnikat'. Ako vysvetľujúce premenné sme do modelu zahrnuli premenné prevažne z druhej a tretej časti dotazníka, teda premenné týkajúce sa profilu študenta, jeho sebadôvery vo vlastné schopnosti pre podnikanie a názorov študentov na pomoc vysokej školy v príprave na podnikanie. Zvolili sme metódu Enter, klasifikačná schopnosť modelu bola 70,6 %. Výsledok použitej metódy je obsahom tabuľky 1, pričom budeme interpretovať len významné premenné.

Z výstupu je zrejmé, že na pravdepodobnosť, že študent bude po skončení štúdia podnikat' významne vplyvajú tri premenné (na hladine významnosti 10 %) a to dôvera vo vlastné schopnosti (premenná CAPACITE), úspešnosť podnikov, ktoré si založili príbuzní alebo blízki respondenta (CREA3) a skutočnosť, či respondent už niekedy bol členom združenia alebo asociácie (ASSO1k), čiže jeho vlastná skúsenosť. Interpretáciou získaných koeficientov zistíme, že zvýšenie sebadôvery o jeden stupeň na 7-bodovej stupnici hodnotenia sa zvýši šanca na podnikanie 2,26 krát. Skúsenosti blízkeho okolia s podnikaním tiež zvyšujú šancu na jeho budúce podnikanie a to až 3,17 krát a významná je tiež vlastná doterajšia skúsenosť študenta ako člena združenia alebo asociácie. Vzhľadom na kódovanie odpovedí je nutné výsledok interpretovať ako zníženie šance podnikat' približne o polovicu, ak by študent nemal doterajšie skúsenosti člena združenia.

Tabuľka 5: Základné štatistické charakteristiky o nezávislých premenných použitých v modeli (výstup SPSS)

		Variables in the Equation					
		B	S.E.	Wald	df	Sig.	Exp(B)
Step 1	CAPACITE	,800	,184	18,932	1	,000	2,226
	SEXE	,306	,423	,525	1	,469	1,358
	DOMAINE(1)	-,225	,430	,273	1	,601	,799
	MILIEU(1)	,639	,414	2,384	1	,123	1,895
	CREA1	,381	,388	,963	1	,326	1,464
	CREA2	1,083	,715	2,292	1	,130	2,953
	CREA3	1,153	,542	4,518	1	,034	3,167
	FORMNEC	,275	,528	,271	1	,603	1,316
	FORMDEJk	,104	,385	,072	1	,788	1,109
	FAMILLE2k	-,094	,154	,374	1	,541	,910
	AMIS2k	-,198	,171	1,336	1	,248	,820
	PROFS2k	,115	,130	,772	1	,380	1,121
	GENS2k	,047	,134	,122	1	,726	1,048
	JOB1k	,859	,580	2,193	1	,139	2,361
	JOB2k	-,625	,443	1,995	1	,158	,535
	ASSO1k	-,794	,420	3,563	1	,059	,452
	Constant	-5,188	2,162	5,758	1	,016	,006

a. Variable(s) entered on step 1: CAPACITE, SEXE, DOMAINE, MILIEU, CREA1, CREA2, CREA3, FORMNEC, FORMDEJk, FAMILLE2k, AMIS2k, PROFS2k, GENS2k, JOB1k, JOB2k, ASSO1k.

Na tendenciu podnikat' nemala vplyv skutočnosť, či študent absolvoval prípravu na založenie podniku ani jeho názor, či je podnikateľský kurz dôležitý, taktiež ani príslušnosť k pohlaviu, vidieku alebo mestu, odboru štúdia, názor príbuzných a okolia, doterajšia práca pre podnik či samofinancovanie štúdia. Je zaujímavé, že ani skutočnosť, či rodičia, príbuzní alebo známi niekedy podnikali významne neovplyvnila rozhodnutie študentov podnikat' v budúcnosti, pričom skutočnosť, či toto podnikanie bolo úspešné alebo nie, vplývala významne.

4. Záver

Slovenská republika implementovala ciele Lisabonskej stratégie do Národného akčného plánu zamestnanosti na roky 2004 – 2006 a Národného strategického referenčného rámca na roky 2007 – 2013, ktorý by sa mal primárne zamerať na rozvoj slabých stránok ekonomiky Slovenskej republiky a na znižovanie regionálnych disparít. Medzi slabé stránky ekonomiky Slovenskej republiky patrí nedostatočná konkurencieschopnosť slovenských malých a stredných podnikov a nízky podiel inovujúcich podnikov v priemyselnej výrobe; nepružný trh práce; nedostatočná previazanosť systému vzdelávania na reálne potreby trhu práce a v neposlednom rade zlá situácia týkajúca sa záujmu a účasti slovenských podnikov na výskume a technologickom rozvoji a nedostatočná infraštruktúra vedy a výskumu a uplatňovanie výsledkov výskumu v praxi. Pre dosiahnutie týchto cieľov je jedným z predpokladov vybudovanie fungujúceho podnikateľského prostredia na Slovensku.

Cieľom príspevku bolo zistiť, či mladá generácia vysokoškolských študentov má ambície podnikat', podieľať sa na tvorbe a postupnom rozvoji podnikateľského prostredia a popísať faktory, ktoré by tieto tendencie mohli podporiť. Z dotazníkového prieskumu je zrejmé, že mladí ľudia sa chcú zamestnať a po skončení štúdia očakávajú zaujímavú prácu s možnosťou kariérneho rastu a istoty zamestnania. Približne 40 % študentov uvažuje o možnosti vlastného podnikania, pričom táto skupina si najmenej dôveruje v schopnosť získať financovanie bankou, kapitál od známych a rodiny a zaujať parterov. Študenti vítajú a oceňujú organizovanie podnikateľského kurzu. Významnými faktormi pre rozhodovanie o vlastnom podnikaní sú aj pozitívne skúsenosti najbližšieho okolia a sebadôvera. Vzhľadom na zistené závery je aj naďalej veľmi aktuálna otázka kvalitnej prípravy študentov na podnikanie a tým aj výzva pre Slovenské vysoké školstvo, aby takéto kurzy v rámci

vysokoškolského štúdia organizovali. Nedôvera študentov v možnosti získania finančnej podpory je výzvou pre hospodársku politiku podpory malých a stredných podnikov zo strany štátu a vytváranie dostatočných záruk pre poskytovanie úverov začínajúcim podnikateľom od komerčných bánk. V konečnom dôsledku sú pre budúce podnikanie motivujúce aj osobné skúsenosti s úspešným podnikaním okolia.

Vynára sa aj potreba riešenia makroekonomického problému stále pretrvávajúcej kolektivistickej mentality, rozširujúcich sa intervencií štátu a pokles individuálnej zodpovednosti, ktoré sú príčinami straty podnikateľského ducha.

Je nevyhnutné, aby Národný strategický referenčný rámec obsahoval konkrétne a účinné opatrenia na zlepšenie situácie prioritne v oblastiach, ktoré môžu napomôcť rozvoju podnikateľského prostredia a tým aj zlepšiť situáciu v zamestnanosti na Slovensku.

5. Literatúra

- [1] HOREHÁJOVÁ, M., MARASOVÁ, J. 2009. Le risque entrepreneurial comme facteur de production. In: Zborník z XX Medzinárodnej konferencie krajín V4. Bratislava: Ekonomická univerzita. 2009. ISBN: 978-80-225-2801-6.
- [2] STANKOVIČOVÁ, I., VOJTKOVÁ, M. 2007. Viacrozmerné štatistické metódy s aplikáciami. Bratislava: Iura Edition, 2007. ISBN 978-80-8078-152-1.
- [3] Návrh inštitucionálneho zabezpečenia koordinácie lisabonskej agendy v Slovenskej republike. <http://www.finance.gov.sk/>

Adresa autorov:

Alena Kaščáková, Ing. PhD.
KKMaIS EF UMB
Tajovského 10
975 90 Banská Bystrica
alena.kascakova@umb.sk

Gabriela Nedelová, RNDr. PhD.
KKMaIS EF UMB
Tajovského 10
975 90 Banská Bystrica
gabriela.nedelova@umb.sk

Tento príspevok vznikol s podporou grantu VEGA 1/0795/08 a grantu KEGA 3/5214/07.

Analýza časového radu emisií SO_x pomocou programu R

Time series analysis emissions SO_x with R package

Miriam Andrejiová, Zuzana Kimáková

Abstract: Time series analysis is one of the most important applications of statistical methods. R is a freely download statistical package from CRAN which can be found on the internet at <http://cran.r-project.org>. The aim of this paper is to demonstrate a time series analysis with R package.

Key words: time series analysis, R package, exponential smoothing, decomposition, ARIMA modelling.

Kľúčové slová: analýza časového radu, program R, exponenciálne vyrovňovanie, dekompozícia, ARIMA modelovanie.

1. Úvod

Analýza časových radov je jednou z najvýznamnejších aplikácií štatistických metód, pričom jej spojenie s využitím štatistických programov je nevyhnutné. V súčasnej dobe existuje množstvo komerčných i nekomerčných programov. Cieľom príspevku je vykonať analýzu časového radu emisií prostredníctvom programu R, ktorý patrí k tzv. programom s otvoreným zdrojovým kódom - Open Source Software. Aktuálnu verziu programu R pre OS Windows nájdeme na stránke <http://www.r-project.org/>.

R je pomerne univerzálnym štatistickým nástrojom na spracovanie, analýzu údajov a grafické výstupy. Súčasťou základného prostredia je niekoľko štandardných, odporúčaných balíkov, medzi nimi aj balík *stat*. Mnohé ďalšie sa dajú inštalovať z archívu CRAN na domovskej stránke. V našom prípade sme využili na analýzu časových radov balíky *stat*, *pastecs*, *outliers*, *forecast*, *tseries*.

Pre spracovanie sú použité údaje o emisiách SO_x namerané na bloku č.5 v Elektrárnach Vojany v jednotlivých mesiacoch rokov január 2004 až november 2007. Merné množstvá (mg.m⁻³_{nr}) sú uvedené v tabuľke 1.

Tabuľka 6: Emisie SO_x

	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
2004	206	234	236	268	184	263	245	233	252	168	154	86
2005	135	196	193	221	250	257	254	205	267	251	198	183
2006	254	235	207	252	210	234	257	273	235	206	253	205
2007	141	165	180	305	327	300	312	335	318	306	212	

2. Analýza časového radu emisií

Jeden zo spôsobov ako získať základné štatistické charakteristiky je využiť balík *stats* alebo doinštalovaním balíka *pastecs*.

```
> summary(sox)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   86.0   201.5   235.0   231.1   257.0   335.0

> var(sox)
[1] 2779.036

> sd(sox)
[1] 52.71656
```

```
> library(pastecs)
> stat.desc(sox)
      nbr.val  nbr.null  nbr.na      min      max      range
4.700000e+01 0.000000e+00 0.000000e+00 8.600000e+01 3.350000e+02 2.490000e+02
      sum      median      mean  SE.mean CI.mean.0.95      var
1.086100e+04 2.350000e+02 2.310851e+02 7.689501e+00 1.547816e+01 2.779036e+03
      std.dev      coef.var
5.271656e+01 2.281262e-01
```

V ďalšom kroku prevedieme hodnoty emisií SO_x do časového radu pomocou príkazu `ts()` (package `stats`).


```
> soxnts<-ts(sox,start=2004, frequency=12)
> soxnts
      Jan Feb Mar Apr May Jun Jul Aug Sep Oct Nov Dec
2004 206 234 236 268 184 263 245 233 252 168 154  86
2005 135 196 193 221 250 257 254 205 267 251 198 183
2006 254 235 207 252 210 234 257 273 235 206 253 205
2007 141 165 180 305 327 300 312 335 318 306 212
```

Veľmi účinným spôsobom prezentácie údajov je grafické znázorňovanie. Na obrázku 1 je časový vývoj emisií (`ts.plot(soxnts)`).




Obrázok 4: Vývoj emisií SO_x v období 2004 až do novembra 2007

Hodnota 86 sa javí ako odľahlá, čo nám potvrdil nielen boxplot (`boxplot()`, package `outliers`), ale aj príkaz na hľadanie odľahlých hodnôt `outlier()`. Nakoniec sme sa rozhodli hodnotu 86 nahradiť aritmetickým priemerom (ďalej budeme pracovať s časovým radom `soxnts`).



Obrázok 5: Boxplot

Normalitu náhodnej zložky môžeme posúdiť vizuálne z histogramu (`hist(soxnts)`) a rankitového grafu (`qqnorm()`) alebo ju môžeme overiť pomocou Shapiro – Wilkovho testu normality (`shapiro.test()`). Pretože $p \geq \alpha$, nulovú hypotézu H_0 o normalite nezamietame na hladine významnosti $\alpha=0,05$.




Obrázok 6: Histogram, rankitový graf

```
> shapiro.test(soxnts)
```

Shapiro-Wilk normality test

```
data: soxnts
W = 0.9798, p-value = 0.5846
```

Dekompozíciu časového radu na sezónnu, trendovú a náhodnú zložku môžeme vykonať pomocou `decompose(soxnts)`, príkazom `plot()` získame jej grafický výstup. Výsledok `plot(decompose(soxnts))` je na obrázku 4 (package `stats`).



Obrázok 7: Dekompozícia časového radu

Balík `forecast` dáva možnosť automatického nájdenia najvýhodnejšieho modelu exponenciálneho vyrovňovania príkazom `ets(soxnts)`, kde ETS predstavuje *Exponential Smoothing*. V našom prípade výsledkom je jednoduché exponenciálne vyrovňovanie:

```
> ets=ets(soxnts)
> ets
ETS(A,N,N)
```

Call:

```
ets(y = soxnts)
```

```
Smoothing parameters:
alpha = 0.5639
```

```
Initial states:
l = 219.1868
```

Najvhodnejší model doplnený o predpoveď získame `summary(forecast(soxnts))` alebo príkazom `forecast(ets(soxnts))`. Predpoveď je až do novembra 2009, pričom sú vypočítané aj 80% a 95% -ný interval spoľahlivosti pre prognózu v jednotlivých mesiacoch.

```
> forecast(ets(soxnts))
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Dec 2007	255.6136	199.14371	312.0835	169.250346	341.9769
Jan 2008	255.6136	190.78394	320.4433	156.465175	354.7621
Feb 2008	255.6136	183.38534	327.8419	145.149992	366.0772
Mar 2008	255.6136	176.67718	334.5501	134.890747	376.3365
Apr 2008	255.6136	170.49606	340.7312	125.437542	385.7897

Hodnoty vyrovnaného časového radu získame príkazom `fitted()`:

```
> fitted(ets)
```


	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug
2004	219.1868	211.7506	224.2973	230.8966	251.8196	213.5754	241.4464	243.4503
2005	206.5783	166.2146	183.0109	188.6438	206.8898	231.2001	245.7489	250.4018
2006	199.4213	230.1988	232.9062	218.2974	237.3027	221.9064	228.7261	244.6700
2007	220.3267	175.5936	169.6197	175.4733	248.5147	292.7734	296.8485	305.3926

	Sep	Oct	Nov	Dec
2004	237.5573	245.7017	201.8849	174.8821
2005	224.7993	248.5967	249.9519	220.6557
2006	260.6456	246.1838	223.5237	240.1457
2007	322.0885	319.7830	312.0106	

Na grafické zobrazenie vyrovnaného časového radu emisií spolu s predpoveďou môžeme použiť funkciu `plot(forecast(soxnts))`. Na obrázku 5 je graf časového radu emisií spolu s vyrovnaným časovým radom. Prognóza na ďalšie obdobie je znázornená na obr. 6.



Obrázok 8: Porovnanie pôvodného a odhadnutého radu



Obrázok 9: Prognóza

Mieru presnosti prognózy určíme funkciou `accuracy()`:

```
> accuracy(ets)
```


ME	RMSE	MAE	MPE	MAPE	MASE
1.3744013	44.0637044	34.8049262	-2.3710781	16.1735571	0.9221547

Ďalšie príkazy, ktoré ponúka program R v rámci exponenciálneho vyrovňovania: `coef()`, `residuals()`, `simulate()`, `accuracy()`.


Overenie stacionarity časového radu môžeme vykonať pomocou balíka `tseries` a to prostredníctvom Augmented Dickey-Fuller testu jednotkového koreňa (`adf.test(soxnts)`). Alternatívou k ADF testu je test Kwiatkovského, Phillipsa, Schmidta a Shina, tzv. KPSS test (`kpss.test(soxnts)`). Testy zamietli hypotézu o stacionarite nášho časového radu na hladine významnosti $\alpha=0,05$. Aby sme odstránili nestacionaritu, odporúčajú sa rôzne

transformácie; jednou z nich je aj vytvorenie radu prvých diferencií (`diff(soxnts)`), ktoré už vykazujú stacionaritu.

Identifikácia **ARIMA modelu** sa uskutočňuje pomocou autokorelačnej funkcie (ACF) v kombinácii s parciálnou autokorelačnou funkciou (PACF). Vykreslenie autokorelačnej funkcie (ACF) a parciálnej autokorelačnej funkcie (PACF) získame pomocou príkazu `acf()` a `pacf()`. Na obr. 7 a obr. 8 sú vykreslené ACF a PACF pre pôvodné hodnoty časového radu a pre prvé diferencie.



Obrázok 10: ACF a PACF



Obrázok 11: ACF a PACF pre 1. diferencie

Balíček `forecast` nám dáva možnosť okrem automatického nájdenia exponenciálneho vyrovnávania aj automatické nájdenie optimálneho ARIMA modelu (`auto.arima()`) s odhadom parametrov a s prognózou na obdobie až do novembra 2009. Do úvahy berie Akaikeho informačné kritérium (AIC), ktorého hodnota by pre najlepší model mala byť najnižšia.


```
> arima=auto.arima(soxnts)
> arima
Series: soxnts
ARIMA(1,1,1)

Call: auto.arima(x = soxnts)


