

Slovenská štatistická a demografická spoločnosť
Slovak Statistical and Demographic Society

FORUM STATISTICUM SLOVACUM

Recenzovaný vedecký časopis
Scientific peer-reviewed journal

Číslo/Issue: 1/2019



Ročník/Volume: XV

FORUM STATISTICUM SLOVACUM

recenzovaný vedecký časopis Slovenskej štatistickej a demografickej spoločnosti
scientific peer-reviewed journal of the Slovak Statistical and Demographic Society

Ročník/Volume: XV (2019)

Číslo/Issue: 1

Editori / Editors

Iveta Stankovičová (Fakulta managementu Univerzity Komenského v Bratislave, Slovensko)

Martin Boďa (Ekonomická fakulta Univerzity Mateja Bela v Banskej Bystrici, Slovensko)

Redakčná rada / Editorial Board

Branislav Bleha (Prírodovedecká fakulta Univerzity Komenského v Bratislave, Slovensko)

Boris Burcin (Prírodovedecká fakulta Univerzity Karlovej v Prahe, Česko)

Joanna Dębicka (Fakulta manažmentu, informatiky a financií Ekonomickej univerzity vo Wroclawi, Poľsko)

Estefanía Mourelle Espasandín (Fakulta ekonómie a podnikania Univerzity v La Coruña, Španielsko)

Stanislav Katina (Ústav matematiky a štatistiky Masarykovej univerzity v Brne, Česko)

Jana Kubanová (Fakulta ekonomicko-správna Univerzity Pardubice, Česko)

Dagmar Kusendová (Prírodovedecká fakulta Univerzity Komenského v Bratislave, Slovensko)

Viera Labudová (Fakulta hospodárskej informatiky Ekonomickej univerzity v Bratislave, Slovensko)

Jitka Langhamrová (Fakulta informatiky a štatistiky Vysokej školy ekonomickej v Prahe, Česko)

Ivan Lichner (Ekonomický ústav Slovenskej akadémie vied, Slovensko)

Tomáš Löster (Fakulta informatiky a štatistiky Vysokej školy ekonomickej v Prahe, Česko)

Janka Medová (Fakulta prírodných vied Univerzity Konštantína Filozofa v Nitre, Slovensko)

Silvia Megyesiová (Podnikovohospodárska fakulta v Košiciach Ekonomickej univerzity v Bratislave, Slovensko)

Oľga Nanásiová (Fakulta elektrotechniky a informatiky Slovenskej technickej univerzity v Bratislave, Slovensko)

Viliam Páleník (Ekonomický ústav Slovenskej akadémie vied, Slovensko)

Marek Radvanský (Ekonomický ústav Slovenskej akadémie vied, Slovensko)

Hana Řezanková (Fakulta informatiky a štatistiky Vysokej školy ekonomickej v Prahe, Česko)

Ľubica Sipková (Fakulta hospodárskej informatiky Ekonomickej univerzity v Bratislave, Slovensko)

Mária Stachová (Ekonomická fakulta Univerzity Mateja Bela v Banskej Bystrici, Slovensko)

Anna Tirpáková (Fakulta prírodných vied Univerzity Konštantína Filozofa v Nitre, Slovensko)


Vladimír Úradníček (Ekonomická fakulta Univerzity Mateja Bela v Banskej Bystrici, Slovensko)

Mária Vojtková (Fakulta hospodárskej informatiky Ekonomickej univerzity v Bratislave, Slovensko)

Tomáš Želinský (Ekonomická fakulta Technickej univerzity v Košiciach, Slovensko)



Vydavateľ: Slovenská štatistická a demografická spoločnosť, Miletičova 3, 824 67 Bratislava, Slovensko. **Publisher:** Slovak Statistical and Demographic Society, Miletičova 3, 824 67 Bratislava, Slovakia. **Adresa redakcie/Editorial office:** Miletičova 3, 824 67 Bratislava, Slovakia. **IČO/Company ID:** 00178764. **DIČ/Tax ID:** 2021504276. **Mailový kontakt/E-mail contact:** adm.ssds@ssds.sk **Web site/Webové sídlo:** <http://www.ssds.sk/>



Registráciu vykonalo Ministerstvo kultúry Slovenskej republiky. **Dátum registrácie:** 27. júla 2005. **Evidenčné číslo:** EV 3287/09. **Tematická skupina:** B1. **Periodicita:** minimálne dvakrát ročne. **ISSN:** 1336-7420.

Registered by the Ministry of Culture of the Slovak Republic. **Date of registration:** 27 July 2005. **Registration No:** EV 3287/09. **Topic group:** B1. **Periodicity:** at least two issues per year. **ISSN:** 1336-7420.

Časovo-prostorová statistická analýza finančních dat Spatio-temporal statistical analysis of financial data

Marek Brabec, Marek Malý

Oddělení statistického modelování, Ústav Informatiky, Akadémia vied Českej republiky, Pod Vodárenskou věží 2, Praha, Česká Republika

Department of Statistical Modelling, Institute of Computer Science of the Czech Academy of Sciences, Pod Vodárenskou věží 2. Prague, Czech Republic

mbrabec@cs.cas.cz, mmaly@cs.cas.cz

Abstrakt: V tomto příspěvku se věnujeme strukturované statistické prostorové analýze založené na GAM (Generalized Additive Model) paradigmatu s penalizovanými komponentami. V centru zájmu bude zejména modelování agregovaných prostorových dat (např. součtů/průměrů za různé správní oblasti typu kraj, okres) na různých prostorových škálách, a to jak ve statickém (standardním geostatistickém) tak časoprostorovém (modelování prostorově-proměnlivých trendů) smyslu. Modelování bude analogické GMRF (Gaussian Markov Random Field) přístupu, formulovanému ovšem z poněkud odlišné perspektivy. Přístup ilustrujeme v aplikaci zaměřené na rozsáhlá data o finančním hospodaření škol v ČR.

Abstract: This paper is devoted to the structured statistical spatiotemporal analysis based on GAM (Generalized Additive Model) approach with penalized components. We focus on aggregated (areal) spatial data on different spatial scales (e.g. region- and district-averages), both in the static (standard geostatistical) and spatiotemporal (modelling spatially-varying temporal trends) sense. Modelling is based on GMRF (Gaussian Markov Random Field) perspective. We will illustrate the approach on large scale data about financial management of elementary schools in the Czech Republic over several years.

Klíčová slova: finanční data, časoprostorové modelování, GAM, GMRF, hospodaření základních škol

Key words: financial data, spatiotemporal modelling, GAM, GMRF, elementary school financial management

1 Úvod

V oblasti státní správy vzniká nemalé množství dat používaných pro rutinní sledování různých aspektů aktivity podřízených a/nebo dozorovaných organizací. Jde o nejrozličnější finanční ukazatele (např. vybrané účetní položky) zaměřené na kontrolu finančních toků v organizačních složkách státu. Typicky jde o rozsáhlá časoprostorová data (tzv. Big Data), jež mohou být velmi cenná i pro retrospektivní analýzy, jejichž výsledky mohou sloužit pro detekci časových trendů i prostorových nehomogenit ve financování a/nebo hospodaření různých organizací, jež při dohlížecím monitoringu v „online“ stylu nemusí být patrné. V tomto článku se podíváme na vybrané aspekty hospodaření základních škol v ČR s pomocí pokročilých semiparametrických statistických metod. Cílem

našeho zkoumání bude strukturovaná analýza vývoje financování základních škol a průzkum jejich prostorové homogenity. Analýzu koncipujeme tak, že nám umožní zkoumat případné odchylky o linearity a homogenity velmi neparametrickým způsobem, tedy podstatně obecněji oproti standardnímu lineárnímu, při analýze ekonomických dat běžně používanému přístupu.

Kromě toho, že je rozsah finančních, resp. účetních dat značný (což s sebou přináší řadu výpočetních výzev při přípravě ke zpracování i vlastní statistické analýze), je pro efektivní extrakci informací z dat vhodné navrhnout statistické modely, jež se dokáží automaticky vypořádat s celou řadou komplikovaných vlastností reálných dat – např. jejich časoprostorovou povahou (a z ní plynoucí autokorelací v čase i prostoru), výskytem odlehklých pozorování neboli outlierů (což jsou řídce, ale přece se vyskytující extrémně malé či extrémně velké hodnoty některých ukazatelů) i požadavky na snadnou interpretaci modelové struktury a jejích komponent.

Pro zohlednění výše zmíněných problémů charakteristických pro reálná finanční data využijeme přístup GAM (Generalized Additive Model, Wood, 2017, Hastie, Tibshirani, 1990), který je zobecněním přístupu GLM (Generalized Linear Model, McCullagh, Nelder, 1989) založeným na penalizovaných splinech (Eilers, Marx, 1996). GAM metodologie je velmi populární v nejrůznějších oblastech přírodních i technických i společenských věd (Puklová et al. 2019, Brabec et al. 2018, Li, Chen, 2018, Linton 2000, Serra et al. 2006). Po formulaci modelu použitelného pro časoprostorovou analýzu na různých prostorových měřítcích agregace ukážeme jeho použití na reálných datech o financování a hospodaření základních škol v ČR.

Po úvodu v kapitole 1 zformulujeme obecný GAM model v odstavci 2.1 a komentujeme jeho strukturu a důležité vlastnosti. V odstavci 2.2 pak ilustrujeme jeho použití na reálných datech a zmíníme interpretaci některých výsledků včetně grafických. V části 3 pak shrneme výhody GAM přístupu ke studovanému problému.

2 Časovo-prostorový statistický model

2.1 Formulace modelu

Pro účely retrospektivních ekonometrických analýz jde hlavně o detekci trendů většího prostorového měřítka, nikoli o zkoumání jednotlivého hospodářského subjektu (to je samozřejmě důležité při rutinně prováděné kontrole). Proto pracujeme s daty vybraných indexů prostorově (kraj, okres) i časově (roční hodnoty) agregovanými. Prostorová agregace za územní jednotky samozřejmě vylučuje přímočaré použití standardních geostatistických modelů

pro bodově adresovaná prostorová data a jejich analýzu pomocí prostorové interpolace krigingového typu (Cressie, 1991). Přírozenější je v tomto kontextu (kde jednotlivé datum představuje agregát za plošný útvar, např. průměr za polygon, jako je tomu v našem případě) použití tzv. areal data přístupu založeného na GMRF, tedy Gaussovských Markovských náhodných polích (Rue, Held, 2005) používaného mimo jiné v moderní prostorové ekonometrii (Kelejian, Piras, 2017). Protože ale data o hospodaření škol vykazují komplikovanou strukturu jak v čase, tak i v prostoru, je výhodné ji při statistické analýze zohlednit a sestavit statistický model strukturovaně, tedy tak, aby umožňoval extrakci a analýzu různých, fyzicky interpretovatelných komponent (nikoli jen prostorové struktury en bloc). K tomu se dobře hodí GAM přístup (Wood, 2017) s tím, že GMRF struktura je v rámci formulace komplexního časoprostorového (opakovaně) použita jako stavební blok.

Pro průměrnou hodnotu závisle proměnné Y_{ijt} (např. indikátor stavu majetku vzhledem k velikosti školy, indikátor závislosti na dotacích atd.) v kraji i , okrese j a roce t budujeme časoprostorový model, tedy formálně model dovolující (parsimonní) interakci časových a prostorových efektů. Jeho obecná struktura diktovaná strukturou dat tedy bude:

$$Y_{ijt} = \mu + S(i, j) + T(t) + ST(i, j, t) + \varepsilon_{ijt}, \quad (1)$$

kde:

- μ je absolutní člen,
- $S(i, j)$ je (marginální) prostorový efekt j -tého okresu uvnitř i -tého kraje („zprůměrovaný“ přes čas),
- $T(t)$ je (marginální) časový efekt („zprůměrovaný“ přes prostor),
- $ST(i, j, t)$ je časoprostorový (tedy formálně interakční) efekt (půjde o parsimonní formulaci interakce s regularizací založenou na penalizaci pro zvýšení kvality odhadu, nikoli standardní saturevanou interakci, na kterou jsme zvyklí z ANOVA),
- ε_{ijt} je náhodná chyba.

Pro agregované (průměrné) hodnoty nemohou případné trendy v čase a/nebo prostoru být zcela nahodilé; lze očekávat jistou hladkost. Zároveň ale nelze a priori předpokládat nějaký konkrétní parametrický tvar, ba dokonce ani stacionaritu, standardně využívanou v analýze časových řad či prostorových dat. Proto je výhodné model (1) implementovat s využitím jednoduché semiparametrické formulace komponent $S(i, j)$, $T(t)$ a $ST(i, j, t)$ – tedy formulace založené na relativně bohatých třídách funkcí dovolujících popis komplikovaných časových a prostorových trendů, ale s penalizací ne-hladkosti

(kterou lze přepsat do penalizačních kvadratických členů na jejich lineárních parametrech).