Coefficients:
      ar1      ma1
 0.5189 -0.9647
s.e. 0.1587 0.1037

sigma^2 estimated as 1747: log likelihood = -237.77
AIC = 481.53 AICc = 482.1 BIC = 487.02
> forecast(arima)
      Point Forecast      Lo 80      Hi 80      Lo 95      Hi 95
Dec 2007      225.1792 171.5554 278.8030 143.1687 307.1897
Jan 2008      232.0173 170.6625 293.3722 138.1832 325.8515
Feb 2008      235.5654 171.7790 299.3517 138.0126 333.1181
```

Overenie modelu môžeme vykonať vykreslením ACF a PACF pre rezíduá (obr.9), ktorých hodnoty by mali byť takmer nulové. Normalitu rezíduí overíme opäť pomocou rankitového grafu (obr.10) alebo pomocou Shapiro – Wilkovho testu.



Obrázok 12: ACF a PACF pre rezíduá



Obrázok 13: Grafické overenie normality(rankitový graf, histogram)

K ďalším možnostiam, ktoré ponúka program R, patrí napríklad vykreslenie sezónneho grafu (`seasonplot()`), priebehu časového radu spolu s autokorelačnými funkciami (`tsdisplay()`) a iné.

3. Záver

Program R predstavuje integrovaný systém umožňujúci manipuláciu, spracovanie, analýzu a grafické zobrazenie štatistických údajov. K jeho mnohým výhodám patrí dostupnosť a legálnosť. Hoci R nedosahuje úroveň komerčných programov (STATISTICA, systém SAS, Statgraphics a pod.), aj napriek tomu je vhodnou a postačujúcou alternatívou vo výučbe štatistiky. Podrobnejšie využitie programu, a to nielen pri analýze časových radov, nájdeme v manuáloch na oficiálnej stránke <http://www.r-project.org/>.

4. Literatúra

- [1]CROKER, S. T. 2008. Times Series Analysis with SAS and R.
<http://www.nesug.org/proceedings/nesug08/sa/sa07.pdf>
- [2]RUBLÍKOVÁ, E. 2007. Analýza časových radov. Bratislava: Iura Editionl, 2007. 207 s. ISBN 978-80-8078-139-2.
- [3]SHUMWAY,R.H. – STOFFER, D.S. 2006. Times Series Analysis and Its Applications: With R Example. New Yourk:2006. In: <http://www.stat.pitt.edu/stoffer/tsa2/index.html>.
- [4]ZUCCHINI,W. – NENEDIĆ, O. Times Series Analysis with R – Part I. In: <http://www.statoek.wiso.uni-goettingen.de/veranstaltungen/>.
- [5]R DOCUMENTÁCIA

Adresa autorov:

Miriám Andrejiová, RNDr., PhD.
Katedra aplikovanej matematiky SjF
Technická univerzita v Košiciach
Letná 9
042 00 Košice
miriam.andrejiova@tuke.sk

Zuzana Kimáková, RNDr.
Katedra aplikovanej matematiky SjF
Technická univerzita v Košiciach
Letná 9
042 00 Košice
zuzana.kimakova@tuke.sk

Exploračná analýza počtu obyvateľov a plochy okresov na Slovensku Exploration analysis of districts population and area in Slovakia

Samuel Koróny[†]

Abstract

The paper deals with exploratory data analysis applications to available data of 79 Slovak districts from the year 2007. Both examined variables district area and number of its inhabitants are nonhomogenous according to results. The reason of nonhomogeneity is that linear dependance between area and population can be divided to 5 distinct clusters by means of regression clustering.

Keywords: regional disparities, cluster analysis, regression analysis

Kľúčové slová: regionálne disparity, zhuková analýza, regresná analýza

Úvod

Územné a správne členenie Slovenska prešlo za posledných 100 rokov viacerými zmenami. Aktuálne členenie je na základe Zákona č. 221/1996 Z. z. o územnom a správnom usporiadaní SR, ktorý republiku rozdelil na 8 krajov a 79 okresov. Podľa klasifikačného systému štatistických územných jednotiek zavedených Eurostatom sa vyčlenili tri regionálne a dve lokálne úrovne. Celé územie SR je definované ako jednotka NUTS 1, regióny NUTS 2 sú tvorené dvomi až tromi jednotkami NUTS 3. Jednotkami NUTS 3 sú kraje. Organizačnými jednotkami na lokálnej úrovni sú okresy (LAU 1 alebo NUTS 4) a obce (LAU 2 alebo NUTS 5). Slovensko malo k 31. decembru 2007 spolu 2 891 obcí, z toho bolo 138 miest (bez 17 mestských častí v Bratislave a 22 mestských častí v Košiciach) (databáza RegDat ŠÚ SR).

Cieľom nášho príspevku je zistiť, či súčasné rozdelenie územia Slovenska do 79 okresov má dobré štatistické vlastnosti (homogenita apod.) vo veľkosti okresov a počte ich obyvateľov, pretože si myslíme, že tam treba začať pri možnej kritike súčasného rozdelenia Slovenska (Korec, 2005).

1. Dáta

Pre zistenie základných štatistických vlastností veľkosti okresov a počtu ich obyvateľov sme použili údaje dostupné na stránke Štatistického úradu SR v regionálnej databáze „RegDat.“ Štatistickou jednotkou je v našom prípade okres vymedzený podľa Zákona č. 221/1996 Z. z. o územnom a správnom usporiadaní SR. Posledné uverejnené dáta boli za obdobie ku koncu roka 2007. Z dvoch základných absolútnych ukazovateľov – plocha okresu a počet jeho obyvateľov sme vypočítali relatívny ukazovateľ – hustotu obyvateľstva. Hustota obyvateľstva je definovaná ako počet obyvateľov k 31. 12. daného roka pripadajúci na jednotku plochy (km²). Preto sme pri analýze použili údaje o počte obyvateľov ku koncu roka a nie k jeho stredu (1.7.), ako je to obvyklé pri strednom stave obyvateľstva.

2. Použité metódy

Pre splnenie cieľa príspevku (štatistická exploračná analýza plošnej veľkosti okresov a počtu ich obyvateľov) sme použili niekoľko zhukovacích štatistických metód implementovaných v systémoch NCSS verzia 2001 a SPSS verzia 13. Pre nájdenie zhukov

[†] RNDr. Samuel Koróny, PhD. Ústav vedy a výskumu UMB, Banská Bystrica

Táto práca bola podporovaná Agentúrou na podporu výskumu a vývoja na základe zmluvy č. APVV-0649-07.

v daných okresných ukazovateľoch sme aplikovali metódu k priemerov a regresného zhlukovania zo systému NCSS a dvoj krokovú zhlukovú metódu pre možné automatické zistenie počtu zhlukov pomocou informačných kritérií AIC a BIC v SPSS (s dvomi vzdialenosťami log likelihood a euklidovskou). Pre grafické zobrazenie hodnôt sme urobili štandardné a vyhladené histograme a rozptylové grafy v štatistickom systéme NCSS.

3. Jednorozmerná exploračná analýza ukazovateľov

Pre prvotnú orientáciu uvádzame základné štatistické parametre analyzovaných ukazovateľov v tabuľke 1. Z nej je zrejmé, že rozsah plochy okresov je veľký a siaha od 9,59 km² (okres Bratislava 1) až po 1551,14 km² (okres Levice). Všetkých 9 najmenších okresov patrí medzi mestské okresy (Bratislava 1 až 5, Košice 1 až 4). Ďalší v poradí desiaty je okres Kysucké Nové Mesto (173,68 km²). Smerodajná odchýlka (367) je relatívne veľká v porovnaní s aritmetickým priemerom (621), o čom svedčí veľká hodnota variačného koeficientu 0,591. Všetko toto poukazuje na príliš rozťahnutú distribúciu plochy okresov. Podobné závery je možné vyvodit' aj pre ukazovateľ počtu obyvateľov (variačný koeficient 0,539). V prípade ukazovateľa hustoty obyvateľov sa veľká hodnota variačného koeficientu dá očakávať, pretože podiel aj dvoch normálne rozdelených veličín je cauchyovské rozdelenie, ktoré má podstatne väčšie pravdepodobnosti výskytu odľahlých hodnôt. Najmenšia hustota obyvateľov je v okrese Medzilaborce (28,48), najväčšia pre Bratislavu 1 (4301,88).

Tabuľka 1: Štatistické parametre okresov: plocha (v km²), počet obyvateľov (v tisícoch) a ich hustota

Ukazovateľ	N	Mean	Std. Dev.	COV	Minimum	Maximum
Plocha	79	621	367	0.591	10	1 551
Obyvatelia	79	68	37	0.539	12	166
Hustota	79	256	561	2.189	28	4 302

Pre porovnanie uvádzame tabuľku 2 pri vylúčení mestských okresov. Situácia z hľadiska štatistických parametrov pre plochu a počet obyvateľov je podobná. V prípade hustoty sa však radikálne zmenila v priemere (z 256 na 102 obyvateľov na km²), smerodajnej odchýlke (z 561 na 44 obyvateľov na km²) aj variačnom koeficiente (z 2,189 na 0,430). Príčina je v extrémne veľkých hodnotách hustoty všetkých mestských okresov, ktoré zvyšujú všetky tri uvedené parametre. Najväčšia hustota obyvateľov je potom v okrese Kysucké Nové Mesto (195,76 obyv./1 km²). Je to spôsobené jeho malou plochou (173,68 km²).


Tabuľka 2: Štatistické parametre okresov bez mestských okresov

Ukazovateľ	N	Mean	Std. Dev.	COV	Minimum	Maximum
Plocha	70	692	327	0.472	174	1 551
Obyvatelia	70	68	38	0.558	12	166
Hustota	70	102	44	0.430	28	196

Rozsah plochy okresov je od necelých 10 km² po 1551 km², preto sme pre grafické zobrazenie urobili histogram od nuly do 1600 so 16 stĺpkami (so šírkou 100 km²). Ich počet je príliš vysoký, ale je to užitočné pre orientáciu v rozdelení hustoty hodnôt. Histogram plochy všetkých 79 okresov je na grafe 1. Z neho je zrejmé, že maximálna hustota plochy

okresov je v intervale od 300 do 400 km² (12 okresov, čo je 15,2 %). Druhé v poradí sú okresy v intervaloch od 0 po 100 km² (všetkých 9 mestských okresov, čo je 11,4 %), od 400 po 500 km² a od 500 do 600 km² (tiež po 9 okresov - 11,4 %). Potom hustoty monotónne klesajú pre zväčšujúce sa hodnoty plochy okresov. Priebeh jednoznačne ukazuje na kladnú šikmosť. Mestské okresy sústredené v intervale 0 až 100 km² sú oddelené od ostatných okresov minimom od 100 do 200 km² (1 okres - Kysucké Nové Mesto) a od 200 do 300 km² (3 okresy – Hlohovec, Bytča, Banská Štiavnica). Rozptylový diagram pod vodorovnou osou poukazuje na to, že podstatná časť hodnôt sa nachádza v intervale od 300 do 1200 km² (10 percentil je 94 km², 90 percentil je 1 105 km²).


Pre zistenie lokálnej hustoty je vhodné použiť vyhladený histogram, ktorý nevyžaduje apriórne obmedzenia alebo informácie na konkrétne rozdelenie. Na grafe 1 je zobrazený aj vyhladený histogram s parametrom 0,15, ktorý ukazuje na to, že plocha okresov nie je homogénna a ich rozdelenie je multimodálne. Pri danom parametre sa dá zistiť 6 lokálnych maxím (módov) a preto rozdelenie okresov vzhľadom na plochu nie je homogénne. Podľa relatívne optimálnej zhlukovej metódy k priemerov má rozdelenie plochy okresov SR 5 alebo 6 zhlukov. Dvojvkroková zhluková metóda v SPSS (de jure je schopná nájsť prirodzené zhluky) identifikovala 3 zhluky. Nie sú podstatné rozdiely v počte zhlukov (každá zhlukovacia metóda používa vlastnú heuristickú metódu, vzdialenosť atď. a je pochopiteľné, že sú rozdiely vo výsledkoch), ale v tom, že sa vôbec našli zhluky tam, kde by sme ich nečakali. Podotýkame, že automatická dvojvkroková metóda nenájde žiadne zhluky, ak ide o homogénny súbor. Je zrejmé, že výsledné rozdelenie plochy okresov nie je homogénne. Otázka je: koľko je vlastne zhlukov okresov a čím sú spôsobené.



Graf 1: Histogram plochy okresov v km² (parameter vyhladenia 0,15)

Pri počte obyvateľov sú závery podobné. Na grafe 2 je histogram počtu obyvateľov so šírkou 1 000 obyvateľov, s celkovým rozsahom od 0 do 170 000 obyvateľov. Tiež vzbudzuje podozrenie, že ide o multimodálne rozdelenie. Pre potvrdenie podozrenia sme opäť urobili vyhladený histogram, ktorý pri zvolenom parametri 0,25 poukazuje na prítomnosť 3 až 4

módov. Zhuková metóda k priemerov jednoznačne identifikovala 4 zhuky. Dvojokrová zhuková analýza našla 2 alebo 3 zhuky (podľa druhu vzdialenosti). Situácia je podobná, ako v prípade veľkosti okresov.



Graf 2: Histogram počtu obyvateľov okresov v tisícoch


Na základe uvedených skutočností môžeme skonštatovať, že rozdelenie územia Slovenska do 79 okresov podľa Zákona č. 221/1996 Z. z. o územnom a správnom usporiadaní SR vytvorilo z hľadiska štatistiky nehomogénne súbory tak v plošnej veľkosti okresov, ako aj v počte ich obyvateľov.

4. Dvojrozmerná exploračná analýza ukazovateľov

V rámci jednorozmernej analýzy sme dokázali, že jednotlivé ukazovatele plochy a počtu obyvateľov okresov vytvorených na základe Zákona č. 221/1996 Z. z. o územnom a správnom usporiadaní SR nemajú homogénne, ani symetrické distribúcie. Pokúsime sa nájsť odpoveď v spoločnom dvojrozmernom priestore ukazovateľov plochy okresov a počtu ich obyvateľov.

Na grafe 3 je zobrazená závislosť počtu obyvateľov od plochy okresov spolu s lineárnou regresnou priamkou a 95 percentnými intervalmi spoľahlivosti pre jednotlivé hodnoty. Pri pohľade naň sú zrejmé dva základné rysy. Úplne vľavo sú sústredené mestské bratislavské a košické okresy, ktoré vytvárajú zhuk silne pretiahnutý vo vertikálnom smere a vyznačujú sa veľkou hustotou. Tento zhuk sa dá dobre aproximovať relatívne strmou regresnou priamkou. Ostatné okresy sa tiež dajú preložiť regresnou priamkou. Je ale jasné, že rezíduá takého modelu by boli silne heteroskedastické.

To znamená, že so zvyšujúcou sa plochou okresu by bola väčšia aj chyba lineárnej závislosti počtu obyvateľov od plochy okresov.



Graf 3: Graf závislosti počtu obyvateľov okresu od jeho plochy


Ďalej platí, že hustota obyvateľov je pomerový ukazovateľ a mal by spĺňať základný predpoklad priamej úmernosti medzi absolútnym ukazovateľom v čitateli a menovateli. To znamená, že veľkosť hustoty by mala byť konštantná pre rôzne hodnoty daných absolútnych ukazovateľov. Pre zistenie platnosti predpokladu sme použili robustný Spearmanov korelačný koeficient, ktorý je menej citlivý na odľahlé hodnoty. Pre závislosť medzi plochou okresu a jeho hustotou je $r = -0,422$ ($p < 0,001$). Pre počet obyvateľov je $r = 0,458$ ($p < 0,001$). Z nich vyplýva, že čím je väčší počet obyvateľov, tým je väčšia hustota. Pre plochu je to naopak: čím je menšia plocha, tým je väčšia hustota. Hustota teda nie je ani približne konštantná pre rôzne reálne veľkosti plochy a počtu obyvateľov okresov.

Riešenie problému sme našli v zhlukovej analýze. Všetky dostupné zhlukové metódy (okrem metódy najbližšieho suseda) nájdu zhluky viac menej guľovitého tvaru. V zaujímavých publikáciách manželov Kovanícových (Kovanicová, 1995, 1996) je popísaná gnostická analýza dát ako alternatíva k štatistickej analýze. Je tam o. i. uvedený aj iný postup pre zistenie zhlukov v dátach pomocou robustných gnostických regresných modelov. Myšlienka spočíva v nájdení lineárnych štruktúr vhodných na preloženie priamkou vo viacrozmernom dátovom priestore. Ide teda o nájdenie liniových (vláknitých) zhlukov. Podobný nerobustný postup je implementovaný ako regresné zhlukovanie v systéme NCSS podľa publikácie (Spaeth 1985). Ide o prepojenie lineárnej regresie a zhlukovania.

V našom prípade je dôležitá skutočnosť, že regresná priamka musí prechádzať cez počiatok (pri nulovej veľkosti okresu uvažujeme 0 obyvateľov). Najprv sme použili štandardné regresné zhľukovanie s nenulovým absolútnym členom. Výsledkom bolo rozdelenie daného súboru dát na niekoľko takmer horizontálnych a rovnobežných zhľukov, ktoré mali nenulový absolútny člen a nedokázali vyčleniť všetky mestské okresy do jedného samostatného zhľuku.


Pri zadaní nulového absolútneho člena (podmienke prechodu cez počiatok) sa výskumná vzorka dát priam brilantne rozdelila na 5 zhlukov. Pre získanie optimálneho rozdelenia sme použili 100 náhodných štartov a 100 iterácií pre eliminovanie závislosti riešenia od počiatkových podmienok. Pri danom algoritme sa hľadá maximálny koeficient determinácie

pri minimálnom počte zhlukov. Z grafu 4 je vidieť, že pre počty zhlukov 2 až 4 koeficient postupne rastie, ale pri prechode od štyroch zhlukov k piatim náhle vzrastie z 0,908 na 0,985 a ďalej rastie veľmi pomaly. Päť zhlukov je jednoznačne optimálne riešenie úlohy počtu zhlukov pomocou regresného zhlukovania.



Graf 4: Bodový graf závislosti koeficientu determinácie od počtu zhlukov

Výsledné optimálne rozdelenie pomocou regresného zhlukovania je na grafe 5. Nájdené rozdelenie regresných zhlukov je významné minimálne na hladine $p < 0,001$. Regresné priamky však na grafe neprechádzajú cez počiatok, lebo v štatistických systémoch je v grafickom zobrazení táto možnosť bežne nedostupná.



Graf 5: Graf závislosti počtu obyvateľov od plochy okresu pri rozdelení do 5 zhlukov

Nájdene rozdelenie okresov do 5 zhlukov odstráni nielen heteroskedasticitu, ale zaručí aj lineárny vzťah medzi počtom obyvateľov a plochou okresu a teda aj konštantnosť hustoty. V tabuľke 3 sú štatistické parametre nájdeneých zhlukov plochy okresov (v km²), počtu obyvateľov (v tisícoch) a ich hustoty. Očíslované sú od 1 (zhluk okresov s najmenšou hustotou) po 5 (mestské bratislavské a košické okresy s najvyššou hustotou).

Tabuľka 3: Štatistické parametre okresov: plocha (v km²), počet obyvateľov (v tisícoch) a ich hustota v nájdeneých zhlukoch

Ukazovateľ	N	Mean	Std.Dev.	Minimum	Maximum	Zhluk
Plocha	17	723	371	292	1 471	1
Obyvatelia	17	37	21	12	83	1
Hustota	17	51	9	28	63	1
Plocha	21	738	336	327	1 551	2
Obyvatelia	21	61	26	28	118	2
Hustota	21	83	7	71	95	2
Plocha	16	739	314	282	1 347	3
Obyvatelia	16	84	32	31	147	3
Hustota	16	117	14	97	139	3
Plocha	16	550	259	174	960	4
Obyvatelia	16	93	46	34	166	4
Hustota	16	168	15	145	196	4
Plocha	9	68	33	10	97	5
Obyvatelia	9	73	30	30	118	5
Hustota	9	1 452	1 110	786	4 302	5

Okresy v nájdeneých zhlukoch sú v poradí od najmenej po najväčšiu hustotu rozdelené nasledovne:

Zhluk 1 (Medzilaborce, Krupina, Turčianske Teplice, Sobrance, Poltár, Snina, Brezno, Rožňava, Gelnica, Stropkov, Veľký Krtíš, Liptovský Mikuláš, Revúca, Rimavská Sobota, Banská Štiavnica, Svidník, Žarnovica);

Zhluk 2 (Malacky, Detva, Košice - okolie, Tvrdošín, Levice, Kežmarok, Dolný Kubín, Bardejov, Zlaté Moravce, Bánovce nad Bebravou, Stará Ľubovňa, Námestovo, Humenné, Myjava, Lučenec, Zvolen, Senica, Levoča, Ružomberok, Žiar nad Hronom, Poprad);

Zhluk 3 (Komárno, Trebišov, Vranov nad Topľou, Michalovce, Nové Mesto nad Váhom, Dunajská Streda, Nové Zámky, Bytča, Sabinov, Púchov, Čadca, Topoľčany, Martin, Skalica, Banská Bystrica, Považská Bystrica);

Zhluk 4 (Prievidza, Galanta, Šaľa, Pezinok, Partizánske, Spišská Nová Ves, Senec, Trenčín, Piešťany, Hlohovec, Ilava, Trnava, Prešov, Nitra, Žilina, Kysucké Nové Mesto);

Zhluk 5 (Košice 1, Bratislava 3, Košice 4, Bratislava 4, Košice 2, Bratislava 2, Bratislava 5, Košice 3, Bratislava 1).

Pre interpretovanie rozdielov medzi zhlukmi sme urobili ad hoc Mannov-Whitneyov presný test v SPSS pre rozdiel v parametre polohy. Jeho hodnota je čisto interpretačná, pretože pri každom vhodnom rozdelení na zhluky sú rozdiely významné a navyše ide o základný súbor. Z výsledkov testu vyplýva:

V ploche sa od seba významne líšia mestské okresy v zhluke číslo 5 od okresov v štyroch ostatných zhlukoch ($p < 0,001$). Príčinou je menšia plocha okresov v zhluke 5.

V počte obyvateľov je významný rozdiel medzi okresmi v zhľuku číslo 1 a ostatnými zhľukmi (max $p < 0,01$). Príčinou je menší absolútny počet obyvateľov okresov v zhľuku 1 v porovnaní s ostatnými.

V hustote obyvateľstva sú významné rozdiely medzi všetkými dvojicami zhľukov okresov ($p < 0,001$).

Záver

Na základe voľne dostupných údajov z databázy RegDat Štatistického úradu SR sme urobili štatistickú analýzu plošnej veľkosti súčasných okresov a počtu ich obyvateľov za rok 2007. Z jej výsledkov vyplýva, že posledné rozdelenie územia Slovenskej republiky na základe Zákona č. 221/1996 Z. z. o územnom a správnom usporiadaní SR na 79 okresov spôsobilo nehomogenitu ich štatistických distribúcií v zmysle multimodality. Príčinu nehomogenity sme našli použitím regresného zhľukovania, ktoré jednoznačne identifikovalo 5 zhľukov okresov v spoločnom dvojrozmernom priestore ukazovateľov plošnej veľkosti okresov a počtu ich obyvateľov. Ich interpretácia nie je na prvý pohľad jasná a bude predmetom ďalšieho výskumu.

Literatúra

KOREC, P. et al. 2005. Regionálny rozvoj Slovenska v rokoch 1989-2004 : Identifikácia menej rozvinutých regiónov Slovenska. 1. vyd. Bratislava : Geo-grafika, 2005. ISBN 80-969338-0-9

KOVANICOVÁ, D. - KOVANIC, P. Poklady skryté v účetnictví - díl II: Finanční analýza účetním výkazů, Praha : Polygon 1995 ISBN 80-85967-07-3

KOVANICOVÁ, D. - KOVANIC, P. Poklady skryté v účetnictví - díl III: Finanční řízení rozvoje podniku, Praha : Polygon 1996 ISBN 80-85967-35-9

SPÄTH, H. 1985. Cluster Dissection and Analysis. Theory, FORTRAN Programs, Examples. Ellis Horwood, Chichester. ISBN 0853127360

Adresa autora:

RNDr. Samuel Koróny, PhD.

Ústav vedy a výskumu UMB

Cesta na amfiteáter 1

974 01 Banská Bystrica

Email: samuel.korony@umb.sk

Použitie bázy fuzzy pravidiel pri ohodnocovaní finančného zdravia podnikov v Slovenskej republike

Evaluating Financial Health of Slovak Companies Using Fuzzy Rule Base

Pavol Král', Vladimír Hiadlovský

Abstract: The aim of this paper is to discuss substantial problems connected to the prediction of possible financial distress in the case of the Slovak companies. We focus our attention on the application of fuzzy set theory in this process. A fuzzy rule base emulating an expert decision-making process is used to evaluate the financial health of companies. The proposed approach is illustrated using the open source statistical software R.

Key words: fuzzy sets, fuzzy rule base, financial health, R

Kľúčové slová: fuzzy množiny, báza fuzzy pravidiel, finančné zdravie, R

1. Úvod

Pri posudzovaní finančného zdravia podniku a predpovedaní prípadných finančných problémov podnikov sa využívajú rôzne finančné ukazovatele. Môžeme ich použiť ako vstup pre expertný odhad alebo pre tvorbu rôznych modelov s využitím napríklad viacrozmerných štatistických metód. Príkladom expertného prístupu je Kralickov quick test (pozri [4]), ktorý je vytvorený implementáciou subjektívnych teoretických vedomostí a praktických skúseností ekonóma – tvorcu testu a transformuje ich do výpočtu celkového skóre príslušného podniku s využitím vybraných finančných ukazovateľov. Interpretácia získaného výsledku sa opäť odvíja od teoretických znalostí a praktických skúseností tvorcu tohto testu. Príkladom rýdzo kvantitatívneho prístupu je použitie rôznych klasifikačných a diskriminačných metód. Prvou viacrozmernou štatistickou metódou používanou na tieto účely bola diskriminačná analýza (pozri [2]). Okrem samotnej diskriminačnej analýzy sa v súčasnosti používajú najmä klasifikačné stromy, klasifikačné lesy, logistická regresia a neurónové siete. V týchto prípadoch je rozhodnutie o stave podniku založené na výstupoch modelu, ktorý rezultuje z použitia zvolenej metódy na vhodnú, obyčajne pomerne rozsiahlu, dátovú množinu. Subjektivita rozhodovateľa sa tu obmedzuje len na znalosť podmienok aplikovateľnosti jednotlivých metód a schopnosť interpretovať model. Obidva prístupy majú viaceré výhody a nevýhody. Hlavnou nevýhodou prístupu založeného na vybraných štatistických metódach je jeho obmedzená časová platnosť (pozri [1]) a zložitosť modifikácie modelu pri zmenených podmienkach podmienená dostupnosťou kvalitných vstupných údajov. Ďalším problémom je často nevhodná štruktúra vstupného súboru, keď množstvo podnikov, ktorých typ stavu chceme prioritne predikovať, je výrazne nižšie v porovnaní s ďalšími skupinami. To znamená, že musíme byť nadmieru opatrní pri výbere vhodnej metódy, konštrukcii príslušného modelu a najmä pri jeho samotnej interpretácii, pretože môže dôjsť k výraznému nadhodnoteniu jeho predikčnej schopnosti. Výhodou je naopak veľmi dobrá kvalita predikcie pri existencii kvalitného dátového súboru.

V prípade expertných prístupov založených na výpočte celkového skóre firmy na základe jej hodnôt finančných ukazovateľov je výhodou výrazná jednoduchosť jeho realizácie a jednoduchá interpretácia. Nevýhodou je stanovenie striktných hraníc pri interpretácii, čo môže viesť k zaradeniu firiem s takmer identickými hodnotami finančných ukazovateľov do rôznych skupín. Túto nevýhodu je síce možné eliminovať použitím fuzzy čísel pri výpočte celkového skóre, ale získaný výsledok je potom ťažšie interpretovateľný. Väčšou nevýhodou tohto prístupu je, že väčšinou neberie do úvahy možné vzťahy medzi ukazovateľmi a každý

z nich vníma izolovane. Z uvedeného je zrejmé, že je vhodné obidva prístupy kombinovať, čím je možné využiť výhody obidvoch a zároveň aspoň čiastočne eliminovať ich nevýhody.

V našom článku budeme prezentovať alternatívny prístup, pri ktorom budeme vychádzať prioritne zo subjektívnych znalostí rozhodovateľa o jednotlivých finančných ukazovateľoch a ich vzájomných vzťahoch. Budeme predpokladať, že rozhodovateľ je schopný vytvoriť jednoduchú bázu pravidiel vyjadrujúcich vzťah medzi hodnotami finančných ukazovateľov a ním odhadovanou subjektívnou pravdepodobnosťou výskytu finančných problémov podniku. Tieto pravidlá sú vo svojej podstate často vágne, preto na ich konštrukciu i samotné vyhodnotenie použijeme teóriu fuzzy množín.

Na konštrukciu modelu založeného na báze fuzzy pravidiel môžeme použiť R, prostredie a jazyk pre štatistické výpočty a grafiku, ktoré je voľne dostupné na adrese (<http://www.r-project.org/>).

Príspevok je členený nasledujúcim spôsobom:

V nasledujúcej časti príspevku budeme prezentovať základy teórie fuzzy množín s dôrazom na vysvetlenie základných pojmov, tretiu časť príspevku venujeme základom fuzzy inferencie, konštrukcii bázy pravidiel a defuzifikácii, v štvrtej časti príspevku stručne popíšeme možnosti využitia štatistického softvéru R pri konštrukcii fuzzy inferenčného systému a v záverečnej časti na základe subjektívnych znalostí rozhodovateľa skonštruujeme príklad fuzzy inferenčného systému použiteľného na hodnotenie finančného zdravia podniku na základe hodnôt vybraných finančných ukazovateľov.

2. Základy teórie fuzzy množín

Aby sme mohli skonštruovať bázu fuzzy pravidiel a zodpovedajúci fuzzy inferenčný systém, musíme poznať základné pojmy z teórie fuzzy množín

Za rok vzniku teórie fuzzy množín môžeme považovať rok 1965 ([7]). Základným pojmom teórie fuzzy množín je fuzzy množina. Každá fuzzy množina je jednoznačne určená svojou funkciou príslušnosti.

Definícia 1 (napríklad [3])

Nech U je základnou množinou. Funkciou príslušnosti fuzzy podmnožiny A množiny U nazveme zobrazenie $\mu_A : U \rightarrow \langle 0, 1 \rangle$. Množinu všetkých fuzzy podmnožín U označíme $F(U)$.

V prípade, že chceme zaviesť pre množiny z $F(U)$ množinové operácie zjednotenie, prienik a doplnok, použijeme tzv. t-normy, t-konormy a negátory.

Definícia 2 (napríklad [3])

Triangulárna norma T je binárna operácia na jednotkovom intervale, ktorá je komutatívna, asociatívna, neklesajúca v oboch argumentoch a jej neutrálnym prvkom je 1.

Definícia 3 (napríklad [3])

Triangulárna konorma S je binárna operácia na jednotkovom intervale, ktorá je komutatívna, asociatívna, neklesajúca v oboch argumentoch a jej neutrálnym prvkom je 0.

Historicky najstaršou t-normou (t-konormou) je minimum (maximum).

Definícia 4 (napríklad [3])

Negátor N je nerastúca unárna operácia na jednotkovom intervale, pre ktorú platí $N(1) = 0, N(0) = 1$.

Najčastejšie používaným negátorom, ktorý sa nazýva štandardným negátorom, je negátor definovaný pre každé $u \in \langle 0, 1 \rangle$ ako $N(u) = 1 - u$.

Množinové operácie potom definujeme bodovo nasledujúcim spôsobom:

Definícia 5 (napríklad [3])

Nech T je t-norma, S je t-konorma a N je negátor. Potom zovšeobecnený prienik $\cap_T$, zjednotenie $\cup_S$ a doplnok co_N fuzzy množín definujeme nasledujúcimi vzťahmi: pre všetky $A, B \in F(U)$ a pre všetky $u \in U$,

$$\begin{aligned}\mu_{A \cap_T B}(u) &= T(\mu_A(u), \mu_B(u)), \\ \mu_{A \cup_S B}(u) &= S(\mu_A(u), \mu_B(u)), \\ \mu_{\text{co}_N(A)}(u) &= N(\mu_A(u)).\end{aligned}\tag{1}$$

Ak ako základnú množinu U uvažujeme množinu reálnych čísel, hovoríme o fuzzy kvantitách. Najčastejšie používaným typom fuzzy kvantít sú tzv. fuzzy čísla.

Definícia 6 (napríklad [3])

Fuzzy číslo je fuzzy množina $A \in F(R)$, pre ktorú platí

1. μ_A je normálna, t. j. existuje $u \in R$, pre ktoré platí $\mu_A(u) = 1$,
2. Množina $A_\alpha = \{u \mid u \in R \text{ and } \mu_A(u) \geq \alpha\}$ je pre každé $\alpha \in (0, 1)$ uzavretým intervalom,
3. Množina $\text{supp}(A) = \sup_\alpha \{A_\alpha\}$ je v R ohraničená.

Existujú dve základné typy fuzzy čísel - trojuholníkové a lichobežníkové fuzzy čísla. V oboch prípadoch sú to po častiach lineárne fuzzy čísla. Každé trojuholníkové (lichobežníkové) fuzzy číslo je možné reprezentovať prostredníctvom trojice, resp. štvorice reálnych čísel. Fuzzy čísla budeme v ďalšom texte využívať ako vstupy pri fuzzy inferencii.

3. Základy fuzzy inferencie

Fuzzy inferencia je postup, pri ktorom odvodíme záver na základe bázy fuzzy pravidiel. Tento postup je založený na tzv. zovšeobecnenom modus ponens. Zovšeobecnený modus ponens reprezentuje nasledujúca schéma:

Pravidlo:	AK X je A , POTOM Y je B
Zistenie:	X je A^*

Záver:	Y je B^*

Táto schéma je nazývaná zovšeobecnený modus ponens, ak je splnená podmienka: AK $A = A^*$, POTOM $B = B^*$ (pozri napríklad [3]).

Nech X patrí do $F(U)$ a Y patrí do $F(V)$. Pravidlo vo vyššie uvedenej schéme je možné reprezentovať pomocou fuzzy relácie FR , $FR \in F(U \times V)$. Výstup B^* vzťahujúci sa na vstup A^* vypočítame ako zloženie fuzzy relácie FR a vstupu A^* (pozri napríklad [3]):

$$\mu_{B^*}(v) = \sup_{u \in U} (T(\mu_{FR}(u, v), \mu_{A^*}(u))),\tag{2}$$

kde T je spojitá t-norma.

Vo všeobecnosti nepracujeme s jedným fuzzy pravidlom, ale s viacerými. Tieto fuzzy pravidlá vytvárajú tzv. bázu fuzzy pravidiel. Bázu fuzzy pravidiel je možné definovať nasledujúcim spôsobom:

Definícia 7 (napríklad [6])