Postulujeme tedy:

- $S(i, j) = s_{kraj}(i) + s_{okres}(j)$,
- $T(t) = s_{čas}(t)$,
- $ST(i, j, t) = s_{kraj,čas}(i) \cdot t + s_{okres}(j) \cdot t$,

a dostáváme pak již konkrétní specifikaci:

$$Y_{ijt} = \mu + s_{čas}(t) + s_{kraj}(i) + s_{okres}(j) + s_{kraj,čas}(i) \cdot t + s_{okres}(j) \cdot t + \varepsilon_{ijt}, \quad (2)$$

kde:

- $s_{čas}(t)$ je penalizovaný spline (v letech),
- $s_{kraj}(i)$, respektive $s_{okres}(j)$ jsou GMRF prostorové struktury (v krajích, respektive okresech) implikující hladkost jen pomocí matice sousednosti (Rue, Held, 2005), tedy s tím, že rozdělení náhodného efektu dané prostorové jednotky je dáno jen průměrem jejích sousedů (jednotek, které mají s danou jednotkou společnou hranici),
- $s_{kraj,čas}(i) \cdot t$ a $s_{okres}(j) \cdot t$ jsou interakční členy formulované jako prostorově-proměnlivé směrnice lineárního trendu v letech (Hastie, Tibshirani 1993).

Povšimněme si, že model (2) dovoluje nejen časovou, prostorovou a časoprostorovou segregaci předpokládanou v (1), ale umožňuje též separaci prostorové a časoprostorové komponenty do dvou složek rozdílného prostorového měřítka: krajového a okresního. Umožňuje tak mj. studovat, kde je variability více a/nebo kde jsou trendy strmější.

Kvůli výše zmíněné přítomnosti outlierů si pro ε_{ijt} nelze vystačit s běžně používaným normálním rozdělením. Při explorativních analýzách jsme například – zcela v duchu poučení z robustní statistiky – zaznamenali, že i jen velmi malý podíl outlierů dokázal v Gaussovském modelu „překlopit znaménko“ všeobecně rostoucího trendu na pokles apod. Proto v modelu používáme (výpočetně podstatně komplikovanější) podobu náhodné chyby:

$$\varepsilon_{ijt} \sim t(0, \nu), \quad (3)$$

tedy t-rozdělení s počtem stupňů volnosti ν odhadovaným z dat. Odhad ν typicky vychází velmi nízký (okolo 3), což odpovídá rozdělení s velmi těžkými chvosty. Jednou z podstatných praktických výhod je, že model (2), (3) pak automaticky vykazuje robustní chování a s outliery (které není vždy jednoduché ve velkých

kvantech dat „manuálně“ vytrídít) se umí elegantně vypořádat. Pro praktickou implementaci statistické inference je výhodné, že simultánní odhad všech komponent modelu (2), (3) lze pořídit maximalizací penalizované věrohodnostní funkce s tím, že neznámé penalizační konstanty jsou odhadovány (zobecněnou) crossvalidační procedurou.

Model (2), (3) je kompletně formulovaným statistickým popisem, tedy kompletním popisem pravděpodobnostního chování dat. Jakmile je model „identifikován“ (jeho „funkcionální parametry“ odhadnuty pomocí maximalizace penalizované věrohodnostní funkce), lze z něj odvodit různé charakteristiky zajímavé pro analýzu (jednotlivé komponenty, jejich syntézu atd.) i praktické účely (odhady/predikce hodnot indikátoru Y_{ijt} v konkrétním čase a oblasti, jejich agregaci do jiného než původního rozlišení v datech apod.), a to nejen v podobě bodových odhadů, ale i středních chyb. Vzhledem k tomu, že jednotlivé neparametrické členy modelu jsou formulovány jako lineární vzhledem ke svým parametrům, je odvození středních chyb (i plné kovarianční matice) pro sadu odhadů jednotlivých komponent jednoduché. Odtud lze pak v dalším kroku snadno konstruovat střední chyby i pro nově spočtené (lineární) agregace odhadů (např. agregace do jiných prostorových či časových jednotek, než byly původně v datech), a tedy i jejich (asymptotické) konfidenční intervaly.

K výpočtům, manipulacím s daty i statistickému modelování jsme použili prostředí R (R Core Team, 2019), GAM modelování využívalo knihovny mgcv (Wood, 2001).

2.2 Ilustrace na reálných datech

Použití obecného modelu (2), (3) na reálných finančních datech velkého rozsahu ilustrujeme na příkladu časoprostorové analýzy indikátoru majetku korigovaného na velikost školy (IM), spočteného jako poměr stálá aktiva / mzdové náklady, a to pro základní školy v ČR za období let 2012-2017. Tento poměrový ukazatel byl speciálně navržen experty Ministerstva financí s cílem standardizovat (normalizovat) stálá aktiva na velikost školy (samotný účetní ukazatel „Stálá aktiva“ je totiž vzhledem k řádově odlišné velikosti jednotlivých škol zcela neporovnatelný).


Pomocí modelu (2), (3) se na data můžeme podívat podrobněji. Například můžeme hledat odpovědi na následující otázky:

- i) Existují nějaké výraznější odchylky lokálního průměru IM od krajového průměru?
- ii) Existují výraznější krajově-specifické odchylky meziročního trendu od celkového meziročního trendu ČR?


- iii) Existují výraznější lokální odchylky meziročního trendu (na měřítku menším než kraj)?

Protože máme k dispozici jen údaje na krajské a okresní úrovni, použijeme jako příklad lokálního efektu odlišnosti na okresní úrovni. Pro větší stabilitu je model reparametrizován: namísto proměnné rok používáme proměnnou (rok-2014.5), což to odpovídá přibližné ortogonalizaci efektu absolutního členu a směrnice. V následujících grafech je pak zobrazena průměrná hodnota sledovaného indikátoru IM na daném území uprostřed sledovaného období 2012-2017. Jak vidíme z legendy, světlejším barvám odpovídají vyšší průměrné hodnoty indikátoru.

Vidíme, že celé území není zcela homogenní (Graf 1). Ale také - dosti překvapivě a v rozporu s apriorním expertním názorem - že se určité (byť většinou menší) nehomogenity vyskytují i na území jednoho kraje (Graf 2). Zařazení komponenty menšího prostorového měřítka také umožňuje lépe vytipovat specifické chování (např. vyšší hodnoty IM) některých menších jednotek oproti okolí (viz např. odchylka v Ústeckém kraji v severních Čechách), ale i geografické strukturování či geografický trend uvnitř některých krajů (viz např. hodnoty odhadů pro jednotlivé okresy na severovýchodě České republiky).




Graf 1 Statický prostorový trend na úrovni krajů, komponenta $s_{kraj}(\cdot)$
(Zdroj: vlastní zpracování)




Graf 2 Statický prostorový trend na úrovni okresů, komponenta $s_{okres}(\cdot)$
(Zdroj: vlastní zpracování)

Marginální časový trend není statisticky významný (p -hodnota=0.996), proto jej nevykresluje. Interakční členy však ukazují (Graf 3 a Graf 4), že směrnice lineárního trendu není v prostoru zcela homogenní. Ano, struktura směrnic popisujících meziroční trend je uvnitř krajů velmi hladká (statisticky nevýznamná), ale zajímavé je si povšimnout, že v podstatě jen podtrhuje západovýchodní gradient pozorovaný na krajové úrovni (s tím, že vidíme drobný náznak struktury např. uvnitř Moravskoslezského či Libereckého kraje). Jde ale jen o slabé a (zatím) neprůkazné tendence. Hlavní efekty vidíme v prostorové oblasti, nikoli v oblasti časové či časoprostorové změny.



Graf 3 Prostorová variabilita směrnice lineárního trendu na úrovni krajů,
komponenta $s_{kraj,čas}(\cdot)$ (Zdroj: vlastní zpracování)



Graf 4 Prostorová variabilita směrnice lineárního trendu na úrovni okresů, komponenta $s_{okres}(\cdot)$ (Zdroj: vlastní zpracování)

Obecný model (2), (3) lze samozřejmě pro specializované účely dále zpřesňovat. Například může být zajímavé otestovat, zda okresní sousedé Prahy 1. řádu (okresy, které hraničí s Prahou) a/nebo okresní sousedé 2. řádu (okresy sousedící s okresy, které mají s Prahou společnou hranici) na tom jsou systematicky hůře než Praha. Tento efekt je snadné otestovat zařazením indikátoru požadované sousednosti do modelu, tedy jednoduchým zobecněním modelu (2), (3). V případě Prahy a IM není efekt sousednosti (1. ani 2. řádu) významný (p-hodnoty 0.269 a 0.205 pro sousedy 1., resp. 2. řádu).

3 Závěr

Semiparametrické statistické modelování pro strukturovaná časoprostorová data je potenciálním zdrojem cenných informací o chování velkých dat z rutinního monitoringu účetnictví v různých organizacích. Detaily tohoto chování mohou při jednoduché analýze snadno uniknout či být maskovány (a pozměněny) různými komplikacemi, které se v datech reálně vyskytují (např. přítomností outlierů).

Strukturovaný statistický přístup je užitečný jak při analýze agregovaných dat (inference o jednotlivých komponentách komplexního modelu), syntéze (např. odhadu agregací do jiných měřítek než těch použitých v původních datech), ale i predikci (v čase i prostoru). Z hlediska flexibility se k modelování (např. finančních, účetních dat) osvědčuje GAM přístup výhodný i výpočetně a z pohledu vývoje i zpřesňování modelu.

Výhodou našeho přístupu založeného na flexibilním semiparametrickém přístupu je obecnost (není např. svázán standardními předpoklady o linearitě,

normalitě apod.). Umožňuje podrobně studovat detaily kvantitativních závislostí v čase i prostoru. Ty je možné testovat i zobrazovat graficky, což je velmi výhodné při věcné/praktické interpretaci nalezených zjištění a vztahů.

4 Literatura

- Brabec, M., Prochazka, P., Maturkanic, D. (2018): Semiparametric statistical analysis of the Blade Tip Timing data for detection of turbine rotor speed instabilities. *Qual Reliab Engng Int.* 2018;34,1308-1314.
- Cressie, N. (1991). *Statistics for Spatial Data*. New York. Wiley.
- Eilers, P.H.C., Marx, B.D. (1996). Flexible Smoothing with B-splines and Penalties. *Statistical Science*, 11(2), 89-121.
- Hastie, T.J., Tibshirani, R.J. (1990). *Generalized Additive Models*. London: Chapman & Hall.
- Hastie, T.J., Tibshirani, R.J. (1993). Varying-coefficient models. *JRSS B*, 55, 757-796.
- Kelejian, H., Piras, G. (2017). *Spatial Econometrics*. London: Academic Press.
- Li, W., Chen, S. (2018). The Early Exercise Premium in American Options by Using Nonparametric Regressions. *International Journal of Theoretical and Applied Finance*, 21
- Linton, O. (2000). Efficient Estimation of Generalized Additive Nonparametric Regression Models. *Econometric Theory* 16(4): 502–523.
- McCullagh, P., Nelder, J. (1989). *Generalized linear models*. Boca Raton: Chapman & Hall.
- Puklova, V., Zejglicova, K., Kratenova, J., Brabec, M., Maly, M. (2019). Childhood respiratory allergies and symptoms in highly polluted area of Central Europe. *International Journal of Environmental Health Research*. *International Journal of Environmental Health Research*, 29:1, 82-93
- R Core Team (2019). *R: A Language and Environment for Statistical Computing*. Zdroj: <http://www.R-project.org/>.
- Rue, H., Held, L. (2005). *Gaussian Markov Random Fields; Theory and Applications*, Boca Raton: Chapman & Hall/CRC.
- Serra, T., Goodwin, K. Gil, J. and Mancuso, A. (2006). Non-parametric Modelling of Spatial Price Relationships. *Journal of Agricultural Economics* 57(3): 501–522.
- Wood, S. (2001). mgcv: GAMs and Generalized Ridge Regression for R. *R News* 1(2), 20-25.
- Wood, S. (2017). *Generalized Additive Models: An Introduction with R*. Boca Raton: Chapman and Hall/CRC.

5 Poděkování

Článek byl vypracován s podporou Strategie AV 21, programu Naděje a rizika digitálního věku, aktivity „Vývoj modelu pro sledování finančních toků ve vybraných organizačních složkách státu s cílem detekce netypických trendů i prostorových nehomogenit“, ve spolupráci s Ministerstvem financí ČR a také s podporou na dlouhodobý koncepční rozvoj výzkumné organizace RVO 67985807.

Predikcia finančného zdravia vybraných podnikov v Slovenskej republike

Predicting financial health of selected companies in the Slovak Republic

Mária Danišovská, Mária Stachová^a

^a Univerzita Mateja Bela v Banskej Bystrici, , Ekonomická fakulta, Katedra kvantitatívnych metód a informačných systémov, Tajovského 10, Banská Bystrica, Slovenská republika

^a Matej Bel University in Banská Bystrica, , Faculty of Economics, Department of Quantitative Methods and Information Systems, Tajovského 10, Banská Bystrica, Slovak Republic
maria.stachova@umb.sk

Abstrakt: *Kedže finančné problémy podnikov môžu prerásť do obrovských rozmerov a spôsobiť tak veľké straty či ovplyvniť fungovanie viacerých subjektov z blízkeho ale aj vzdialeného okolia podniku, je dôležité s dostatočnou presnosťou a predstihom finančnú tieseň rozpoznať, predpovedať a následne sa pokúsiť jej zabrániť. Preto hlavným cieľom tohto príspevku je vytvorenia mechanizmu, ktorý by dokázal podnik upozorniť na blížiace sa finančné ohrozenie. Príspevok sa zaoberá možnosťami predikcie finančného zdravia vybraných podnikov Slovenskej republiky, pričom sa porovnávajú vytvorené matematicko-štatistické modely (založené na stromových štruktúrach) aplikované na viacročné reálne dáta tvorené finančnými indikátormi podnikov z pohľadu presnosti ich predikcie.*

Abstract: *Financial problems of companies can lead into huge distress and cause a big loss or can have negative impact on many subjects from companies' environments. Thus, it is important to recognize, predict and identify the financial distress with high accuracy and try to avoid this situation. The main goal of this contribution is to create a mechanism that is able to notice the financial menace. The study shows possibilities for financial distress prediction of selected companies of Slovakia and also it compares estimated mathematical statistical models (tree-based) that are built on real data sets consist of financial indicators.*

Kľúčové slová: *stromové štruktúry, predikčné modely, finančné zdravie podnikov, finančné indikátory*

Key words: *tree-based models, prediction models, financial health of companies, financial indicators*

1 Úvod

V odbornej literatúre sa môžeme stretnúť s rôznym chápaním finančného zdravia podniku. Podľa Mihokovej et al. (2007) je to spôsobené tým, že kritériá, pomocou ktorých sa posudzuje stav podniku sa rôznia, pretože predstavujú subjektívne priority hodnotiteľov.

Na presné zhodnotenie finančného zdravia a dlhodobej udržateľnosti spoločnosti je potrebné brať do úvahy viacero finančných meraní. Maverick (2016) prezentuje likviditu, platobnú schopnosť, ziskovosť a efektívnosť

prevádzky ako štyri hlavné oblasti finančného zdravia, ktoré by sa mali preskúmať. Dodáva však, že zo štyroch oblastí je pravdepodobne najlepším meraním zdravia spoločnosti úroveň ziskovosti.

Východiskom pri posudzovaní finančného zdravia podniku je udržanie si životaschopnosti a schopnosti vytvárať čo možno najlepšie výsledky hospodárenie pre vlastníkov podniku. V podstate ide o to, aby si podnik vedel zachovať rovnováhu vzhľadom k meniacim sa podmienkam a potrebám vonkajšieho prostredia, ale aj vzhľadom ku kľúčovým záujmovým skupinám majúcim podiel na rozhodovaní a fungovaní podniku (Kašík et al., 1998).

Napredovanie podniku je ovplyvnené vonkajšími a vnútornými faktormi. Manažéri ako rozhodujúca zložka vnútorného prostredia podniku, sú do veľkej miery zodpovední za súčasný a budúci stav podniku. Očakáva sa od nich, že budú schopní uskutočňovať správne rozhodnutia v správnom čase, k tomu by im mali pomáhať rôzne metódy a nástroje.

Finančné ukazovatele popisujúce finančnú situáciu podniku môžeme klasifikovať podľa Lesákovej et al. (2015) do niekoľkých skupín:

- ukazovatele likvidity,
- ukazovatele aktivity,
- ukazovatele zadlženosti,
- ukazovatele rentability,
- ukazovatele trhovej hodnoty.

Finančné ukazovatele v úlohách predikcie finančného zdravia zastávajú väčšinou funkciu prediktorov, ale môže byť prostredníctvom nich charakterizované aj samotné finančné zdravie, resp. finančná tieseň podniku. Úradníček et.al (2016, s.20) uvádzajú, že: „empirické štúdie zaoberajúce sa hodnotením finančného zdravia podnikov, resp. predikciou ich finančných problémov, využívajú vo svojich analýzach rozsiahle súbory ukazovateľov so zámerom poskytnúť čo najkomplexnejšie a najpresnejšie výsledky“.

Predikovanie finančných ťažkostí podniku vychádza zo skutočnosti, že vzniknutým problémom predchádzajú určitú dobu príznaky (symptómy) resp. signály, ktoré upozorňujú na blížiacu sa nebezpečenstvo. Práve včasné zachytenie týchto signálov dáva priestor manažérovi prijať rozhodnutia, ktorými dokážu blížiacu sa krízu predísť alebo aspoň zmierniť jej účinky. Na základe toho môžeme skonštatovať, že vo finančnom manažmente má predikovanie finančnej situácie svoj význam a je dôležité venovať mu náležitú pozornosť.

Na klasifikáciu a následnú predikciu vybraných podnikov z pohľadu rizika finančnej tiesne budeme používať viacrozmerné štatistické metódy a to: logistickú regresiu, CART algoritmus na vytvorenie klasifikačného stromu, model náhodného lesa a tzv. REEM strom, čo je klasifikačný strom pre panelové dáta. Všetky analýzy boli robené v štatistickom systéme R (R Core Team, 2016).

2 Dáta a metodológia

Pre účely analýzy bola použitá dátová množina obsahujúce finančné indikátory, na základe ktorých boli následne vytvorené klasifikačné modely.

2.1 Dáta vybraných podnikov Slovenskej republiky

Dátová množina obsahujúca finančné údaje o podnikoch bola vytvorená z údajov, ktoré boli spracované firmou CRIF – Slovak Credit Bureau, s.r.o na základe požiadaviek riešiteľov projektu VEGA 1/0647/14, ktorý bol uskutočnený pod záštitou Ekonomickej fakulty Univerzity Mateja Bela v Banskej Bystrici. Údaje pochádzali z výstupov účtovníctva, v horizonte rokov 2009 až 2013, malých, stredných a veľkých podnikov, pôsobiach na území Slovenskej republiky.

Konkrétne išlo o dáta za vybrané slovenské podniky, ktoré boli podľa odvetvovej klasifikácie zaradené medzi priemyselnú výrobu, stavebníctvo, veľkoobchod a maloobchod. Objasnenie výberu práve týchto sekcií poskytuje tlačová správa spoločnosti CRIF– Slovak Credit Bureau, s.r.o (2015), ktorá ich z dôvodu množstva vyhlásených konkurzov označuje za najrizikovejšie sekcie. V dátovej množine boli zastúpené všetky právne formy podnikania (Cút, 2016).

Poskytnutá dátová množina pozostávala z pozorovaní za 2583 podnikov v priebehu rokov 2010 až 2013. Pre jednotlivé podniky sme mali k dispozícii 7 pomerových finančných ukazovateľov, ktoré mali pri vytváraní predikčných modelov finančného zdravia slovenských podnikov funkciu prediktorov. Voľba týchto finančných ukazovateľov sa opiera o expertný výber riešiteľov projektu VEGA 1/0647/14, založený na zabezpečení lineárnej nezávislosti a nekorelovanosti medzi nimi, s prihliadnutím na predchádzajúce výsledky obdobných výskumov Altmana (1968), Karasa a Režňákovéj (2013) (Úradníček et.al., 2016). Pomenovanie, popis a spôsob výpočtu prediktorov poskytuje tabuľka 1.

Predikovanou premennou bola finančná vitalita podniku v stanovenom období. Táto premenná je označovaná ako default a má povahu kategoriálnej premennej, ktorá nadobúda hodnotu z dvoch možných alternatív: 0 alebo 1. Podnik, ktorému je priradená hodnota premennej defaultu 0 je považovaný za prosperujúci podnik, ktorý sa nenachádza vo finančnej tiesni. Druhú skupinu tvoria podniky, ktoré majú hodnotu premennej defaultu 1, tie sú pokladané za

neprosperujúce podniky, ktorým hrozí finančná tieseň. Jednotlivým podnikom bola priradená hodnota premennej defaultu pomocou tzv. kľúča, ktorý bol vytvorený na základe empirického výskumu Bođu a Úradníčka (2016). Kľúč pozostáva z nasledujúcich troch kritérií:

- likvidita III. stupňa bola menšia ako 1,
- vlastné imanie malo hodnotu menšiu ako 0,
- výsledok hospodárenia po zdanení mal hodnotu menšiu ako 0.

Tab. 1 Pomenovanie, popis a spôsob výpočtu finančných ukazovateľov použitých pri konštrukcii predikčných modelov pre slovenské podniky (Zdroj: vlastné spracovanie podľa Cúta 2016)

Označenie	Popis	Spôsob výpočtu
L_III	Likvidita 3. stupňa	bežné aktíva / bežné pasíva
LIAB_SAL	Doba splatnosti záväzkov	záväzky / tržba *360
LIAB_CF	Tokové zadlženie	záväzky / bilančný cash flow
LIAB_ASS	Celková zadlženosť majetku	celkové záväzky vrátane časového rozlíšenia pasív / majetok *100
OPER_ROA	Prevádzková rentabilita aktív	výsledok hospodárenia z hospodárskej činnosti / majetok *100
ROS	Čistá rentabilita tržieb	čistý zisk / tržby
NEW_SAL	Podiel novovytvorenej hodnoty v tržbách	novovytvorená hodnota / tržby

Pričom len podnik, spĺňajúci všetky tri uvedené kritéria bol označený ako neprosperujúci (Úradníček et.al, 2016). Ukazovateľ likvidity 3. stupňa vyjadruje pomer obežného majetku ku krátkodobým záväzkom. Ak tento ukazovateľ dosahuje hodnotu nižšiu ako 1, podnik použil krátkodobé cudzie zdroje na financovanie dlhodobého majetku čím mu vznikol nekrytý dlh a zároveň tým porušil zlaté bilančné pravidlo. To hovorí o tom, že dlhodobý majetok by mal byť financovaný porovnateľnými dlhodobými zdrojmi. Záporná hodnota vlastného imania signalizuje, že záväzky podniku presahujú celkovú výšku jeho majetku. Tretie kritérium, vyjadruje čistú stratu z podnikateľskej činnosti za sledovaný rok, čo samo o sebe ešte nemusí predstavovať výrazné problémy, ale vzhľadom na druhé kritérium už môžeme avizovať pretrvávajúce finančné ťažkosti.

Je pravdepodobné, že v podnikoch, ktoré sa ocitnú vo finančných problémoch je možné už skôr spozorovať signály naznačujúce nepriaznivý vývoj v budúcom období. Tento predpoklad umožňuje predpovedať finančnú kondíciu podniku

prostredníctvom údajov za predchádzajúce obdobia. Z toho dôvodu nie sú hodnoty prediktorov a predikovanej premennej z toho istého časového obdobia. Rozdiel medzi týmito časovými obdobiami predstavuje dĺžku doby, na ktorú sa chce finančné zdravie podniku predikovať. My sme si ako horizont predikcie zvolili dvojročné a trojročné obdobie. To znamená, že hodnoty prediktorov ako nezávislých premenných pochádzali z roku 2010 (t) a hodnota predikovanej premennej z roku 2012 ($t+2$) v prípade dvojročného horizontu predikcie a z roku 2013 ($t+3$) pri trojročnom horizonte predikcie. Pre analýzy pomocou metódy REEM stromu, ktorá pracuje s panelovými dátami sme mali hodnoty prediktorov ako nezávislých premenných z roku 2011 a 2012 (t , $t+1$) a hodnota predikovanej premennej z roku 2013 ($t+2$) v prípade dvojročného horizontu predikcie. V prípade trojročnej periódy predikcie sme mali hodnoty prediktorov ako nezávislých premenných z roku 2010, 2011 a 2012 (t , $t+1$, $t+2$) a hodnota predikovanej premennej z roku 2013 ($t+3$). Pre manažérov podnikov je dôležité vedieť identifikovať blížiac sa finančné ťažkosti v dostatočnom predstihu, ktorý im umožňuje prijať opatrenia na odvrátenie neželanej situácie. Na druhej strane predikčné obdobie by nemalo byť príliš dlhé, vzhľadom na súčasný dynamický vývoj ekonomiky. Z toho dôvodu sme si pre výskum zvolili práve obdobie dvoch a troch rokov. Tabuľka 2 poskytuje prehľad o počte podnikov označených za prosperujúce a neprosperujúce v jednotlivých sledovaných časových obdobiach.

Tab. 2 Prehľad o počte prosperujúcich a neprosperujúcich slovenských podnikoch (Zdroj: vlastné spracovanie)

Horizont predikcie	Prosperujúce podniky	Neprosperujúce podniky
2 roky	1710	873
3 roky	1811	772

Z uvedených čísel vyplýva, že percentuálny pomer prosperujúcich k neprosperujúcim podnikom bol v oboch prípadoch približne 70:30.

Dáta boli ešte pred samotnou analýzou náhodne rozdelené na trénovaciu množinu a testovaciu množinu v pomere 70:30.