Nech Φ je zobrazenie z priestoru vstupov $F(U)$ do priestoru výstupov $F(V)$. Báza fuzzy AK – POTOM pravidiel s n pravidlami, jedným vstupom a jedným výstupom má nasledujúcu podobu:

Pravidlo 1: AK X je A_1 POTOM Y is C_1

...

Pravidlo n : AK X je A_n POTOM Y je C_n

kde $X \in F(U)$ je fuzzy vstup, $Y \in F(V)$ je vstupu zodpovedajúci fuzzy výstup, $A_i \in F(U)$, $i = 1, 2, \dots, n$, sú predpoklady reprezentujúce oblasť aplikability pravidla, $C_i \in F(V)$, $i = 1, 2, \dots, n$, sú dôsledky.

Bázu fuzzy pravidiel môžeme získať napríklad na základe mienky experta. Ak máme bázu pravidiel a vstup X , výstup Y získame ako zloženie fuzzy relácie FR reprezentujúcej uvažovanú bázu pravidiel a vstupu X .

Existuje množstvo možností, ako odvodiť fuzzy reláciu na základe existujúcej bázy pravidiel so vstupom X . My sa obmedzíme na najstarší a najľahšie aplikovateľný prístup Mamdaniho-Asillianiho. Výsledkom tohto prístupu je spojitá fuzzy relácia definovaná nasledujúcim spôsobom:

$$\mu_{FR}(u, v) = \max_i \left(\min(\mu_{A_i}(u), \mu_{C_i}(v)) \right), \quad (3)$$

kde $i = 1, 2, \dots, n$, $u \in U, v \in V$.

Výstup Y vypočítame pomocou nasledujúceho vzťahu

$$\mu_Y(v) = \max_i \left(\sup_{u \in U} \left(\min(\mu_{FR_i}(u, v), \mu_X(u)) \right) \right). \quad (4)$$

Výhodou prístupu Mamdaniho – Asilianiho je napríklad aj skutočnosť, že pri odvodzovaní nezáleží na tom, či najprv vyhodnotíme jednotlivé pravidlá a potom výsledky agregujeme do výslednej podoby (FITA) alebo zvolíme opačný postup (FATI).

Bázu s jedným vstupom je možné jednoducho zovšeobecniť na bázu pravidiel s k vstupmi a jedným výstupom (see [3, 6]):

Pravidlo 1: **AK** X_1 je A_{11} **A** ... **A** X_k je A_{k1} **POTOM** Y je C_1

...

Pravidlo n : **AK** X_n je A_{1n} **A** ... **A** X_k je A_{kn} **THEN** Y je C_n .

Výstup, ktorý odvodíme fuzzy inferenciou s využitím takejto bázy fuzzy pravidiel, je síce fuzzy kvantitou, ale vo všeobecnosti nemusí byť fuzzy číslom. To znamená, že ho nemôžeme priamo interpretovať. Okrem toho je v mnohých prípadoch potrebné, aby sme výsledok fuzzy inferencie dokázali reprezentovať jediným reálnym číslom. Proces, v ktorom získame takúto interpretáciu, sa nazýva defuzzifikácia. Existuje veľmi veľké množstvo defuzzifikačných metód. Výber vhodnej metódy závisí od situácie. Najčastejšie používanou je tzv. metóda ťažiska.

Definícia 8 (napríklad [3])

Nech A je fuzzy množina definovaná na intervale $\langle a, b \rangle$, kde $a \neq b$. Potom ťažiskom fuzzy množiny A nazveme číslo t , pre ktoré platí vzťah:

$$t = \frac{\int_a^b \mu_A(u) u du}{\int_a^b \mu_A(u) du}. \quad (5)$$

4. Fuzzy inferenčný systém v R

Teória fuzzy množín je implementovaná v R balíčku *sets* (pozri [5]). Tento balíček ponúka voľbou *fuzzy logic* možnosť výberu trojice t-norma, t-konorma a negátor, ktorá sa má použiť pri definícii množinových operácií. Dostupné sú nasledujúce voľby: *drastic*, *product*, *Lukasiewicz*, *Fodor*, *Frank*, *Hamacher* a *Zadeh logic*. Základným nastavením je *Zadeh logic*, čo znamená, že použijeme minimum ako t-normu, maximum ako t-konormu a štandardný negátor. Táto logika je použitá aj v Mamdaniho – Asilianiho prístupe. Balíček *sets* ďalej umožňuje definovať fuzzy množiny, fuzzy čísla, fuzzy premenné a bázy fuzzy pravidiel. Báza fuzzy pravidiel a fuzzy premenné môžu byť kombinované do fuzzy inferenčného systému. Výslednú fuzzy kvantitu môžeme defuzifikovať s využitím niekoľkých metód, ktorých názvy naznačujú podstatu príslušnej metódy. Balíček poskytuje nasledujúce metódy defuzifikácie: *centroid* (metóda ťažiska), *meanofmax*, *smallestofmax*, *largestofmax*.

5. Hodnotenie finančného zdravia podniku s využitím bázy fuzzy pravidiel

Konštrukciu modelu je nevyhnutné začať výberom vhodných finančných ukazovateľov. Je potrebné, aby vybraných ukazovateľov bolo primerané množstvo a aby boli v praxi často používané. Rozhodli sme sa subjektívne vybrať nasledujúce ukazovatele:


TZ – tokové zadĺženie, ROE – rentabilita vlastného kapitálu, CZA – celková zadĺženosť aktív, DUZ – doba úhrady záväzkov, UK – úrokové krytie. Tieto ukazovatele sú v praxi často používané a pre naše potreby dostatočne popisujú globálnu finančnú situáciu podniku.

Z dôvodu výpočtovej jednoduchosti boli pre všetky uvedené ukazovatele stanovené hranice hodnôt, ktoré môžu nadobúdať. Hodnoty presahujúce tieto hranice sú potom transformované na dolnú resp. hornú hranicu. Uvažované hranice sú uvedené v nasledujúcej tabuľke. Pre jednoduchosť v nej neuvádzame merné jednotky, keďže pri našom výpočte nehrajú úlohu.

Tabuľka 7: Hranice hodnôt finančných ukazovateľov

Finančný ukazovateľ	Dolná hranica	Horná hranica
TZ	0	20
ROE	-15	30
CZA	30	95
DUZ	0	120
UK	0	20

Zvolené finančné ukazovatele transformujeme do intervalu $\langle 0;10 \rangle$, aby sme získali jednotnú základnú množinu pre všetky vstupy a zjednodušili si tak výpočet. Pre každý z uvažovaných ukazovateľov vytvoríme jazykovú škálu s piatimi stupňami *veľmi nízky*, *nízky*, *stredný*, *vysoký* a *veľmi vysoký*. Každý hodnote fuzzy škály priradíme trojuholníkové fuzzy číslo tak, aby všetky priradené fuzzy čísla tvorili fuzzy rozklad intervalu $\langle 0;10 \rangle$ v zmysle Ruspiniho, t. z. pre každý prvok u z tohto intervalu musí platiť $\sum_i \mu_{A_i}(u) = 1$. Pre jednoduchosť budeme uvažovať identickú šírku fuzzy čísel. Na nasledujúcom obrázku môžete vidieť príklad takéhoto rozkladu.



Obrázok 14: Reprezentácia jazykovej škály s tromi hodnotami

V nasledujúcom kroku skonštruujeme bázu fuzzy pravidiel s viacerými vstupmi a jedným výstupom – „pravdepodobnosťou“ finančných problémov (PFP). Rovnako ako v prípade finančných ukazovateľov uvažujeme päťstupňovú jazykovú škálu, ale nad jednotkovým intervalom. Sformulovali sme nasledujúcich päť pravidiel, ktoré by mali dostatočne ohodnocovať finančné zdravie podniku:

AK TZ je veľmi nízke A ROE je veľmi vysoká, POTOM PFP je veľmi nízka

AK TZ je vysoké A ROE je nízka POTOM PFP je vysoká

AK CZA je nízka A DUZ je nízka A UK je vysoké POTOM PFP je nízka

AK CZA je stredná A DUZ je vysoké A UK je vysoké POTOM PFP je stredná

AK CZA je veľmi vysoká A ROE je veľmi nízka A DUZ je veľmi vysoká POTOM PFP je veľmi vysoká

S využitím tejto bázy pravidiel a vzťahu (4) vieme pre každý podnik vypočítať „pravdepodobnosť“ finančných problémov. Táto pravdepodobnosť je vo všeobecnosti fuzzy kvantitou. Pre jednoduchú interpretáciu takto získanú fuzzy množinu zväčša defuzifikujeme na základe vzťahu (5).


Použitie navrhutej bázy pravidiel si budeme ilustrovať na dvoch podnikoch. Jeden z podnikov je reprezentantom finančne zdravého podniku, v prípade druhého hodnoty finančných ukazovateľov indikujú možné problémy podniku. Hodnoty ukazovateľov opäť uvádzame bez použitia merných jednotiek:

„Zdravý“ podnik: CZA = 30 , DUZ = 30, ROE = 15, TZ = 2, UK = 7,


„Nedravý“ podnik: CZA = 75 , DUZ = 100, ROE = 5, TZ = 20, UK = 0.5.

S použitím nášho fuzzy inferenčného systému získame pre tieto podniky nasledujúce výsledky

Pre „zdravý“ podnik:



Obrázok 2: Ukážka možného výsledku fuzzy inferencie pre „zdravý” podnik
 Výsledkom defuzifikácie je číslo 0,08.
 Pre „nezdravý” podnik:



Obrázok 3: Ukážka možného výsledku fuzzy inferencie pre „nezdravý” podnik
 Výsledkom defuzifikácie je číslo 0,60237.

Je zrejmé, že náš fuzzy inferenčný systém nám poskytuje ľahko interpretovateľné výsledky, ktoré sú v súlade s naším očakávaním.

6. Záver

Na základe získaných výsledkov si dovoľujeme tvrdiť, že použitie vhodnej bázy fuzzy pravidiel môže byť užitočným nástrojom pre posudzovanie finančného zdravia podniku, pretože poskytuje ľahko interpretovateľné výsledky, база pravidiel nie je závislá na kvalite vstupnej dátovej množiny a je možná jej pomerne ľahká modifikácia na základe doplnkových expertných informácií. База pravidiel prezentovaná v tomto článku je samozrejme prvotným pokusom o prezentáciu alternatívneho prístupu k posudzovaniu finančného zdravia podnikov a je nevyhnutná jej ďalšia verifikácia, prípadné úpravy a doplnenie o ďalšie pravidlá. Predmetom hlbšej diskusie môže byť aj súbor ukazovateľov použitých pri konštrukcii jednotlivých fuzzy pravidiel, stanovenie hraníc finančných ukazovateľov i voľba samotných pravidiel. Potrebné je aj detailné porovnanie s momentálne zaužívanými postupmi, najmä z hľadiska kvality a stability kvality predikcie v slovenských podmienkach, ktorému sa z dôvodu obmedzeného rozsahu podrobnejšie nevenujeme. Okrem toho si musíme uvedomiť fakt, že sme sa z dôvodu jednoduchosti a rozsahu implementácie metód teórie fuzzy množín v

programe R, venovali len historicky najstaršiemu a najjednoduchšiemu prístupu Mamdaniho – Asilianiho, napriek existencii mnohých modernejších prístupov, napríklad bázy s podmiennečne sa zapalujúcimi pravidlami.

Všetky vyššie spomenuté skutočnosti budú predmetom ďalšieho intenzívneho vedeckého výskumu autorov.

PodĎakovanie. Tento príspevok vznikol s podporou grantu VEGA 1/4634/07.

7. Literatúra

- [1] ALTMAN, E. I. 2000. Predicting financial distress of companies: Revisiting the Z-score and Z Model. Working paper, 2000, www.stern.nyu.edu.
- [2] ALTMAN, E. I. 1968. Financial Ratios, Discriminant Analysis, and the Prediction of Corporate Bankruptcy. *Journal of Finance*, 23(4), 1968, s. 589-609.
- [3] KOLESÁROVÁ, A. – KOVÁČOVÁ, M. 2004. Fuzzy Sets and its Applications. Slovak University of Technology, Bratislava, 2004. 160 s. ISBN 80-227-2036-4.
- [4] KRÁLICEK, P. 1995. Kennzahlen für Geschäftsführer. Ueberreuter, Wien 1995
- [5] MEYER, D. – HORNIK, K. 2009. Generalized and Customizable Sets in R. *Journal of Statistical Software* 31(2), 2009, s. 1 – 27, <http://www.jstatsoft.org/v31/i02/>.
- [6] NAVARA, M. Fuzzy Control, http://cmp.felk.cvut.cz/~navara/fl/fc_Foligno04.pdf.
- [7] ZADEH, L.A. 1965. Fuzzy Sets. *Information and Control* 8, 1965, s. 338 – 353.

Adresa autora (-ov):

RNDr. Pavol Kráľ, PhD.
Tajovského 10
975 90 Banská Bystrica
pavol.kral@umb.sk

Ing. Vladimír Hiadlovský
Tajovského 10
975 90 Banská Bystrica
vladimir.hiadlovsky@umb.sk

Špecifiká patologických zmien pri vrodených a dedičných dystrofiách sietnice

The specifics of the pathological changes by the hereditary dystrophies of the retina

Anton Gerinec, Miroslav Chynoranský, Ján Luha, Tamara Štetinová

Abstract: The authors in their abstract presented the results of statistic comparison of following electrophysiologic investigation of the group of patients, who suffered from various types of herededegenerative diseases of the retina and the optic nerve in their abstract.

The parametres were very various, it's s depending on the concrete type of retinal disease, of course, so that the statistic parametres very various, too.

Key words: hereditary retinal dystrophies, EOG, ERG, VEP, statistics.

Kľúčové slová: tapetoretinálne dystrofie, EOG, ERG, VEP, štatistika.

1. Úvod

Na Klinike detskej oftalmológie v Bratislave boli od októbra r. 2003 do októbra r.2008 skúmané patologické zmeny v zmysle rôznych foriem vrodeného a dedičného heredodegeneratívneho ochorenia sietnice a súvisiacich anatomickeo-histologických štruktúr na súbore 495 pacientov.

Na skúmanie boli využité elektrofyziologické vyšetrovacie metódy používané pri diagnostike porúch vizuálneho systému, ktoré sú výhodné predovšetkým v prípadoch, kedy oftalmológ vyžaduje objektivizáciu klinického nálezu, alebo potrebuje výsledok na stanovenie predklinického štádia ochorenia.

Svetlo, dopadajúce na retinu (sietnicu oka), je konvertované zložitým systémom na elektrické signály. Špeciálne elektródy, umiestnené na určité konkrétne miesta pozdĺž zrakovej dráhy zaznamenávajú odpovede, evokované svetelným stimulom oka. Tento princíp vyjadruje podstatu rôznych elektrofyziologických testov- ERG, PERG, EOG, VEP

Okrem pohlavia, veku a diagnózy, boli skúmané nasledovné charakteristiky: dA predstavoval tzv.diferenciu amplitúd, teda číselný rozdiel v amplitúde medzi vlnou -a- a -b- v ERG zázname. Fyziologická hodnota varíruje medzi cca 5 až 15 mikrovoltami. Latencie vlny -a- a -b- boli zosnímané a zaznamenané v milisekundách, fyziologické hodnoty pre vlnu -a- boli okolo 21ms, pre vlnu -b- cca 45ms. Všetky nami získané parametre boli v zhode s celosvetovými parametrami a predovšetkým podľa odporúčaní celosvetovej medzinárodnej organizácie pre elektrofyziológiu ISCEV/ISCERG, s príslušným prepočtom, vzhľadom na použitie kožných elektród na našom pracovisku.

Je potrebné pripomenúť, že vlna -a- predstavuje odpoveď fotoreceptorov (tyčíniek a čapíkov, fotosenzitívnych elementov sietnice), vlna -b- zase odpoveď bipolárnych buniek sietnice. Pri vlne b sa zaznamenávajú dva vrcholy b1 a b2.

V príspevku sa venujeme štatistickej analýze premenných dA_a Lat_a dA_b1 Lat_b1 dA_b2 Lat_b2 pre ERG vyšetrenie.

2. Základné charakteristiky skúmaného súboru

V skúmanom súbore bolo 60 % mužov a 40 % žien vo veku od 0 do 70 rokov, pričom vo vekovej kategórii od 0 do 20 rokov bolo 33%, v kategórii od 21 do 34 rokov 30 % a v kategórii od 35 do 70 rokov 37% pacientov. Rozloženie podľa diagnóz je v tabuľke:

M_Stargardt	M_Best	Retinoschisis_iuvenilis	Dystrophia_conorum	TRD_pigmentosa	Albinismus	Drúzy_makuly_ADD	TRD_sec_Leber	Fundus_flavimaculatus	Fundus_albipunctatus	Pattern_D	Dyschromatopsia	Hemeralopia_essentialis
12%	7%	5%	5%	34%	6%	2%	4%	15%	3%	1%	5%	2%

Pri diagnóze č. 8 TRD sec.Leber bolo namerané iba pohlavie, vek a diagnóza – skúmané premenné pri tejto diagnóze nie je možné merať, nakoľko od okamihu narodenia dieťaťa sú na sietnici prítomné ťažké vývojové zmeny, navyše stav je nemenný a detičky sú nevidomé. Podrobnejšie rozloženie podľa pohlavia, veku a diagóz je v kontingenčnej tabuľke:

pohl Pohlavie * vek_kat kategórie veku * diagnoza diagnóza Crosstabulation

				vek_kat kategórie veku			Total
diagnoza diagnóza				1 0-20	2 21-34	3 35-70	1 0-20
1 M.Stargardt	pohl Pohlavie	1 muž	Count	1	5	18	24
			% within pohl Pohlavie	4,2%	20,8%	75,0%	100,0%
			% within vek_kat kategórie veku	11,1%	31,3%	56,3%	42,1%
		2 žena	Count	8	11	14	33
			% within pohl Pohlavie	24,2%	33,3%	42,4%	100,0%
			% within vek_kat kategórie veku	88,9%	68,8%	43,8%	57,9%
	Total		Count	9	16	32	57
			% within pohl Pohlavie	15,8%	28,1%	56,1%	100,0%
			% within vek_kat kategórie veku	100,0%	100,0%	100,0%	100,0%
2 M.Best	pohl Pohlavie	1 muž	Count	12	13	11	36
			% within pohl Pohlavie	33,3%	36,1%	30,6%	100,0%
			% within vek_kat kategórie veku	100,0%	100,0%	100,0%	100,0%
	Total		Count	12	13	11	36
			% within pohl Pohlavie	33,3%	36,1%	30,6%	100,0%
			% within vek_kat kategórie veku	100,0%	100,0%	100,0%	100,0%
3 Retinoschisis_iuvenilis	pohl Pohlavie	1 muž	Count	15	9	2	26
			% within pohl Pohlavie	57,7%	34,6%	7,7%	100,0%
			% within vek_kat kategórie veku	100,0%	100,0%	100,0%	100,0%
	Total		Count	15	9	2	26
			% within pohl Pohlavie	57,7%	34,6%	7,7%	100,0%
			% within vek_kat kategórie veku	100,0%	100,0%	100,0%	100,0%
4 Dystrophia_conorum	pohl Pohlavie	1 muž	Count	12	3	3	18
			% within pohl Pohlavie	66,7%	16,7%	16,7%	100,0%
			% within vek_kat kategórie veku	92,3%	42,9%	100,0%	78,3%
		2 žena	Count	1	4	0	5
			% within pohl Pohlavie	20,0%	80,0%	,0%	100,0%
			% within vek_kat kategórie veku	7,7%	57,1%	,0%	21,7%
	Total		Count	13	7	3	23
			% within pohl Pohlavie	56,5%	30,4%	13,0%	100,0%
			% within vek_kat kategórie veku	100,0%	100,0%	100,0%	100,0%
5 TRD pigmentosa	pohl Pohlavie	1 muž	Count	20	25	50	95
			% within pohl Pohlavie	21,1%	26,3%	52,6%	100,0%
			% within vek_kat kategórie veku	58,8%	62,5%	54,3%	57,2%

	2 žena		Count	14	15	42	71
			% within pohl Pohlavie	19,7%	21,1%	59,2%	100,0%
			% within vek_kat kategórie veku	41,2%	37,5%	45,7%	42,8%
	Total		Count	34	40	92	166
			% within pohl Pohlavie	20,5%	24,1%	55,4%	100,0%
			% within vek_kat kategórie veku	100,0%	100,0%	100,0%	100,0%
6 Albinizmus	pohl Pohlavie	1 muž	Count	18			18
			% within pohl Pohlavie	100,0%			100,0%
			% within vek_kat kategórie veku	64,3%			64,3%
	2 žena		Count	10			10
			% within pohl Pohlavie	100,0%			100,0%
			% within vek_kat kategórie veku	35,7%			35,7%
	Total		Count	28			28
			% within pohl Pohlavie	100,0%			100,0%
			% within vek_kat kategórie veku	100,0%			100,0%
7 Drúzy makuly ADD	pohl Pohlavie	1 muž	Count	0	6		6
			% within pohl Pohlavie	,0%	100,0%		100,0%
			% within vek_kat kategórie veku	,0%	85,7%		75,0%
	2 žena		Count	1	1		2
			% within pohl Pohlavie	50,0%	50,0%		100,0%
			% within vek_kat kategórie veku	100,0%	14,3%		25,0%
	Total		Count	1	7		8
			% within pohl Pohlavie	12,5%	87,5%		100,0%
			% within vek_kat kategórie veku	100,0%	100,0%		100,0%
8 TRD sec.Leber	pohl Pohlavie	1 muž	Count	9			9
			% within pohl Pohlavie	100,0%			100,0%
			% within vek_kat kategórie veku	42,9%			42,9%
	2 žena		Count	12			12
			% within pohl Pohlavie	100,0%			100,0%
			% within vek_kat kategórie veku	57,1%			57,1%
	Total		Count	21			21
			% within pohl Pohlavie	100,0%			100,0%
			% within vek_kat kategórie veku	100,0%			100,0%
9 Fundus flavimaculatus	pohl Pohlavie	1 muž	Count	7	12	12	31
			% within pohl Pohlavie	22,6%	38,7%	38,7%	100,0%
			% within vek_kat kategórie veku	46,7%	44,4%	35,3%	40,8%
	2 žena		Count	8	15	22	45
			% within pohl Pohlavie	17,8%	33,3%	48,9%	100,0%
			% within vek_kat kategórie veku	53,3%	55,6%	64,7%	59,2%
	Total		Count	15	27	34	76
			% within pohl Pohlavie	19,7%	35,5%	44,7%	100,0%
			% within vek_kat kategórie veku	100,0%	100,0%	100,0%	100,0%
10 Fundus albipunctatus	pohl Pohlavie	1 muž	Count	1	7		8
			% within pohl Pohlavie	12,5%	87,5%		100,0%
			% within vek_kat kategórie veku	100,0%	53,8%		57,1%
	2 žena		Count	0	6		6
			% within pohl Pohlavie	,0%	100,0%		100,0%
			% within vek_kat kategórie veku	,0%	46,2%		42,9%
	Total		Count	1	13		14
			% within pohl Pohlavie	7,1%	92,9%		100,0%
			% within vek_kat kategórie veku	100,0%	100,0%		100,0%
11 Pattern D	pohl Pohlavie	1 muž	Count	2	3		5
			% within pohl Pohlavie	40,0%	60,0%		100,0%
			% within vek_kat kategórie veku	100,0%	100,0%		100,0%
	Total		Count	2	3		5
			% within pohl Pohlavie	40,0%	60,0%		100,0%
12 Dyschromatopsia	pohl Pohlavie	1 muž	Count	4	6	3	13
			% within pohl Pohlavie	30,8%	46,2%	23,1%	100,0%

				% within vek_kat kategórie veku	36,4%	54,5%	100,0%	52,0%				
				2 žena	Count	7	5	0	12			
					% within pohl Pohlavie	58,3%	41,7%	,0%	100,0%			
					% within vek_kat kategórie veku	63,6%	45,5%	,0%	48,0%			
				Total	Count	11	11	3	25			
					% within pohl Pohlavie	44,0%	44,0%	12,0%	100,0%			
					% within vek_kat kategórie veku	100,0%	100,0%	100,0%	100,0%			
					13 Hemeralopia essentialis	pohl Pohlavie	1 muž	Count		3	4	7
								% within pohl Pohlavie		42,9%	57,1%	100,0%
				% within vek_kat kategórie veku					75,0%	66,7%	70,0%	
2 žena	Count		1	2		3						
	% within pohl Pohlavie		33,3%	66,7%		100,0%						
	% within vek_kat kategórie veku		25,0%	33,3%		30,0%						
	Total	Count		4		6	10					
% within pohl Pohlavie			40,0%	60,0%	100,0%							
% within vek_kat kategórie veku			100,0%	100,0%	100,0%							

Na doplnenie charakterizácie skúmaného súboru pacientov uvádzame v tabuľke základné štatistické charakteristiky sledovaných premenných za celý súbor a za podsúbory podľa pohlavia, vekových kategórií a diagnóz. Taktiež uvádzame P-hodnoty analýzy rozptylu testovania vplyvu znakov pohlavie vek a diagnóza na skumane premenne.

kat_znak	dA_a	Lat_a	dA_b1	Lat_b1	dA_b2	Lat_b2	n
spolu	8,15	31,62	9,35	55,01	8,94	62,58	495
muži	8,71	30,87	9,33	54,06	9,27	61,33	296
ženy	7,28	32,81	9,38	56,51	8,43	64,56	199
P-hodnota AR pre znak pohlavie	0,002	0,000	0,938	0,007	0,091	0,002	
0-20	9,75	31,07	10,33	54,21	10,06	60,04	162
21-34	8,73	30,83	10,15	51,33	9,86	59,28	150
35-70	6,38	32,73	7,88	58,77	7,26	67,44	183
P-hodnota AR pre znak vek	0,000	0,001	0,000	0,000	0,000	0,000	
M.Stargardt	9,24	31,07	12,97	53,9	12,88	59,4	57
M.Best	14,81	31,2	16,14	49,73	15,71	53,49	36
Retinoschisis juvenilis	14,07	25,22	3,52	46,07	4,16	48,08	26
Dystrophia conorum	7,9	29,4	9,76	48,43	9,95	51,7	23
TRD pigmentosa	3,41	34,12	4,7	63,14	5,11	72,6	166
Albinizmus	11,16	33,53	11,65	55,36	11,71	64,45	28
Drúzy makuly ADD	7,88	25,18	10,28	49,63	14,85	53,36	8
Fundus flavimaculatus	9,13	33,45	11,66	56,37	8,13	66,61	76
Fundus albipunctatus	10,96	23,76	17,03	23,76	15,94	45,44	14
Pattern D	10,26	27,2	10,58	49,4	8,64	54,52	5
Dyschromatopsia	11,9	24,88	13,06	46,16	12,24	47,39	25
Hemeralopia essentialis	4,75	36,22	5,23	58,44	8,41	62	10
P-hodnota AR pre znak diagnóza	0,000	0,000	0,000	0,000	0,000	0,000	

3. Vybrané výsledky štatistickej analýzy

Ako vidno z výsledkov tabuľky uvedenej na záver druhej kapitoly skúmané premenné, charakterizujúce vlastnosti pacientov, sa významne líšia v závislosti od diagnózy pacienta,

pohlavia (okrem dA_b1 a dA_b2, pri pohlaví), veku a čo je podstatné aj podľa priebehu liečenia – čo dokladujeme v ďalšom texte.

Priebeh liečenia, resp. presnejšie, sledovanie progresie alebo regresie ochorenia jednotlivého pacienta charakterizujú tri merania - premenné dA_a, dA_b1, dA_b2, resp. Lat_a, Lat_b1, Lat_b2. Na základe nameraných údajov sme rozoznávali, či sa vplyvom podpornej, nekauzálnej liečby zdravotný stav mení a ako. Nakoľko sme skúmali skupinu pacientov s dystrofiami sietnice, ktoré majú ťažký priebeh a mnohé z nich infaustný priebeh quoad visum, výsledky jednotlivých meraní sa menili minimálne, ale i nekauzálna liečba mala pozitívne opodstatnenie vo väčšine prípadov.

Výsledky párových t-testov za celý súbor pacientov vykazujú signifikantné odlišnosti podľa priebehu vyšetrení.

Paired Samples Statistics

		Mean	N	Std. Deviation	Std. Error Mean	Sig. (2-tailed)
Pair 1	dA_a	8,1539	449	4,72567	,22302	0,000
	dA_b1	9,3503	449	5,57160	,26294	
Pair 2	dA_a	8,1539	449	4,72567	,22302	0,000
	dA_b2	8,9434	449	5,16994	,24398	
Pair 3	dA_b1	9,3503	449	5,57160	,26294	0,000
	dA_b2	8,9434	449	5,16994	,24398	
Pair 4	Lat_a	31,6203	449	4,99120	,23555	0,038
	Lat_b1	55,0098	449	9,42989	,44502	
Pair 5	Lat_a	31,6203	449	4,99120	,23555	0,000
	Lat_b2	62,5831	449	11,03859	,52094	
Pair 6	Lat_b1	55,0098	449	9,42989	,44502	0,000
	Lat_b2	62,5831	449	11,03859	,52094	


Zaujímavá je podrobnejšia analýza priebehu liečenia podľa diagnóz. V tabuľke výsledkov párového t-testu vidno podrobnejšie priebeh liečenia skupín pacientov podľa jednotlivých diagnóz. Nesignifikantná zmena priebehu liečenia je zaznamenaná iba v niekoľkých prípadoch.

Paired Samples Test, Podľa diagnóz

Diagnóza	č. páru	pár	Sig. (2-tailed)	Diagnóza	č. páru	pár	Sig. (2-tailed)
1 M.Stargardt	Pair 1	dA_a - dA_b1	,000	7 Drúzy makuly ADD	Pair 1	dA_a - dA_b1	,032
	Pair 2	dA_a - dA_b2	,000		Pair 2	dA_a - dA_b2	,000
	Pair 3	dA_b1 - dA_b2	,625		Pair 3	dA_b1 - dA_b2	,000
	Pair 4	Lat_a - Lat_b1	,000		Pair 4	Lat_a - Lat_b1	,000
	Pair 5	Lat_a - Lat_b2	,000		Pair 5	Lat_a - Lat_b2	,000
	Pair 6	Lat_b1 - Lat_b2	,000		Pair 6	Lat_b1 - Lat_b2	,002
2 M.Best	Pair 1	dA_a - dA_b1	,023	9 Fundus flavimaculatus	Pair 1	dA_a - dA_b1	,000
	Pair 2	dA_a - dA_b2	,193		Pair 2	dA_a - dA_b2	,035
	Pair 3	dA_b1 - dA_b2	,276		Pair 3	dA_b1 - dA_b2	,000
	Pair 4	Lat_a - Lat_b1	,000		Pair 4	Lat_a - Lat_b1	,000
	Pair 5	Lat_a - Lat_b2	,000		Pair 5	Lat_a - Lat_b2	,000
	Pair 6	Lat_b1 - Lat_b2	,000		Pair 6	Lat_b1 - Lat_b2	,000
3 Retinoschisis juvenilis	Pair 1	dA_a - dA_b1	,000	10 Fundus albipunctatus	Pair 1	dA_a - dA_b1	,000
	Pair 2	dA_a - dA_b2	,000		Pair 2	dA_a - dA_b2	,000
	Pair 3	dA_b1 - dA_b2	,237		Pair 3	dA_b1 - dA_b2	,098
	Pair 4	Lat_a - Lat_b1	,000		Pair 4	Lat_a - Lat_b1	1,000
	Pair 5	Lat_a - Lat_b2	,000		Pair 5	Lat_a - Lat_b2	,000
	Pair 6	Lat_b1 - Lat_b2	,002		Pair 6	Lat_b1 - Lat_b2	,000
4 Dystrophia conorum	Pair 1	dA_a - dA_b1	,003	11 Pattern D	Pair 1	dA_a - dA_b1	,372
	Pair 2	dA_a - dA_b2	,000		Pair 2	dA_a - dA_b2	,315
	Pair 3	dA_b1 - dA_b2	,676		Pair 3	dA_b1 - dA_b2	,239
	Pair 4	Lat_a - Lat_b1	,000		Pair 4	Lat_a - Lat_b1	,000

	Pair 5	Lat_a - Lat_b2	,000		Pair 5	Lat_a - Lat_b2	,000
	Pair 6	Lat_b1 - Lat_b2	,000		Pair 6	Lat_b1 - Lat_b2	,000
5 TRD pigmentosa	Pair 1	dA_a - dA_b1	,000	12 Dyschromatopsia	Pair 1	dA_a - dA_b1	,206
	Pair 2	dA_a - dA_b2	,000		Pair 2	dA_a - dA_b2	,750
	Pair 3	dA_b1 - dA_b2	,229		Pair 3	dA_b1 - dA_b2	,295
	Pair 4	Lat_a - Lat_b1	,000		Pair 4	Lat_a - Lat_b1	,000
	Pair 5	Lat_a - Lat_b2	,000		Pair 5	Lat_a - Lat_b2	,000
	Pair 6	Lat_b1 - Lat_b2	,000		Pair 6	Lat_b1 - Lat_b2	,034
6 Albinizmus	Pair 1	dA_a - dA_b1	,593	13 Hemeralopia essentialis	Pair 1	dA_a - dA_b1	,556
	Pair 2	dA_a - dA_b2	,432		Pair 2	dA_a - dA_b2	,005
	Pair 3	dA_b1 - dA_b2	,959		Pair 3	dA_b1 - dA_b2	,007
	Pair 4	Lat_a - Lat_b1	,000		Pair 4	Lat_a - Lat_b1	,000
	Pair 5	Lat_a - Lat_b2	,000		Pair 5	Lat_a - Lat_b2	,000
	Pair 6	Lat_b1 - Lat_b2	,000		Pair 6	Lat_b1 - Lat_b2	,011

Uvedené zistenia môžeme prezentovať graficky:



4. Záver

Incidencia dystrofického ochorenia sietnice u človeka má v posledných rokoch jednoznačne ascendentný charakter. Určitú časť chorých, ktorí doposiaľ diagnostikovaní

neboli, je možné detekovať pomocou zdokonalených a stále sa zdokonaľujúcich elektrofyziologických techník. Vyššie počty retinálnych dystrofií zaznamenávame možno aj v absolútnych číslach, t.j. prevalencia a incidencia ochorenia sa skutočne zvyšuje priamo úmerne s lokálnou izoláciou a vysokou incidenciou príbuzenských sobášov u ľudí.

Predpokladom dystrofií je porucha **metabolických** funkcií retiny, následkom čoho vzniká jej **funkčný** deficit

Elektrofyziologické vyšetrenie býva nápomocné v dokumentácii a kvantifikovaní symptómov u pacienta. Pomáha pri odlíšení chorôb sietnice, ktoré sú lokalizované v oblasti makuly, od periférnych degeneratívnych, resp.dystrofických zmien sietnice, keďže viaceré elektrofyziologické testy na zrkové funkcie sú zamerané na špecifické vlastnosti tyčínok a čapíkov.

Okrem uvedeného význam testov spočíva taktiež v diferencovaní porúch na sietnici od chorôb zrakového nervu.

V nedávnej minulosti nastal navyše významný pokrok v identifikácii zodpovedných **génov** a mechanizmov prenosu vrodených **dyschromatopsií**. Poruchy farebného videnia sprevádzajú množstvo dystrofií sietnice, pri ktorých sú sprievodným symptómom, alebo známkou dynamiky ochorenia.

Okrem iného sa nám podarilo preukázať **jednoznačnú genetickú determináciu** u vyšetrovaných subjektov, bez dokázanej viazanosti na pohlavie. Prítomná patologická vloha sa v procese prenosu z generácie na generáciu –**inbreedingom**- signifikantne spotenčovala, čo sa prejavilo výraznejšími klinickými príznakmi, vedúcimi k postupnej strate zraku na úroveň praktickej slepoty s tým, že tieto symptómy oveľa **vo väčšej miere a hlavne včasnšie pacienta invalidizovali**. Veková hranica v týchto prípadoch sa posunula už do 1.decénia!

Ďalším zaujímavým výsledkom skúmania pri vyhodnocovaní výsledkov z aspektu výskytu heredodegeneratívnych ochorení sietnice bolo zistenie tzv.“**endemických**“ **oblastí** v rámci Slovenska. Štatisticky najvyšší výskyt týchto handicapujúcich ochorení sme zaznamenali v okresoch Čadca, Zvolen, Poprad a Zamagurie, oblasť Spiša, Svidník a juhovýchod Slovenska. Je možná hypotéza vyššieho percenta príbuzenských zväzkov (a tým posilňovania patologickej alely), často dokonca bez vedomia samotných vyšetrovaných.

Každopádne, výhody objektívneho elektrofyziologického testovania sa môžu prejavovať vo väčšej miere v budúcnosti, pretože priamo súvisia s rozvojom genetických vyšetrovacích metód a genetického inžinierstva, a genus loci môžu presnejšie odhaliť, na akej úrovni sa tá ktorá porucha skrýva.

Bolo by tiež vhodné a potrebné podrobnejšie sa venovať vyšetrovaniu celých rodín, tomu, ako sa patologická alela prejaví v nasledujúcich generáciách a tento údaj priebežne štatisticky hodnotiť, pretože **hlavný význam ERG, EOG a VEP** spočíva v budúcnosti v podchytení dedičných ochorení sietnice, v genetickom poradenstve a predovšetkým v prenatalnej diagnostike v spolupráci s génovým inžinierstvom, ale **i v neustálej, cielené zameranej osвете** tak, ako je to bežné v okolitých krajinách s vyspelým zdravotníctvom.

5. Literatúra

- [1] Gerinec, A., Chynoranský, M., Smyková, T.: Príčiny slepoty a slabozrakosti u detí v SSR, Čs. oftal. 1990, 46, (2), s. 121- 127
- [2] Chajdiak J. (2003): Štatistika jednoducho. Statis Bratislava 2003, ISBN 808565928-X.
- [3] Luha J. (1985): Testovanie štatistických hypotéz pri analýze súborov charakterizovaných

kvalitatívnymi znakmi. Vydal Odbor Výskumu programov ČST a divákov v SR. Bratislava 1985.

[4] Luha J.(2003): Matematickoštatistické aspekty spracovania dotazníkových výskumov. Štatistické metódy vo vedecko-výskumnej práci 2003, SŠDS, Bratislava 2003, ISBN 80-88946-32-8.

[5] Luha J.: Viacrozmerné štatistické metódy analýzy kvalitatívnych znakov. *EKOMSTAT 2005*, Štatistické metódy v praxi. SŠDS Trenčianske Teplice 22. – 27. 5. 2005.

[6] Luha J. (2008): Prvotná štatistická analýza kvalitatívnych dát. FORUM STATISTICUM SLOVACUM 2/2008. SŠDS Bratislava 2008. ISSN 1336-7420.

[7] Luha J. (2009): Korelácia javov. FORUM STATISTICUM SLOVACUM 2/2009. SŠDS Bratislava 2009. ISSN 1336-7420.

[8] Stankovičová I., Vojtková M.(2007): Viacrozmerné štatistické metódy s aplikáciami. IURA EDITION, Bratislava 2007, ISBN 978-80-8078-152-1.

[9] Štetinová T. (2009).: Diagnostika tapetoretinálnych dystrofií pomocou elektrofyzologických vyšetrovacích metód, PhD. dizertačná práca, LF UK Bratislava 2009.

Adresa autorov:

Anton Gerinec, Prof., MUDr., CSc.
Klinika detskej oftalmologie DFNSP-LFUK
Limbová 1, Bratislava
Prednosta
gerinec@dfnsp.sk

Ján Luha, RNDr., CSc.
Ústav lekárskej biológie, genetiky a klinickej
genetiky LF UK a FNSP
Sasinkova 4, Bratislava
jan.luha@fmed.uniba.sk

Miroslav Chynoranský, Doc., MUDr., CSc.
Fakultná nemocnica s poliklinikou
I. očná klinika
Ružinovská 20, Bratislava
m.chynoransky@fmed.uniba.sk

Tamara Štetinová, MUDr., PhD.
Klinika detskej oftalmologie DFNSP-LFUK
Limbová 1
Bratislava
ocellus@ocellus.sk; stetinova@dfnsp.sk

Faktory regionální konkurenceschopnosti

Factors of regional competitiveness

Jakub Odehnal, Marek Sedlačík

Abstract: The goal of the contributions is the application of canonical analysis to assessment of correlation among factors of regional competitiveness. These factors were created as a result of theoretical study published in [1] Variables were obtained from the set of Regional Yearbook and describe 202 European NUTS 2 regions.

Key words: regional competitiveness, canonical analysis

Klíčová slova: regionální konkurenceschopnost, kanonická analýza

1. Úvod

Cílem příspěvku je popsat možné přístupy k měření regionální konkurenceschopnosti, která může být chápána jako schopnost regionů, generovat vysokou úroveň příjmů a zaměstnanosti. Důraz je kladen na identifikaci faktorů regionální konkurenceschopnosti a jejich možné odvození, užité v různých literárních zdrojích. Vymezené faktory regionální konkurenceschopnosti charakterizující jednotlivé regiony jsou dále analyzovány s ohledem na jejich možné vzájemné vazby.

2. Teoretické přístupy k měření konkurenceschopnosti

Před samotnou analýzou teoretických zdrojů hodnocení konkurenceschopnosti je nutné pojem konkurenceschopnost přiblížit přinejmenším ve dvou rovinách. V první rovině je tedy možné se v řadě prací setkat s analýzou konkurenceschopnosti ekonomik jednotlivých zemí [4, 6], ve druhé rovině s hodnocením tzv. regionální konkurenceschopnosti [1, 7].

Podrobné analýzy hodnocení konkurenceschopnosti ekonomik jednotlivých zemí, nalezneme zejména jako publikační výstupy zahraničních institucí jako je např. švýcarský Institute for Management and Development nebo World Economic Forum.

Ročenka konkurenceschopnosti [4] publikovaná IMD hodnotí 57 světových ekonomik pomocí 329 kritérií, jež jsou agregovány do následujících 4 faktorů konkurenceschopnosti:

- a) faktor ekonomické výkonnosti,
- b) faktor efektivnosti vlády,
- c) faktor efektivnosti podniků,
- d) faktor infrastruktury.

Faktor ekonomické výkonnosti je dále členěn na tzv. subfaktory hodnotící úroveň domácí ekonomiky, mezinárodního obchodu, mezinárodních investic, zaměstnanosti a cenové úrovně. Faktor efektivnosti vlády obsahuje subfaktory veřejné finance, fiskální politiku, institucionální rámec, podniková legislativa a společenský rámec. Faktor efektivnosti podniků je tvořen subfaktory označenými jako produktivita, trh práce, finance, způsoby řízení a faktor infrastruktury je tvořen subfaktory označenými jako základní infrastruktura, technologická infrastruktura, vědecká infrastruktura, zdraví a životní prostředí a vzdělání. Výsledkem takového šetření je žebříček 57 států hodnocených dle úrovně konkurenceschopnosti, která

dle použité definice představuje způsob, jakým stát vytváří, rozvíjí a udržuje prostředí, které podporuje konkurenceschopnost firem. Výsledné pořadí a detailní popis hodnocených zemí je pravidelně od roku 1989 publikován ve World Competitiveness Yearbook [4].

Studie Světového ekonomického fóra zaměřená na hodnocení konkurenceschopnosti je pravidelně od roku 1979 publikována v tzv. Zprávě o konkurenceschopnosti států. Konkurenceschopnost je tak v [6] chápána jako soubor ustanovení, politik a faktorů, které determinují úroveň produktivity v zemi. Základním ukazatelem konkurenceschopnosti použitým v publikaci The Global Competitiveness Report 2008-2009 je souhrnný ukazatel Global Competitiveness Index, hodnotící 134 zemí pomocí tzv. 12 pilířů: instituce, infrastruktura, makroekonomická stabilita, zdraví a základní vzdělání, vyšší vzdělávání, efektivita trhu výrobků, efektivita trhu práce, finanční trhy, technologická připravenost, velikost trhu, obchodní sofistikovanost, inovace.

Jako alternativní ukazatel konkurenceschopnosti je v [6] použit tzv. New Global Competitiveness Index, který teoreticky vychází z teorie konkurenceschopnosti M. Portera. Konkurenceschopnost je tak charakterizována jako makroekonomická konkurenceschopnost, tvořena makroekonomickou politikou, společenským a sociálním rámcem a mikroekonomická konkurenceschopnost, která je závislá zejména na kvalitě podnikatelského prostředí, propracovanosti firemních strategie a podmínkami rozvoje klastrů. Výsledkem studie je pořadí hodnocených zemí dle souhrnného indexu, pořadí zemí dle proměnných jednotlivých pilířů a postavení hodnocených ekonomik v rámci tzv. etap konkurenceschopného rozvoje.

Analýzu teoretických přístupů k regionální konkurenceschopnosti zahájíme definicí regionální konkurenceschopnosti publikované v [1], dle které je konkurenceschopnost považována za schopnost regionů generovat vysokou úroveň příjmů a zaměstnanosti. Autoři v [1] zároveň definují klíčové faktory regionální konkurenceschopnosti, jež jsou rozděleny do tří hlavních oblastí:

- 1) Infrastruktura a její dostupnost
- 2) Lidské zdroje
- 3) Produktivní (hospodářské) prostředí

Obdobně studie Evropské komise Second Report on Economic and Social Cohesion [1] analyzuje socioekonomická data s cílem popsat regionální vývoj v regionech a identifikovat proměnné charakterizující regionální konkurenceschopnost. Mezi tyto proměnné autoři řadí:

- a) ukazatele zaměstnanosti a produktivity zaměstnanců,
- b) ukazatele demografického vývoje a jeho vlivu na regionální konkurenceschopnost,
- c) ukazatele znalostní ekonomiky.

Z tuzemských vědeckých prací můžeme nalézt analýzu konkurenceschopnosti např. v podobě Working Paperu, CES VŠEM s názvem Ukazatele regionální konkurenceschopnosti v České republice [7], ve které je konkurenceschopnost sledována ve třech kategoriích:

- a) makroekonomická výkonnost,
- b) inovační výkonnost,
- c) kvalita života.

Jednotlivé proměnné jsou srovnány pro regiony České republiky geograficky odpovídající regionům NUTS 3, tedy krajům ČR. Souhrnná analýza regionální

konkurenceschopnosti je vytvořena srovnáním úrovně a dynamiky vývoje dílčích ukazatelů makroekonomické výkonnosti, inovační výkonnosti a kvality života. Ve studii je prokázán zejména nerovnoměrný hospodářský vývoj v regionech jako je Praha a Středočeský kraj ve srovnání s ostatními regiony ČR.

Z popsanych výsledků hodnocení regionální konkurenceschopnosti je zřejmé, že mezi proměnné charakterizující regiony autoři ve většině případů volí proměnné popisující makroekonomický výstup, proměnné popisující situaci na regionálním trhu práce, proměnné popisující demografický vývoj obyvatelstva, inovační potenciál či dostupnou infrastrukturu v regionech. Obdobné proměnné byly vybrány i pro regionální analýzu vztahu mezi skupinami proměnnými charakterizujícími regionální konkurenceschopnost provedenou ve čtvrté části textu.

3. Popis použitých datových souborů

Data pro regionální analýzu vztahu mezi vytvořenými ukazateli konkurenceschopnosti byla získána z publikace Eurostat Regional Yearbook [2] rozdělené do následujících 13 kapitol: obyvatelstvo, audit měst, hrubý domácí produkt, účty domácností, obchodní odvětvová statistika, trh práce, odvětvová produktivita, pracovní náklady, doprava, cestovní ruch, věda, technologie a inovace, zdraví a zemědělství. K regionální analýze byly z dostupné publikace [2] vybrány proměnné, odpovídajícím proměnným charakterizující regionální konkurenceschopnost v [1, 7].

Zvolené proměnné tedy jsou: HDP na obyvatele, počet ICT patentů na mil. obyvatel, počet biotechnologických patentů na mil. obyvatel, zaměstnanost v technologicky a vědecky náročných oborech, počet High-tech patentů na mil. obyvatel, celková změna počtu obyvatel, čistá migrace, příjem domácností, dlouhodobá nezaměstnanost, míra zaměstnanosti v regionech, míra nezaměstnanosti v regionech, produktivita práce (HDP na zaměstnance), produktivita služeb, celkové výdaje na vědu a výzkum v regionech jako % HDP, procento zaměstnaných výzkumných pracovníků v regionu, zaměstnanci vědy a výzkumu jako % pracovní síly, Poskytování IT služeb v regionu, hustota silnic v regionech, počet lůžek v ubytovacích zařízeních na tisíc obyvatel a podíl pracovní síly s terciálním vzděláním na celkové pracovní síle.

K regionální analýze konkurenceschopnosti bylo vybráno 202 regionů, odpovídají geografickému členění regionů na úrovni NUTS 2. Počet regionů byl zvolen s přihlédnutím k dostupnosti regionálních dat, ve kterých se vyskytují chybějící pozorování, která bylo nutné před samotnou analýzou doplnit. K doplnění chybějících dat byl použit tzv. ZET algoritmus [5, 8].

Faktory regionální konkurenceschopnosti byly vytvořeny s přihlédnutím k vytvořeným faktorům publikovaných v [1, 7]. Názvy jednotlivých faktorů a proměnné, které je tvoří zobrazuje následující tabulka 1.

Tabulka 8: Faktory regionální konkurenceschopnosti

Faktor inovací a kvality lidských zdrojů (F1)	Faktor regionálního trhu práce (F2)	Faktor ekonomické výkonnosti (F3)	Faktor infrastruktury (F4)
Počet ICT patentů	Dlouhodobá nezaměstnanost	HDP na obyvatele	Hustota silnic
Počet biotechnologických patentů	Míra zaměstnanosti	Produktivita práce	Kapacita ubytovacích zařízení
Počet high-tech patentů	Míra nezaměstnanosti	Produktivita služeb	
Zaměstnanost v technologicky náročných oborech	% pracovní síly s terciálním vzděláním	Příjem domácností	
Výdaje na VaV			

% zaměstnaných výzkumných
pracovníků
Zaměstnanci VaV jako % pracovní
síly
Poskytování IT služeb
Celková změna počtu obyvatel
Čistá migrace

4. Analýza vztahu mezi faktory regionální konkurenceschopnosti

Vztah mezi jednotlivými skupinami proměnných, charakterizujících regionální konkurenceschopnost prostřednictvím vytvořených faktorů je zkoumán užitím tzv. kanonické analýzy [3]. Prvotním výstupem kanonické analýzy je stanovení korelačního koeficientu mezi dvěma skupinami proměnných tzv. skupinového korelačního koeficientu. Z tabulky 2 pozorujeme výsledky skupinového korelačního koeficientu mezi 6ti vytvořenými dvojicemi faktorů regionální konkurenceschopnosti. Nejvyšší hodnotu tak pozorujeme v případě dvojice faktorů inovací a kvality lidských zdrojů (F1) a faktoru ekonomické výkonnosti (F3).

Tabulka 2: Skupinové korelační koeficienty

F1 vs. F2	F1 vs. F3	F1 vs. F4	F2 vs. F3	F2 vs. F4	F3 vs. F4
0,74	0,8	0,46	0,7	0,52	0,59

Bližší analýza statistických vazeb skupin proměnných obsažených v těchto dvou faktorech s nejvyšší hodnotou skupinového korelačního koeficientu je dále provedena prostřednictvím vytvořených umělých proměnných tzv. kanonických proměnných. Kanonické proměnné jsou normované (mají nulovou střední hodnotu a jednotkový rozptyl) latentní proměnné získané lineárními transformacemi proměnných v každé ze srovnávaných skupin. První pár kanonických proměnných se získá jako lineární kombinace proměnných v první skupině a lineární kombinace proměnných ve druhé skupině, přičemž obě lineární kombinace se vyberou tak, aby obě transformované proměnné měly maximální korelační koeficient. Koeficienty obou lineárních transformací se nazývají kanonické váhy a lze je použít k interpretaci vazeb mezi studovanými skupinami proměnných. Druhý pár kanonických proměnných a kanonické váhy se získají podobným postupem, ale s dodatečnou podmínkou, že vytvořené kanonické proměnné musí být nekorelované s kanonickými proměnnými vytvořenými v prvním kroku. Analogickým postupem se získají další páry kanonických proměnných. Korelační koeficienty mezi jednotlivými páry kanonických proměnných se nazývají kanonické korelační koeficient. Příslušné kanonické korelace pak popisují strukturu vazeb mezi studovanými skupinami proměnných a lze pomocí nich stanovit koeficient skupinové korelace (viz např. [2]). Tabulka 3 pak zobrazuje kanonické váhy, které odpovídají kanonickým korelacím mezi faktorem inovací a kvality lidských zdrojů a faktorem ekonomické výkonnosti regionů.

Tabulka 9: Kanonické váhy (levá a pravá sada)

	Kanonický korelační koeficient 1	Kanonický korelační koeficient 2	Kanonický korelační koeficient 3	Kanonický korelační koeficient 4		Kanonický korelační koeficient 1	Kanonický korelační koeficient 2	Kanonický korelační koeficient 3	Kanonický korelační koeficient 4
Celková změna počtu obyvatel	0,10	0,96	0,64	-0,08	HDP na obyvatele	0,43	-1,12	1,24	1,05
Čistá migrace	0,35	-0,68	-0,71	0,26	Příjem domácností	0,91	0,02	-2,40	-0,23
Výdaje na VaV	-0,03	0,61	-0,14	-1,07	Produktivita práce	-0,44	-1,70	1,32	-3,73
% zaměstnaných výzkumných pracovníků	0,07	-1,15	0,25	0,27	Produktivita služeb	0,08	3,00	0,14	2,79
Zaměstnanci VaV jako % pracovní síly	0,79	0,10	-0,06	0,39					

Poskytování IT služeb	-0,03	0,14	0,70	0,64
Počet high-tech patentů	-0,74	-0,04	3,45	-1,04
Počet ICT patentů	0,83	0,11	-3,16	1,22
Počet high-tech patentů	0,14	0,22	-0,44	-0,42
Zaměstnanost v technologicky náročných oborech	-0,04	-0,30	-0,39	-0,35

Z tabulky 2 pozorujeme, že 1. dvojice kanonických proměnných mají největší váhy u faktoru inovací a kvality lidských zdrojů v ukazateli tzv. patentové statistiky (počet ICT patentů), v ukazateli zaměstnanosti ve VaV, v ukazateli čisté migrace a nejvyšší zápornou váhu v ukazateli počtu high-tech patentů. V případě faktoru ekonomické výkonnosti regionů pak největší váhu pozorujeme v proměnné charakterizující příjem domácností. Druhá dvojice kanonických proměnných má v případě F1 největší váhu u proměnné charakterizující celkovou změnu obyvatelstva a nejvyšší zápornou hodnotu váhy u proměnné charakterizující % zaměstnaných výzkumných pracovníků ve VaV. V případě faktoru F2 pak nejvyšší kladnou hodnotu váhy pozorujeme u proměnné popisující produktivitu služeb a nejvyšší zápornou hodnotu vah u proměnné HDP na obyvatele. Třetí dvojice kanonických proměnných má nejvyšší kladnou hodnotu vah u F1 u proměnné počtu high-tech patentů a nejvyšší zápornou hodnotu u počtu ICT patentů. V případě F2 pozorujeme nejvyšší kladnou hodnotu vah u proměnné charakterizující produktivitu práce a nejvyšší zápornou hodnotu vah u proměnné příjem domácností. V případě čtvrté dvojice kanonických proměnných pozorujeme u F1 nejvyšší hodnoty vah u proměnné počtu ICT patentů a nejvyšší zápornou hodnotu vah u proměnné charakterizující výdaje na VaV. U F2 pak nejvyšší kladné a záporné hodnoty pozorujeme u proměnných charakterizujících produktivitu a to produktivitu služeb a produktivitu práce.

5. Závěr

V příspěvku byly představeny možné teoretické přístupy k identifikaci faktorů regionální konkurenceschopnosti vycházející z dostupných publikací, zabývajících se hodnocením regionální konkurenceschopnosti. Pro analýzu vztahu mezi vytvořenými faktory byla použita metoda kanonické analýzy. K samotné analýze bylo použito 20 převážně socioekonomických proměnných charakterizujících postavení 202 regionů Evropské unie. Vzhledem k výskytu chybějících pozorování u některých proměnných, byla před samotnou kanonickou analýzou chybějící pozorování doplněna metodou tzv. ZET algoritmu. Prostřednictvím zjištěného skupinového korelačního koeficientu byla prokázána největší korelace mezi skupinami proměnných odpovídajících faktoru inovací a kvality lidských zdrojů a faktoru ekonomické výkonnosti regionů.

6. Literatura

- [1] CAMBRIDGE ECONOMETRICS - MARTIN, R.L. et al.: A Study on the Factors of Regional Competitiveness. Cambridge Econometrics. 184 s. 2004.
- [2] EUROPEAN COMMISSION: Eurostat Regional Yearbook 2007, Luxembourg: Office for Official Publications of the European Communities, 2007, ISBN 978-92-79-05077-0.
- [3] HEBÁK, P. Vícerozměrné statistické metody. Vyd. 1. Praha: Informatorium, 2004. 239 s.
- [4] IMD (2008): World Competitiveness Yearbook. Dostupné na: <http://www.imd.ch/research/publications/wcy/World-Competitiveness-Yearbook-Results.cfm>

- [5] ODEHNAL, J., NEUBAUER, J., MICHÁLEK, J. Použití neúplných datových souborů ke klasifikaci regionů EU. Statistika, přijato k publikaci.
- [6] WEF (2008): Global Competitiveness Report 2008–2009. Dostupné na:
<http://www.weforum.org/site/homepublic.nsf/Content/Global+Competitiveness+Programme+%5CGlobal+Competitiveness+Report>.
- [7] WP CES VŠEM 5/2007. Kahoun, J. Ukazatele regionální konkurenceschopnosti v České republice.
- [8] ZAGORUIKO, N. G., YOLKINA, V. N. Handbook of Statistics. 1st edition. Vol. 2. P. R. Kirihnaiah and L. N. Kanal. [s.l.] : North-Holland Publishing Company, Inference and Data Tables with Missing Values, s. 493-500. 1982.

Adresa autora (-ov):

Jakub Odehnal, Ing.
Fakulta ekonomiky a managementu
Univerzita obrany
Kounicova 65
662 10 Brno
odehnal@mail.muni.cz

Marek Sedlačík, Mgr., Ph.D.
Fakulta ekonomiky a managementu
Univerzita obrany
Kounicova 65
662 10 Brno
marek.sedlacik@unob.cz

Funkcia užitočnosti v teórii a v praxi **Utility function in theory and practice**

Radka Riesová

Abstract: This paper demonstrates a possibility of practical application of utility function in the decision-making regarding concluding insurance. The aim of this paper is to show differences in the decision-making under different attitudes to risk represented by utility function. Utility function is constructed from the information gleaned from questionnaires.

Key words: utility function, maximum premium.

Kľúčové slová: funkcia užitočnosti, maximálne poistné.

1. Úvod

V každom základnom kurze mikroekonómie sú študenti oboznamovaní s funkciami užitočnosti predovšetkým z teoretického aspektu. Ich praktické využitie ustupuje častokrát do úzadia. Z tohto dôvodu tento príspevok poukazuje na možnosť praktickej aplikácie funkcie užitočnosti v jednorozmernej pravdepodobnostnej rozhodovacej úlohe o uzavretí poistenia majetku voči riziku požiaru.

Primárnym cieľom je na základe empirického pozorovania ukázať jednoduchú konštrukciu funkcie užitočnosti konkrétnych subjektov a poukázať na odlišnosti v ich správaní vzhľadom na individuálny postoj k riziku. Sekundárnym cieľom je využiť konkrétne funkcie užitočnosti na určenie maximálneho poistného v krytí rizika požiaru.

Na skonštruovanie funkcie užitočnosti bol použitý dotazník, na ktorý ochotne odpovedali štyridsiati[‡] študenti všetkých študijných programov 1. ročníka inžinierskeho štúdia na Ekonomickej fakulte Univerzity Mateja Bela v Banskej Bystrici. Na ďalšie spracovanie údajov bol použitý programový balík MS Excel a Eviews 4.0.

2. Rozhodovanie v ekonomických situáciách a teória užitočnosti

V ekonomickej praxi sa často stretávame s pravdepodobnostnými rozhodovacími úlohami, v ktorých sa zvolí optimálne rozhodnutie nielen na základe priamych preferencií, ale aj na základe zváženia miery rizika spojeného s príslušným rozhodnutím.

Rôzny postoj ľudí k riziku v pravdepodobnostných rozhodovacích úlohách možno zohľadniť prostredníctvom aplikácie teórie užitočnosti. V polovici 20. storočia maďarský matematik John von Neumann a americký ekonóm Oskar Morgenstern vyvinuli teóriu očakávaného úžitku vo svojej práci *Theory of Games and Economic Behaviour*. Základná myšlienka spočíva v tom, že subjekt si pri rozhodovaní v podmienkach rizika nezvolí alternatívu s najvyššou očakávanou hodnotou, ale s najvyšším očakávaným úžitkom. Princíp maximalizácie očakávanej užitočnosti hovorí, že racionálny rozhodovateľ si vyberie z n alternatívnych rozhodnutí také, ktorého očakávaná užitočnosť je maximálna.

3. Funkcia užitočnosti bohatstva a jej konštrukcia

Pri rozhodovaní investora o štruktúre svojho portfólia, či pri rozhodovaní o možnosti poistiť sa možno využiť jednorozmernú kardinálnu funkciu užitočnosti – funkciu bohatstva $U(w)$. Kardinálna funkcia užitočnosti na rozdiel od ordinálnej funkcie užitočnosti, nás môže upozorniť aj na suboptimálne alternatívy s hodnotením veľmi blízkym hodnoteniu optimálnej rozhodovacej alternatívy. Takáto funkcia užitočnosti rozhodovateľa transformuje jeho

[‡] Nízky počet študentov participujúcich sa na ankete nemá vplyv na kvalitu záverov.

preferencie do merateľnej užitočnosti a priraduje číselne vyjadrenú mieru užitočnosti jednotlivým hodnotám sledovanej veličiny X .

Grafickým zobrazením funkcie užitočnosti bohatstva $U(w)$ je rastúca krivka s rôznou intenzitou rastu u každého z nás. Vo všeobecnosti platí, že ľudia vyhľadávajúci riziko sa rozhodnú radšej riskovať (môžu získať väčšiu užitočnosť ako stratiť), kým ľudia averzní voči riziku sa vyhýbajú (môžu stratiť väčšiu užitočnosť ako získať). Treba si uvedomiť, že funkcia užitočnosti je špecifická pre každého jedinca a dá sa zistiť iba empirickým pozorovaním rozhodovateľa. Pri zostrojení funkcie užitočnosti sa budeme opierať o metódu založenú na hypotetickej hre a na určovaní bodov indiferencie rozhodovateľa. Empirické pozorovanie bolo uskutočnené prostredníctvom dotazníka.

Opierali sme sa o hypotetickú hru, ktorú približuje tabuľka 1. Respondenti si mali predstaviť situáciu, že sú vlastníkami investície, ktorá im môže priniesť nulový zisk s pravdepodobnosťou p_1 alebo stratu vo výške -30 000 € s pravdepodobnosťou $1 - p_1$. Majú však možnosť odstúpiť od investície za sankciu ${}_k x$ pre $k = 1, 2, \dots, 5$. Navzájom sa vylučujúcim budúcim situáciám S_j pre $j = 1, 2$ zodpovedajú navzájom sa vylučujúce alternatívne rozhodnutia D_i pre $i = 1, 2$.

Tabuľka 10: Rozhodovacia tabuľka na základe dotazníka preloženého respondentom

	S_1 Zisk s pravdepodobnosťou p_1	S_2 Strata s pravdepodobnosťou $1 - p_1$
D_1 Ponechanie investície	$U(w + 0) = 1$	$U(w - 30\,000) = 0$
D_2 Neponechanie investície	$U(w - {}_k x) = {}_k p$	$U(w - {}_k x) = {}_k p$

Prameň: vlastné spracovanie

Respondenti mali za úlohu určiť najväčšiu pravdepodobnosť straty $1 - {}_k p_1$, pri ktorej by si investíciu ešte ponechali a neboli by ochotní zaplatiť sankciu ${}_k x$. Takto bolo získaných 5 bodov indiferencie pre pravdepodobnosti nulového zisku ${}_k p_1$, ktoré sa viazali na zaplatenie sankcie vo výške ${}_k x$. Pre užitočnosti v bodoch indiferencie platí vzťah:

$$U(w - {}_k x) = {}_k p_1 U(w + 0) + (1 - {}_k p_1) U(w - 30\,000) = {}_k p_1. \quad (1)$$

Získané body indiferencie hovoria o tom, aká veľká je užitočnosť rozhodovateľa, ak sa zníži jeho bohatstvo o výšku sankcie ${}_k x$. Je zjavné, že táto užitočnosť je determinovaná hodnotou pravdepodobnosti zisku ${}_k p_1$ v bodoch indiferencie, ktorú určuje rozhodovateľ na základe vlastného uváženia. Postoj rozhodovateľa k riziku je daný subjektívnym určením pravdepodobnosti zisku ${}_k p_1$. Subjektívne určená pravdepodobnosť výhry ${}_k p_1$ nemá nič spoločné so skutočnou šancou hru vyhrať. Odráža v sebe predovšetkým rozhodovateľov úsudok a spôsob vnímania rizika, ktorý je determinovaný jeho skúsenosťami a vedomosťami aj z minulých období. Funkcia užitočnosti tak mapuje rozhodovateľov postoj prijať riziko v danej rozhodovacej úlohe.

Nasledovne bola všetkými známymi bodmi preložená funkcia užitočnosti. Pre každého respondenta sme dostali špecifickú krivku užitočnosti, ktorá bola v niektorých častiach intervalu $\langle w - 30\,000, w \rangle$ konvexná a v iných konkávna. Aby sme získali informáciu o tom, či je príslušný rozhodovateľ averzný voči riziku, alebo nie je, a zároveň aby sme získali funkčný predpis, podľa ktorého budeme viesť definovať funkciu užitočnosti, preložili sme údajmi kvadratickú funkciu. Väčšina respondentov (64%) sa ukázala ako skupina ľudí averzných

voči riziku. Na základe vypočítaných indexov determinácie kvadratických regresných modelov všetkých respondentov bolo evidentné, že kvadratická regresia nebola najvhodnejším spôsobom vyhladenia u všetkých respondentov a určite by bolo potrebné nájsť pre nich štatisticky významnejší model užitočnosti. Z respondentov sme si vybrali dvoch averzných (respondent A1 a respondent A2) s funkciami užitočnosti bohatstva:


$${}^{A1}U(w_{-k}x) = -4.10^{-10}{}_k x^2 + 2.10^{-5}{}_k x + 0,9777, \quad (2)$$

$${}^{A2}U(w_{-k}x) = -7.10^{-10}{}_k x^2 + 10^{-5}{}_k x + 0,9774 \quad (3)$$


a jedného vyhľadávajúceho riziko (respondent V3) s funkciou užitočnosti bohatstva:

$${}^{V3}U(w_{-k}x) = 5.10^{-10}{}_k x^2 + 5.10^{-5}{}_k x + 0,9489. \quad (4)$$

U týchto respondentoch sa kvadratické funkcie užitočnosti javili ako štatisticky relatívne dobré. Z výstupov príslušných kvadratických regresných modelov sme na 5% hladine významnosti zamietli nulové hypotézy o štatistickej nevýznamnosti regresných koeficientov a súčasne aj nulové hypotézy o štatistickej nevýznamnosti modelov ako celku. Kvadratický model užitočnosti averzného respondenta A1 vysvetľuje až 99,63% variability užitočnosti a u averzného respondenta A2 až 99,73%. U respondenta V3 vyhľadávajúceho riziko vysvetľuje kvadratická funkcia užitočnosti až 99,28% variability užitočnosti.



Obrázok 1: Pôvodná a vyhladená kvadratická funkcia užitočnosti respondenta A2
Prameň: vlastné spracovanie



Obrázok 2: Pôvodná a vyhladená kvadratická funkcia užitočnosti respondenta V3
Prameň: vlastné spracovanie

4. Funkcia užitočnosti a rozhodnutie poistiť sa

V praxi sa stretávame so situáciami, keď sú ľudia ochotní zaplatiť poistné P , hoci očakávaná hodnota rozhodnutia poistiť sa je menšia ako očakávaná hodnota rozhodnutia nepoistiť sa. Ľudia si totiž pocit bezpečia vážia viac ako rozdiel medzi očakávanými výsledkami. Rozhodovanie poistiť sa proti novej škode X alebo nepoistiť sa možno chápať ako rozhodovaciu úlohu medzi istou alternatívou – poistiť sa D_1 – neistou alternatívou – nepoistiť sa D_2 . Rozhodovacia úloha je popísaná v tabuľke 2.

Tabuľka 11: Rozhodovacia tabuľka pri rozhodovaní o možnosti poistiť sa

	S_1 Nastanie poistnej udalosti s pravdepodobnosťou p_1 vo výške X	S_2 Nenastanie poistnej udalosti s pravdepodobnosťou $1 - p_1$	Očakávaná užitočnosť rozhodnutia D_i
D_1 Poistiť sa	$U(w - P)$	$U(w - P)$	$U(w - P)$
D_2 Nepoistiť sa	$U(w - X)$	$U(w)$	$p_1 U(w - X) + (1 - p_1) U(w)$

Prameň: vlastné spracovanie

Vieme, že funkcia užitočnosti subjektu s averziou voči riziku je funkciou konkávnou. Z Jensenovej nerovnosti pre konkávnou funkciu užitočnosti platí:


$$E[U(w - X)] \leq U(E[w - X]) = U(w - E[X]). \quad (5)$$

Zo vzťahu vyplýva, že očakávaná užitočnosť averzného rozhodovateľa v prípade neistoty (nepoistenia sa) môže byť menšia ako užitočnosť istého rozhodnutia (poistiť sa) subjektu averzného voči riziku. Rozhodovateľ averzný voči riziku s bohatstvom w sa dá poistiť proti novej škode X pri poistnom menšom alebo rovnom ako je maximálne poistné $P^{\max}$, ktoré je ochotný zaplatiť. Pri väčšom poistnom, ako je $P^{\max}$, by rozhodovateľovi prinieslo neisté rozhodnutie väčšiu užitočnosť ako isté rozhodnutie.

Ak je daná funkcia užitočnosti rozhodovateľa $U(w)$ a existuje k nej inverzná funkcia $U^{-1}(w)$, potom pre istý ekvivalent poistenia (hodnota bohatstva, pri ktorej je užitočnosť z poistenia rovnaká ako očakávaná užitočnosť z nepoistenia) platí:

$$(w - P^{\max}) = U^{-1}(E[U(w - X)]). \quad (6)$$


Istý ekvivalent je vždy menší ako očakávaná hodnota z nepoistenia sa. Rozhodovateľ sa teda poistí len v prípade, že hodnota jeho bohatstva po zaplacení poistného bude väčšia ako istý ekvivalent $(w - P^{\max})$.



Obrázok 3: Určenie maximálneho poistného pomocou istého ekvivalentu

Prameň: vlastné spracovanie

V tejto časti budeme skúmať rozhodnutie, či poistiť chatu v hodnote 30 000 € proti riziku požiaru s pravdepodobnosťou nastania p_1 . Kvantifikujeme maximálne poistné, ktoré by boli ochotní zaplatiť nami vybraní averzní respondenti z nášho empirického skúmania. Respondent vyhľadávajúci riziko by svoj majetok nepoistil, pretože na celom uvažovanom intervale $\langle w - 30\,000; w \rangle$ je očakávaná užitočnosť rozhodnutia nepoistiť sa väčšia ako očakávaná užitočnosť rozhodnutia poistiť sa (vyplýva to z konvexnosti jeho funkcie užitočnosti). Pomocou vzťahu pre maximálne poistné (6) a funkcie riešiteľ v programe MS Office bola zistená závislosť výšky maximálneho poistného v prípade poistenia chaty v hodnote 30 000 € proti riziku požiaru na pravdepodobnosti nastania požiaru. S rastúcou pravdepodobnosťou vzniku požiaru rástla aj hodnota maximálneho poistného, ktoré sú respondenti ochotní zaplatiť. Potvrdilo sa, že averznejší respondent A2 je ochotný zaplatiť vyššie maximálne poistné ako menej averzný respondent A1 pri tej istej pravdepodobnosti nastania požiaru. Táto skutočnosť sa prejavila vo vypuklejšom tvare krivky užitočnosti averznejšieho respondenta A2 a vo vyššej hodnote koeficienta averzie voči riziku.