2.2 Použité metódy

Na klasifikáciu a následnú predikciu vybraných podnikov z pohľadu rizika finančnej tiesne budeme používať viacrozmerné štatistické metódy a to: logistickú regresiu, CART algoritmus na vytvorenie klasifikačného stromu, model náhodného lesa a tzv. REEM strom, čo je klasifikačný strom pre panelové dáta.

2.3.1 Rozhodovací strom

Rozhodovacie stromy sú predstaviteľmi neparametrických modelov. Možno ich konštruovať prostredníctvom viacerých algoritmov. Medzi najznámejšie patrí algoritmus CART (Classification and Regression Trees) (Breiman et al., 1984).

James et al. (2013) uvádza niekoľko kladných vlastností rozhodovacích stromov, prostredníctvom ktorých zvýhodňuje ich použitie oproti iným metódam:

- Stromy sa veľmi ľahko vysvetľujú. Z hľadiska vysvetlenia sú oveľa jednoduchšie ako lineárna regresia.
- Stromy sa dajú zobrazíť graficky a ľahko ich interpretujú aj ľudia bez odborných alebo špecializovaných vedomostí (najmä ak sú malé).
- Stromy sú schopné zvládnuť aj kvalitatívne prediktory bez potreby vytvárať fiktívne premenné.

Konštrukcia klasifikačného stromu vychádza z algoritmu, ktorý dokáže zo všetkých prediktorov vybrať premennú, spolu s určitou deliacou hodnotou, prostredníctvom ktorého sa dosiahne rozdelenie množiny údajov (začínajúc celým súborom údajov) na dve, vnútorne čo najviac homogénne, podskupiny vzhľadom na cieľovú hodnotu. Každá podskupina je ďalej rozdeľovaná do dvoch menších až kým sa vetvenie ukončí (Barlin et al. 2013). Cieľom je nájsť v každom uzle premennú spolu s jej hodnotou rozdelenia, následkom čoho dochádza k vetveniu a vzniknú podmnožiny, ktoré sú maximálne homogénne (čisté) v ich hodnote triedy (Abu-Hanna a Keizer, 2003).

Terek et al. (2010, s. 93) uvádza, že vetvenie stromu sa zastaví ak nastane niektorá z nasledujúcich situácií:

- „Uzol je čistý, t.j. obsahuje rovnaké hodnoty výstupnej premennej.
- Všetky pozorovania v uzle majú rovnaké hodnoty vstupných premenných.
- Strom dosiahol používateľom definovanú hĺbku vetvenia.
- Počet pozorovaní v rodičovskom uzle je menší ako používateľom definovaný minimálny počet pozorovaní.
- Počet pozorovaní v dcérskom uzle je menší ako používateľom definovaná minimálna hranica.
- Redukcia nečistoty uzla, ktorý by sa mal optimálne rozštiepiť, je nižšia ako používateľom definovaná“.

Klasifikačný strom má stromovú štruktúru, v ktorej uzol predstavuje premennú, vetvy uzla reprezentujú hodnotu (alebo rozsahy hodnôt) príslušnej premennej a list označuje klasifikačnú triedu (Camdeviren et al., 2007).

2.3.2 Náhodný les

Booth et al. (2014) charakterizuje náhodný les ako neparametrický a nelineárny klasifikačný a regresný algoritmus, ktorý najprv navrhol a vyvinul Breiman (2001).

Uradníček et al. (2016) opisujú náhodný les ako techniku vytvárajúcu metamodel, ktorý pozostáva z viacerých jednoduchších modelov, konkrétne z rozhodovacích stromov. Náhodný les klasifikuje objekt do kategórie (triedy), kam by ho zaradila väčšina stromov, ktoré náhodný les tvoria.

Algoritmus náhodného lesa je postavený na modeloch rozhodovacích stromov, ktoré o výsledku „hlasujú“. Princíp fungovania tohto algoritmu je založený na tom, že v každom uzle stromu sa náhodne vyberajú m premenné zo všetkých n vstupných premenných a každý uzol stromu sa rozdelí pomocou vybraných m premenných, tým vzniká množstvo divergentných stromov. Náhodný výber funkcií v každom uzle znižuje koreláciu medzi stromami v lese (Yeh et al. 2014).

Jednou z hlavných výhod náhodného lesa je to, že sa dokáže vyhnúť nadmernému preučeniu modelu. Je obzvlášť robustný a umožňuje prítomnosť odľahlých hodnôt a šumu v tréningovej množine. Navyše má iba dva hyperparametre (počet premenných v náhodnej podskupine v každom uzle a počet stromov v lese) a zvyčajne nie je veľmi citlivý na ich hodnoty (Yeh et al., 2014).

Náhodný les poskytuje nielen klasifikáciu pozorovaní, ale určuje aj význam každej premennej vo výsledkoch klasifikácie (Maione et al., 2016).

2.3.3 Logistická regresia

Logistická regresia modeluje nelineárnu funkciu pravdepodobnosti dichotomického výsledku (Neter et al., 1989). Král (2009) vysvetľuje, že ide o modelovanie podmienenej pravdepodobnosti jednej hodnoty kategoriálnej premennej Y od vysvetľujúcich premenných $X_1, X_2, \dots, X_k$.

Zalai et al., (2016) uvádza, že za viacnásobnú logistickú regresiu sa považuje modelovanie závislosti odhadu pravdepodobnosti nastania obmeny vysvetľovanej premennej od viacerých vysvetľujúcich premenných. „Výsledný model možno použiť na predikciu závisle premennej, keďže výstupom je odhad pravdepodobnosti a vysvetlenie závislosti medzi premennými“ (Zalai et al., 2016, s. 151).

Použitie logistickej regresie na vytvorenie ratingového modelu so sebou prináša viaceré výhody. Hodnoty závislých premenných nemusia mať normálne rozdelenie a významnosť jednotlivých premenných nie je nutné vopred testovať.

Z toho vyplýva, že z hľadiska využiteľnosti a náročnosti prípravy údajov je logistická regresia na rozdiel od iných konvenčných techník, ako je diskriminačná analýza omnoho praktickejšia (Zalai et al., 2016).

Princíp logistickej regresie vysvetlíme s podporou Kráľa (2009). Majme dichotomickú vysvetľovanú premennú Y , ktorá nadobúda hodnotu 1 alebo 0. $Y=1$ znamená, že sledovaný jav, v našom prípade finančné ohrozenie podniku, nastal. V prípade, že $Y=0$, sledovaný jav nenastal a podnik nie je v ohrození. X predstavuje vektor nezávislých premenných, v našom prípade finančno-ekonomických ukazovateľov ($X_1, X_2, \dots, X_k$). Podmienenú pravdepodobnosť (p) ohrozenia podniku ($Y=1$) môžeme vyjadriť pomocou vzťahu:

$$p = P(Y = 1/X). \quad (1)$$

Ďalej uvažujeme, že s pravdepodobnosťou p budú podniku hroziť finančné ťažkosti a s pravdepodobnosťou $p-1$ bude podnik mimo ohrozenia. Potom pomer pravdepodobností

$$\frac{p}{1-p} \quad (2)$$

vyjadruje šancu, že podnik bude ohrozený. Šance a pravdepodobnosti poskytujú tie isté informácie, len v inej podobe (Kráľ, 2009).

Vzťah medzi pravdepodobnosťou a vysvetľujúcimi premennými je nelineárny, vyjadrený exponenciálnou logistickou funkciou (Zalai et.al, 2016):

$$p = \frac{e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k}}{1 + e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k)}}, \quad (3)$$

kde

- $X_1, X_2, \dots, X_k$ sú vysvetľujúce premenné, v našom prípade finančno-ekonomické ukazovatele, ktoré plnia funkciu prediktorov,
- $\beta_1, \beta_2, \dots, \beta_k$ sú regresné koeficienty pre jednotlivé prediktory,
- β_0 je lokujúcou konštantou lineárneho regresného modelu.

Logaritmovaním šancí zmeníme závislú premennú na spojitú hodnotu, a tým získame vzťah medzi logaritmom šancí a vektorom vysvetľujúcich premenných, ktorý má lineárny charakter.


$$\ln\left(\frac{p}{1-p}\right) = \ln[e^{(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k)}] = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad (4)$$

Po vytvorení modelu logistickej regresie, tým myslíme po odhadnutí parametrov modelu, sa model často využíva na prognózovanie pre nové

pozorovania. Prognózovanie binárneho výsledku sa uskutočňuje nastavením špecifikovanej hodnoty, ktorá je označovaná ako deliaci bod (angl. cut point, alebo treshold). Pozorovanie sa klasifikuje do jednej z dvoch príslušných kategórií (1,0). Ak je odhadnutá pravdepodobnosť, že sledovaný jav nastane vyššia ako hodnota deliaceho bodu predpokladá sa, že jav v budúcnosti nastane ($Y=1$), ale ak je pravdepodobnosť nižšia predpokladá sa, že jav nenastane ($Y=0$). Vo väčšine prípadov je hodnota deliaceho bodu nastavená na 0,5. To je zvyčajné najmä, keď sú obe skupiny približne rovnako zastúpené (Fan a Wang, 1999).

3 Výsledky

Prvou metódou na zostrojenie predikčného modelu bol rozhodovací strom. Použili sme balíček rpart (Therneau et al.,2017), ktorý zahŕňa algoritmus CART. Výsledný strom je zobrazený na obrázku 1.



Obr. 1 Rozhodovací strom zostrojený na základe údajov za slovenské podniky pri dvojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Z obrázku 1 môžeme vyčítať, že model rozdelil podniky v koreňovom uzle na základe prediktora, ktorým je celková zadlženosť majetku označená ako LIAB_ASS. Podniky, ktoré spĺňajú vrcholnú podmienku sú klasifikované ako finančne neohrozené (0). Ostatné podniky sú v ďalších uzloch rozdeľované podľa podmienok súvisiacich s prediktormi: rentabilita tržieb (ROS), prevádzková rentabilita aktív (OPER_ROA) a doba splatnosti záväzkov (LIAB_SAL).

Predikčná schopnosť vytvoreného klasifikačného stromu je vyjadrená v tabuľke 3 formou klasifikačnej matice. V tabuľke sme uviedli miery klasifikačnej

schopnosti modelu dosiahnuté na trénovacej a testovacej množine, aby sme ich mohli navzájom porovnať.

Tab. 3 Klasifikačná tabuľka rozhodovacieho stromu zostrojeného na základe údajov za slovenské podniky pri dvojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Skutočné zaradenie	Predikované zaradenie					
	Trénovacia množina			Testovacia množina		
	0	1	% správne zaradených podnikov	0	1	% správne zaradených podnikov
0	1031	166	86,13	423	90	82,46
1	193	418	68,41	101	161	61,45
Celková predikčná schopnosť:	80,14 %			75,35 %		

Z tabuľky 3 je zrejmé, že model dosahuje lepšie miery kvality klasifikácie na trénovacej množine. Čo sa dalo predpokladať vzhľadom na to, že model bol vytvorený prostredníctvom trénovacej množiny. Pri hodnotení úspešnosti modelu majú preto lepšiu vypovedateľnú schopnosť výsledky dosiahnuté na testovacej množine. Celková predikčná schopnosť modelu je 75,35%. Je dôležité si všímať aj jednotlivé schopnosti modelu klasifikovať podnik do správnej skupiny. Tieto miery sa nazývajú špecifickosť a senzitivita. Nami vytvorený model rozhodovacieho stromu má vyššiu schopnosť správne klasifikovať finančne zdravé podniky (špecifickosť) ako schopnosť správne klasifikovať finančne ohrozené podniky (senzitivitu).

Ďalším modelom bude náhodný les. Na jeho zostrojenie sme použili balíček randomForest (Liaw a Wiener, 2002). V tabuľke 4 sú zachytené počty správne a nesprávne zaradených podnikov a z nich vypočítané miery kvality klasifikácie skonštruovaného modelu. Môžeme pozorovať, že výsledky trénovacej a testovacej množiny sa líšia len minimálne. Celková klasifikačná schopnosť modelu na testovacej množine dosahuje 75,74 %.

Tretí model sme zostavili metódou logistickej regresie.

Pri určovaní predikčnej schopnosti vytvoreného modelu bol deliaci bod optimalizovaný na hodnotu 0,3 na základe optimalizačného kritéria, ktorým bola minimalizácia súčtu chýb prvého a druhého druhu.

Tab. 4 Klasifikačná tabuľka náhodného lesa zostrojeného na základe údajov za slovenské podniky pri dvojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Skutočné zaradenie	Predikované zaradenie					
	Trénovacia množina			Testovacia množina		
	0	1	% správne zaradených podnikov	0	1	% správne zaradených podnikov
0	998	199	83,38	421	92	82,07
1	215	396	64,81	96	166	63,36
Celková predikčná schopnosť:	77,1 %			75,74 %		

Tabuľka 5 prezentuje predikčné schopnosti modelu logistickej regresie. Celková schopnosť je 54,84%. Model dosahuje až 94,66 % úspešnosť pri klasifikácií finančne ohrozených podnikov. Na druhej strane jeho úspešnosť správne klasifikovať finančne zdravé podniky je len 34,5%. Je to spôsobené hodnotou deliaceho bodu, ktorý bol nastavený v prospech defaultných podnikov.


Doteraz sme sa venovali modelom, ktoré predikovali finančné zdravie na obdobie dvoch rokov. Teraz popíšeme modely skonštruované rovnakými metódami pre trojročný horizont predikcie. To znamená, že pri ich vytváraní sme použili hodnoty premennej defaultu z obdobia $t+3$ roky.

Tab. 5 Klasifikačná tabuľka logistickej regresie zostrojenej na základe údajov za slovenské podniky pri dvojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Skutočné zaradenie	Predikované zaradenie					
	Trénovacia množina			Testovacia množina		
	0	1	% správne zaradených podnikov	0	1	% správne zaradených podnikov
0	448	749	37,43	177	336	34,5
1	34	577	94,44	14	248	94,66
Celková predikčná schopnosť:	56,69 %			54,84 %		

Obrázok 2 zobrazuje výsledný rozhodovací strom. Je vidieť, že vytvorený strom je zložený z piatich úrovní. Koreňový uzol obsahuje podmienku s prediktorom

označeným ako LIAB_ASS, ktorý predstavuje celkovú zadlženosť majetku. Strom v ďalších úrovniach roztrieduje podniky na základe prediktorov ROS, LIAB_CF potom opäť použije LIAB_ASS a následne OPER_ROA.



Obr. 2 Rozhodovací strom zostrojený na základe údajov za slovenské podniky pri trojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Úspešnosť modelu predikovať finančné zdravie podnikov je prezentovaná prostredníctvom tabuľky 6.

Tab. 6 Klasifikačná tabuľka rozhodovacieho stromu zostrojeného na základe údajov za slovenské podniky pri trojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Skutočné zaradenie	Predikované zaradenie					
	Trénovacia množina			Testovacia množina		
	0	1	% správne zaradených podnikov	0	1	% správne zaradených podnikov
0	1041	227	82,1	445	98	81,95
1	197	343	63,52	101	131	56,47
Celková predikčná schopnosť:	76,55 %			74,32 %		

Na základe uvedených množstiev správne a nesprávne zatriedených podnikov sme zistili, že celková predikčná schopnosť modelu na testovacej množine je

74,32 %. Môžeme tiež skonštatovať, že zostrojenému modelu sa darí lepšie klasifikovať finančné neohrozené podniky než tie ohrozené.

Pokračovali sme vytvorením modelu náhodného lesa. Pri konštrukcii sme použili balík systému R: *randomForest* (Liaw a Wiener, 2002).

Tabuľka 7 zobrazuje klasifikačné matice obsahujúce údaje, prostredníctvom ktorých sme odvodili klasifikačné schopnosti modelu dosiahnuté na trénovacej aj testovacej množine. Môžeme vidieť, že vytvorený model má na testovacej množine celkovú predikčnú schopnosť 72,9%. Špecifickosť modelu je na úrovni 84,71 % a je vyššia ako senzitivita, ktorá dosahuje len 45,26 %.

Tab. 7 Klasifikačná tabuľka náhodného lesa zostrojeného na základe údajov za slovenské podniky pri trojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Skutočné zaradenie	Predikované zaradenie					
	Trénovacia množina			Testovacia množina		
	0	1	% správne zaradených podnikov	0	1	% správne zaradených podnikov
0	1072	196	84,54	460	83	84,71
1	290	250	46,3	127	105	45,26
Celková predikčná schopnosť:	73,12 %			72,9 %		

Analogicky ako pri dvojročnom horizonte predikcie, sme zostavili aj model logistickej regresie. Výsledné percentá popisujúce presnosť modelu sú v tabuľke 8.


Tab. 8 Klasifikačná tabuľka logistickej regresie zostrojenej na základe údajov za slovenské podniky pri trojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Skutočné zaradenie	Predikované zaradenie					
	Trénovacia množina			Testovacia množina		
	0	1	% správne zaradených podnikov	0	1	% správne zaradených podnikov
0	905	363	71,37	393	150	72,38
1	174	366	67,78	95	137	59,05
Celková predikčná schopnosť:	70,3			68,39		

Tabuľka 8 nám prezentuje celkovú predikčnú schopnosť modelu, ktorá je 68,39 %. Špecifickosť vytvoreného modelu, ktorá dosahuje 72,38 % je vyššia ako jeho senzitivita s hodnotou 59,05 %.

Keďže použité dáta mali charakter panelových dát, mohli sme aplikovať aj klasifikačný strom upravený na prácu s panelovými dátami, tzv. REEM strom, ktorý je súčasťou R balíčka REEMtree (Sela, Simonoff, 2011).


Strom odhadnutý na dvojročných dátach je na obrázku 3.



Obr. 3 REEM strom zostrojený na základe údajov za slovenské podniky pri dvojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Koreňový uzol a aj nasledujúce dcérske uzly obsahujú podmienku s prediktorom označeným ako LIAB_ASS, ktorý predstavuje celkovú zadlženosť majetku. Strom v ďalších úrovniach roztrieduje podniky na základe prediktorov OPER_ROA a LIAB_CF.

Na obrázku 4 je zobrazený REEM strom odhadnutý na trojročnej predikcii. Strom sa od predchádzajúceho líši len málo a to konkrétne tým, že pribudol do koncového uzla prediktor NEW_SAL.



Obr. 4 Rozhodovací strom zostrojený na základe údajov za slovenské podniky pri trojročnom horizonte predikcie (Zdroj: vlastné spracovanie)

Úspešnosť oboch modelov predikovať finančné zdravie podnikov je prezentovaná prostredníctvom Tabuľky 9.

Tab. 9 Klasifikačná tabuľka REEM stromu zostrojeného na základe údajov za slovenské podniky pri dvojročnej a trojročnej perióde predikcie (Zdroj: vlastné spracovanie)

Skutočné zaradenie	Predikované zaradenie					
	Trénovacia perióda 2 roky			Trénovacia perióda 3 roky		
	0	1	% správne zaradených podnikov	0	1	% správne zaradených podnikov
0	1260	551	69,6	772	200	79,4
1	51	721	93,4	71	463	86,7
Celková predikčná schopnosť	76,7			82,0		

Tabuľka 9 nám prezentuje celkovú predikčnú schopnosť oboch modelov. Je viditeľné, že model zostrojených na trojročnej perióde predikcie je presnejší a jeho chybovosť je približne 18 %. V oboch prípadoch je, na rozdiel od modelov spomínaných vyššie, REEM strom presnejší pri predikcii podnikov, ktoré majú riziko finančnej tiesne.

4 Záver


Zmyslom predikovania finančnej situácie je vedieť identifikovať blížiac sa finančné ťažkosti v dostatočnom predstihu, ktorý umožňuje prijať opatrenia na odvrátenie neželanej situácie. Na druhej strane predikčné obdobie by nemalo byť príliš dlhé vzhľadom na súčasný dynamický vývoj ekonomiky. Z toho dôvodu sme sa rozhodli pre dvojročný a trojročný horizont predikcie.

Zostrojili sme modely logistickej regresie zastupujúce tradičné štatistické prístupy a modely rozhodovacích stromov a náhodných lesov, ktoré patria medzi moderné prístupy data miningového charakteru a tiež model REEM stromu, ktorý v sebe zahŕňa algoritmus pre spracovanie panelových dát a tým pádom dokáže rozlíšiť a dať do súvisu aj časové zmeny vo finančných indikátoroch. Dôvodom výberu týchto techník je ich nenáročnosť na predispozíciu dátových množín, jednoduchá interpretovateľnosť a ľahká orientácia vo výstupoch.

Vyhodnotenie modelov ukázalo, že takmer všetky vytvorené modely (až na model REEM stromu) boli úspešnejšie pri klasifikácii finančne zdravých podnikov. Väčšia chybovosť pri zaraďovaní finančne ohrozených a zbankrotovaných podnikoch bola spôsobená tým, že tieto podniky mali menšie zastúpenie v rámci dátových množín, pomocou ktorých sme modely vytvárali.


V rámci porovnávania modelov sme sledovali hodnoty predikčných schopností, ktoré boli dosiahnuté na testovacích množinách. Graf 1 zobrazuje pre každý vytvorený model s dvojročným horizontom predikcie jeho celkovú predikčnú schopnosť a schopnosť správne zaradiť z hľadiska finančného zdravia neohrozené a ohrozené podniky. Do tohto porovnania sme nezahrnuli model REEM stromu, keďže nepatrí k statickým modelom a to, že dokáže pracovať s panelovým charakterom dát ho robí s danými modelmi neporovnateľný. Pripomíname, že za defaultný podnik sme považovali ten, ktorého likvidita III. stupňa bola menšia ako jedna a zároveň jeho vlastné imanie a výsledok hospodárenia po zdanení boli záporné.

Vychádzajúc z grafu môžeme skonštatovať, že predikčné schopnosti modelu náhodného lesa a rozhodovacieho stromu sú takmer rovnaké. Ich celková predikčná schopnosť nepatrne presahuje 75 %. Pri zatriedňovaní neohrozených podnikov sa darí o niečo lepšie modelu rozhodovacieho stromu zatiaľ čo modelu náhodného lesa sa darí lepšie pri ohrozených podnikoch. Z hľadiska správneho zaradenia ohrozených podnikov je ale jednoznačne najúspešnejší model logistickej regresie. Zásľuhu má na tom hodnota deliaceho bodu, ktorá bola nastavená v prospech defaultných podnikov. Tým pádom je model pri klasifikácii nedefaultných podnikov slabší a celková predikčná schopnosť je na úrovni 54,84 %.



Graf 1 Porovnanie predikčných schopností modelov vytvorených pre slovenské podniky s dvojročným horizontom predikcie (Zdroj: vlastné spracovanie)

Tieto výsledky môžeme porovnať s výsledkami dosiahnutými pri trojročnom horizonte predikcie, ktoré sú zachytené pomocou grafu 2. Tu si môžeme všimnúť, že model logistickej regresie aj napriek nastaveniu hodnoty deliaceho bodu v prospech ohrozených podnikov dosahuje lepšiu predikčnú schopnosť pri neohrozených podnikoch. Pri zatriedovaní ohrozených podnikov je však v porovnaní s ostatným dvoma modelmi najúspešnejší. Z hľadiska celkovej predikčnej schopnosti je najlepším modelom rozhodovací strom. Model náhodného lesa je zas najpresnejší pri klasifikácii neohrozených podnikov.



Graf 2 Porovnanie predikčných schopností modelov vytvorených pre slovenské podniky s trojročným horizontom predikcie (Zdroj: vlastné spracovanie)

Ako bolo už spomenuté v predchádzajúcej kapitole, model REEM stromu pracoval presnejšie pri trénovacej perióde trojročnej, kde dosahoval celkovú presnosť až 82%. Ale zároveň ešte aj jeho schopnosť predikovať pri dvojročnej trénovacej perióde (76,7%) prevýšila zvyšné statické modely.

Na základe dosiahnutých výsledkov nemôžeme jednoznačne určiť, ktorý model je najlepší. Závisí od individuálnych potrieb a kritérií, ktoré používateľa vyžaduje od modelu.

5 Literatúra

- Altman, E.I. (1968). *Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy*. The Journal of Finance, 23(4), 589-609.
- Abdou, H.A. et al. (2016). *Predicting creditworthiness in retail banking with limited scoring data*. Knowledge-Based Systems, 103, 89-103.
- Abu-Hanna, A., Keizer, N. (2003). *Integrating classification trees with local logistic regression in Intensive Care prognosis*. Artificial Intelligence in Medicine, 29(1-2), 5-23.
- Barlin, J. B. et al. (2013). *Classification and regression tree (CART) analysis of endometrial carcinoma: Seeing the forest for the trees*. Gynecologic Oncology, 130(3), 452-456.
- Breiman, L. et al. (1984). *Classification and regression trees*. Monterey: Wadsworth.
- Bodá, M., Úradníček, V. (2016). *The portability of Altmans Z-score model to prediction corporate financial distress of Slovak companies*. Technological and Economic Development of Economy, 22(4), 532-553.
- Booth, A. et al. (2014). *Automated trading with performance weighted random forests and seasonality*. Expert Systems with Applications, 41(8), 3651-3661.
- Camdeviren, H. A. et al. (2007). *Comparison of logistic regression model and classification tree: An application to postpartum depression data*. Expert Systems with Applications, 32(4), 987-994.
- CRIF – Slovak Credit Bureau, s. r. o.: Počet firiem zbankrotovaných v roku 2014 bol opäť rekordný – tlačová správa [online]. 2015. [cit. 2018-02-04]. Dostupné na internete: <http://www.crif.sk/Novinky/Novinky/Documents/TS_CRIF_SK_Pocet%20firiem%20zbankrotovanych%20v%20roku%202014%20bol%20opat%20rekordny.pdf>.
- Cút, S. (2016). *Predikovanie finančného vývoja podniku v rýchlo sa meniacom ekonomickom prostredí*. Dissertation thesis. Banská Bystrica: EF UMB, 2016. 220 s.
- Fan, X., Wang, L. (1999). *Comparing Linear Discriminant Function with Logistic Regression for the Two-Group Classification Problem*. The Journal of Experimental Education. [online]. 1999. [cit. 2018-05-04]. Dostupné na internete: <<https://files.eric.ed.gov/fulltext/ED422391.pdf>>.
- Fu, C.Y. (2004). *Combining loglinear model with classification and regression tree (CART): An application to birth data*. Computational Statistics & Data Analysis, 45(4), 865-874.
- Chaudary, A. et al. (2016). *An improved classifier for multi-class classification*. Information Processing in Agriculture, 3(4), 215-222.
- James, G. et al. (2013). *An Introduction to Statistical Learning with Applications in R*. New York: Springer, 431 s.