Obrázok 4: Maximálne poistné averzného respondenta 1 a averzného respondenta 2
Prameň: vlastné spracovanie

5. Záver

Práca poukázala na možnosť konštrukcie konkrétnej funkcie užitočnosti bohatstva pre jednotlivca prostredníctvom empirického pozorovania a s využitím fiktívnej hry. Pri získavaní údajov pre konštrukciu funkcie užitočnosti pomocou dotazníka sme sa stretli aj s problémami a potvrdilo sa, že zostrojiť individuálnu funkciu užitočnosti nie je jednoduchá vec. Ukázalo sa, že respondenti, ktorí nemajú za sebou základný kurz štatistiky, mali problém porozumieť zadaniu a nevedeli pracovať s pravdepodobnosťami tak ako tí, čo takýto kurz absolvovali. Veľkou nevýhodou získavania údajov je aj to, že respondentov väčším počtom svojich otázok zaťažíme. Pritom nemáme istotu, či každá ich odpoveď zohľadňuje ich skutočný pocit, alebo či sa chcú svojimi odpoveďami čo najrýchlejšie dotazovania zbaviť.

Získali sme však aj údaje, na základe ktorých sme mohli skonštruovať relatívne dobré funkcie užitočnosti. Konkrétne funkcie užitočnosti sme následne využili v rozhodovacej úlohe o kúpe poistenia. Zistili sme, že rozhodnutie o kúpe poistky je ovplyvnené pravdepodobnosťou vzniku požiaru, cenou poistenia a zároveň aj funkciou užitočnosti rozhodovateľa.

Vzťah na výpočet maximálneho poistného pomocou funkcie užitočnosti ukazuje, že poistenec je ochotný zaplatiť vyššie poistné, ako je netto poistné. Pod čistým poistným rozumieme očakávanú hodnotu poistených škôd. Inak povedané poistenie existuje preto, že ľudia sú ochotní zaplatiť za poistenie vyššiu sumu, ako je očakávaná suma zodpovedajúca možným škodám. Poisťovateľ získava od poistencov poistné, ktoré je vyššie ako je výška očakávaných škôd, v dôsledku čoho tu vzniká priestor pre tvorbu zisku (po úhrade prípadných nákladov spojených s poisťovacou činnosťou).

Zaujímavým zistením bola aj skutočnosť, že čím sú ľudia averznejší voči riziku, tým sú ochotnejší zaplatiť za elimináciu rizika väčšiu sumu. Poisťovne by sa mali preto sústreďovať predovšetkým na túto skupinu rozhodovateľov.

Ukázalo sa, že funkcia užitočnosti má svoje opodstatnenie aj v praxi, a preto by som vo svojej budúcej práci rada venovala pozornosť aj problematike koeficientu averzie voči riziku a skúmaniu funkcie užitočnosti poisťovateľa.

6. Literatúra

- [1] FECENKO, J. 2006. Neživotné poistenie. Bratislava: EKONÓM, 2006. 199 s. ISBN 80-225-2191-4
- [2] HEBÁK, P. 1998. Pravděpodobnostní rozhodování v ekonomických situacích. Praha: VŠE, 1998. 120 s. ISBN 80-7079-429-1
- [3] KAAS, R. a kol. 2001. Modern actuarial risk theory. Boston: Kluwer Academic Publishers, 2001. 306 s. ISBN 1-4020-2952-7
- [4] LAPIN, L.L. 1991. Quantitative Methods for Business Decisions. Orlando: Hartcourt Brace College Publishers, 1991. 954 s. ISBN 0-15-574331-7
- [5] TALAŠOVÁ, J. 2003. Fuzzy metody vícekritériálního hodnocení a rozhodování. Olomouc: Univerzita Palackého v Olomouci, 2003. 179 s. ISBN 80-244-0614-4
- [6] VARIAN, H.R. 1993. Mikroekonomie, Moderní přístup. Praha: VICTORIA PUBLISHING, 1993. 643 s. ISBN 80-85865-25-4

Adresa autora

Radka Riesová
Univerzita Mateja Bela v Banskej Bystrici
Ekonomická fakulta
Tajovského 10
975 90 Banská Bystrica
rriesova@gmail.com

Ekonometrické modelovanie transmisného mechanizmu menovej politiky

Econometric modeling of the monetary transmission mechanism

Viera Roháčová

Abstract: This thesis presents influence of specific channels of monetary transmission operating by the use of the effects that monetary policy has on interest rates, exchange rates, equity and real estate prices, bank lending and firm balance sheets. Primary aim of this work is examining the mutual relationships between economic variables in Slovakia to find out whether the practice confirms economic theory. We use econometric modeling for the research and we interpret partial results with query on expected relations. We constructed a relatively good econometric model of the monetary transmission mechanism which can be confirming the basic economic premise underlying the whole theory of monetary policy. This thesis could be contribution for evaluation past development and it can serve as recommendation for operating monetary policy to the future.

Key words: Transmission mechanism, Monetary policy, Money supply, Interest rate, Consumption, Investment, Econometric modeling.

Kľúčové slová: transmisný mechanizmus, menová politika, peňažná zásoba, úroková miera, spotreba, investície, ekonometrické modelovanie.

1. Úvod

Proces pôsobenia centrálnej banky v trhovej ekonomike je v ekonomickej teórii známy pod pojmom transmisný mechanizmus menovej politiky. Naším cieľom bude skúmanie transmisného mechanizmu menovej politiky v reálnom prostredí slovenskej ekonomiky s úmyslom nájsť najvhodnejší ekonometrický model, ktorý by slúžil na čo možno najkvalitnejšie vysvetlenie vzájomného vplyvu jednotlivých makroekonomických veličín. Základným pilierom, o ktorý sa budeme počas celej konštrukcie opierať, je ekonomická teória transmisného mechanizmu menovej politiky.

2. Transmisný mechanizmus menovej politiky podľa ekonomickej teórie

Jednu z možných definícií transmisného mechanizmu ponúka Európska centrálna banka[§], ktorá ho chápe ako: „spôsob, akým zmeny úrokových sadzieb prostredníctvom rôznych kanálov ovplyvňujú správanie hospodárskych subjektov, hospodársku aktivitu a v konečnom dôsledku celkovú cenovú úroveň“. Centrálna banka považuje za svoj konečný cieľ menovú, resp. cenovú stabilitu. Vzhľadom na fakt, že Európska centrálna banka sa pohybuje v trhovom prostredí nie je schopná zaistiť tento cieľ priamo, keďže nereguluje vývoj cenovej hladiny administratívnym spôsobom. Jediným pre ňu dostupným operačným nástrojom sú základné menovo-politické úrokové sadzby väčšinou s týždňovou alebo dvojtyždňovou splatnosťou. Zmenou úrokových sadzieb Európska centrálna banka reaguje na identifikované ekonomické nerovnováhy a odchýlky očakávaného vývoja inflácie od stanoveného cieľa.

[§] ECB (2006, s. 33)

Veľkú vzdialenosť medzi voľbou a následným použitím konkrétneho menového nástroja a dosiahnutím konečného cieľa, prekonáva centrálna banka v troch po sebe nasledujúcich fázach. Od rozhodnutia centrálnej banky o výbere a následnej aplikácii vhodných nástrojov menovej politiky na dosiahnutie vytýčených cieľov (tvorba menových impulzov) sa začína reťaz reakcií, ktoré sa najprv prejavujú na finančných trhoch (prvá fáza menovej transmisie), postupne sa šíria do celej ekonomiky vo forme rozhodnutí domácností a podnikateľskej sféry (druhá fáza transmisie), ktoré sa v konečnom dôsledku prejavujú na agregovanej úrovni vzájomnou interakciou agregovaného dopytu a ponuky na trhu v podobe zmeny spotreby, národného dôchodku, úrovne zamestnanosti a v zmene cenovej hladiny (tretia fáza transmisie). Proces šírenia menových impulzov je podmienený splnením základného predpokladu vzájomnej kauzality ekonomických veličín a vzťahov.** V odbornej literatúre sa druhá fáza transmisného mechanizmu (t. j. prenos rozhodnutí centrálnej banky do reálnej ekonomiky) člení do tzv. kanálov menovej transmisie. Vymedzenie transmisných kanálov však u jednotlivých autorov nie je totožné. Tradičné členenie kanálov menovej politiky rozlišuje úrokový kanál, kanál menového kurzu, kanál ovplyvňujúci ceny aktív v ekonomike a úverový kanál (Ireland, 2005, s. 3-5). Pre účely ďalšej podrobnejšej analýzy fungovania transmisného mechanizmu vymedzíme základné teoretické vzťahy medzi ekonomickými veličinami vyplývajúce z teórie jednotlivých kanálov transmisie:

1. Transmisia prostredníctvom úrokových mier (Interest rate channel)

$$\downarrow M \Rightarrow \uparrow R \Rightarrow \downarrow C$$

2. Transmisia prostredníctvom menového kurzu (Exchange rate channel)

$$\uparrow M \Rightarrow \downarrow R \Rightarrow \downarrow ZK \Rightarrow \downarrow E \Rightarrow \uparrow HDP$$

3. Transmisia prostredníctvom cien aktív (Other asset price channel)

$$\downarrow M \Rightarrow \uparrow R \Rightarrow \downarrow P_a \Rightarrow \downarrow \text{bohatstvo} \Rightarrow \downarrow C \Rightarrow \downarrow HDP$$

4. Transmisia prostredníctvom úverov (Credit channel)

I. Kanál bankových pôžičiek

$$\uparrow M \Rightarrow \downarrow R \Rightarrow \downarrow R_u \Rightarrow \uparrow \dot{U} \Rightarrow \uparrow I$$

II. Súvahový kanál

$$\uparrow M \Rightarrow \downarrow R \Rightarrow \uparrow \text{bohatstvo} \Rightarrow \uparrow \dot{U} \Rightarrow \uparrow C$$

kde: M- ponuka peňazí

R- krátkodobá úroková sadzba

C- spotreba

ZK- zahraničný špekulačný kapitál

E- kurz domácej meny

P_a - ceny akcií

R_u - úrokové sadzby z úverov

$\dot{U}$ - objem úverov

I- investície

HDP- hrubý domáci produkt

3. Špecifikácia modelu

3.1 Klasifikácia jednotlivých premenných v súlade s ekonomickou teóriou

Pri skúmaní vzájomných závislostí jednotlivých ekonomických veličín sa obmedzíme na štvrťročné údaje vybraných ekonomických ukazovateľov v podmienkach Slovenskej republiky počas sledovaného obdobia rokov 2002 - 2007. (Najmä z dôvodu zverejňovania niektorých ukazovateľov (napr. HDP) len v štvrťročných intervaloch, pri ostatných ukazovateľoch použijeme ich priemery z mesačných dát). Sme si pri tom vedomí istej nepresnosti, ktorá sa môže odraziť na vypovedacej hodnote finálneho modelu. Pri modelovaní transmisného mechanizmu budeme pracovať s nasledujúcimi premennými:

M2 - ponuka peňazí, kde za reprezentanta považujeme peňažnú zásobu M2

R - krátkodobá úroková sadzba, kde za reprezentanta považujeme priemernú úrokovú mieru z medzibankových vkladov (3-mesačný BRIBOR)

** Spracované podľa LACOVÁ (2006, s.83)

SPOTREBA - konečná spotreba domácností podľa klasifikácie individuálnej spotreby COICOP

KURZ - kurz domácej meny, kde za reprezentanta považujeme priemerné štvrťročné výmenné kurzy slovenskej koruny voči EUR

SAX - ceny akcií, kde za reprezentanta považujeme slovenský akciový index SAX

INF - spotrebiteľské ceny merané HICP, zmena oproti rovnakému obdobiu predchádzajúceho roka,

UVER - objem úverov, kde za reprezentanta považujeme úvery podnikom a obyvateľstvu

HDP - hrubý domáci produkt v bežných cenách za roky 1995-2008.

Z priebehu jednotlivých kanálov transmisného mechanizmu môžeme odvodiť nasledujúce funkčné vzťahy (1), ktoré budeme v ďalšom skúmaní považovať za kľúčové:

$$R_t = f_1(M2_t)$$

$$SPOTREBA_t = f_2(R_t, SAX_t, UVER_t)$$

$$KURZ_t = f_3(R_t)$$

$$SAX_t = f_4(R_t)$$

$$UVER_t = f_5(R_t)$$

$$INF_t = f_6(SPOTREBA_t, KURZ_t) \quad (1)$$

$$HDP_t = f_7(SPOTREBA_t, KURZ_t, INF_t)$$

3.2 Stanovenie predpokladaných znamienok parametrov

Z ekonomickej teórie ďalej vyplýva, že derivácia funkcie f_1 podľa $M2$ by mala byť záporná (reštriktívna menová politika centrálnej banky má za následok zníženie ponuky peňazí (M), čo pri nezmenenom dopyte po peniazoch a očakávaníach vedie k zvýšeniu reálnych a nominálnych úrokových sadzieb peňažného trhu).

Derivácie f_2 podľa SAX a $UVER$ by mali byť kladné (domácnosti reagujú na pokles cien aktív znížením spotreby, pretože pociťujú, že hodnota ich finančného bohatstva, slúžiaceho na zaistenie pred možnými budúcimi krízami, sa zmenšila; pri zvýšení kredibility ekonomických subjektov, vzniká vyššia šanca na získanie úveru a v konečnom dôsledku môže dôjsť k zvýšeniu spotrebného správania domácností) a derivácia f_2 podľa R by mala byť záporná (ako tvrdí Lacová (2006, s.83): „Menovou politikou vyvolaný nárast úrokových sadzieb môže teda viesť k zmenám hotovostných tokov veriteľov a dlžníkov, a tým tiež k zmene ich spotrebných a investičných výdavkov t.j. zníženie dopytu po úveroch, pretože sa zvyšujú ich splátky úrokov.“).

Derivácia f_3 podľa R by mala byť záporná (s poklesom domácich úrokových sadieb dochádza k úniku zahraničného špekulačného kapitálu, ktorý doposiaľ zarábala na úrokových diferenciáloch a tento únik kapitálu je spojený so znehodnocovaním kurzu domácej meny).

Derivácia f_4 podľa R by mala byť záporná (kapitálový trh reaguje na nárast úrokových sadzieb poklesom cien akcií, čo vyplýva napríklad aj z keynesiánskej teórie: reštriktívna menová politika zvyšuje úrokové sadzby, čím zvýhodňuje držbu dlhopisov v porovnaní s akciami, čím dochádza k poklesu ich cien).

Derivácia f_5 podľa R by mala byť kladná (zníženie krátkodobej úrokovej miery povedie k poklesu úrokových sadzieb z úverov, ktoré banky poskytujú svojim klientom (abstrahujeme od bonity potenciálnych dlžníkov), čo pre podniky znamená zlacnenie ceny kapitálu, ktorý môžu prostredníctvom bankových pôžičiek získať, čoho následkom by mohlo byť zvýšenie objemu novo-poskytnutých úverov).

Derivácie f_6 podľa $SPOTREBA$ a $KURZ$ by mali byť kladné (klesajúce výdavky domácností na tovary dlhodobej spotreby sa prejavujú v miere inflácie (zoslabenie inflačných tlakov), napríklad podľa Dovčiaka (1999) : „V malých otvorených ekonomikách s plávajúcim výmenným kurzom, uvoľnenie menovej politiky napr. môže viesť k znehodnoteniu

výmenného kurzu, k rastu cien dovážaných tovarov a môže viesť k rastu cien domácej produkcie.“).

Derivácie f_7 podľa **SPOTREBA**, **KURZ**, **INF** by mali byť kladné (spotreba je súčasťou HDP t.j. s poklesom spotreby dochádza k jeho poklesu; znehodnocovanie kurzu domácej meny pôsobí proexportne resp. zlacňuje export a zdražuje import a v konečnom dôsledku sa zvyšuje čistý export a tým teda aj hrubý domáci produkt; ku znižovaniu tempa rastu HDP dochádza väčšinou v súčinnosti s klesajúcou mierou inflácie).

3.3 Voľba matematického a analytického tvaru modelu

Za predpokladu linearity funkcií (1), dostaneme nasledujúcu sústavu rovníc (2), kde grécke písmená označujú parametre a u_i pre $i=1,2,...,7$ reprezentujú rušivú zložku jednotlivých regresných rovníc, pričom na tieto regresné špecifikácie sú kladené obvyklé predpoklady.

$$\begin{aligned} R_t &= \alpha_1 + \beta_1 M2_t + u_1 & SPOTREBA_t &= \alpha_2 + \beta_2 R_t + \gamma_2 SAX_t + \delta_2 UVER_t + u_2 \\ KURZ_t &= \alpha_3 + \beta_3 R_t + u_3 & SAX_t &= \alpha_4 + \beta_4 R_t + u_4 \\ UVER_t &= \alpha_5 + \beta_5 R_t + u_5 & INF_t &= \alpha_6 + \beta_6 SPOTREBA_t + \gamma_6 KURZ_t + u_6 \\ HDP_t &= \alpha_7 + \beta_7 SPOTREBA_t + \gamma_7 KURZ_t + \delta_7 INF_t + u_7 \end{aligned} \quad (2)$$

Po vzájomnom dosadení jednotlivých rovníc dostávame funkčný vzťah pre vývoj hrubého domáceho produktu, ktorý je nasledovný:

$$\begin{aligned} HDP_t &= (\alpha_7 + \beta_7 \alpha_2 + \beta_7 \beta_2 \alpha_1 + \beta_7 \gamma_2 \alpha_4 + \beta_7 \delta_2 \alpha_5 - \beta_7 \delta_2 \beta_5 \alpha_3 / \beta_3 - \gamma_7 \alpha_6 / \gamma_6 - \alpha_2 \beta_6 \gamma_7 / \gamma_6 + \delta_7 \alpha_6) + \\ &+ (\beta_7 \delta_2 \beta_5 / \beta_3 + \delta_7 \gamma_6) KURZ_t + (\delta_7 \beta_6) SPOTREBA_t + (\beta_7 \gamma_2 \beta_4 - \beta_2 \beta_6 \gamma_7 / \gamma_6) R_t + (\beta_7 \beta_2 \beta_1) M2_t + \\ &+ (-\gamma_2 \beta_6 \gamma_7 / \gamma_6) SAX_t + (-\delta_2 \beta_6 \gamma_7 / \gamma_6) UVER_t + (\gamma_7 / \gamma_6) INF_t + \\ &+ (\beta_7 \beta_2 u_1 + \beta_7 \gamma_2 u_4 - \beta_7 \delta_2 \beta_5 u_3 / \beta_3 + \beta_7 \delta_2 u_5 + \beta_7 u_2 + u_2 \beta_6 \gamma_7 / \gamma_6 - \gamma_7 u_6 / \gamma_6 + \delta_7 u_6 + u_7) \end{aligned} \quad (3)$$

Ak urobíme vhodnú substitúciu jednotlivých členov rovnice, pri ekonometrickom modelovaní budeme vychádzať z nasledujúceho jednorovnicového lineárneho regresného modelu (4), kde β_i , $i=1,2,...,7$ označujú parametre a ε je rušivá zložka, pričom na túto regresiu sú kladené obvyklé predpoklady.

$$HDP_t = \beta_0 + \beta_1 KURZ_t + \beta_2 SPOTREBA_t + \beta_3 R_t + \beta_4 M2_t + \beta_5 SAX_t + \beta_6 UVER_t + \beta_7 INF_t + \varepsilon_t \quad (4)$$

pre $t = 1, 2, \dots, 24$

4. Kvantifikácia modelu

Za pomoci programu EViews sme metódou najmenších štvorcov odhadli parametre modelu. V nasledujúcej časti sa nachádzajú odhadnuté parametre modelu spolu s najdôležitejšími štatistikami:

$$\begin{aligned} HDP = & -708012.896 + 11466.994 KURZ + 1.583 SPOTREBA - 9550.459 R + 470.670 M2 + \\ (p\text{-value}) & (0.0323) \quad (0.0792) \quad (0.0133) \quad (0.1407) \quad (0.0184) \quad (5) \\ & - 98.572 SAX + 107.74 UVER + 1052.160 INF \\ & (0.7084) \quad (0.1564) \quad (0.5424) \end{aligned}$$

$R\text{-squared} = 0.981657$ $Akaike \text{ info criterion} = 21.72679$ $Prob(F\text{-statistic}) = 0.000000$

5. Verifikácia modelu

V rámci *ekonomickej verifikácie* budeme skúmať, či odhadnuté parametre sú v súlade s ekonomickou teóriou transmisného mechanizmu menovej politiky. Pri stanovovaní predpokladaných znamienok v predchádzajúcej časti sme dospeli k nasledujúcim záverom:

$$\begin{array}{ccccccc} \beta_1 < 0 & \beta_2 < 0 & \beta_3 < 0 & \beta_4 < 0 & \beta_5 > 0 & \beta_6 > 0 & \beta_7 > 0 \\ & \gamma_2 > 0 & & & & \gamma_6 > 0 & \gamma_7 > 0 \\ & \delta_2 > 0 & & & & & \delta_7 > 0 \end{array} \quad (6)$$

Takže malo by platiť:

$$\beta_1 = \delta_7 \gamma_6 + (\beta_7 \delta_2 \beta_5 / \beta_3) = 11466.994$$

Z predpokladaných znamienok $\delta_7, \gamma_6, \beta_7, \beta_5$ a β_3 vyplýva, že parameter β_1 by mal byť kladný resp. záporný. Odhad parametra β_1 je kladný, čo je v súlade s ekonomickou teóriou.

$$\beta_2 = \delta_7 \beta_6 = 1.583$$

Z predpokladaných znamienok δ_7 a β_6 vyplýva, že parameter β_2 by mal byť kladný. Odhad parametra β_2 je kladný, čo je v súlade s ekonomickou teóriou.

$$\beta_3 = \beta_7 \gamma_2 \beta_4 - (\gamma_7 \beta_6 \beta_2 / \gamma_6) = -9550.459$$

Z predpokladaných znamienok $\beta_7, \gamma_2, \beta_4, \gamma_7, \beta_6, \beta_2$ a γ_6 vyplýva, že parameter β_3 by mal byť kladný resp. záporný. Odhad parametra β_3 je záporný, čo je v súlade s ekonomickou teóriou.

$$\beta_4 = \beta_7 \beta_2 \beta_1 = 470.670$$

Z predpokladaných znamienok β_7, β_2 a β_1 vyplýva, že parameter β_4 by mal byť kladný. Odhad parametra β_4 je kladný, čo je v súlade s ekonomickou teóriou transmisného mechanizmu.

$$\beta_5 = -\gamma_7 \beta_6 \gamma_2 / \gamma_6 = -98.572$$

Z predpokladaných znamienok $\gamma_7, \beta_6, \gamma_2$ a γ_6 vyplýva, že parameter β_5 by mal byť záporný. Odhad parametra β_5 je záporný, čo je v súlade s ekonomickou teóriou.

$$\beta_6 = -\gamma_7 \beta_6 \delta_2 / \gamma_6 = 107.74$$

Z predpokladaných znamienok $\gamma_7, \beta_6, \delta_2$ a γ_6 vyplýva, že parameter β_6 by mal byť záporný. Odhad parametra β_6 je kladný, čo nie je v súlade s ekonomickou teóriou transmisného mechanizmu, z ktorej sme vychádzali. Túto skutočnosť však môžeme prisúdiť charakteru dát ÚVER. Ide o stav ku koncu mesiaca úverov podnikom a obyvateľstvu pričom v januári 2005 došlo k zmene metodiky na metodiku Európskej centrálnej banky.

$$\beta_7 = \gamma_7 / \gamma_6 = 1052.160$$

Z predpokladaných znamienok γ_7 a γ_6 vyplýva, že parameter β_7 by mal byť kladný. Odhad parametra β_7 je kladný, čo je v súlade s ekonomickou teóriou transmisného mechanizmu.

Následne sme daný model sme podrobili *ekonometrickej verifikácii*. Nasledujúca tabuľka predstavuje zosumarizovanie zistených výsledkov vykonaných testov:

Tabuľka 12: Zhrnutie výsledkov vykonaných testov, lineárny model

A. Metóda „vpred“	- všetky premenné sa javia ako opodstatnené
B. Redundant variables test	- premenné INF a SAX sa javia ako nepodstatné
C. Ramseyho RESET test	- ukazuje sa, že X a ε sú nekorelované (X nestochastická), v modeli sú všetky podstatné premenné a model má správnu funkčnú formu
D. Chowov test predikcie	- lineárnu špecifikáciu modelu možno považovať za vyhovujúcu
E. Rekurzívne rezíduá	- model sa javí byť stabilný
F. Testy heteroskedasticity F.1. grafická metóda F.2. Whiteov test	Možno predpokladať: - F.1. homoskedasticita - F.2. homoskedasticita + ε a X sú nezávislé + lineárna špecifikácia modelu je vyhovujúca
G. Testy autokorelácie G.1. Durbinov-Watsonov test G.2. Breuchov-Godfreyov test	Možno predpokladať: - G.1. nemožno rozhodnúť - G.2. autokorelácia 1. rádu- NIE (F real, LM real) autokorelácia 2. rádu- NIE (F real)
H. Testy multikolinearity H.1. Kleinov test H.2. Test Farrara a Glaubera	Možno predpokladať: - neprítomnosť multikolinearity - prítomnosť multikolinearity

Zdroj: Vlastné spracovanie

Výsledok testu nepresnej špecifikácie modelu založenom na rekurzívnych rezíduách má pre nás len informatívny charakter, nakoľko v našom skúmaní je opodstatnenosť daných premenných v modeli podložená v prvom rade ekonomickou teóriou. Niektoré vysvetľujúce premenné sa zdajú ako štatisticky nevýznamné, hoci F-štatistika hovorí o štatistickej významnosti celého modelu. Tento fakt (zdanlivý rozpor medzi nevýznamnými výsledkami t-testov a výsledkom F-testu) prisudzujeme prítomnosti multikolinearity. Z globálneho hľadiska môžeme náš klasický lineárny regresný model považovať za relatívne postačujúci.

6. Záver

Prvoradým cieľom nášho skúmania bolo overenie platnosti transmisného mechanizmu menovej politiky, ako ho pozná ekonomická teória, a jeho čo možno najoptimálnejšie premietnutie do ekonometrického modelu. Vychádzali sme pritom z platnosti jednotlivých transmisných kanálov, z ktorých sme odvodili kľúčové vzťahy medzi danými ekonomickými veličinami. Pomocou metódy najmenších štvorcov sme odhadli parametre jednorovnicového lineárneho regresného modelu, ktorý sme v ďalšej časti verifikovali z viacerých hľadísk. Primárnym pre nás bolo splnenie daných predpokladov ekonomickej teórie, čo sa nám s malou odchýlkou aj poradilo. Následne sme model podrobili viacerým testom ako súčasť ekonometrickej a štatistickej verifikácie modelu. Z výsledkov a záverov, ku ktorým sme pri jednotlivých testoch dospeli je zrejmé, že náš model transmisného mechanizmu menovej politiky spĺňa podstatnú väčšinu základných predpokladov, na ktorých je ekonometrické modelovanie postavené.

Vzhľadom na to teda môžeme konštatovať, že sa nám podarilo konštruovať pomerne dobrý ekonometrický model transmisného mechanizmu menovej politiky, ktorý môže byť do istej miery potvrdením základnej ekonomickej premisy, na ktorej stojí celá teória transmisného mechanizmu menovej politiky.

Na záver musíme poznamenať, že sme si uvedomili, že okrem nášho modelovania transmisného mechanizmu pomocou klasického jednorovnicového lineárneho regresného modelu existujú ďalšie analytické nástroje (napr. VAR alebo modelovanie transmisného mechanizmu pomocou rekurzívneho systému simultánnych rovníc), ktoré by mohli poskytnúť hlbší pohľad do existencie vzájomných previazaností medzi ekonomickými veličinami.

7. Použitá literatúra

- [1] CECHETTI, S.G. 1994. Distinguishing theories of the monetary transmission mechanism. In: Federal Reserve Bank of St. Louis, 1994 October 20-21
- [2] DOVČIAK, P. 1999. Kanály transmisného mechanizmu menovej politiky. In: Biatec 4/5, 1999, s.32
- [3] ECB. 2006. Európska centrálna banka, Eurosystem, Európsky systém centrálnych bánk. Frankfurt nad Mohanom: Kern & Birner GmbH & CO KG, 2006. ISBN 92-9181-946-8
- [4] HUŠEK, R. 1999. Ekonometrická analýza. Praha: EKOPRESS, 1999. ISBN: 80-86119-19-X
- [5] IRELAND, N.P. 2005. The monetary transmission mechanism. Boston College and NBER, October 2005.
- [6] KANDEROVÁ, M. – ÚRADNÍČEK, V. 2007. Štatistika a pravdepodobnosť pre ekonómov, 2. časť. Banská Bystrica: OZ FINANC, 2007. ISBN 978-80-969535-1-6
- [7] LACOVÁ, Ž. 2006. Vybrané aspekty konvergenzie v oblasti transmisie menových impulzov na domácnosti. In: Zborník z MVK „Vplyv konvergenčných procesov na ekonomiku a životný štýl nových členských krajín EÚ“, EF UMB, Banská Bystrica, 2006. ISBN-80-8083-270-6
- [8] MISHKIN, F.S. 1996. The Channels of Monetary Transmission: Lessons for Monetary Policy. In : NBER Working Paper 5945

- [9] REVENDA, Z. 2001. Centrální bankovníctví . Praha: Management Press, 2001. ISBN-80-726105-1-1
- [10] ŠMÍDKOVÁ, K. 2002. Transmisní mechanismus měnové politiky na počátku 3.tisíciletí. In: Finance a úvěř 52, 2002, č. 5

Softvér

- [11] Eviews 4
- [12] Excel
- [13] SPSS 13.0

Internetové zdroje

- [14] Mesačné prehľady NBS za roky 2002-2008 dostupné na <http://www.nbs.sk/>
- [15] <http://www.statistics.sk/pls/elisw/casovy_Rad.procDlg>
- [16] <http://epp.eurostat.ec.europa.eu/portal/page?_pageid=0,1136173,0_45570701&_dad=portal&_schema=PORTAL>
- [17] <<http://portal.statistics.sk/showdoc.do?docid=9613>>

Adresa autora:

Viera Roháčová, Bc.
Univerzita Mateja Bela v Banskej Bystrici
Ekonomická fakulta
Tajovského 10
975 90 Banská Bystrica
rohacova.v@gmail.com

Niektoré problémy logiky projektovania Some questions of logic of designing

Tatjana Šimanovská

Abstract: Designing is a very complex and multidimensional domain of human knowledge and activity. Our attention was primarily focused on a problem of logic of designing. We have treated the question of logical formalism for design.

Key words: methodology of designing, logic, logic of methods of optimization, possible worlds, environment, management of change.

Kľúčové slová: metodológia projektovania, logika, logika metód optimalizácie, možné svety, environment, manažment zmeny.

V tomto príspevku sa budeme zaoberať vybranými problémami logiky projektovania, najmä v súvislosti s koncepciou Herberta Simona. Môžeme si položiť otázku, či sú formy logického uvažovania (myslenia) v prírodných vedách vhodné aj pre projektovanie. Prírodné vedy sa zaoberajú vecami ako sú, a preto bežné systémy logiky, napr. výroková alebo predikátová logika, im veľmi dobre slúžia pri skúmaní sveta. Projektovanie sa však zaoberá vecami aké by mali byť, t.j. vynaliezanie artefaktov, ktoré majú dosiahnuť vopred stanovené ciele. Možno predpokladať, že projektovanie vyžaduje určité špeciálne pravidlá dedukcie alebo modifikáciu existujúcich pravidiel deklaratívnej logiky. Niektorí autori tvorili rozmanité paradoxy, aby demonštrovali potrebu odlišnej imperatívnej logiky (logic of imperatives) alebo normatívnej deontickej logiky. Ako odpoveď na tieto paradoxy sa rozvíjali mnohé konštrukcie modálnej logiky, ale žiadny z týchto systémov sa neukázal vhodným pre logické požiadavky procesu projektovania.

Podľa H. Simona je špeciálna imperatívna logika zbytočná a požiadavky projektovania možno uspokojiť nenáročnou adaptáciou deklaratívnej logiky (pod ktorou môžeme rozumieť výrokovú a predikátovú logiku, ako sme pochopili zo Simonových úvah). Simon zdôrazňuje slovo „zbytočný“ (unnecessary), lebo nemenovaný modálny logik ho obvinil z toho, že vo svojich článkoch tvrdil, že modálna logika bola „nemožná“ (impossible). Simonove úvahy v toto obvinenie popierajú. Modálna logika, tak ako žirafa, môže ukázať svoju existenciu tým, že sa vystaví na verejnosti. Otázkou však nie je jej existencia, ale to, načo je dobrá. A pre modálneho logika by nemalo byť problémom rozlíšiť „nie nutnosť“ (non - necessity) a „nemožnosť“ (impossibility). (Pozri [6], s. 59.)

Druhy logiky potrebné na projektovanie najľahšie objavíme tak, keď preskúmame, akú logiku používajú projektanti. V minulosti projektanti uvažovali vágne a intuitívne. Možno povedať, že nepoužívali logiku v pravom zmysle slova. Avšak jestvuje oblasť projektovej praxe, v ktorej sú štandardy presnosti usudzovania (dedukovania) vysoké. Je to oblasť tzv. optimalizačných metód, ktoré sa najviac rozvíjajú v štatistickej teórii rozhodovania a manažérskej vede. Ich dôležitosť rastie aj v teórii inžinierskeho projektovania. Teórie pravdepodobnosti a úžitkovosti sa dostali do centra pozornosti nielen projektantov praktikov, ale aj najvýznamnejších matematikov a logikov súčasnosti. Napríklad F. P. Ramsey, B. de Finetti, A. Wald, J. von Neumann, J. Neyman, K. Arrow, L. J. Savage a pod. Aj L. Nowak zdôrazňuje význam optimalizácie, presnejšie formovania optimalizačných tvrdení ako dôležitý znak vied o projektovaní a samotného projektovania.

Simonovu logiku metód optimalizácie môžeme stručne rozviesť takto: Vnútny environment problému projektovania reprezentuje množina daných alternatív činnosti. Alternatívy môžu

byť dané v plnom rozsahu. Všeobecnejšie, špecifikujú sa z hľadiska riadiacich premenných, ktoré definujú oblasti činnosti. Vonkajší environment reprezentuje množina parametrov, ktoré možno poznať s istotou alebo podľa pravdepodobnosti distribúcie. Ciele adaptácie vnútorného environmentu na vonkajší definuje funkcia úžitkovosti - funkcia, obvykle skalár, riadiacich premenných a parametrov environmentu - doplnená počtom obmedzení (nerovností medzi funkciami riadiacich premenných a environmentálnymi parametrami). Problémom optimalizácie je nájsť prijateľnú množinu hodnôt riadiacich premenných kompatibilnú s obmedzeniami, ktorá maximalizuje funkciu úžitkovosti daných hodnôt parametrov environmentu. (V prípade pravdepodobnosti môžeme namiesto „maximalizovať funkciu úžitkovosti,“ povedať „maximalizovať očakávanú hodnotu funkcie úžitkovosti“) ([6], s. 60). Na ilustráciu uvádzame ako zaujímavú *paradigmú pre imperatívnu logiku*, ktorú Simon aplikuje na problém výživy:

Príklad:

Logické termíny		Problém výživy
riadiace premenné	(„prostriedky“)	množstvá potravín
fixované (určené)		ceny potravín
parametre	(„zákony“)	{
		nutričný obsah
obmedzenia		nutričné požiadavky
	}	{
funkcia úžitkovosti	(„ciele“)	- náklady

Obmedzenia charakterizujú vnútorný environment;

parametre charakterizujú vonkajší environment.

Problém: Dané sú obmedzenia a fixované parametre; hľadáme hodnoty riadiacich premenných, ktoré maximalizujú úžitkovosť ([6], s. 61).

Tento problém je jednoduchý príklad triedy problémov, s ktorými si ľahko poradíme aj v prípade, že počet premenných je veľmi veľký. Použijeme matematický formalizmus známy ako lineárne programovanie.^{††} Takto formalizovaný problém optimalizácie sa stáva štandardným matematickým problémom, t.j. maximalizovať funkciu podriadenú obmedzeniam. Pri dedukovaní odpovede môžeme teda použiť štandardnú predikátovú logiku. V tejto súvislosti vzniká otázka, ako môžeme formalizovať bez špeciálnej imperatívnej logiky? Simon tvrdí, že formalizovať môžeme tak, že budeme uvažovať množinu možných svetov.^{‡‡} Najskôr uvažujeme všetky možné svety, ktoré spĺňajú obmedzenia vonkajšieho environmentu, potom hľadáme v množine špecifický svet, ktorý vyhovuje zvyšným obmedzeniam cieľa a maximalizuje funkciu úžitkovosti. Logika je presne tá istá, ako keby sme obmedzenia cieľa a požiadavku maximalizácie ako nové „prírodné zákony“ pripojili k jestvujúcim prírodným zákonom v podmienkach environmentu. Jednoducho sa pýtame, aké hodnoty riadiacich premenných sú vo svete, ktorý vyhovuje všetkým týmto podmienkam a uzavrieme, že tieto hodnoty sú hodnotami riadiacich premenných aké majú byť ([6], s. 62). Problematika premenných hrá veľkú rolu v súčasnosti mimoriadne diskutovanom manažmente zmeny. Simon sa zaoberá sociálnym manažmentom zmeny. Podľa neho

^{††} Zoznam potravín je daný a riadiace premenné budú množstvá rozmanitých potravín. Environmentálne parametre sú ceny a nutričný obsah (kalórie, vitamíny, minerály a pod.) každej potraviny. Funkcia úžitkovosti predstavuje náklady (s mínusovým znakom), ktoré sú podriadené obmedzeniam (napr., že neobsahujú viac ako 2000 kalórií denne a pod.). Tieto obmedzenia charakterizujú vnútorný environment.

^{‡‡} Simon prebral pojem možné svety od J. Jorgensena [2], s. 288 - 296. Túto ideu používali niektorí logici, napr. R. Montague, S. Kanger a J. Hintikka, na vybudovanie formálneho mostu medzi predikátovými kalkulmi a modálnou logikou pomocou takzvaných sémantických alebo modelových teoretických metód. Avšak žiadna z týchto teórií nevenovala dostatočnú pozornosť špeciálnej úlohe, ktorú hrajú v teórii riadiace premenné a obmedzujúce kritériá. Pojmom možné svety sa Simon zaoberá aj v práci [4] v III. Kapitole.

najjednoduchšie morálne usudzovanie vedie k nasledovnému všeobecnému pravidlu zavádzania zmeny: spoločnosť, ktorá má prospech zo zmeny, by mala platiť hlavnú cenu za zavedenie zmeny a mala by šľachetne kompenzovať tých, ktorým by mohla zmena uškodiť. Preto našou úlohou je prognózovať dlhodobé efekty zmeny. (Pozri [5], s. 13.) Poznávame, že čitateľ sa môže hlbšie oboznámiť so súčasnými názormi na problematiku manažmentu zmeny v [3].

Aby sme mohli predikovať dlhodobú rovnováhu musíme identifikovať dva hlavné aspekty celkovej situácie: 1) premenné, ktoré sa budú meniť autonómne a neúprosne - „prvé príčiny“ a 2) konštantné nemeniace sa „dané“ v situácii, ktorej sa iné premenné musia prispôbiť. Tieto sú kladivom a nákovou, ktoré vyteľávajú formu budúcnosti. Presnosť našich predikcií bude menej závisieť od presného prognózovania priebehu zmeny, než od správneho stanovenia faktorov, ktoré sú pevnými hybnými silami, a ktoré sú rovnako pevnými invariantmi. Prognóza podľa Simona spočíva v identifikácii kladiva a nákovy. (Pozri [5], s. 14 - 15.)

V príspevku sme sa pokúsili načrtnúť vybrané problémy logiky projektovania, ktoré si vyžadujú hlbšiu analýzu a slúžia predovšetkým ako inšpirácia pre ďalšie rozpracovanie tejto zaujímavej problematiky, ktorá je veľmi aktuálna v súvislosti so situáciou ľudstva v turbulentnej súčasnosti a hľadaním riešení pre jeho možnú lepšiu budúcnosť.

Literatúra

- [1] HOLOMEK, J., ŠIMANOVSKÁ T. 2002. Úvod do metodológie praktických vied. Bratislava 2002. 163 s. ISBN 80-8054-249-X.
- [2] JORGENSEN, J.: Imperatives and Logic. In: Erkenntnis, 1937 - 1938, No. 7.
- [3] MABEY, CH., MAYON - WHITE, B. (ED.): Managing Change. The Open University, London 1993.
- [4] SIMON, H. A.: Administrative Behavior. Macmillan, New York 1947.
- [5] SIMON, H. A.: The New Science of Management Decision. Prentice-Hall, New Jersey 1977.
- [6] SIMON, H. A.: The Sciences of the Artificial. Cambridge 1969.

Adresa autora

Tatjana Šimanovská, PhDr., PhD.
ÚM STU Bratislava
Vazovova 5, 812 43, Bratislava
tatjana.simanovska@stuba.sk

Aplikace waveletů v analýze časových řad

Application of wavelets in analyse of time series

Jana Šimsová

Abstract: In this paper we introduce the application of wavelets in time series. First the wavelet theory is briefly introduced and wavelet decomposition is illustrated in an easy example. Then we demonstrate de-noising of data by wavelet decomposition with various kinds of thresholding on time series of U.S. treasury bill contracts in 100 consecutive trading days.

Key words: Discrete wavelet transformations, scale and wavelet coefficients, thresholding

Klíčové slová: Diskrétní waveletová transformace, škálové a waveletové koeficienty, prahování.

6. Úvod

Ve Fourierově transformaci rozkládáme danou funkci do tvaru lineární kombinace funkcí sinus a kosinus různých frekvencí. V modelované časové řadě se tedy snažíme těmito funkcemi popsat změny v oblasti frekvencí. Protože funkce sinus a kosinus jsou periodické funkce, které jsou definovány na celé reálné ose, jakákoli změna v konkrétním časovém úseku se při popisu těmito funkcemi projeví na celé reálné ose. Ve waveletové transformaci používáme k reprezentaci dané časové řady funkce, které nazýváme wavelety. Tyto báze funkce mají většinou konečný nosič nebo alespoň exponenciální pokles v nekonečnu. Jsou tedy lokalizované v čase. Zároveň jsou wavelety definovány tak, že jsou schopny reagovat i na změny ve škále. Waveletová báze se skládá ze škálové funkce (otec) a mateřského waveletu, ze kterého se pomocí posunutí a dvojkové dilatace vytvoří wavelety na různých úrovních škály. V tomto článku jsou nejprve připomenuty vlastnosti waveletové transformace, která je pak názorně ukázána na jednoduchém příkladu a následně je užito waveletové dekompozice a komprese pro reálnou časovou řadu a je uvedeno, jak lze časovou řadu očistit pomocí prahování waveletových koeficientů.

7. Diskrétní waveletová transformace

Uvedeme zde pouze základní vlastnosti waveletů, protože celá teorie je velmi rozsáhlá oblast. Základní funkce má název *škálová funkce* (otec) $\varphi(x)$, pro kterou platí důležitý vztah s názvem *dilatační rovnice*

$$\varphi(x) = \sqrt{2} \sum_{k \in \mathbb{Z}} h_k \varphi(2x - k). \quad (1)$$

Koeficienty h_k se nazývají *škálové koeficienty*. Pokud má škálová funkce konečný nosič, škálových koeficientů je konečně mnoho nenulových. Pro škálové koeficienty škálové funkce, která má nosič délky L , platí

$$\sum_{k=0}^{2L-1} h_k = \sqrt{2}, \quad \sum_k h_k h_{k+l} = 2\delta_{0,l}. \quad (2)$$

Funkce zvaná (*mateřský*) *wavelet* $\psi(x)$ je definována vztahem

$$\psi(x) = \sqrt{2} \sum_{k \in \mathbb{Z}} g_k \varphi(2x - k), \quad (3)$$

kde koeficienty g_k se nazývají *waveletové koeficienty* a platí pro ně

$$\sum_{k=0}^{2L-1} g_k = 0, \sum_{k=0}^{2L-1} g_k^2 = 1, \sum_k h_k h_{k+2l} = 0. \quad (4)$$

Mezi škálovými a waveletovými koeficienty platí vztah $g_k = (-1)^k h_{L-1-k}$.

Pomocí dilatací a celočíselných posunutí se z mateřského waveletu a škálové funkce vytvoří funkce následujícím způsobem

$$\varphi_{j,k}(x) = 2^{\frac{j}{2}} \varphi(2^j x - k), \quad j, k \in \mathbb{Z} \quad (5)$$

$$\psi_{j,k}(x) = 2^{\frac{j}{2}} \psi(2^j x - k), \quad j, k \in \mathbb{Z}. \quad (6)$$

Funkci $f(x)$ můžeme psát jako lineární kombinaci

$$f(x) = \sum_{k \in \mathbb{Z}} c_{j_0,k} \varphi_{j_0,k}(x) + \sum_{j \geq j_0} \sum_{k \in \mathbb{Z}} d_{j,k} \psi_{j,k}(x), \quad (7)$$

Pokud máme data $x = (x_0, x_1, \dots, x_{T-1})$, kde $T = 2^J$, $J > 0$, $J \in \mathbb{Z}$, pocházející například z nějakého stochastického procesu, *diskrétní waveletová transformace* W je definována vztahem

$$d_{j,k} = \sum_{t=0}^{T-1} x_t \psi_{j,k}(t), \quad (8)$$

Pro $j = 0, 1, \dots, J-1, k = 0, 1, \dots, 2^j - 1$. V maticovém tvaru můžeme psát $d = Wx$ nebo $x = W^{-1}d$. Pokud pracujeme s ortogonálními wavelety, pro matici W platí $W^T = W^{-1}$. Koeficienty $d_{j,k}$ mohou být spočteny pomocí *Mallatova algoritmu*, který využívá vztahů mezi koeficienty $c_{j,k}$ a $d_{j,k}$ na sousedních úrovních

$$c_{j-1,k} = \sum_l h_{l-2k} c_{j,l} \quad (9)$$

$$d_{j-1,k} = \sum_l g_{l-2k} c_{j,l}. \quad (10)$$

Mezi nejpoužívanější patří wavelety zkonstruované I. Daubechies, dále Meyerovy wavelety, coinflety nebo symmlety, atd. Daubechies wavelety mají řadu užitečných vlastností. Například jsou ortogonální, mají konečný nosič, jistý stupeň hladkosti a určitý počet nulových momentů. Příkladem nejjednoduššího a nejstaršího waveletu, který se mezi tyto Daubechies wavelety řadí, je Haarův wavelet daný předpisem

$$\psi(x) = \begin{cases} 1, & 0 \leq x < 1/2, \\ -1, & 1/2 \leq x < 1, \\ 0, & \text{jinde.} \end{cases} \quad (11)$$

Pro tento wavelet existují dva škálové koeficienty $h_0 = h_1 = \frac{1}{\sqrt{2}}$ a dva waveletové koeficienty

$g_0 = \frac{1}{\sqrt{2}}, g_1 = -\frac{1}{\sqrt{2}}$. Ukažme na jednoduchém příkladě, jak bude vypadat diskrétní waveletová transformace s užitím Haarova waveletu. Uvažujme například vektor

$x = (2, 7, 5, 6)^T$, tedy vektor délky 2^J , kde $J = 2$. Máme tedy tři waveletové úrovně. Diskrétní waveletová transformace bude mít tvar

$$\begin{pmatrix} 2 \\ 7 \\ 5 \\ 6 \end{pmatrix} = \begin{pmatrix} 1 & 1 & \sqrt{2} & 0 \\ 1 & 1 & -\sqrt{2} & 0 \\ 1 & -1 & 0 & \sqrt{2} \\ 1 & -1 & 0 & -\sqrt{2} \end{pmatrix} \begin{pmatrix} c_0 \\ d_{00} \\ d_{10} \\ d_{11} \end{pmatrix} \quad (12)$$

A tím koeficienty transformace dostaneme z rovnice

$$\begin{pmatrix} c_0 \\ d_{00} \\ d_{10} \\ d_{11} \end{pmatrix} = \frac{1}{4} \begin{pmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & -1 & -1 \\ \sqrt{2} & -\sqrt{2} & 0 & 0 \\ 0 & 0 & \sqrt{2} & -\sqrt{2} \end{pmatrix} \begin{pmatrix} 2 \\ 7 \\ 5 \\ 6 \end{pmatrix} = \begin{pmatrix} 5 \\ -\frac{1}{2} \\ -\frac{5\sqrt{2}}{4} \\ -\frac{\sqrt{2}}{4} \end{pmatrix}. \quad (13)$$


Nyní ukážeme, jak původní vektor rozložíme do zmíněných tří úrovní. První úroveň zastupuje složka c_0 . Proto jedinečně tuto složku vektoru z rovnice (13) necháme nenulovou a ostatní složky položíme rovny 0. Vynásobením takto vzniklého vektoru maticí W dostaneme vektor $S = (5, 5, 5, 5)^T$. Další úroveň je zastoupena koeficientem d_{00} . Vytvoříme vektor, jehož druhá složka je rovna $-\frac{1}{2}$ a ostatní složky nulové. Pronásobením tohoto vektoru maticí W dostaneme vektor $D_1 = \left(-\frac{1}{2}, -\frac{1}{2}, \frac{1}{2}, \frac{1}{2}\right)^T$. Poslední úroveň je zastoupena koeficienty d_{10}, d_{11} . Vynásobením vektoru, ve kterém tyto dvě složky budou rovny 0 a druhé dvě budou d_{10}, d_{11} , maticí W , dostaneme vektor $D_2 = \left(-\frac{5}{2}, \frac{5}{2}, -\frac{1}{2}, \frac{1}{2}\right)^T$. Našli jsme waveletovou dekompozici původního vektoru do hladké složky S a složek detailů D_1 a D_2 . Platí

$$\begin{pmatrix} 2 \\ 7 \\ 5 \\ 6 \end{pmatrix} = \begin{pmatrix} 5 \\ 5 \\ 5 \\ 5 \end{pmatrix} + \begin{pmatrix} -\frac{1}{2} \\ -\frac{1}{2} \\ \frac{1}{2} \\ \frac{1}{2} \end{pmatrix} + \begin{pmatrix} -\frac{5}{2} \\ \frac{5}{2} \\ -\frac{1}{2} \\ \frac{1}{2} \end{pmatrix} \quad (14)$$


Na tomto jednoduchém příkladě jsme ukázali, jak lze původní data rozložit do složky, která charakterizuje hladkou část, a složky detailů. Detaily jsou popsány pomocí hodnot souvisejících s wavelety „vysokých frekvencí“ neboli jemnější škálové úrovně. Tyto detaily mohou v signálu (časové řadě) zastupovat šumy. Pro vyhlazení časové řady tedy některé z těchto detailů můžeme zanedbat. Na reálných datech nebudeme používat Haarův wavelet, ale wavelety, které jsou hladší a mají tedy lepší aproximační vlastnosti.

8. Analýza dat


V této části budeme pracovat s reálnou časovou řadou kontraktů amerických krátkodobých státních obligací během sta po sobě jdoucích obchodních dnů. Z této řady $x(t)$ byl nejprve odečten trend ve tvaru $T(t) = 91,265 - 0,05212x(t)$ a byla získána data $y(t)$ pro $t = 1, 2, \dots, 100$. Tato časová řada je stacionární s průměrem rovným nule. Protože počet dat není ve tvaru $T = 2^J$, doplníme tuto řadu na řadu délky 2^7 přidáním prvních 28 nulových hodnot. Na takto upravenou časovou řadu provedeme waveletovou dekompozici $d(t) = Wy(t)$ pomocí waveletu Dabechies4. Na data $d(t)$ provedeme tzv. prahování. Prahování je nejčastěji dvojího druhu: tvrdé nebo měkké prahování. Tvrdé prahování znamená, že každou absolutní hodnotu koeficientu $d_{j,k}$, která je složkou vektoru $d(t)$, snížíme o jistý práh (předem danou hodnotu λ). Měkké prahování znamená, že absolutní hodnoty detailů ($d_{j,k}$) snížíme o hodnotu λ . Pokud po tomto snížení bude tato hodnota záporná, nahradíme ji nulou. V našem případě jsme použili ve všech uvedených případech měkkého prahování s různými hodnotami parametru λ . Výběr prahových parametrů je založen na modelu $y = f(t) + e$, kde e je bílý šum $N(0,1)$. Jedna z metod navrhuje volbu parametru λ tvaru $\sqrt{2 \ln T}$. Metoda SUER odhaduje parametr λ minimalizací rizika založeném na Steinově nestranném odhadu rizika (Stein's Unbiased Estimate of Risk). Metoda minimaxi hledá parametr λ jako minimum maxima střední kvadratické chyby mezi danou a očištěnou časovou řadou. Po provedení prahování byla provedena inverzní waveletová transformace $y(t) = W^T d(t)$ a byla tak získána očištěná časová řada $\tilde{y}(t)$, ze které jsme vypustili prvních 28 hodnot. K získání očištěné původní řady $\tilde{x}(t)$ jsme k hodnotám $\tilde{y}(t)$ jsme přičetli trend. Výsledky očištěné časové řady s různými typy prahového parametru λ jsou uvedeny v následujících čtyřech grafech.




Obrázek 15: původní a očištěná časová řada s měkkým prahováním $\lambda = \sqrt{2 \ln T}$



Obrázek 2: původní a očištěná časová řada s měkkým prahováním $\lambda = 0,4245$



Obrázek 3: *původní a očištěná časová řada s měkkým prahem λ minimaxi*



Obrázek 4: *původní a očištěná časová řada s měkkým prahem λ založeným na SUER*

9. Závěr

Na konkrétním příkladu časové řady jsme se snažili demonstrovat použití waveletové transformace a vliv různých druhů prahování na očištění časové řady od šumů, které jsou ve waveletové dekompozici representovány koeficienty rozkladu na vysokých škálových úrovních. Data byla zpracovávána SW Matlab s toolboxem wavelet.

10. Literatura

- [1] ARINO, M.A.- MORETTIN, P.A.- VIDAČKOVIC, B. 2004. Wavelets Scalograms and Their Applications in Economic Time Series. In: Brazilian Journal of Probability and Statistics, č. 18, 2004, s. 37-51.
- [2] GENÇAY, R. – SELCUK, F.-WHITCHER, B. 2002. An Introduction to Wavelets and Other Filtering Methods in Finance and Economics, 2002, 359 s. ISBN 978-0-12-279670-8.
- [3] CHAINN, CH.- MORETTIN, P.A. 1998. A Wavelet Analysis for Time Series. In: Journal of Nonparametric Statistics. Č. 10, 1998, s. 1-46.
- [4] PERCIVAL, D.B. – WALDEN, A.T. 2007. Wavelet methods for Time Series Analysis, 2007, 594 s. ISBN 978-0-521-68508-5.
- [5] SCHLEICHER, CH. 2002. An Introduction to Wavelets for Economists. In: Bank of Canada Working Paper 2002-3. ISSN 1192-5434.
- [6] ŠIMSOVÁ, J. 2007. Wavelety a časové řady. In: FORUM STATISTICUM SLOVACUM. 2007, č. 4. Slovenská statistická a demografická spoločnosť, 2007, s. 143 – 148.

Adresa autora :

Jana Šimsová, RNDr., Ph.D.
 Moskevská 54
 400 96 Ústí nad Labem
 jana.simsova@ujep.cz

T-učenie

T-learning


Ondrej Tretiak

Abstract: The document refers to the emerging new forms of education, including already existing e-learning applications. The main objective focuses on emerging t-learning applications which may mean a significant benefit for the society as well as for individuals. This paper describes the predication in the t-learning what can bring us the future in this field. It also describes what areas could benefit from digital television in education and how it could help in learning not only healthy but also disabled people.

Kľúčové slová: T-učenie, digitálne televízia, E - učenie, IP, učenie, multimédia, ...

1. Úvod

Podľa [1] termín “t-learning“ (e-learning pomocou digitálnej televízie) je skratka znamenajúca TV – založenú na interaktívnom vzdelávaní. Tlearning je o interaktívnom prístupe k vzdelávacím materiálom bohatým na video. Podľa [3] T-learning sa charakterizuje aj ako zblíženie medzi interaktívnou televíziou (iTV) a e-learningom. Je chápaný aj ako využívanie počítačových technológií podporujúcich rôzne kurzy a vzdelávacie činnosti. T-learning predstavuje zblížovanie dvoch technológií: a to televízie a počítačových technológií. Zahŕňa okrem toho aj mobilné technológie a Internet Protokol. Podľa [4] Internet Protocol (IP) je dátovo orientovaný komunikačný protokol sieťovej vrstvy využívaný cieľovým a zdrojovým strojom na výmenu dát cez sieť s prepínaním paketov. T-learning sa môžeme chápať tiež ako zblížovanie multimédií a e-learningu. Multimédia predstavujú používanie viac ako jedného média napríklad : text, grafika, animácie a iné. Televízia alebo iné vhodné zariadenia pre vysielanie predstavujú hlavné médium v T-learningu. Ďalšie zariadenia sú implementované ako sekundárne média pre podporu vzdelávania. Definícia T-learningu je reprezentovaná nasledujúcim obrázkom 1. [3]



Obrázok 16: T-learning ako zblížovanie IP, DTV a mobilných technológií a e-learningu

2. Využívanie T-learningu

Využíva sa najmä v prostredí domova cez televíziu alebo podobné zariadenie. Ak nemáme k dispozícii televíziu, iným zariadením môže byť napríklad aj osobný počítač. Zariadenia podobné televízii by mali plniť najmä funkciu takzvaného “spotrebiteľského“ zariadenia, ktoré je ľahko použiteľné a spoľahlivé. Príkladom môže byť televízor, varná kanvica, prípadne chladnička. Hoci má e-learning v súčasnej dobe tendenciu využívať pri vzdelávaní hlavne internet prostredníctvom počítača, v súčasnosti existujú aj

formy vzdelávania, ktoré môžu využívať aj iné elektronické a digitálne zariadenia. Príkladom je už spomínaný t-learning, teda využívanie digitálnej televízie pri vzdelávaní a m-learning, takzvané mobilné vzdelávanie.

T-learning možno pokladať za podmnožinu e-learningu, pri ktorom sa využíva prístup k jednotlivým aplikáciám pomocou digitálnej domácej televízie. T-learning by mohol významne zvýšiť vzdelávacie možnosti rôznymi spôsobmi, ktoré e-learning využívajúci internet nemôže v súčasnej dobe poskytnúť. T-learning sa nemusí využívať a prebiehať len na domácich televízoroch. Rovnako ako ho využívame v domácnosti, mohol by byť dostupný aj z iného miesta, napríklad v škole, na rôznych pracoviskách, knižniciach alebo inom verejno-vzdelávacom mieste.

M-learning - mobilné vzdelávanie môžeme pokladať tiež za ďalšiu podmnožinu e-learningu. Je to vzdelávanie dostupné pomocou mobilného telefónu alebo iného bezdrôtového zariadenia. Neustálym vývojom t-learningu a m-learningu spolu s rastom nových technologických riešení sa budú neustále medzi sebou všetky tieto technológie viac a viac prekrývať. Vývoj e-learningu je závislý na počítačových hardwarových, softwarových a internet službách, ktoré zaisťujú tvorbu produktov, ich štandardizáciu a dosť nízke ceny pre kupujúcich. Dodávanie nových technológií je v dnešnej dobe obvyčajne jednoduché, ale nie vždy veľmi spoľahlivé, vyžaduje racionálne a aj odborné vedomosti na obsluhovanie počítača.

V trocha odlišnej forme aj t-learning dosť závisí na vývoji veľmi spoľahlivých a ľahko použiteľných spotrebiteľských zariadení. Vyžaduje využívanie vlastného, štandardného hardwaru, softwaru a sieťovej infraštruktúry. T-learning sa v počiatočných používal predovšetkým ako fráza hlavne medzi analytikmi, ktorí sledujú jeho vývojový a trhový stav pomocou časových období. Súčasnosti jeho vývoj smeruje dopredu, ale je veľmi nepravdepodobné, že by si ľudia zrazu povedali "Využívajme T-learning" alebo "Musíme sa ísť učiť pomocou T-learningu". Neustálym vývojom digitálnej televízie a aj ostatných technológií, akými je napríklad prostredie na tvorbu t-learningových aplikácií a samotné aplikácie sa začne t-learning viac využívať. Dôležité bude správne ho predstaviť a ukázať ľuďom. Vysvetliť im aké výhody im môže poskytnúť a ako im môže uľahčiť ich vzdelávanie, ktoré je v dnešnej dobe tak dôležité.

3. Rozdiely medzi e-learningom a t-learningom

So samotným e-learningom sa stretávame najmä na počítačoch, forma t-learningu teda e-learningu cez digitálnu televíziu nie je ešte veľmi rozšírená. Prakticky sa dá povedať, že táto nová forma vzdelávania sa ešte len testuje, v niektorých štátoch Európy. Dôvodom je aj samotná digitálna televízia, lebo aj tá je ešte len v polohe vývoja a zavádzania v jednotlivých krajinách. Samotný t-learning vyžaduje digitálnu televíziu na vysokej úrovni a dostupnú prakticky u každého, kto prejaví o využívanie t-learning záujem. Vznikajúce rozdiely medzi e-learningom a t-learningom evidujeme:

- a. vo forme ovládania, ovládanie t-learningu diaľkovým ovládačom je jednoduchšie než samotný e-learning cez počítač, vyhľadávanie určitého kurzu bude cez digitálnu televíziu kliknutím na oblasť, ktorá nás zaujíma a televízia vykoná všetko za nás. Celý kurz sa bude riadiť cez diaľkový televízny ovládač.
- b. lepšia dostupnosť, dnešnej dobe je samozrejme lepšie prístupný e-learningový kurz cez počítač, lebo cez digitálnu televíziu sa všetko ešte len testuje. Časom, ak dôjde k masívnemu nárastu používateľov digitálnej televízie, kurzy cez DT sa stanú dostupnejšie. Televíziu má k dispozícii viac ľudí a podľa [2] mnohí ľudia nechcú nikdy využívať počítač a na internet chcú radšej pristupovať cez

iný terminál, akým je napríklad digitálna televízia. S toho dôvodu budú aj radšej využívať e-learningové aplikácie cez televíziu ako cez počítač.

- c. Časom bude m-learning, lepšia dostupnosť digitálnej televízie cez mobilné telefóny, ak sa rozšíri štandard DVB-H vo väčšej miere. Potom bude možné využívať na vzdelávanie aj mobilné telefóny, ktorých súčasťou bude DTV, napríklad na pracovných cestách, v aute, vo vlaku, alebo kde sa naskytne možnosť a čas.

4. Predikácia vývoja a obsahu t-learningu:

Vývoj:

Dnešná doba nám ponúka veľké množstvo možností vzdelávania. Každým rokom pribúdajú nové možnosti ako sa vzdelávať, alebo sa zdokonaľujú tie staré. Medzi ne môžeme zaradiť aj novorozvíjajúcu sa disciplínu t-learning. Na Slovensku je prakticky ešte u väčšiny ľudí neznáma a možno o nej ešte ani nikdy nepočuli. Dôvodov je viac. Môžeme medzi ne zaradiť pomalšiu informatizáciu spoločnosti, t.j. napríklad internet sa u nás ešte len presadzuje a začína zavádzať do domácnosti a škôl. Čo sa týka t-learningu, veľmi dôležitá je aj samotná digitálna televízia. Jej zavádzanie je tiež iba v začiatkoch, ale v priebehu ďalšieho desaťročia by mala úplne nahradiť analógové vysielanie. Keď sa podarí vyriešiť tieto už existujúce problémy, ľudia začnú mať väčší záujem aj o nové formy vzdelávania, medzi ktoré určite bude časom patriť aj t-learning. Samotná digitálna televízia nám už aj dnes ponúka veľmi dobré služby, ale čo sa týka vzdelávania sme len úplne v začiatkoch. Prebieha vytváranie prvých t-learningových aplikácií medzi, ktoré sa radia hlavne výučbové hry. Tieto aplikácie sú testované hlavne v štátoch západnej a severnej Európy medzi ktoré patria Veľká Británia, Taliansko, Fínsko a Nemecko. V priebehu 10 rokov by mohlo dôjsť k vysokému nárastu aplikácií, lebo v týchto štátoch sú už vo väčšej miere zavedené technológie, aké vyžaduje t-learning. Budúcnosť by mohla priniesť veľké možnosti ako využívať digitálnu televíziu na vzdelávanie. Digitálna televízia by sa mohla zamerať na tieto oblasti: na zdravotnú starostlivosť pre občanov, forma výučby jazykov pre nevidiacich, ale aj zdravých, učenie posunkového jazyka pre učiteľov nepočujúcich, rôzne kurzy varenia, rôzne cvičenia aj pre postihnuté deti a iné možnosti.

T-learning by sa mohol začať využívať aktívne na Slovensku v priebehu ďalšieho desaťročia. Teda po nahradení analógového vysielania digitálnym vysielaním pravdepodobne v roku 2015. Je možno, že vtedy budú rôzne t-learningové aplikácie vytvorené aj pre digitálnu televíziu cez mobilné telefóny, lebo aj tá sa už čoskoro začne u nás využívať. Bola by to vynikajúca pomôcka ako sa vzdelávať pri cestovaní v aute, vlakom, autobusom či iným dopravným prostriedkom.

Obsah:

Učenie jazykov: Digitálna televízia by sa mohla stať vynikajúcim nástrojom a pomôckou pri učení cudzích jazykov. Mohla by slúžiť nielen zdravým, ale aj slabozrakým a nevidiacim ľuďom. Učenie prostredníctvom televízie je výhodné v tom, že učiaci sa môže počúvať a zároveň aj vidieť jednotlivé predmety, o ktorých sa rozpráva. Toto mu uľahčí zapamätanie si jednotlivých slovíčok, prípadne fráz. Pri digitálnej televízii je napríklad možnosť sledovaný program zastaviť aj pri živom vysielaní a následne si pustiť nejakú časť aj viac krát za sebou. Ďalej je tu možnosť si živé vysielanie aj nahráť priamo do pamäte. Spomínaná funkcia zastavenia živého vysielania by mohla byť výborne využívaná pri učení jazykov. Hlavne ak niekto sleduje jazykový kurz a nestíha. Je tu možnosť si kurz zastaviť a prehrať si ho znova a pustiť si pokračovanie kurzu až keď zvládne danú časť a následne si kurz spustiť, kde skončil. Pre toho, kto sa chce kurzom intenzívnejšie venovať, je najlepším riešením kurz si nahráť. Potom sa môže k jednotlivým častiam, ktoré mu spôsobovali najväčšie problémy

vrátiť a prejsť si ich viac krát, až kým ich nezvládne. Výhodou je, že si stačí kurz nahrat' do pamäte a keď už všetko zvládne stačí ho jednoducho vymazať. Digitálna televízia by mohla slúžiť hlavne ako výborná pomôcka pri učení jazykov pre slabozrakých a nevidiacich divákov. Jazykové kurzy by si mohli riadiť za pomoci ovládača, ktorý by bol vybavený braillovým písmom. Ovládač by mohol byť vybavený popri braillovom písme aj zvukom, ktorý by každému užívateľovi oznamoval na čo je to-ktoré tlačítko určené. Po čase ako by si zapamätal, na čo sú jednotlivé tlačítka, bola by tu možnosť túto funkciu vypnúť a využívať ovládač aj bez zvuku. Ovládač na televízor by bol vybavený tlačítkom, ktoré by umožňovalo znova spustiť, prípadne vypnúť zvuk pre ozvučenie jednotlivých tlačítok.

Mohli by sa vytvoriť aj kurzy určené priamo pre zrakovo postihnutých, ktoré by boli nahovorené pomalšie. Pri jednotlivých kurzoch by bolo oznámené či je určený pre zdravých, alebo zrakovo postihnutých. Bola by možnosť zväčšovať jednotlivé slovíčka, vety, obrázky na obrazovke, aby uľahčovali prácu slabozrakým divákom, teda záujemcom o jazykový kurz. Takýmto spôsobom by sa mohol zvýšiť záujem o štúdium jazykov, stalo by sa príjemnejším, jednoduchším a aj zábavnejším a to nielen pre zdravých.

Vznik kurzov by mohol podporovať najprv štát, prípadne Európska Únia a neskôr rôzne neziskové alebo komerčné organizácie. Podpora štátu by mohla ísť nielen na vývoj, ale aj na možnosti si zaobstarať digitálnu televíziu s jazykovými, prípadne inými aplikáciami. Teda mohol by podporovať rodiny, ktoré majú v rodine určitých členov postihnutých alebo sociálne slabšie rodiny, čím by zvýšil vzdelanosť spoločnosti a tým aj zlepšil sociálnu otázku spoločnosti. Na výber by mohlo byť niekoľko jazykov, a aj rôzne formy ako sa ich učiť, napríklad slovíčka cez obrázky. Stačilo by sa dotknúť obrázku a hneď by sa ozvalo čo daný obrázok znamená. K dispozícii by mohol byť klasický ovládač a ovládač vybavený s braillovým písmom.

T-learningové aplikácie by sa mohli stať vynikajúcou pomôckou aj pre učiteľov hluchonemých detí, lebo mnohí študenti, ktorí sa rozhodnú študovať špeciálnu pedagogiku s takýmto zameraním, často krát nevedia ako sa posunkový jazyk naučiť. Na škole majú síce základy, ale tie sú nedostačujúce. T-learningové kurzy zamerané na posunkovú reč by si určite našli početnú skupinu používateľov.