- Karas, M., Režňáková, M. (2013). *Bankruptcy Prediction Model of Industrial Enterprises in the Czech Republic*. International Journal of Mathematical Models and Methods in Applied Sciences. 7(5).
- Kašík, J., Michalko, M. et al. (1998). *Podniková diagnostika*. Ostrava : Tandem, 343 s.
- Kráľ, P. et al. (2009). *Viacrozmerné štatistické metódy so zameraním na riešenie problémov ekonomickej praxe*. Banská Bystrica: Univerzita Mateja Bela, Ekonomická fakulta v Banskej Bystrici, 175 s.
- Liaw, A., Wiener, M. (2002). *Classification and Regression by random Forest*. R News, 2(3), 18-22.
- Mahjoobi, J., Etemad-Shahidi, A. (2008). *An alternative approach for the prediction of significant wave heights based on classification and regression trees*. Applied Ocean Research, 30(3), 172-177.
- Maione, C. et al. (2016). *Comparative study of data mining techniques for the authentication of organic grape juice based on ICP-MS analysis*. Expert Systems with Applications, 49, 60-73.
- Mihoková, L., Vida, M., Kádár, G. (2007). *Diagnostika efektívnosti a konkurencieschopnosti podniku a prechod podniku do krízového stavu*. Intercathedra, 23, 78-81.
- Neter, J. et al. (1989). *Applied linear regression models*. Homewood, Ill. : Irwin, 667 s.
- Sela, R. J. and Simonoff, J. S. (2011). RE-EM Trees: Regression Trees with Random Effects, R package, version 0.90.3.
- Stankovičová, I., Vojtková, M. (2007). *Viacrozmerné štatistické metódy s aplikáciami*. Bratislava: Iura Edition, 261 s
- Terek, M. et al. (2010). *Hĺbková analýza údajov*. Bratislava: Iura Edition, 265 s.
- Therneau, T., Atkinson, B., Ripley, B. (2017). rpart: Recursive Partitioning and Regression Trees. R package version 4.1-11 [online]. 2017 [cit. 2018-02-12]. Dostupné na internete: <<http://CRAN.R-project.org/package=rpart>>.
- Úradníček, V. et al. (2016). *Variantné metódy predikcie finančného zdravia podnikov v podmienkach dynamického ekonomického prostredia*. Banská Bystrica : Belianum. Vydavateľstvo Univerzity Mateja Bela v Banskej Bystrici. Ekonomická fakulta, 136 s.
- Yeh, C.-C. et al. (2014). *Going-concern prediction using hybrid random forests and rough set approach*. Information Sciences, 254, 98-110.
- Zalai, K. (2000). *Osobitosti prognózovania finančného vývoja slovenských podnikov*. Biatec, 8(1), 12-14.

6 Poďakovanie

Mária Stachová bola podporená grantovou agentúrou VEGA, č. projektu 1/0767/18 SMART model - podporný nástroj rozhodovania pri riadení podniku.

Hodnotenie výkonnosti zamestnancov pomocou DEA: prípadová štúdia

Performance evaluation of employees by using DEA: a case study

Viera Mendelová

Univerzita Mateja Bela v Banskej Bystrici, , Ekonomická fakulta, Katedra kvantitatívnych metód a informačných systémov, Tajovského 10, Banská Bystrica, Slovenská republika
Matej Bel University in Banská Bystrica, , Faculty of Economics, Department of Quantitative Methods and Information Systems, Tajovského 10, Banská Bystrica, Slovak Republic
viera.mendelova@umb.sk

Abstrakt: Jednou z kľúčových podmienok pre dosiahnutie vysokej výkonnosti podnikov je vysoká výkonnosť vlastných zamestnancov. Na úspešné fungovanie podniku je potrebné disponovať účinnými nástrojmi merania výkonnosti zamestnancov. Príspevok sa zameriava na možnosti hodnotenia výkonnosti zamestnancov pomocou metódy DEA (Data Envelopment Analysis). Cieľom príspevku je zhodnotiť výkonnosť 50 zamestnancov vybraného call centra aplikáciou metódy DEA. Výkonnosť zamestnancov je posudzovaná s ohľadom na dve dimenzie hodnotenia: dimenzia nákladov a dimenzia kvality. Príspevok ukazuje, že metóda DEA môže poskytnúť flexibilný nástroj na hodnotenie výkonnosti zamestnancov.

Abstract: One of the key conditions for achieving high business performance is the high performance of its own employees. For the successful business operation, it is necessary to have effective tools for the employee performance evaluation. The paper focuses on the possibilities for employee performance evaluation using data envelopment analysis (DEA). The aim of the paper is to evaluate the performance of 50 employees of the selected call center using the DEA method. Employee performance is assessed with respect to the two dimensions of evaluation: the cost and the quality dimension. The paper shows that the DEA can provide a flexible tool to evaluate the performance of employees.

Kľúčové slová: Hodnotenie výkonnosti zamestnancov, efektívnosť, metóda DEA

Key words: Employee performance evaluation, efficiency, Data Envelopment Analysis

1 Úvod

Cieľom riadenia ľudských zdrojov je zabezpečiť pre podnik dostatočný počet zamestnancov vo vhodnej kvalifikačno-profesnej a vekovej štruktúre. Vo všeobecnosti medzi základné činnosti podniku, resp. personálneho útvaru podniku v oblasti personalistiky patrí: (1) plánovanie potreby zamestnancov, (2) získavanie a výber zamestnancov, (3) rozmiestňovanie zamestnancov, (4) hodnotenie zamestnancov a ich práce, (5) vytvorenie správneho a účinného systému odmeňovania zamestnancov, (6) zabezpečenie kolektívneho vyjednávania, (7) vytváranie podnikových sociálnych služieb a (8) spolupôsobenie pri vytváraní vhodnej podnikovej kultúry (Kupkovič et al., 2003, s. 190-191). Hodnotenie zamestnancov

a ich výkonov má pre fungovanie podniku rozhodujúci význam a hoci táto činnosť patrí medzi najcitlivejšie oblasti riadenia ľudských zdrojov, od kvality jej vykonania v značnej miere závisí i kvalita celej personálnej práce v podniku.

Hoci v podnikovej praxi existuje niekoľko tradičných metód uplatniteľných na hodnotenie zamestnancov¹, v poslednom období sa začali objavovať aplikácie nových moderných metód založených na multikriteriálnom hodnotení výkonnosti. Jednou z nich je i metóda DEA (*Data Envelopment Analysis*), ktorá vznikla v 70. rokoch 20. storočia ako metóda merania technickej efektívnosti tzv. samostatne rozhodovacích jednotiek (*Decision Making Units – DMUs*). DEA vychádza z neparametrickej Farrellovej (1957) konštrukcie hranice produkčných možností (*Production Possibility Frontier – PPF*), pričom hlavná myšlienka spočíva v stanovení mier efektívnosti DMUs na základe ich vzdialenosti od skonštruovanej PPF. Pri aplikáciách DEA na oblasť merania výkonnosti zamestnancov sa na každého zamestnanca pozerá ako na istú DMU, ktorá svojou pracovnou činnosťou premieňa skupinu vstupov na skupinu výstupov. V úvode je potrebné poznamenať, že z definičného hľadiska existuje rozdiel medzi pojmami *efektívnosť* a *výkonnosť*. Kým pod pojmom *efektívnosť* sa vo všeobecnosti myslí schopnosť jednotky dosahovať z danej úrovne vstupov maximálnu úroveň výstupov, ktorú je vzhľadom na produkčné možnosti možné dosiahnuť, pod pojmom *výkonnosť* sa myslí „schopnosť jednotky dosahovať požadovanú úroveň výstupov“ (Lesáková, 2004). Je evidentné, že *efektívnosť* je dosiahnutá pri generovaní maximálnej úrovne výstupov z danej úrovne vstupov a na druhej strane *výkonnosť* je dosiahnutá v prípade, že skutočný výkon spĺňa požadovaný alebo želaný výkon. *Výkonnosť* teda nie je ukazovateľom, ktorý by všeobecne hovoril o skutočnej úspešnosti, efektívnosti, či produktivite danej jednotky. Dosahovanie vysokých výkonov nemusí znamenať, že zo vstupov, ktoré má jednotka k dispozícii, nie je možné vyprodukovať viac a dosiahnuť ešte vyšší efekt. Na komplexnejšie vyjadrenie úspešnosti činnosti jednotky je potrebné zachytiť vzájomné súvislosti medzi používanými vstupmi a dosahovanými výstupmi a na ich základe potom zhodnotiť postavenie a možnosti jednotky z hľadiska dosahovanej efektívnosti. Napriek tomu, že DEA je primárne orientovaná na meranie *efektívnosti*, tzn. meria úspešnosť transformácie vstupov na výstupy, v ďalšej časti príspevku budeme pri meraní efektívnosti zamestnancov pomocou tejto metódy hovoriť o *výkonnosti* zamestnancov s tým, že pod *výkonnosťou* budeme chápať *efektívnosť* zamestnancov.

V porovnaní s tradičným systémom hodnotenia výkonnosti zamestnancov má metóda DEA niekoľko výhod. Ako uvádza Zbranek (2013), metóda DEA poskytuje komplexné skóre výkonnosti, ktoré umožňuje objektívne vyhodnotiť a porovnať

¹ Kupkovič et al. (2003, s. 211) v tejto súvislosti uvádza dve skupiny metód: metódy orientujúce sa na minulosť a metódy orientujúce sa na budúcnosť.

výkonnosť zamestnancov, berúc do úvahy nielen výstupy, ale aj vstupy, čím reaguje na očakávania zamestnancov na kvantifikáciu ich nedostatkov a prekonanie nevýhod tradičných systémov hodnotenia kvality. Z doterajších výskumov zameraných na uplatniteľnosť DEA pri hodnotení výkonnosti zamestnancov sú známe napríklad štúdie Lotfiho a Shirouyehzada (2010) a Shirouyehzada et al. (2012), ktorí využili DEA na hodnotenie výkonnosti 55 zamestnancov spoločnosti zaoberajúcej sa distribúciou. Ďalej Osman et al. (2011) použili metódu DEA na hodnotenie relatívnej výkonnosti 32 zdravotných sestier pracujúcich na jednotke intenzívnej starostlivosti v jednej z najuznávanejších nemocníc v Libanone. Tao (2012) navrhol skombinovať hodnotenie výsledkov pracovnej sily (Workforce Scorecard) s metódou DEA na hodnotenie výkonnosti zamestnancov na dvoch oddeleniach čínskej motorovej spoločnosti. Zbranek (2013) využijúc metódu DEA hodnotil výkonnosť 60 zamestnancov v pekárenskej spoločnosti.

Cieľom nášho príspevku je zhodnotiť výkonnosť 50 zamestnancov vybraného call centra v sledovanom mesiaci október 2017 využitím metódy DEA. Príspevok je štruktúrovaný nasledovne. Nasledujúca kapitola prezentuje analyzovanú množinu hodnotených zamestnancov so špecifikáciou uvažovaných vstupov a výstupov ich pracovnej činnosti. V tretej kapitole je uvedená metodika DEA uplatnená na skúmanú oblasť hodnotenia výkonnosti zamestnancov. Štvrtá kapitola prezentuje dosiahnuté výsledky a posledná kapitola sumarizuje a uzatvára príspevok.

2 Materiál

V príspevku bude snahou zhodnotiť výkonnosť 50 zamestnancov vybraného stredne veľkého call centra za mesiac október 2017. Operatívne zvládnutie činnosti zamestnancov call centra sa bude posudzovať s ohľadom na dve dimenzie hodnotenia: (i) *dimenzia náklady*: náklady uskutočnených hovorov a (ii) *dimenzia kvalita*: kvalita uskutočnených hovorov. *Dimenzia náklady* predstavuje nákladovosť uskutočnených hovorov jednotlivých zamestnancov a keďže pri potenciálnom zvyšovaní výkonnosti jednotlivých zamestnancov je prirodzené uvažovať o ich minimalizácii, v koncepcii DEA ich budeme považovať za vstupy. Na druhej strane, *dimenziu kvality* pokrývajúcu výsledok činnosti zamestnancov v podobe kvality uskutočnených hovorov budeme v DEA modelovaní považovať za výstupy. Pri posudzovaní nákladovosti (*dimenzia náklady*) využijeme dva ukazovatele: náklady na minútu hovoru (x_1) a náklady na kontakt (x_2) a pri posudzovaní kvality (*dimenzia kvalita*) využijeme štyri parciálne ukazovatele: spokojnosť zákazníka (y_1), kvalita hovoru (y_2), podiel rýchlo vybavených hovorov (y_3) a priemerná rýchlosť vybavenia (y_4). Bližší popis k jednotlivým ukazovateľom poskytuje Tab. 1.

Tab. 1: Uvažované vstupy a výstupy zamestnancov call centra (*Zdroj: vlastné spracovanie*)

Ukazovateľ		Merná jednotka	Náplň ukazovateľa
Vstupy			
x_1	Náklady na minútu hovoru	USD	Ukazovateľ vyjadruje priemerné náklady na minútu prichádzajúceho hovoru.
x_2	Náklady na kontakt	USD	Ukazovateľ vyjadruje priemerné náklady na jeden prichádzajúci hovor.
Výstupy			
y_1	Spokojnosť zákazníka	%	Ukazovateľ vyjadruje priemerné hodnotenie spokojnosti zákazníkmi (na škále 0 % [najhoršie] až 100 % [najlepšie])
y_2	Kvalita hovoru	%	Ukazovateľ vyjadruje priemerné hodnotenie kvality hovoru interným posudzovateľom (na škále 0 % [najhoršie] až 100 % [najlepšie])
y_3	Podiel rýchlo vybavených hovorov	%	Ukazovateľ udáva percento rýchlo vybavených dopytov volajúcich klientov do 30 sekúnd.
y_4	Priemerná rýchlosť vybavenia	sekundy	Ukazovateľ určuje priemernú rýchlosť vybavenia dopytu volajúceho klienta.

Je zrejmé, že v skupine výstupov nie je pri všetkých ukazovateľoch vhodné uvažovať, v rámci zvyšovania výkonnosti, o ich maximalizácii. Týka sa to ukazovateľa priemerná rýchlosť vybavenia (y_4), pri ktorom je vhodnejšie uvažovať o jeho minimalizácii. V koncepcii DEA sa jedná o problém tzv. nežiaduceho výstupu. Jednou z možností ako možno daný výstup zahrnúť do analýzy je transformácia pôvodného nežiaduceho výstupu vhodnou transformačnou procedúrou na žiaduci výstup, ktorý je potom možné prostredníctvom klasických DEA modelov maximalizovať. Už Koopmans (1951) navrhol transformáciu v zmysle pridania znamienka mínus pred nežiaduce výstupy a isté zdokonalenie tohto prístupu ponúkajú Seiford a Zhu (2002), ktorí dopĺňujú prístup Koopmansa (1951) nájdením vhodného translačného vektora, ktorý následne zabezpečí, aby záporné hodnoty nežiaducich výstupov nadobudli kladnú hodnotu. Podľa autorov je pri tejto transformácii zabezpečená tzv. klasifikačná invariancia (*Classification Invariance*), tzn. klasifikácia efektívnych a neefektívnych jednotiek je invariantná voči transformácii dát. V našej analýze aplikujeme prístup Seiforda a Zhua (2002) a pre každého zamestnanca ($i = 1, \dots, 50$) transformujeme pôvodnú hodnotu ukazovateľa y_{4i} v tvare:

$$y_{4i}^T = 200 - y_{4i}. \quad (1)$$

Keďže výsledkom klasických DEA modelov je identifikácia dodatočného zvýšenia žiaducich výstupov v snahe zvýšenia efektívnosti jednotky, v prípade transformovaného nežiaduceho výstupu v tvare (1) ide *de facto* o identifikáciu dodatočného zníženia nežiaduceho výstupu.

Nasledujúca Tab. 2 prezentuje súhrnnú štatistiku všetkých uvažovaných vstupov a výstupov. Kompletne vstupné dáta použité v príspevku sú dostupné u autora na požiadanie.

Tab. 2: Uvažované vstupy a výstupy zamestnancov call centra (*Zdroj: vlastné spracovanie*)

Ukazovateľ	Priemer	Medián	Smerodajná odchýlka	Min	Max
Vstupy					
x_1	2,95	3,24	1,39	0,50	5,48
x_2	6,58	5,25	4,90	0,75	23,96
Výstupy					
y_1	0,49	0,50	0,06	0,39	0,60
y_2	0,50	0,50	0,05	0,40	0,64
y_3	0,48	0,48	0,10	0,19	0,76
y_4	38,16	25,00	32,19	1,00	127,00

Z manažérskeho hľadiska je ďalej známe, že uvažované vstupy a výstupy nemajú rovnakú dôležitosť v rámci činnosti zamestnancov. Náklady na minútu hovoru (x_1) sú vnímané 1.5-krát závažnejšie ako náklady na celý kontakt (x_2), hodnotenie hovorov zákazníkom (y_1) a interným posudzovateľom (y_2) sú približne rovnako dôležité, podiel rýchlo zodpovedaných hovorov (y_3) a rýchlosť odpovede (y_4) sú taktiež približne rovnako dôležité a ukazovatele y_1 a y_2 majú asi 2-násobnú dôležitosť než druhé dva ukazovatele (y_3 a y_4). Na zohľadnenie odlišnej dôležitosti jednotlivých ukazovateľov zavedieme normalizované váhy relatívnej dôležitosti vstupov $\mathbf{w}^- = (w_1^-, w_2^-)$, ($w_1^- + w_2^- = 1$) a normalizované váhy relatívnej dôležitosti výstupov $\mathbf{w}^+ = (w_1^+, \dots, w_4^+)$, ($w_1^+ + \dots + w_4^+ = 1$). Dá sa jednoducho ukázať, že vyššie uvedené predpoklady zodpovedajú váham vstupov $\mathbf{w}^- = (0,6; 0,4)$ a váham výstupov $\mathbf{w}^+ = (0, \bar{3}; 0, \bar{3}; 0,1\bar{6}; 0,1\bar{6})$.

3 Metodika

Pri identifikácii najvhodnejšieho typu DEA modelu na oblasť merania výkonnosti zamestnancov je nutné vychádzať z troch kritérií klasifikácie DEA modelov. Z hľadiska prvého kritéria je nutné zvoliť buď radiálny prístup (ktorý uvažuje o radiálnom, resp. proporčnom charaktere uvažovaných premenných), alebo neradiálny prístup (ktorý uvažuje o neradiálnom, resp. neproporčnom

charaktere uvažovaných premenných). V našom prípade možno tvrdiť, že vzhľadom na prevládajúci neradiálny charakter uvažovaných premenných, predstavujú neradiálne modely vhodnejšiu a komplexnejšiu alternatívu oproti radiálnym modelom. Neradiálne modely navyše kvantifikujú silnú Paretovu-Koopmansovu technickú efektívnosť, zatiaľ čo radiálne modely kvantifikujú len slabú Farrellovu technickú efektívnosť. Radiálne modely zanedbávajú potenciálne dodatočné neproporcionálne zmeny vstupov a výstupov a nezahrňujú ich do konečnej miery efektívnosti. Z hľadiska druhého kritéria je nutné zvoliť predpoklad výnosov z rozsahu. V zásade možno zvoliť buď predpoklad konštantných výnosov z rozsahu (*Constant Returns to Scale – CRS*), alebo predpoklad variabilných výnosov z rozsahu (*Variable Returns to Scale – VRS*). Predpoklad CRS, ktorý je vo všeobecnosti prísnejší z hľadiska identifikácie efektívnych jednotiek v porovnaní s predpokladom VRS a je vhodný len vtedy, keď všetci zamestnanci pracujú na svojej optimálnej úrovni. V skutočnosti však niektoré faktory, ako je pracovná záťaž, stres a tlak, môžu zabrániť zamestnancom pracovať na ich optimálnej úrovni. Na elimináciu vplyvu tzv. neefektívnosti rozsahu (*scale inefficiency*) je v tomto prípade na účely merania efektívnosti vhodnejšie využiť predpoklad VRS. V našej analýze budeme uvažovať tak s predpokladom CRS, ako aj s predpokladom VRS, nakoľko našou snahou bude zhodnotiť a porovnať výkonnosť zamestnancov tak z dlhodobého hľadiska, ako aj z krátkodobého hľadiska. Tretie kritérium ďalej vyžaduje voľbu orientácie modelu, resp. voľbu stránky efektívnosti, ktorá má byť pomocou DEA kvantifikovaná. Naším zámerom je identifikovať všetky stránky efektívnosti zamestnancov. Z tohto dôvodu aplikujeme neorientovaný model, ktorý súčasne zohľadní tak vstupnú stránku efektívnosti, ako aj výstupnú stránku efektívnosti.

DEA model, ktorý umožňuje zohľadniť všetky vyššie spomenuté predpoklady je vážený SBM model Tonea (2001). Matematickú formuláciu váženého SBM modelu s predpokladom CRS (WSBM-C model) možno zostaviť nasledovne. Nech ľubovoľná jednotka o , $o \in \{1, \dots, n\}$ používa m vstupov vyjadrených vektorom $x_o = (x_{1o}, \dots, x_{mo})$ na dosiahnutie s výstupov vyjadrených vektorom $y_o = (y_{1o}, \dots, y_{so})$. Pre každú DMU o , sa rieši nasledujúca optimalizačná úloha

$$\min_{s^-, s^+, \lambda} \rho = \frac{1 - \frac{1}{m} \sum_{j=1}^m w_j^- \frac{s_j^-}{x_{jo}}}{1 + \frac{1}{s} \sum_{r=1}^s w_r^+ \frac{s_r^+}{y_{ro}}} \quad (2)$$

pri podmienkach

$$s_j^- = x_{jo} - \sum_{i=1}^n \lambda_i x_{ji}, j = 1, \dots, m,$$

$$s_r^+ = \sum_{i=1}^n \lambda_i y_{ri} - y_{ro}, r = 1, \dots, s,$$

$$\lambda_i, s_j^-, s_r^+ \geq 0 \quad i = 1, \dots, n, j = 1, \dots, m, r = 1, \dots, s.$$

V optimalizačnej úlohe (2) λ_i predstavuje váhu (*intensity variable*) spojenú s jednotkou i , w_j^- predstavuje normalizovanú váhu relatívnej dôležitosti vstupu j , w_r^+ predstavuje normalizovanú váhu relatívnej dôležitosti výstupu r , s_j^- predstavuje doplnkovú premennú (*sklz, slack*) pre vstup j a s_r^+ predstavuje doplnkovú premennú (*sklz, slack*) pre výstup r .

Optimalizačná úloha váženého SBM modelu s predpokladom VRS (WSBM-V model) nadobúda podobu (2) s pridaním dopĺňujúcej obmedzujúcej podmienky v tvare $\sum_{i=1}^n \lambda_i = 1$. Optimálne riešenie ρ^* oboch modelov predstavuje skóre efektívnosti (výkonnosti), ktoré pre efektívne jednotky nadobúda hodnotu 1 a pre neefektívne jednotky nadobúda hodnoty z intervalu (0,1).

4 Výsledky a diskusia

Na účely globálneho zhodnotenia výkonnosti zamestnancov call centra v dlhodobom horizonte sme v prvom kroku aplikovali WSBM-C model (2). Výsledky (pozri Tab. 3) ukázali, že z celkového počtu 50 zamestnancov len 5 zamestnancov dosahuje plnú výkonnosť (skóre výkonnosti sa rovnalo 1). Priemerné skóre výkonnosti na úrovni 0,41 znamená, že priemerný zamestnanec call centra dosahuje v priemere len 41 % výkonnosť najefektívnejšieho zamestnanca. Najmenej výkonný zamestnanec (Z9) dosahuje len 14 % výkonnosť tých najlepších zamestnancov.

Model WSBM-C poskytuje pre jednotlivých zamestnancov okrem samotného skóre výkonnosti i tzv. referenčnú množinu, (*Reference Set*) tzn. množinu takých zamestnancov ($\lambda_i^* > 0$), ktorí sú najvýkonnejší a ktorí pre daného zamestnanca predstavujú vzory z hľadiska dosahovanej výkonnosti. Ako prezentuje Tab. 3, zamestnanec Z30 je najčastejšie zaraďovaným zamestnancom do referenčných množín a považuje sa za vzor až pre 18 neefektívnych zamestnancov. Navyše, pre neefektívnych zamestnancov sa formulujú odporúčania na zvýšenie ich efektívnosti (*Projections*). Pre danú jednotku o sa formulujú odporúčania $\hat{x}_{jo}$ pre vstup j a odporúčania $\hat{y}_{ro}$ pre výstup r v tvare:

$$\hat{x}_{jo} = x_{jo} - s_j^{-*} \quad \text{a} \quad \hat{y}_{ro} = y_{ro} + s_r^{+*}, \quad (3)$$

kde s_j^{-*} a s_r^{+*} sú optimálne riešenia modelu (2). Vzhľadom na aditívny charakter transformácie nežiaduceho výstupu v tvare (1), odporúčania pre nežiaduci výstup $\hat{y}_{4o}$ sú formulované v tvare $\hat{y}_{4o} = y_{4o} - s_4^{+*}$.