Slovník cudzích slov :Cez televíziu by sa dal výborne využívať aj slovník cudzích slov, ktorý by bol tiež veľmi výhodný pre nevidiacich. Cez mikrón by povedali, ktoré slovo potrebujú vyhľadať alebo by ho mohli napísať. Kurz by poskytol všetky informácie, prípadne prečítal všetko o žiadanom slove. Mohla by byť aj taká alternatíva, ktorá by umožňovala žiadané slovo zadať pomocou braillového písma. K dispozícií by bola nejaká pomôcka, prípadne klávesnica s potrebnými znakmi

5. Záver

Na t-learningové kurzy je potrebná kvalitná digitálna televízia, ktorá sa ale v dnešnej dobe ešte len zavádza a zdokonaľuje Na Slovensku by mala nahradiť analógové vysielanie do roku 2015. Týmto rokom by sa mohli začať naplno využívať aj samotné t-learningové aplikácie. V súčasnosti sa ale kurzy len testujú a prostredie pre ich vytváranie sa tiež ešte stále vyvíja. Výhodou takýchto kurzov bude jednoduchosť vzdelávania a podpora celoživotného vzdelávania, ktoré nielen že si dnešná spoločnosť vyžaduje, ale majú význam aj pre náš celkový rast.

6. Literatúra

- [1] <http://www.pjb.co.uk/t-learning/contents.htm>
- [2] <http://www.tvcentrum.sk/print.php?art=66>
- [3] <http://www.it.lut.fi/eaeie05/proceedings/p21.pdf>
- [4] http://sk.wikipedia.org/wiki/Internet_protokol

Adresa autora :

Ondrej Tretiak, Ing.
Gercenova 13
85101 Bratislava
ondrej.tretiak@yahoo.com
ondrejtretiak@gmail.com

Predikovanie ekonomickej pridanej hodnoty pomocou logistickej regresie

Economic value added prediction basen upon logistic regression

Vladimír Úradníček

Abstract:

The article focuses upon a possibility of the application of the selected multivariate statistical method to the prediction of the shareholders' wealth measured by economic value added. Utilizing data on a set of enterprises, the article guides in the application of logistic regression in an attempt to capture the likelihood of the positive economic value added for the given enterprise.

Key words: economic value added, prediction, multivariate statistical methods, logistic regression

Kľúčové slová: ekonomická pridaná hodnota, predikcia, viacrozmerné štatistické metódy, logistická regresia

1. Úvod

Jedným z alternatívnych cieľov podnikania môže byť maximalizácia ekonomického zisku podniku. Ekonomický výsledok hospodárenia zohľadňuje na rozdiel od účtovného výsledku hospodárenia aj tzv. alternatívne náklady. Ukazovateľom, ktorý meria veľkosť vytvoreného ekonomického výsledku hospodárenia v podniku (ekonomický zisk, resp. stratu) je *ukazovateľ ekonomickej pridanej hodnoty (ukazovateľ EVA – economic value added)*. Ekonomická pridaná hodnota je významným faktorom väzby na trhovú hodnotu podniku. Z toho vyplýva význam jej analyzovania ako pre manažment, tak osobitne pre vlastníkov podniku. Príspevok ilustruje možnosť využitia logistickej regresie pri predikovaní odpovede na základnú otázku: S akou pravdepodobnosťou môžeme očakávať, že hodnota ukazovateľa EVA bude kladná, t.j. podnik bude produkovať pre svojich vlastníkov ekonomický zisk ($EVA > 0$) a nie ekonomickú stratu ($EVA < 0$), čo by znamenalo, že sa „ničí“ hodnota bohatstva vlastníkov podniku..

2. Teoretické východiská konceptu ekonomickej pridanej hodnoty

Koncept EVA vytvorili pracovníci newyorskej poradenskej firmy Stern – Stewart & Co. začiatkom poslednej dekády minulého storočia.

EVA meria ako podnik za dané obdobie prispel svojimi aktivitami ku zmene hodnoty pre svojich vlastníkov.

Existujú dva základné prístupy k definovaniu ukazovateľa EVA:

- 1) Z pohľadu vlastníkov (shareholders):

aby podnik vytváral hodnotu pre vlastníkov, musí platiť, že

výnosnosť vlastními investovaného kapitálu (meraná ROE) musí byť väčšia ako alternatívna miera nákladu na kapitál (r_E), t.j.

$$ROE > r_E, \text{ potom}$$

$$EVA = (ROE - r_E) \cdot E, \quad (1)$$

kde E je trhovú hodnotu vlastného imania (*equity*).

2) Z pohľadu všetkých „zainteresovaných“ (stakeholders):

výnosnosť celkového investovaného kapitálu > celková miera nákladu na kapitál, t.j.

$$\text{„ROA=NOPAT/C“} > \text{WACC, potom} \\ \text{EVA} = \text{NOPAT} - \text{WACC} \cdot C, \quad (2)$$

kde

NOPAT = čistý operatívny zisk po zdanení (Net Operating Profit After Taxes),

WACC = vážený aritmetický priemer nákladov kapitálu (Weighted Average Cost of Capital), t.j. $\text{WACC} = r_E \cdot \frac{E}{C} + r_D \cdot (1-t) \cdot \frac{D}{C}$,

D sú explicitne úrokované cudzie zdroje,

r_D je celková priemerná efektívna úroková sadzba, ktorou sa úrokuje explicitne úrokované cudzie zdroje,

t je daňová sadzba (*tax*)

$C = E + D$ je celkový kapitál viazaný v majetku, ktorý slúži na operatívnu činnosť podniku.

Dá sa ukázať, že obe definičné vymedzenia ukazovateľa *EVA* sú za určitých zjednodušujúcich predpokladov identické.

$$\begin{aligned} \text{NOPAT} - \text{WACC} \cdot C &= \text{EBIT} \cdot (1-t) - \left(r_E \cdot \frac{E}{C} + r_D \cdot (1-t) \cdot \frac{D}{C} \right) \cdot C = \\ &= \text{EBIT} \cdot (1-t) - r_E \cdot E - r_D \cdot (1-t) \cdot D = \check{C}Z + \acute{U} \cdot (1-t) - r_E \cdot E - r_D \cdot D \cdot (1-t) = \\ &= \check{C}Z + \acute{U} \cdot (1-t) - r_E \cdot E - \acute{U} \cdot (1-t) = \check{C}Z - r_E \cdot E = \left(\frac{\check{C}Z}{E} - r_E \right) \cdot E = (\text{ROE} - r_E) \cdot E \end{aligned}$$

kde

EBIT je výsledok hospodárenia pred úrokmi a zdanením,

$\check{C}Z$ je čistý zisk,

$\acute{U}$ sú nákladové úroky.

Ak je hodnota ukazovateľa *EVA* > 0, potom sa zvyšuje „bohatstvo“ vlastníkov, ak je hodnota ukazovateľa *EVA* < 0, tak sa ich bohatstvo „ničí“ a ak je hodnota tohto ukazovateľa nulová, potom sa výška „bohatstva“ vlastníkov nemení.

Základom pre určenie ekonomickej pridanej hodnoty sú teda tri kľúčové ukazovatele: NOPAT, WACC a C, pričom určenie každého je do určitej miery problematické. NOPAT by mal byť výsledkom tej časti podnikateľskej činnosti, ktorá slúži základnému podnikateľskému cieľu – tzv. operatívnej činnosti (neoperatívnu činnosťou je napr. investovanie dočasne voľných prostriedkov do cenných papierov), očisteným o upravené dane. Pri určovaní NOPAT sa obvykle vychádza z hrubého výsledku hospodárenia z bežnej činnosti (HVBČ_B), ktorý sa v „hrubých rysoch“ stotožňuje s EBIT-om, C predstavuje vlastný a explicitne úročený cudzí kapitál viazaný v aktívach, potrebných na dosiahnutie NOPAT-u (v tzv. čistých operatívnych aktívach – NOA) a určuje sa úpravami z hodnoty účtovných aktív na začiatku sledovaného obdobia (pri väčších výkyvoch sa vychádza z priemeru C na začiatku a na konci sledovaného obdobia). Určenie EVA je založené na úprave účtovných veličín (NOPAT, C) na ekonomické veličiny blížiac sa pohľadu kapitálového trhu na podnik. Úplný zoznam úprav je obchodným tajomstvom ako firmy Stern Stewart & Co, ktorej je koncept EVA registrovanou

ochrannou známkou, tak prípadne iných spoločností, ktoré sa zaoberajú vyčíslovaním ekonomickej pridanej hodnoty.

Pre konštrukciu modelu logistickej regresie sa pre ukazovateľ „ROA“ = NOPAT/C aplikuje druhý DuPontov rozklad, ktorý v multiplikatívnej väzbe rozkladá ukazovateľ „ROA“ na rentabilitu tržieb a obrátkovosť operatívnych aktív v tržbách.

3. Aplikácia logistickej regresie pre predikovanie ukazovateľa EVA

Uvažujme binárnu vysvetľovanú premennú Y s alternatívnym rozdelením, ktorá nadobúda hodnotu 1 s pravdepodobnosťou π , ak pre sledovaný prípad nastane udalosť U a hodnotu 0 s pravdepodobnosťou $1 - \pi$, ak udalosť U nenastane.

Očakávame, že premenná Y súvisí s premennými X_i , $i = 1, 2, \dots, k$, ak rôzne hodnoty prediktorov vedú k rôznym hodnotám pravdepodobnosti π .

Pri modelovaní vzťahu

$$P(Y_i = 1) = \pi_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i; i = 1, 2, \dots, n, \quad (3)$$

kde ε_i je náhodná zložka, nemôžeme použiť lineárny regresný model, pretože predikované hodnoty by nemuseli spĺňať podmienku výskytu hodnôt pravdepodobnosti z intervalu od 0 do 1.

Zavádza sa preto ako vysvetľovaná premenná tzv. logit, ktorý je definovaný ako $\ln\left(\frac{\pi}{1-\pi}\right)$ s hodnotami od $-\infty$ do $+\infty$ a logistická regresná funkcia bude v tvare

$$\text{logit}(\pi) = \ln\left(\frac{\pi}{1-\pi}\right) = Z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k.$$

(4)

Hľadanú pravdepodobnosť potom dostaneme spätnou transformáciou

$$\pi = \frac{e^Z}{e^Z + 1}.$$

(5)

Logistickou regresiou štandardne odhadujeme pre sledovanú štatistickú jednotku pravdepodobnosť, že udalosť U nastane, t.j. štatistická jednotka s určitou množinou hodnôt vysvetľujúcich premenných patrí do modelovanej kategórie $Y = 1$. Predpokladáme pritom, že udalosť U nastane, ak pravdepodobnosť je vyššia ako zvolená prahová hodnota (*cut point*), najčastejšie rovná 0,5. Pri nižšie odhadnutej pravdepodobnosti predpokladáme, že udalosť U nenastane.

e^{β_i} meria elasticitu i -tej vysvetľujúcej premennej na hodnotu hľadanej pravdepodobnosti. Čím viac je hodnota $e^{\beta_i} > 1$, tým citlivejšia je hľadaná pravdepodobnosť na zmeny premennej X_i . Ak vynásobím vo vzťahu (5) výraz e^Z výrazom e^{β_i} , dostaneme priamo novú hodnotu hľadanej pravdepodobnosti pri jednotkovej kladnej zmene premennej X_i . Pri jednotkovej zápornej zmene premennej X_i je potrebné v uvedenom vzťahu vynásobiť e^Z výrazom $1/e^{\beta_i}$.

Na základe získaných a upravovaných účtovných dát výberovej vzorky 2506 francúzskych obchodných podnikov a distribučných spoločností^{§§} bol odhadnutý binárny logistický regresný model, v ktorom ako vysvetľujúce premenné boli použité:

^{§§} Parienté, S: *Performances financières comparées des industriels et distributeurs français de PGC, ILEC*, N° 6/08, octobre 2008 In: Parienté, S. 2009. *Analyse financières et évaluation d'entreprise*. 2^e édition. Paris : Pearson Education France, 2009. s. 169 – 170. ISBN: 978 –2–7440–7364–9.

R – obrátka operatívnych aktív v tržbách (počet),

M – operatívna zisková marža (v %),

k – celkové kapitálové náklady (v %),

T – „veľkosť“ podniku – umelá binárna premenná, ktorá nadobúdala hodnotu 1, ak veľkosť tržieb z predaja tovaru bola medzi 15 až 30 miliónov eur (približne veľký supermarket) a hodnotu 0 inak.

Výsledky zisťovania uvádza tabuľka 1:

Tabuľka 13: Výsledné odhady koeficientov logistického regresného modelu

	β_i	e^{β_i}
R	0,380	1,462
M	2,002	7,402
k	-0,494	0,610
T	0,323	1,382
Konštanta	-2,876	0,056

Prameň: Parienté, S. 2009. Analyse financières et évaluation d'entreprise. 2^e édition. Paris : Pearson Education France, 2009. s. 169 – 170. ISBN: 978-2-7440-7364-9.

Odhadnutý model mal teda tvar:

$$Z = -2,876 + 0,380 R + 2,002 M - 0,494 k + 0,323 T.$$

Ak nami sledovaný podnik mal tržby z predaja 8 miliónov eur, jeho operatívne aktíva sa obrátili v tržbách 4,1 krát za rok, operatívna zisková marža bola 2,8 % a celkové kapitálové náklady dosiahli 9 %, potom pravdepodobnosť, že daný podnik dosiahne pozitívnu hodnotu ukazovateľa EVA bude

$$Z = -2,876 + 0,380 \cdot 4,1 + 2,002 \cdot 2,8 - 0,494 \cdot 9 + 0,323 \cdot 0 = -0,1584$$

a

$$\pi(EVA > 0) = \frac{e^{-0,1584}}{e^{-0,1584} + 1} = 0,4605.$$

Ak by sa podarilo znížiť celkové priemerné kapitálové náklady o jeden percentuálny bod na 8%, potom

$$\pi(EVA > 0) = \frac{e^{-0,1584} / 0,610}{e^{-0,1584} / 0,610 + 1} = 0,5832.$$

V prípade, že by sme sústredili našu pozornosť na zvýšenie operatívnej ziskovej marže o jeden percentuálny bod na 3,8 %, potom

$$\pi(EVA > 0) = \frac{e^{-0,1584} \cdot 7,402}{e^{-0,1584} \cdot 7,402 + 1} = 0,8633.$$

4. Záver

Príspevok ilustroval na reálnom príklade vybraných francúzskych obchodných podnikov a distribučných spoločností možnosť využitia logistickej regresie ako alternatívnej viacrozmernej štatistickej metódy pri predikovaní pravdepodobnosti nárastu bohatstva akcionárov meraným na báze ukazovateľa ekonomickej pridanej hodnoty. Vzhľadom na existenciu ekonomickej krízy by mohlo byť pre budúci výskum zaujímavé modifikovanie faktorov modelujúcich výšku ukazovateľa EVA.

5. Literatúra

- [1] FICZOVÁ, I. – SEDLÁČEK, J. – ÚRADNÍČEK, V. 2002. Finančno-ekonomická analýza podniku – I. časť. Banská Bystrica : OZ Financ, 2002. 185 s. ISBN: 80-968702-1-1
- [2] KRÁĽ A KOL. 2009. Viacrozmerné štatistické metódy so zameraním na problémy ekonomickej praxe. Banská Bystrica : EF UMB, 2009.
- [3] PARIENTÉ, S. 2009. Analyse financières et évaluation d'entreprise. 2^e édition. Paris : Pearson Education France, 2009. 284 s. ISBN 978-2-7440-7364-9.
- [4] STANKOVIČOVÁ, I. - VOJTKOVÁ, M. 2007. Viacrozmerné štatistické metódy s aplikáciami. Bratislava : IURA Edition, 2007. 261 s. ISBN 978-80-8078-152-1

Adresa autora:

Vladimír Úradníček, Ing., Ph.D.
Katedra kvantitatívnych metód a informačných systémov
Ekonomická fakulta
Univerzita Mateja Bela
Tajovského 10, 975 90 Banská Bystrica
vladimir.uradnicek@umb.sk

Tento príspevok bol spracovaný v rámci riešenia projektu VEGA 1/4634/07 – Variantné metódy predikovania finančného vývoja malých a stredných podnikov po zavedení spoločnej európskej meny v SR.

Štatistické spracovanie experimentálne získaných dát v technickej praxi

Statistical Analysis of Data Obtained Experimentally in Technical Practice

Alena Vagaská, Jozef Zajac

Abstract: The paper deals with experimental research and statistical evaluation of experimental data obtained in technical practice. Four selected process factors which enter into technological process of side milling of slots have been evaluated by means of full factorial analysis 2^4 using suitable software.

Key words: Statistical methods, Quality Control, Design of Experiment, factor analysis.

Kľúčové slová: Štatistické metódy, riadenie kvality, plánovaný experiment, faktorová analýza.

1. Úvod

Štatistická analýza a interpretácia experimentálnych dát v klasických i moderných vedných odboroch patrí medzi rozvíjajúce sa smery výskumu a nadobúda čoraz väčší význam, v niektorých vedách sa dokonca stáva jedným zo základných prístupov. Podobne je to aj v technických odboroch. Analyticko-teoretický spôsob identifikácie mnohých technologických procesov je často neefektívny a málo praktický, pretože jeho aplikovaním nie je možné získať úplný model procesu vzhľadom na nevyhnutné zanedbávanie vplyvu určitých veličín. Technologické procesy patria k zložitým dynamickým viacfaktorovým systémom, medzi jednotlivými určujúcimi parametrami sú mnohotvárne vnútorné väzby, zmena jedného parametra obvykle vyvoláva nelineárnu zmenu ďalších parametrov. Práve tieto špecifiká a značný počet parametrov vystupujúcich v technologických procesoch si vyžaduje aplikáciu matematicko-štatistických metód pri zostavovaní matematických modelov. Veľký objem výpočtov pri takomto modelovaní nie je prekážkou vďaka využitiu modernej výpočtovej techniky. Pri spracovaní experimentálnych dát a interpretácii výsledkov je v súčasnosti možné využiť celé spektrum programových systémov pre štatistické vyhodnocovanie dát. Široká ponuka však vyžaduje od experimentátora hlbšie vedomosti zo štatistiky a schopnosť výberu najvhodnejších metód. V článku poukazujeme na možnosti využitia metódy plánovaných experimentov (DoE) pri vytváraní modelov reálnej situácie danej výrobnjej technológie z technickej praxe s použitím štatistického softvéru Statistica.

2. Plánovaný experiment (Design of Experiment)

Ak sa pri riadení kvality využívajú postupy matematickej štatistiky, hovoríme o štatistickom riadení kvality (statistical quality control) [2]. Metódy navrhovania experimentov patria medzi progresívne štatistické techniky riadenia kvality. Za účelom štatistického riadenia kvality obrobenej plochy pri čelnom frézovaní hliníka je potrebné uskutočniť experiment vhodný pre danú problematiku, t.j. uskutočniť frézovanie daného materiálu, sledovať vplyv procesných parametrov na kvalitu obrobenej plochy a následne hodnoty získané meraním spracovať a vyhodnotiť pomocou štatistických metód. Keďže v praxi do výrobného procesu vstupujúce faktory nepôsobia vždy len aditívnym spôsobom, ale vo vzájomnej interakcii, najvýhodnejšie sa ukázalo použiť plánovaný experiment. Plánované experimenty nám umožňujú vytvárať modely reálnych situácií danej výrobnjej technológie a následne ich analyzovať, na základe čoho môžeme znižovať variabilitu procesu a dosiahnuť zníženie nákladov na výrobu. V plánovanom experimente vystupuje jedna (alebo viac) premenná, ktorá sa nazýva ozva (výstupná premenná); a niekoľko predikčných

premenných. Predikčná premenná, ktorá sa mení s cieľom posúdiť jej vplyv na ozvu, sa nazýva faktor, ktorý môže mať viac úrovní. Experiment možno rozdeliť na relatívne samostatné časti, ktoré nazývame pokusy (tie sa môžu opakovať). V jednom pokuse sú úrovne faktorov konštantné. Návrhom (plánom) experimentu je potom výber pokusov, ktoré zaradíme do experimentu, výber počtu opakovaní týchto pokusov, prípadne aj určenie poradia vykonávania pokusov. V experimente nás na produkte vždy zaujíma ozva y . Vzhľadom na to možné ciele experimentu sú: zistiť, ktoré premenné najviac ovplyvňujú y ; zistiť, aké by mali byť premenné x_j , $j = 1, 2, 3, \dots, k$, aby sa hodnota y čo najmenej líšila od požadovanej nominálnej úrovne; zistiť, aké by mali byť x_j , aby bola variabilita y čo najmenšia; zistiť, aké by mali byť x_j , aby bol účinok šumových predikčných premenných čo najmenší. Plánovanie experimentu, jeho realizácia, analýza a reakcia na výsledky experimentu sú aktivity, ktoré musia mať istú postupnosť – vyjadruje to tzv. Demingov cyklus. [3].

Najjednoduchším typom experimentu sú jednofaktorové experimenty. Ak nás však zaujíma vplyv súčasne viacerých faktorov na ozvu, je potrebné realizovať viacfaktorový experiment. Faktoriálny experiment umožňuje analyzovať tento model súčasným variováním všetkých faktorov. Faktory môžu mať nekonečné množstvo úrovní, avšak pri plánovaní experimentu s cieľom dosiahnuť výsledky v rozumných tvaroch stačí skúmať faktory na dvoch, troch alebo až piatich úrovniach [1]. Experiment, v ktorom sú realizované všetky možné kombinácie hladín faktorov bez opakovaní, nazývame úplným faktorovým experimentom. Ak je počet faktorov k a počet hladín každého z nich je λ , potom počet kombinácií N pri úplnom faktorovom experimente zodpovedá počtu pokusov a platí vzťah $N = \lambda^k$. Pri dvoch úrovniach jednotlivých faktorov, ktorých jednotlivé úrovne sa kódujú ako -1 a $+1$ ide o faktorový experiment typu 2^k .

3. Experimentálna procedúra

V prípade skutočného profilu drsnosti obrobeného povrchu hliníka sme sledovali štyri faktory vstupujúce do procesu frézovania (tzv. nezávislé premenné): priemer frézy d [mm], otáčky n [min^{-1}], reznú rýchlosť v_c [$\text{mm} \cdot \text{min}^{-1}$] a hĺbku rezu a_p [mm]. Pre tieto faktory boli realizované pokusy v 2^4 rôznych kombináciách úrovní. Samotný experiment bol vykonávaný v školskom laboratóriu Fakulty výrobných technológií a pozostával z troch základných častí: plánovanie experimentu, výrobná časť a meranie drsnosti obrobeného povrchu. Procesné faktory pôsobia na obrobok a priamo ovplyvňujú drsnosť obrobeného povrchu. Za konkrétne sledované kritéria, ktoré určujú stav obrobeného povrchu a ktoré závisia od procesných faktorov sa považujú: stredná aritmetická hodnota drsnosti Ra [μm], maximálna výška profilu Rz [μm] a stredná kvadratická hodnota drsnosti Rq [μm]. Do procesu obrábania vstupujú aj nekontrolované predikčné premenné nazývané náhodné vplyvy. Sú to veličiny, ktoré spôsobujú kolísanie hodnôt a nemôžeme ich nijako ovplyvňovať. V tabuľke 1 sú uvedené hodnoty dolných a horných hladín a pridelené kódované označenie procesných faktorov. Štyri procesné faktory nadobúdajú dve hladiny ich veľkostí, čo vyjadruje matica plánu experimentu (Tabuľka 2). Počet riadkov matice sa zhoduje s počtom uskutočnených meraní.

Pri realizácii výrobnej časti experimentu, pri ktorej bolo potrebné frézovať požadovaný počet drážok do zvoleného materiálu – hliníka, sme využili CNC obrábacie centrum PK-VMC650S. Ďalej boli použité dve frézy: stopková fréza Ø20 RO F1220 použitá na frézovanie ôsmich drážok na prvej vzorke hliníka a stopková fréza s vymeniteľnými platničkami Ø16 SAP11D použitá na frézovanie ôsmich drážok na druhej vzorke hliníka. Na meranie drsnosti sme použili prenosný profilometer Mitutoyo SJ – 301. Drsnosť obrobeného povrchu po čelnom frézovaní bola meraná následovne. Jednotlivé vyfrézované drážky boli rozdelené na tri časti

a na každej jednej časti boli odmerané hodnotiace veličiny drsnosti povrchu (Ra, Rz, Rq). Každú drážku sme rozdelili na tri časti tzv. zóny (zóna A , zóna B , zóna C). Na každej drážke bolo teda uskutočnených 3×3 meraní, preto na ôsmich drážkach jednej hliníkovej vzorky bolo realizovaných 72 meraní. Obdobné meranie bolo vykonané aj na hliníkovej vzorke č. 2 teda dokopy bolo uskutočnených 144 meraní.

Tabuľka 1: Kódovanie hladín procesných faktorov

Č.	Pomenovanie faktora	Rozmer	Označenie		Hladiny faktorov	
			Pôvodné	Kódované	dolná	horná
1	priemer frézy	[mm]	d	x_1	Ø16	Ø20
2	otáčky	[min ⁻¹]	n	x_2	3000	7000
3	rezná rýchlosť	[mm.min ⁻¹]	v_f	x_3	700	1000
4	hlbka rezu	[mm]	a_p	x_4	0,5	1,5

Tabuľka 2: Matica s aktuálnymi a kódovanými podmienkami pokusov

Č. drážky	Aktuálne podmienky pokusov				Kódované podmienky pokusov			
	[mm]	[min ⁻¹]	[mm.min ⁻¹]	[mm]	x_1	x_2	x_3	x_4
1	20	7000	1000	1,5	1	1	1	1
2	20	7000	1000	0,5	1	1	1	-1
3	20	7000	700	1,5	1	1	-1	1
4	20	7000	700	0,5	1	1	-1	-1
5	20	3000	1000	1,5	1	-1	1	1
6	20	3000	1000	0,5	1	-1	1	-1
7	20	3000	700	1,5	1	-1	-1	1
8	20	3000	700	0,5	1	-1	-1	-1
9	16	7000	1000	1,5	-1	1	1	1
10	16	7000	1000	0,5	-1	1	1	-1
11	16	7000	700	1,5	-1	1	-1	1
12	16	7000	700	0,5	-1	1	-1	-1
13	16	3000	1000	1,5	-1	-1	1	1
14	16	3000	1000	0,5	-1	-1	1	-1
15	16	3000	700	1,5	-1	-1	-1	1
16	16	3000	700	0,5	-1	-1	-1	-1

4. Analýza a interpretácia výsledkov experimentu

Na vyšetrenie vnútorných závislostí a vzťahov zdrojovej matice dát sa použil regresný model faktorovej analýzy, pomocou ktorého bol skúmaný vplyv procesných faktorov na kvalitu obrobeného povrchu. Procesné faktory x_1, x_2, x_3, x_4 (d, n, v_f, a_p) sú vstupné veličiny, drsnosť povrchu, ktorú reprezentuje základné kritérium drsnosti Ra , odpovedá výstupnej veličine Y a preto môžeme písať:

$$Ra = f(d, n, v_f, a_p) \quad (1)$$

Z uvedeného vyplýva, že budeme sledovať viacnásobnú regresnú závislosť:

$$Y = f(x_1, x_2, \dots, x_k, \beta_0, \beta_1, \dots, \beta_k) + \varepsilon \quad (2)$$

Veličina ε , ktorá vystupuje v danej závislosti je náhodná veličina vystupujúca v procese, s ktorou ďalej nebudeme uvažovať. Koeficienty $\beta_0, \beta_1, \dots, \beta_k$ sú koeficienty

skutočnej regresie, ktoré je nutné poznať v praktickom použití modelov a z uskutočnených pokusov je možné určiť ich odhady $b_0, b_1, \dots, b_k$. Regresná rovnica má potom tvar:

$$\hat{y} = b_0 + \sum_{j=1}^k b_j x_j + \sum_{j<l}^k b_{jg} x_j x_g + \sum_{j<l<q}^k b_{jgq} x_j x_g x_q + \dots, \quad (3)$$

kde $\hat{y}$ považujeme za odhad parametra optimalizácie. Odhady koeficientov v regresnom modeli možno vypočítať metódou najmenších štvorcov. Každý výsledok merania je popísaný jednou rovnicou, preto výsledný vzťah obsahuje viacero rovníc než je premenných a tak túto závislosť môžeme napísať v maticovom tvare:

$$[Y] = [X] \cdot [B] \quad (4)$$

kde $[Y]$ je stĺpcový vektor meraných veličín, $[X]$ je matica nezávislé premenných, $[B]$ je stĺpcový vektor odhadov regresných koeficientov. Systém lineárnych rovníc (4) má riešenie, ak $X^T \cdot X$ je nedegeovaná matica. Pre úplný faktorový experiment je charakteristická ortogonálnosť, čiže informačná matica plánu je diagonálna:

$$A = X^T \cdot X = N \cdot E \quad (5)$$

Odhady koeficientov sú:

$$b_0 = \frac{1}{N} \sum_{i=1}^N x_0 y_i, \quad b_j = \frac{1}{N} \sum_{i=1}^N x_{ji} y_i, \quad b_{jg} = \frac{1}{N} \sum_{i=1}^N x_{ji} y_{gi} y_i \quad (6)$$

kde $N = \sum_{i=1}^N x_{ji}^2$ pre $j = 0, 1, \dots, k$.

Ak vo všetkých bodoch plánu uskutočníme ten istý počet pozorovaní, môžeme použiť namiesto y_i priemernú hodnotu $\bar{y}_i$. Disperzia koeficientov je rovnaká pre všetky koeficienty rovníc a určuje sa vzorcom:

$$S^2(b_j) = \frac{S^2(\bar{y})}{N} = \frac{S^2(y)}{N \cdot n} \quad (7)$$

Rovnica regresnej funkcie, úplného faktorového experimentu typu 2^4 , v ktorom sa počíta s pôsobením interakcií má tvar:

$$\hat{y}_{Ra} = b_0 x_0 + b_1 x_1 + b_2 x_2 + b_3 x_3 + b_4 x_4 + b_{12} x_1 x_2 + b_{13} x_1 x_3 + b_{14} x_1 x_4 + b_{23} x_2 x_3 + b_{24} x_2 x_4 + b_{34} x_3 x_4 + b_{123} x_1 x_2 x_3 + b_{134} x_1 x_3 x_4 + b_{234} x_2 x_3 x_4 + b_{1234} x_1 x_2 x_3 x_4 \quad (8)$$

Z rovnosti $B = (X^T \cdot X)^{-1} \cdot X^T \cdot Y$ vypočítame hodnoty regresných koeficientov

$b_0, b_1, b_2, b_3, b_4, b_{12}, b_{13}, b_{14}, b_{23}, b_{24}, b_{34}, b_{123}, b_{124}, b_{134}, b_{234}, b_{1234}$ a to podľa vzťahu:

$$b_j = \frac{1}{N} \cdot \sum_{j=1}^N Y_j, \quad j = 1, 2, \dots, k \quad (9)$$

Pri zisťovaní regresných funkcií pre výstupné hodnoty R_a, R_z sa postupuje rovnakým spôsobom, uvedieme si postup pre R_a . V Tabuľke 3 sa nachádzajú údaje potrebné na zostavenie regresnej funkcie pre hodnotiace kritérium drsnosti povrchu R_a .

Tabuľka 3: Výpočet premenných regresnej funkcie pre hodnotu drsnosti povrchu R_a

Č. p.	Koeficienty regresnej analýzy		Namerané hodnoty hodnoty R_a			$\bar{y}_i$	Disperzia pokusov		Výpočet odchýlky	
	Označ.	Hodnota	y_{i1}	y_{i2}	y_{i3}		$S_i(y)$	$S_i^2(y)$	$(\bar{y}_i - y_i)$	$(\bar{y}_i - y_i)^2$
1	b_0	1,79	0,62	0,61	1,10	0,78	0,28	0,08	-1,02	1,03
2	b_1	0,49	1,14	0,89	1,20	1,08	0,16	0,03	1,04	1,09
3	b_2	-0,85	2,56	1,08	0,65	1,43	1,00	1,00	-0,04	0,00

4	b_3	-0,05	2,59	1,01	1,50	1,70	0,81	0,65	0,69	0,48
5	b_4	-0,13	2,84	3,66	5,89	4,13	1,58	2,49	1,80	3,24
6	b_{12}	-0,18	1,83	3,01	4,33	3,06	1,25	1,56	-0,23	0,06
7	b_{13}	0,04	2,64	2,85	3,14	2,88	0,25	0,06	0,30	0,09
8	b_{14}	0,15	2,33	4,03	3,17	3,18	0,85	0,72	0,42	0,18
9	b_{23}	-0,11	0,83	0,72	0,60	0,72	0,12	0,01	-0,41	0,17
10	b_{24}	0,09	0,48	0,50	0,60	0,53	0,06	0,00	0,42	0,17
11	b_{34}	0,10	0,77	0,65	0,66	0,69	0,07	0,00	-0,41	0,17
12	b_{123}	-0,19	0,61	0,59	0,52	0,57	0,05	0,00	0,41	0,17
13	b_{124}	-0,26	1,16	1,58	0,89	1,21	0,35	0,12	-0,29	0,09
14	b_{134}	0,07	2,34	2,10	2,75	2,40	0,33	0,11	0,40	0,16
15	b_{234}	-0,09	1,24	1,51	1,72	1,49	0,24	0,06	-0,34	0,12
16	b_{1234}	-0,08	3,59	2,36	2,51	2,82	0,67	0,45	0,79	0,63
Σ			27,57	27,15	31,23	28,65	8,07	7,37	3,53	7,83

Pre hodnotiace kritérium drsnosti Ra bola na základe uvedených hodnôt zostavená regresná funkcia, kde sú zohľadnené aj viacúrovňové interakcie:


$$\hat{y}_{Ra} = 1,79 + 0,49x_1 - 0,85x_2 - 0,05x_3 - 0,13x_4 - 0,18x_1x_2 + 0,04x_1x_3 + 0,15x_1x_4 - 0,11x_2x_3 + 0,09x_2x_4 + 0,10x_3x_4 - 0,19x_1x_2x_3 - 0,26x_1x_2x_4 + 0,07x_1x_3x_4 - 0,09x_2x_3x_4 - 0,08x_1x_2x_3x_4$$

Normalita rozloženia súboru opakovaných meraní parametrov profilu Ra a Rz bola testovaná pomocou parametrického Shapiro – Wilksonovho testovacieho kritéria s použitím výpočtového systému Statistica. Z uvedenej analýzy vyplynulo, že všetky opakované merania majú normálne Gaussove rozdelenie. Výpočet regresných koeficientov bol realizovaný v programe Excel, Matlab a Statistica. Pre jednotlivé typy regresných závislostí boli vypracované výpočtové programy, založené na metóde najmenších štvorcov a maticových operáciách. Pre posúdenie štatistickej významnosti regresných koeficientov bol použitý Studentov t – test. Testovacie kritérium t sa pre každý z regresných koeficientov porovnal s tabelovanou hodnotou kritéria na zvolenej hladine významnosti α .

Na základe hypotézy o významnosti jednotlivých koeficientov rovnice z lineárnej regresie bola získaná výsledná rovnica, ktorá charakterizuje maximálnu výšku drsnosti Rz :

$$\tilde{y}_{Rz} = 9,74 + 1,9x_1 - 3,12x_2 - 0,41x_3 - 0,48x_4 - 8,19x_{12} + 0,03x_{13} + 0,58x_{14} - 0,38x_{23} + 0,57x_{24} - 1,74x_{34} - 1,18x_{123} - 1,18x_{124} + 0,09x_{134} - 0,16x_{234} - 0,2x_{1234}$$


Vyhodnocovanie vplyvu procesných faktorov na drsnosť povrchu hliníka bolo realizované pomocou softvérového systému Statistica. Významnosť sledovaných nezávislých premenných - faktorov je zrejmá z Paretoho grafu (Obrázok 1).



Obrázok 1: Pareto graf vplyvu faktorov na Rz

Môžeme konštatovať, že najväčší vplyv na celkovú hodnotu Rz majú otáčky vretena, ktoré predstavujú 53% vplyv. Ďalším významným faktorom je priemer frézy, ktorej podiel je

31 %, kým štatisticky nevýznamná hĺbka rezu a rýchlosť posuvu predstavujú iba 9 % a 7 % vplyv na hodnotu skúmaného parametra R_z . Otáčky vretena ako štatisticky významný faktor so svojou zvyšujúcou sa hodnotou spôsobuje pokles skúmaného parametra R_z . Priemer frézy má opačný efekt. Rovnaký trend môžeme pozorovať ako pri hĺbke rezu tak pri rýchlosti posuvu, no ich vplyv na celkovú hodnotu maximálnej výšky nerovnosti profilu drsnosti R_z je zanedbateľný. Najnižšie hodnoty R_z a tým vyššiu kvalitu obrobeného povrchu pri čelnom frézovaní hliníka možno dosiahnuť použitím vysokých rýchlostí posuvu a vysokých otáčok vretena, je však nutné podotknúť, že uvedené výsledky sú platné len pre obrábanie hliníka v intervale použitých rezných podmienok. Obrázok 2 poukazuje na vplyv otáčok pri určených rýchlostiach posuvu pre určitý typ frézy. Z grafu je zrejmé, že pri nižšej rýchlosti posuvu mala zmena otáčok u frézy Ø16 SAP11D väčší vplyv na drsnosť R_z ako pri rýchlejšom posuve. U frézy Ø20 RO F1220 nastal opačný jav, keď pri rýchlejšom posuve bola zmena drsnosti R_z oveľa väčšia. Fréza Ø16 SAP11D dosiahla vždy lepšie hodnoty drsnosti R_z .



Obrázok 2: Graf marginálnych priemerov a medzí spoľahlivosti (95%)

5. Záver

Predmetom článku bol príklad aplikácie plánovaných experimentov pri hodnotení vplyvu faktorov vstupujúcich do procesu čelného frézovania na parametre profilu drsnosti R_a a R_z povrchu hliníka. Na základe získaných poznatkov je možné optimalizovať podmienky v procese frézovania, vďaka ktorým by sa zabezpečila vyššia produktivita a požadovaná kvalita.

6. Literatúra

- [1] KAŽIMÍR, I. – BEŇO, J. 1989. Teória obrábania. Bratislava: ALFA, 1989. 282 s. ISBN 063-720-89.
- [2] MELOUN, M. – MILITKÝ, J. 2004. Statistická analýza experimentálnych dát. Praha: ACADEMIA, 2004. 960 s. ISBN 80-200-1254-0.
- [3] TEREK, M. – HRNČIAROVÁ, Ľ. 2004. Štatistické riadenie kvality. Bratislava: IURA EDITION, 2004. 234 s. ISBN 80-89047-97-1.

Adresa autora (-ov):

Alena Vagaská, PaedDr., PhD.
KMIK, FVT TU v Košiciach,
Bayerova 1
080 01 Prešov
alena.vagaska@tuke.sk

Jozef Zajac, prof., Ing., PhD.
KVT, FVT TU v Košiciach,
Štúrova 31
080 01 Prešov
jozef.zajac@tuke.sk

Analýza vplyvu regiónu SR na zložky čistého príjmu **Impact analysis of region's Slovakia on the components of net income**

Mária Vojtková

Abstract: The aim of this paper is to assess the impact of the region in Slovakia to selected quantitative indicators of the net cash income from employment and other income items of individual household members in 2007. To assess the impact of the regional factor, we used nonparametric analysis of variance. In addition, we focus on the detection of significant differences between regions of Slovakia. The analysis is based on data collected during a project EU SILC 2007 in Slovakia.

Key words: Net income and its component, EU SILC, regional disparities, nonparametric analysis of variance, comparison two means.

Kľúčové slová: čistý príjem a jeho zložky, EU SILC, regionálne disparity, neparametrická analýza rozptylu, porovnanie zhody dvoch stredných hodnôt

1. Úvod

Čisté príjmy na osobu patria k jednému z významných indikátorov regionálnych disparít. Tento ukazovateľ má vyššiu výpovednú hodnotu o celkových príjmoch obyvateľov, pretože zahŕňa príjmy zo zamestnania a súkromného podnikania (sú to príjmy bez daní z príjmu a sociálnych odvodov), sociálne príjmy a ostatné príjmy. Ako nepriamy indikátor kúpnej sily môže slúžiť pri analýze podnikateľského prostredia.

Cieľom tohto príspevku je posúdenie vplyvu regiónu SR (kraje SR) na vybrané kvantitatívne ukazovatele čistého peňažného príjmu zo zamestnania a ostatné príjmové položky jednotlivých členov domácnosti v roku 2007. Okrem toho sa zameriame na odhalenie významných rozdielov medzi jednotlivými regiónmi podľa posudzovaných ukazovateľov.

Táto práca je podporovaná Agentúrou na podporu výskumu a vývoja na základe zmluvy APVV-0649-07.

2. Vstupné premenné

Pri spomínanej regionálnej analýze sme vychádzali z databázy údajov, ktorá bola výsledkom Zisťovania o príjmoch a životných podmienkach EU SILC 2007. Zisťovanie EU SILC sa realizovalo podľa nariadenia (ES) č. 1177/2003 Európskeho parlamentu a Rady EÚ a doplnujúceho Nariadenia 676/2006. Vytvára sa tak spoločný rámec na systematickú tvorbu štatistík spoločenstva o príjmoch a životných podmienkach domácností. Výberové zisťovanie EU SILC 2007 s údajmi za rok 2007 bolo realizované Štatistickým úradom SR ako integrovaná („rotačná“) forma zisťovania so štyrmi podsúbormi. Pri našej analýze sme sa zamerali na jeden z podsúborov P_súbor. Súbor osobných údajov (P_subor) obsahuje záznam za každú osobu v domácnosti vo veku 16 rokov a viac, ktorá odpovedala na osobný dotazník. Súbor za EU SILC 2007 celkovo pozostáva z 12 573 záznamových viet.

Ako vstupné premenné boli použité premenné zberané na úrovni osoby:

PY010G - peňažný príjem zo zamestnania alebo jemu blízky príjem, premenná predstavuje príjem zamestnanca, ktorý ho dostáva za vykonanú prácu na základe existencie pracovno-právneho vzťahu (štátnozamestnaneckého pomeru, služobného pomeru a členského pomeru) vo forme mzdy, platu, odmeny za výkon funkcie a iný druh odmeny, ktoré sú považované za príjem zo závislej činnosti. Obsahuje príjem z hlavného zamestnania, vedľajšieho zamestnania, mimoriadne odmeny, podiely na zisku a iné peňažné platby od zamestnávateľa.

PY020G - nepeňažný príjem zo zamestnania, premenná zahŕňa iba zložku príjmu, týkajúcu

sa prínosu z využívania služobného auta poskytnutého na súkromné účely a s tým spojených nákladov (napr. bezplatný benzín, poistenie auta, príslušné dane a poplatky).
PY050G - peňažné zisky/ straty z podnikania a inej samostatnej zárobkovej činnosti, premenná obsahuje:

- a) čistý prevádzkový zisk alebo stratu pracujúcich vlastníkov alebo partnerov v nekorporatívnych podnikoch zmenšené o úroky z obchodných pôžičiek,
- b) honoráre zarobené za písanie, vynálezy atď., nezahrnuté do zisku/straty nekorporatívnych podnikov,
- c) nájomné z podnikových budov, nástrojov, zariadení atď., nezahrnuté do zisku/straty nekorporatívnych podnikov.

PY090G - dávky v nezamestnanosti, premenná pozostáva z dávky v nezamestnanosti a opakovaných a jednorazových peňažných dávok a príspevkov, ako je napr. príspevok na vykonávanie absolventskej praxe, príspevok na samostatnú zárobkovú činnosť, príspevok na sťahovanie za prácou a pod.

PY100G - starobné dávky, ide o starobný dôchodok, predčasný starobný dôchodok, výsluhový dôchodok a iné opakované a jednorazové dávky a príspevky, ako napr. príplatok k dôchodku, odchodné, jednorazový vianočný príspevok poberateľom dôchodku a pod.

PY110G - dávky pre pozostalých, premenná zahŕňa vdovský a vdovecký dôchodok, sirotsky dôchodok, príspevok na pohreb a iné opakované a jednorazové peňažné dávky (napr. náhrada nákladov na výživu pozostalých, pozostalostná úrazová renta, jednorazové odškodnenie pre pozostalých a pod).

PY120G - nemocenské dávky, táto premenná zahŕňa nemocenské, ošetrovné a iné peňažné dávky, napr. úrazový príplatok, jednorazové vyrovnanie, náhrada za bolesť a za sťaženie spoločenského uplatnenia, úrazová renta a iné.

PY130G - dávky v invalidite, v rámci premennej sa sleduje invalidný dôchodok, peňažné príspevky na zvýšené výdavky, opakované a jednorazové peňažné dávky na kompenzáciu a iné opakované a jednorazové peňažné dávky (napr. peňažný príspevok na prepravu, príspevok na osobnú asistenciu, príspevok na činnosť pracovného asistenta, príspevok občanovi so zdravotným postihnutím na prevádzkovanie alebo vykonávanie samostatnej zárobkovej činnosti a iné).

PY140G - príspevky na vzdelanie, v rámci premennej sa sledujú granty, štipendiá a iná podpora vzdelávania prijatá študentmi. Nesledujú sa tu štipendiá a podobné príspevky, ktoré sú poskytované vzhľadom na príjem v hmotnej núdzi.

KRAJ - kraj SR, 1- Bratislavský, 2 – Trnavský, 3 – Trenčiansky, 4 – Nitriansky, 5 – Žilinský, 6 – Banskobystrický, 7 – Prešovský a 8 – Košický.

PB040 - osobné prierezové váhy všetkých členov domácnosti vo veku 16 rokov a viac, ktoré možno použiť na vyvodenie záverov týkajúcich sa premenných obsiahnutých v osobnom dotazníku.

Celkové príjmy na osobu domácnosti sa skladajú z niekoľkých zložiek:

- čisté pracovné príjmy zo zamestnania a súkromného podnikania (očistené o daň z príjmu a povinné odvody),
- sociálne príjmy (dávky sociálneho zabezpečenia, dávky nemocenského poistenia, štátne sociálne dávky, dávky sociálnej starostlivosti a podpora v nezamestnanosti),
- ostatné príjmy (príjmy z majetku, vybrané pôžičky, naturálne príjmy, príjmy z predaja poľnohospodárskej produkcie).

V príspevku sme sa zamerali len na tie zložky príjmu, ktoré sú zaznamenané na úrovni osoby vo veku 16 a viac rokov, pričom podrobnejšie sa budeme venovať hlavne pracovným príjmom.

3. Použitá metodológia

Našou úlohou bolo posúdenie závislosti medzi peňažným príjmom zo zamestnania prípadne ostatných príjmových položiek od jednotlivých regiónov SR. Kraje SR sú

kvalitatívnu premennou, ktorú môžeme považovať za faktor. Od jej jednotlivých hodnôt (úrovní) môžu závisieť hodnoty kvantitatívnej premennej (čistého príjmu). Veľkosť peňažného príjmu zo zamestnania prípadne ostatných príjmových položiek je samozrejme ovplyvnená radou ďalších faktorov, ktorých vplyv sme v našej analýze neskúmali.

Analýza bola zameraná na posúdenie vplyvu faktora región na jednotlivé druhy príjmov, čiže sme využili jednofaktorovú analýzu rozptylu. Vzhľadom k tomu, že uvedené vstupné premenné nespĺňajú predpoklady použitia parametrickej analýzy rozptylu, tak pri posúdení vplyvu regionálneho faktora sme využili neparametrickú analýzu rozptylu, ktorá nevyžaduje splnenie žiadnych predpokladov o tvare rozdelení základných súborov.

Existuje celý rad neparametrických alternatív k jednofaktorovej analýze rozptylu. Jednou z možností je Kruskal-Wallisov test, ktorý predpokladá, že prvky výberových súborov (osoby v jednotlivých krajoch SR) sú vzájomne nezávislé a počet výberových súborov (krajo SR) je väčší ako 2. Ide o test, ktorý miesto samotných hodnôt kvantitatívnej premennej využíva poradie hodnôt pozorovaní (Wilcoxonovo skóre). Pri výpočte testovacej charakteristiky všetkým hodnotám kvantitatívnej premennej od najmenej po najväčšiu priradíme poradové čísla a pre každý výberový súbor vypočítame sumu poradí. Nech $R_1, R_2, \dots, R_k$ je suma poradí v jednotlivých krajoch SR (1, 2, ..., k) a $n_1, n_2, \dots, n_k$ je počet analyzovaných osôb v jednotlivých krajoch SR. Kruskal-Wallisovu testovaciu charakteristiku určíme podľa vzťahu:

$$KW = \frac{12}{n \cdot (n+1)} \sum_{i=1}^k n_i \bar{R}_i^2 - 3 \cdot (n+1), \quad (1)$$

kde $\bar{R}_i$ je priemerné poradie v jednotlivých krajoch SR.

Táto veličina má pri platnosti nulovej hypotézy o nezávislosti približne rozdelenie chí-kvadrát s $k-1$ stupňami voľnosti. V prípade porovnávania iba dvoch základných súborov je test identický s Mann-Whitneyovým testom. Uvedený vzorec je platný v prípade, že sa všetky hodnoty kvantitatívnej premennej (príjmu) líšia. Ak uvedený predpoklad neplatí používa sa vzorec s úpravou na spojitost.

Samotná analýza bola uskutočnená pomocou SAS Enterprise Guide 4.1, pričom uvedený softvér obsahuje celý rad ďalších neparametrických testov posudzujúcich vplyv faktora na kvantitatívnu premennú ako Van der Waerdenov test, Ansari-Bradley-ho test, Klotzov test, Siegel-Tukey-ho test, Sabate-ho test a mnoho ďalších. Pri všetkých spomínaných testoch sa pôvodné kvantitatívne hodnoty ukazovateľa nahrádzajú poradiami stanovenými v závislosti od použitej metódy.

4. Regionálna analýza závislosti zložiek čistých príjmov

Pri analýze vplyvu regiónu SR na čistý príjem na osobu a jeho jednotlivé zložky sme najprv posúdili, ktoré druhy príjmu štatisticky významne závisia od faktora región. Aplikovali sme jeden zo spomínaných neparametrických testov analýzy rozptylu, ktorý skúma závislosť príslušného kvantitatívneho ukazovateľa príjmu od regiónu SR. V podstate ide o overenie zhody stredných hodnôt jednotlivých ukazovateľov príjmu na úrovni kraja SR. V prípade, že existuje aspoň jedna dvojica krajov, v ktorých sa stredné hodnoty čistého príjmu štatisticky významne líšia možno hovoriť o vplyve regiónu na daný ukazovateľ čistého príjmu osôb.

Tabuľka 1 obsahuje výsledky neparametrického Kruskal-Wallisovho testu pomocou ktorých sme posúdili závislosť príslušnej zložky čistého príjmu od regiónu. V druhom stĺpci je samotná hodnota testovacej charakteristiky (Chi-Square), v treťom stĺpci je príslušný počet stupňov voľnosti (DF) a v poslednom stĺpci ($Pr > Chi-Square$) je najnižšia možná hladina významnosti pre zamietnutie nulovej hypotézy o nevýznamnom vplyve regionálneho faktora na príslušnú zložku príjmu, ktorá sa tiež označuje ako p-hodnota

V našom prípade je p-hodnota takmer pri všetkých zložkách príjmu pomerne malé číslo. Vyššiu p-hodnotu možno pozorovať iba pri dávkach v nezamestnanosti (PY090G) a nemocenských dávkach (PY120G), čiže tieto dve zložky príjmu nie sú ovplyvnené regiónom. Diskutabilnú p-hodnotu tiež nadobúdajú ďalšie dve zložky sociálnych príjmov a to dávky pre pozostalých (PY110G) a dávky v invalidite (PY130G), pri ktorých sa analytik môže rozhodnúť. Ak pripustí 5% chybu rozhodnutia o zamietnutí nulovej hypotézy, ktorá je v skutočnosti správna, tak uvedené zložky sú štatisticky významné, ale v prípade, že pri testovaní uvažujeme iba s 1% pravdepodobnosťou nesprávneho rozhodnutia, tak výsledkom testu je štatistická nevýznamnosť dávok pre pozostalých a invalidných dávok od regiónu SR. Budeme teda uvažovať, že regiónom sú jednoznačne štatisticky významne ovplyvnené čistý príjem zo zamestnania (PY010G), nepeňažný príjem zo zamestnania (PY020G), zisky-straty z podnikania a inej samostatnej zárobkovej činnosti (PY050G), zo sociálnych príjmov ide o starobné dávky (PY100G) a príspevky na vzdelania (PY140G). Regiónom SR (krajom), v ktorom sa jednotlivé osoby nachádzajú sú teda ovplyvnené všetky pracovné príjmy a iba dve zložky sociálnych príjmov.

Tabuľka 1: Analýza vplyvu regiónu na jednotlivé zložky čistého príjmu

Kruskal-Wallis Test	Chi-Square	DF	Pr > Chi-Square
PY010G	165.5016	7	<.0001
PY020G	118.2188	7	<.0001
PY050G	29.8054	7	0.0001
PY090G	9.7703	7	0.2020
PY100G	29.0227	7	0.0001
PY110G	21.0816	7	0.0370
PY120G	11.7494	7	0.1091
PY130G	22.5928	7	0.0200
PY140G	39.9766	7	<.0001

V ďalšej časti sa zameriame na odhalenie regiónov, ktoré stoja v pozadí signifikantného vplyvu na jednotlivé zložky príjmu. Budeme sa venovať iba tým zložkám príjmu, u ktorých sa prejavila ich štatisticky významná závislosť od regiónu.

Podstatnú časť celkového čistého príjmu osôb tvorí peňažný príjem zo zamestnania (PY010G), takže tomuto ukazovateľu budeme venovať širšiu pozornosť. Základné opisné charakteristiky tohto ukazovateľa podľa jednotlivých regiónov obsahuje tabuľka 2, pričom boli použité osobné prierezové váhy PB040.

Najvyššiu priemernú hodnotu peňažného príjmu zo zamestnania dosahuje Bratislavský kraj, v ktorom je aj najvyššia absolútna hodnota variability. Z pohľadu priemerných peňažných príjmov zo zamestnania nasleduje Trnavský, Košický a Žilinský kraj. Najnižšie priemerné príjmy zo zamestnania badať v Prešovskom, o niečo vyššia priemerná hodnota je v Nitrianskom kraji a za ním nasleduje Banskobystrický kraj. Najvyššia hodnota peňažného príjmu bola zaznamenaná v Žilinskom kraji a naopak najnižšia maximálna hodnota bola v Trnavskom kraji, ktorý sa z pohľadu priemernej hodnoty javí ako druhý najvyšší. Z pohľadu variability možno skonštatovať, že najväčšie rozdiely sú v Prešovskom kraji, Banskobystrickom kraji a Nitrianskom kraji, kde štandardná odchýlka na priemer dosahuje viac ako 130%.


Vzhľadom k tomu, že príjmy vo všeobecnosti sú značne pravostranne zošikmené rozdelenia, vhodnejšou strednou hodnotou sa javí medián. Veľký rozdiel medzi mediánom a priemerom v našom prípade svedčí o veľkom podiele osôb s nižšími príjmami.

V Nitrianskom a Prešovskom kraji až 50% obyvateľov hovorí o nulovom príjme zo zamestnania. Naopak menší rozdiel medzi mediánom a priemerom možno pozorovať v Bratislavskom kraji, kde až 50% obyvateľov tvrdí, že ich príjem je menší alebo rovný 100 000,- Sk.

Tabuľka 2: Opisné charakteristiky peňažného príjmu zo zamestnania podľa regiónov

KRAJ	Rozsah	Priemer	Štand. odchýlka	Median	Minimum	Maximum	Variačný koeficient
1	1248	135836	173042	100000	0	1250000	127,39
2	1263	101273	122755	31035	0	760000	121,21
3	1520	90970	106219	58508	0	1162000	116,76
4	1637	79842	106122	0	0	1000000	132,91
5	1645	95576	119912	20000	0	1404000	125,46
6	1556	82859	111248	9000	0	1369005	134,26
7	1844	74212	103013	0	0	1284455	138,81
8	1859	95709	118329	20000	0	780000	123,63

O silnom pravostrannom zošikmení peňažného príjmu zo zamestnania vo všetkých regiónoch svedčí obrázok 1. Za každý kraj bol zostrojený tzv. box plot, ktorý je jedným z grafických prostriedkov exploračnej analýzy. Vo všetkých obdĺžnikoch je spodná strana obdĺžnika na nulovej hodnote, čo svedčí o pomerne veľkej časti osôb, ktorý nevykazujú v uskutočňovanom zisťovaní žiadny príjem zo zamestnania (čo môže byť zapríčinené



Obrázok 1: Škatuľkový graf čistého peňažného príjmu zo zamestnania podľa regiónov SR

vysokým podielom detí). V obdĺžnikoch za Nitriansky (4) a Prešovský (7) kraj dokonca nie je vidieť deliacu čiaru, ktorá predstavuje hodnotu priemerného peňažného príjmu v danom kraji. Najvyššie extrémne hodnoty peňažného príjmu zo zamestnania možno badať v Žilinskom kraji (5), Banskobystrickom kraji (6) a Prešovskom kraji (7). Až za nimi nasleduje

Bratislavský kraj (1), pri ktorom badať vyššiu koncentráciu odľahlých hodnôt príjmu. Za odľahlý príjem sa považuje príjem, ktorého vzdialenosť od dolného alebo horného kvartilu je väčšia ako 1,5 násobok kvartilového rozpätia.

Pri analyzovaní vplyvu regiónu na príslušnú zložku príjmu je potrebné tiež zistiť medzi, ktorými regiónmi sú významné rozdiely. Ide o testovanie všetkých možných dvojíc regiónov vzhľadom na ich priemerné hodnoty príjmu. Tabuľka 3 obsahuje výsledky Scheffeho testu zhody jednotlivých dvojíc stredných hodnôt peňažného príjmu zo zamestnania. Tabuľka bola upravená tak, aby obsahovala iba signifikantné rozdiely medzi jednotlivými krajinami SR, pričom obsahuje aj 95% interval spoľahlivosti pre rozdiel medzi strednými hodnotami jednotlivých dvojíc regiónov. Výsledky Scheffeho testu potvrdzujú predchádzajúce konštatovania o významnom odlíšení priemerného peňažného príjmu zo zamestnania v Bratislavskom regióne od všetkých ostatných regiónov, pričom najväčší rozdiel možno badať medzi Bratislavským a Prešovským regiónom, kde rozdiel stredných hodnôt tvorí 61 624,- Sk, ďalej Bratislavským a Nitrianskym regiónom t.j. 55 994,- Sk a Bratislavským a Banskobystrickým regiónom. Najnižší signifikantný rozdiel je medzi Žilinským a Nitrianskym regiónom t.j. 15 734 Sk.

Tabuľka 3: Porovnanie zhody stredných hodnôt peňažného príjmu zo zamestnania podľa jednotlivých dvojíc regiónov SR

Signifikantné porovnania na hladine významnosti 0.05 sú označené ***.				
Porovnanie krajov	Rozdiel medzi priemerami	95% interval spoľahlivosti		
1 – 2	34563	15132	50775	***
1 – 5	40260	22263	55786	***
1 – 8	40127	24674	57354	***
1 – 3	44866	25029	59142	***
1 – 6	52977	34940	68875	***
1 – 4	55994	40282	73841	***
1 – 7	61624	45006	77739	***
2 – 6	18414	2043	35866	***
2 – 4	21431	7386	40831	***
2 – 7	27061	12111	44728	***
5 – 4	15734	2449	33625	***
5 – 7	21364	7204	37491	***
8 – 4	15867	914	31182	***
8 – 7	21497	5683	35034	***
3 – 7	16758	3818	34755	***

Ďalšou zložkou celkového príjmu je nepeňažný príjem, ktorý vykazuje najvyšší signifikantný rozdiel v Bratislavskom regióne (7 267,- Sk) v porovnaní s ostatnými regiónmi SR s druhou najvyššou variabilitou 298 % hneď za Nitrianskym regiónom, v ktorom je variabilita 320 % . Štatisticky významné rozdiely vo výške priemerného nepeňažného príjmu v jednotlivých dvojiciach regiónov SR sú uvedené v tabuľke 4. Najvyšší štatisticky významný rozdiel je medzi Bratislavským a Prešovským regiónom (3 941,2 Sk) a najnižší je medzi Žilinským a Prešovským krajom iba 1 385,- Sk. Napriek najnižšej priemernej hodnote nepeňažného príjmu je Prešovský kraj, čo sa týka maximálneho nepeňažného príjmu šiesty

v poradí (121 080,- Sk), pričom najnižšiu maximálnu hodnotu nepeňažného príjmu vykazuje Košický kraj (76 643,- Sk) a o niečo vyššiu hodnotu Trenčiansky kraj (80 000,- Sk).

Tabuľka 4: Porovnanie zhody stredných hodnôt nepeňažného príjmu podľa jednotlivých dvojíc regiónov SR

Signifikantné porovnania na hladine významnosti 0.05 sú označené ***.				
Porovnanie krajov	Rozdiel medzi priemermi	95% interval spoľahlivosti		
1 - 2	2525.8	898,8	4152.9	***
1 - 5	2556.2	1026,0	4086.4	***
1 - 3	3008.2	1451,1	4565.3	***
1 - 6	3182.8	1633,8	4731.8	***
1 - 4	3245.5	1713,7	4777.4	***
1 - 8	3728.5	2236,7	5220.2	***
1 - 7	3941.2	2447,0	5435.4	***
5 - 7	1385.0	2,5	2767.5	***

Ďalšou podstatnou zložkou príjmu sú peňažné zisky alebo straty z podnikania a inej samostatnej zárobkovej činnosti. Tabuľka 5 obsahuje štatisticky významné rozdiely medzi ich priemernou hodnotou v jednotlivých regiónoch. Táto zložka príjmu dosahuje najvyššie priemerné hodnoty v Žilinskom kraji (16 828,- Sk), za ktorým nasleduje Bratislavský kraj (16 429,- Sk). Najvýraznejší signifikantný rozdiel je medzi Žilinským a Košickým krajom (10 444,- Sk) a najnižší signifikantný rozdiel je medzi Bratislavským a Trenčianskym krajom (9 796,- Sk).

Tabuľka 5: Porovnanie zhody stredných hodnôt peňažných ziskov/strát z podnikania a inej samostatnej zárobkovej činnosti podľa jednotlivých dvojíc regiónov SR

Signifikantné porovnania na hladine významnosti 0.05 sú označené ***.				
Porovnanie krajov	Rozdiel medzi priemermi	95% interval spoľahlivosti		
5 - 3	10194	1256	19133	***
5 - 8	10444	1939	18948	***
1 - 3	9796	199	19393	***
1 - 8	10045	851	19239	***

Tabuľka 6: Porovnanie zhody stredných hodnôt starobných dávok podľa jednotlivých dvojíc regiónov SR

Signifikantné porovnania na hladine významnosti 0.05 sú označené ***.				
Porovnanie krajov	Rozdiel medzi priemermi	95% interval spoľahlivosti		
1 - 5	6929	651	13207	***
1 - 7	7306	1176	13436	***

Jedným zo sociálnych príjmov sú starobné dávky, ktorých výrazne signifikantné rozdiely možno pozorovať v tabuľke 6. Najvyšší štatisticky významný rozdiel je medzi Bratislavským a Prešovským krajom, potom medzi Bratislavským a Žilinským krajom. Tieto rozdiely sú pravdepodobne spojené s vyššími príjmami zo zamestnania, z ktorých boli uvedené starobné dávky počítané.

Ďalším sociálnym príjmom sú príjmy, ktoré patria študentom na podporu ich vzdelávania. Tabuľka 7 prezentuje najvyššie štatisticky významné rozdiely medzi priemernými príspevkami na vzdelávanie medzi Prešovským a Bratislavským krajom, ďalej medzi Prešovským a Nitrianskym krajom a nakoniec medzi Prešovským a Žilinským krajom.

Tabuľka 7: Porovnanie zhody stredných hodnôt príspevkov na vzdelávanie podľa jednotlivých dvojíc regiónov SR

Signifikantné porovnania na hladine významnosti 0.05 sú označené ***.				
Porovnanie krajov	Rozdiel medzi priemerami	95% interval spoľahlivosti		
7 – 5	285.54	50.95	520.13	***
7 – 4	308.92	74.03	543.81	***
7 – 1	313.50	59.96	567.05	***

5. Záver

Na základe údajov zo Zisťovania o príjmoch a životných podmienkach EU SILC 2007 sa nám podarilo zistiť, že faktor región (kraj SR) štatisticky významne ovplyvňuje všetky druhy pracovných príjmov a zo sledovaných sociálnych príjmov iba starobné dávky a príspevky na vzdelávanie. Vo všetkých prípadoch sledované zložky príjmu okrem príjmu z podnikania a inej samostatnej zárobkovej činnosti, vykazujú najvyšší signifikantný rozdiel v Bratislavskom kraji v porovnaní s Prešovským krajom. Čo sa týka príjmu z podnikania a samostatnej zárobkovej činnosti najvyšší signifikantný rozdiel bol medzi Žilinským a Košickým krajom. Ostatné zložky predovšetkým sociálnych a iných príjmov nie sú ovplyvnené regiónom, v ktorom sa osoba nachádza. Prínosom článku je aj podrobná analýza najpodstatnejšej zložky pracovného príjmu a to čistého peňažného príjmu zo zamestnania.

6. Literatúra

- [1] Khatree R., Naik N. D. 2000. Multivariate Data Reduction and Discrimination with SAS® Software, First edition, Cary, NC: SAS Institute Inc.
- [2] Labudová V. 2004. Regióny a regionalizácia v členských a kandidátskych krajinách Európskej únie. In: Ekonomika a informatika, Bratislava, roč. 2, č. 2, s. 193-208.
- [3] Sandtnerová S., Sodomová, E. 2007. Charakteristika výberového štatistického zisťovania o príjmoch a životných podmienkach domácností – EU SILC. In: AIESA – 11. medzinárodná vedecká konferencia, Bratislava 17. – 18. 5. 2007
- [4] Šoltés E. 2008. Regresná a korelačná analýza s aplikáciami. Bratislava: Iura Edition, 2008.
- [5] Zisťovanie o príjmoch a životných podmienkach EU SILC 2007. ŠÚ SR, Bratislava 2008.

Adresa autora:

Mária Vojtková, Ing. PhD.

Katedra štatistiky, FHI, Ekonomická univerzita, Dolnozemská 1/b, 852 35 Bratislava

E-mail: vojtkova@euba.sk

OBSAH

	Úvod	1
Bod'a Martin	Predicting bankruptcy of Slovak enterprises by an artificial neural network	3
Bolcárová Mária, Samuhel' Ján	Charakteristika stavebného priemyslu v Slovenskej republike za rok 2007	7
Bolcárová Paula	Tradingové stratégie s opciami	13
Hajduová Zuzana, Andrejkovič Marek	Analýza procesu opráv	19
Hrach Karel, Gabčanová Jana	Faktory pro detekci problematických mikro-regionů	24
Chajdiak Jozef	Prognóza spotreby mias v Slovenskej republike	29
Ivor Jaroslav, Stehlíková Beáta, Tirpáková Anna	Aplikácia štatistických metód pri hodnotení poisťných podvodov	32
Ižariková Gabriela	Matematický softvér ako pomôcka pri riešení niektorých typov závislostí	36
Janová Jitka	Optimalizace využití lesnického těžebního zařízení s ohledem na ochranu půdy	41
Janová Jitka	Využití stochastického programování k plánování produkce v zemědělství	47
Kanderová Mária, Stašová Jana	Aplikácia faktorovej analýzy na finančné ukazovatele platobnej schopnosti podnikov	54
Kaščáková Alena, Nedelová Gabriela	Modelovanie pravdepodobnosti podnikania študentmi slovenských vysokých škôl	59
Kimáková Zuzana, Andrejiová Miriam	Analýza časového radu emisií SO _x pomocou programu R	63
Koróny Samuel	Exploračná analýza počtu obyvateľov a plochy okresov na Slovensku	69
Kráľ Pavol, Hiadlovský Vladimír	Použitie bázy fuzzy pravidiel pri ohodnocovaní finančného zdravia podnikov v Slovenskej republike	77
Luha Ján, Štetinová Tamara, Gerinec Anton, Chynoranský Miroslav	Špecifiká patologických zmien pri vrodených a dedičných dystrofiách sietnice	85
Odehnal Jakub, Sedlačík Marek	Faktory regionální konkurenceschopnosti	93
Riesová Radka	Funkcia užitočnosti v teórii a v praxi	99
Roháčová Viera	Ekonometrické modelovanie transmisného mechanizmu menovej politiky	105
Šimanovská Tatjana	Niektoré problémy logiky projektovania	112
Šimsová Jana	Aplikace waveletů v analýze časových řad	115
Tretiak Ondrej	T – učenie	120
Úradníček Vladimír	Predikovanie ekonomickej pridanej hodnoty pomocou logistickej regresie	125
Vagaská Alena, Zajac Jozef	Štatistické spracovanie experimentálne získaných dát v technickej praxi	130
Vojtková Mária	Analýza vplyvu regiónu SR na zložky čistého príjmu	136

CONTENS

	Introduction	1
Bod'a Martin	Predicting bankruptcy of Slovak enterprises by an artificial neural network	3
Bolcárová Mária, Samužel' Ján	Building industry characterization in Slovak republic in 2007	7
Bolcárová Paula	Trading strategies with options	13
Hajduová Zuzana, Andrejkovič Marek	Analysis of the process of repairing	19
Hrach Karel, Gabčanová Jana	Factors for Detection of Problematic Micro Regions	24
Chajdiak Jozef	Forecast consumption of the meat in the Slovak republic	29
Ivor Jaroslav, Stehlíková Beáta, Tírpáková Anna	The application of statistical methods in evaluating claims of fraud	32
Ižariková Gabriela	Mathematical software as a help solving some types of dependences	36
Janová Jitka	Optimalization of logging machinery use considering soil preservation restriction	41
Janová Jitka	On a stochastic programming approach to production planning in agriculture	47
Kanderová Mária, Stašová Jana	Application of factor analysis to liquidity ratio determination in Slovak corporations	54
Kaščíková Alena, Nedelová Gabriela	Modeling of Probability to Run a Business by Slovak University Students	59
Kimáková Zuzana, Andrejiová Miriam	Time series analysis emissions SO _x with R package	63
Koróny Samuel	Exploration analysis of districts population and area in Slovakia	69
Král' Pavol, Hladlovský Vladimír	Evaluating Financial Health of Slovak Companies Using Fuzzy Rule Base	77
Luha Ján, Štetinová Tamara, Gerinec Anton, Chynoranský Miroslav	The specifics of the pathological changes by the hereditary dystrophies of the retina	85
Odehnal Jakub, Sedlačík Marek	Factors of regional competitiveness	93
Riesová Radka	Utility function in theory and practice	99
Roháčová Viera	Econometric modeling of the monetary transmission mechanism	105
Šimanovská Tatjana	Some questions of logic of designing	112
Šimsová Jana	Application of wavelets in analyse of time series	115
Tretiak Ondrej	T – learning	118
Úradníček Vladimír	Economic value added prediction basen upon logistic regression	125
Vagaská Alena, Zajac Jozef	Statistical Analysis of Data Obtaindec Experimentally in Technical Practice	130
Vojtková Mária	Impact analysis of region's Slovakia on the components of net income	136