Tab. 3: Výsledky WSBM-C modelu (*Zdroj: vlastné spracovanie*)

ID zamestnanca	Skóre	Poradie	Referenčná množina	ID zamestnanca	Skóre	Poradie	Referenčná množina
Z1	0,44	17	Z18	Z26	0,43	19	Z40
Z2	0,36	21	Z30	Z27	0,24	41	Z30
Z3	0,21	46	Z18	Z28	0,26	38	Z40
Z4	0,65	6	Z6, Z18	Z29	0,32	26	Z30
Z5	0,63	7	Z40	Z30	1	1	Z30
Z6	1	1	Z6	Z31	0,21	44	Z40
Z7	0,30	32	Z30	Z32	0,29	33	Z30
Z8	0,33	24	Z30	Z33	0,34	22	Z30
Z9	0,14	50	Z18	Z34	0,43	18	Z30
Z10	0,31	31	Z18	Z35	0,33	23	Z30
Z11	0,44	16	Z40	Z36	0,27	36	Z18
Z12	1	1	Z12	Z37	0,49	13	Z40
Z13	0,32	28	Z18	Z38	0,23	42	Z30
Z14	0,60	8	Z18	Z39	0,21	45	Z40
Z15	0,58	10	Z30	Z40	1	1	Z40
Z16	0,26	39	Z40	Z41	0,48	14	Z18
Z17	0,50	12	Z18	Z42	0,54	11	Z40
Z18	1	1	Z18	Z43	0,24	40	Z40
Z19	0,21	47	Z18	Z44	0,19	48	Z40
Z20	0,32	27	Z30	Z45	0,23	43	Z40
Z21	0,27	35	Z30	Z46	0,31	30	Z30
Z22	0,19	49	Z40	Z47	0,59	9	Z18
Z23	0,32	25	Z30	Z48	0,31	29	Z30
Z24	0,27	37	Z40	Z49	0,47	15	Z30
Z25	0,28	34	Z40	Z50	0,38	20	Z30

Nasledujúca Tab. 4 prezentuje odporúčania pre zamestnanca Z31. Ako je zrejmé, najvýznamnejšie zmeny je potrebné uskutočniť na strane vstupov (potrebné takmer 80 % zníženie pri oboch vstupoch). Z toho možno konštatovať, že hlavnou slabou stránkou daného zamestnanca je vstupná stránka efektívnosti, tzn. že vzhľadom na dosahovanú kvalitu výkonov zamestnanca sú náklady na jeho činnosť pomerne vysoké.

Keďže model WSBM-C je neorientovaný model, ktorý súčasne zohľadňuje vstupnú i výstupnú stránku efektívnosti a navyše vychádza z predpokladu CRS, je pomerne prísny z hľadiska identifikácie efektívnych zamestnancov. Na jeho výsledky preto možno nazerať ako na celkovú výkonnosť zamestnancov v dlhodobom horizonte.

Tab. 4: Odporúčenia WSBM-C modelu pre zamestnanca Z31 (Zdroj: *vlastné spracovanie*)

Vstup/výstup		Merná jednotka	Skutočná hodnota	Odporúčaná hodnota	Rozdiel	Rozdiel v %
x_1	Náklady na minútu hovoru	USD	3,7	0,87	-2,83	-76,52
x_2	Náklady na kontakt	USD	8,41	1,73	-6,68	-79,44
y_1	Spokojnosť zákazníka	%	43,30	47,66	4,36	10,08
y_2	Kvalita hovoru	%	46,20	46,20	0	0
y_3	Podiel rýchlo vybavených hovorov	%	35,90	36,65	0,75	2,09
y_4	Priemerná rýchlosť vybavenia	sekundy	52,00	49,44	-2,56	-4,92


Predpoklad CRS predpokladá, že všetci zamestnanci pracujú na svojej optimálnej úrovni, čo však v krátkodobom horizonte nemusí byť vzhľadom na vplyv vonkajších faktorov ako pracovná záťaž, stres a tlak, vždy možné. Na zohľadnenie vplyvu vyššie spomenutých vonkajších faktorov sme v ďalšom kroku aplikovali WSBM-V model. Opisná štatistika výsledkov oboch použitých modelov prezentuje Tab. 5.

Tab. 5: Súhrnné výsledky použitých DEA modelov (Zdroj: *vlastné spracovanie*)

	Priemer	Medián	Min	Smerodajná odchýlka	Počet efektívnych DMUs
WSBM-C model	0,41	0,32	0,14	0,233	5
WSBM-V model	0,54	0,41	0,14	0,310	14

Oproti modelu WSBM-C, ktorý identifikoval len 5 efektívnych zamestnancov, model WSBM-V, ktorý zohľadňuje vplyv vonkajších krátkodobých faktorov pri meraní výkonnosti, identifikoval 14 efektívnych zamestnancov. Spoločné výsledky aplikovaných modelov (WSBM-C a WSBM-V) by mohli manažérom poskytnúť ďalšie veľmi užitočné informácie. Na tento účel je potrebné pri oboch modeloch stanoviť tzn. prahovú hodnotu (*threshold value*) pre skóre výkonnosti, ktorá by oddeľovala zamestnancov s nízkou výkonnosťou (so skóre nižším než prahová hodnota) od tých s vysokou výkonnosťou (so skóre vyšším ako prahová hodnota). V našom prípade sme zvolili rovnakú prahovú hodnotu pre oba modely na úrovni 0.5. Obr. 1 ilustruje zaradenie zamestnancov podľa ich

dosahovanej výkonnosti do troch skupín podobných tým, ktoré boli pozorované v matici BCG (bližšie pozri Hedley, 1976)²: *Hviezdy*, *Psi* a *Otázniky*.



Obr. 1: Rozdelenie zamestnancov call centra na základe ich DEA výkonnosti: CRS vs. VRS prístup (Zdroj: Vlastné spracovanie)

Skupina *Hviezdy* je tvorená zamestnancami, ktorí dosahujú relatívne vysokú výkonnosť tak v krátkodobom horizonte (skóre WSBM-V nad 0.5), ako aj v dlhodobom horizonte (skóre WSBM-C nad 0.5). Táto skupina je hnacím motorom call centra a mala by byť motivovaná k tomu, aby si udržala svoju vynikajúcu operačnú efektívnosť tým, že im manažment poskytne väčšiu zodpovednosť a kontrolu nad ich prácou. Skupina *Psi* je tvorená zamestnancami, ktorí dosahujú relatívne nízku výkonnosť tak v krátkodobom, ako aj v dlhodobom horizonte (skóre oboch modelov pod 0.5). Ich výkonnosť je neuspokojivá a je na manažmente, aby sa rozhodol či má zmysel daných zamestnancov ďalej motivovať k lepším výkonom, alebo radšej uvažovať o ich prepustení. A nakoniec skupina *Otázniky* je tvorená tými zamestnancami, ktorí dosahujú relatívne vysokú výkonnosť v krátkodobom horizonte (skóre WSBM-V nad 0.5), no ich výkonnosť z dlhodobého hľadiska je pomerne nízka (skóre WSBM-C pod 0.5). Dôvodom, ktorý mohol spôsobiť ich neefektívnosť v dlhodobom horizonte by mohlo byť práve pôsobenie krátkodobých vonkajších faktorov, ako pracovný stres a vyčerpanie, či momentálna (zdravotná alebo sociálna) indispozícia. To, či ide skutočne len o krátkodobé odchýlky ich výkonnosti by bolo potrebné

² Keďže platí, že $\rho_{\text{WSBM-C}}^* \leq \rho_{\text{WSBM-V}}^*$ a uvažujeme rovnakú prahovú hodnotu pre oba modely (0.5), do pravého dolného kvadrantu nemôže byť zaradená žiadna jednotka. Do daného kvadrantu by mohli byť zaradené jednotky len v tom prípade, keby prahová hodnota pre WSBM-C model bola nižšia ako prahová hodnota pre WSBM-V model.

hodnotiť v časovom slede, kde by sa sledovala ich výkonnosť za niekoľko časových období. Tu by sa ukázalo, či títo zamestnanci majú tendenciu sa zaradiť do skupiny *Hviezdy* alebo skôr do skupiny *Psi*.

5 Záver

Cieľom tohto príspevku bolo zhodnotiť výkonnosť 50 zamestnancov vybraného call centra v sledovanom mesiaci október 2017 aplikáciou metódy DEA. Na tomto empirickom príklade bolo ukázané ako je potrebné postupovať pri výbere vhodného DEA modelu vzhľadom na uvažovanú skupinu hodnotených zamestnancov, ako aj uvažovanú skupinu vstupov a výstupov charakterizujúcu činnosť hodnotených zamestnancov. Na účely merania výkonnosti zamestnancov call centra boli postupne aplikované dva neorientované DEA modely (WSBM-C model a WSBM-V model). Na základe výsledkov týchto dvoch modelov bolo následne uskutočnené zoskupenie daných zamestnancov do troch skupín podľa dosahovanej výkonnosti. Takto prezentované výsledky DEA modelov ponúkajú dobrú diskrimináciu medzi výkonnosťou hodnotených zamestnancov a môžu poskytnúť manažérom podnikov flexibilný nástroj na hodnotenie výkonnosti svojich zamestnancov. Analýza výkonnosti uskutočnená v tomto príspevku demonštruje, že metódu DEA možno použiť ako účinný nástroj na meranie a hodnotenie výkonnosti zamestnancov.

Ďalšie užitočné informácie by bolo možné získať porovnaním výsledkov vstupne a výstupne orientovaného modelov. Na náklade ich výsledkov by potom bolo možné detailnejšie zhodnotiť silné a slabé stránky jednotlivých zamestnancov, ako aj identifikovať skupiny zamestnancov, na ktorých možno aplikovať rovnakú formu personálnej politiky. Kým vstupne orientovaný model by odhalil vstupnú stránku efektívnosti (tzn. za efektívnych zamestnancov by vyhodnotil tých, ktorí majú vzhľadom na dosiahnutú kvalitu relatívne nízku nákladovosť), výstupne orientovaný model by odhalil výstupnú stránku efektívnosti (tzn. za efektívnych zamestnancov by vyhodnotil tých, ktorí dosahujú vzhľadom na dané náklady relatívne vysokú kvalitu).

Na záver je potrebné poznamenať, že zmysel hodnotenia zamestnancov je prirodzene podmienený splnením predpokladu, aby hodnotenie prinieslo konkrétne závery, tzn. slúžilo ako prostriedok, nie ako cieľ. Výsledky hodnotenia je potrebné so zamestnancami prekonzultovať a zdokumentovať, aby sa mohli stať základom pre ďalšie personálne rozhodnutia. Ide najmä o sféru efektívneho rozmiestňovania zamestnancov, o sféru odmeňovania najvýkonnejších zamestnancov napríklad formou kariérneho a platového postupu alebo o sféru uvoľňovania a motivácie najmenej výkonných zamestnancov.

6 Literatúra

- Farrell, M.J. (1957). The Measurement of Productive Efficiency. *Journal of the Royal Statistical Society, Series A*, 120, Part III, 253-281.
- Hedley, B. (1976). A Fundamental Approach to Strategy Development. *Long Range Plann* 9(6), 2-11.
- Koopmans, T. (1951). An analysis of production as an efficient combination of activities. T.Koopmans (ed.), *Activity analysis of production and allocation*. New York: John Wiley and Sons, Inc.
- Kupkovič, M., et al. (2003). *Podnikové hospodárstvo*. Bratislava: Sprint v.fra, 2003, 955 p.
- Lesáková, Ľ. (2004). *Metódy hodnotenia výkonnosti malých a stredných podnikov*. Banská Bystrica: Univerzita Mateja Bela, Ekonomická fakulta, 2004. 124 p.
- Lotfi, F.H., Shirouyezhad, H. (2010). Analyzing Efficiency of Human Resource Performance Using Data Envelopment Analysis. 1.st Conference on executive MBA, 2010, 12.
- Osman, I.H., Barbary, L. N., Sidani, Y., Al-Ayoubi, B., Emrouznejad, A. (2011). Data Envelopment Analysis Model for the Appraisal and Relative Performance Evaluation of Nurses at an Intensive Care Unit. *Journal of Medical Systems*, 35, 1039-1062.
- Seiford, L.M., Zhu, J. (2002). Modeling undesirable factors in efficiency evaluation. *European Journal of Operational Research*, 142, 16-20.
- Shirouyehzad, H., Lotfi, F.H., Aryanezhad, M.B., Dabestani, R. (2012). A Data Envelopment Analysis Approach for Measuring the Efficiency of Employees: A case study. *South African Journal of Industrial Engineering*, 23(1), 191-201.
- Tone, K. (2001). A slacks-based measure of efficiency in data envelopment analysis. *European Journal of Operational Research*, 130, 498-509.
- Tao, G. (2012) Multi-Department Employee Performance Evaluation Based on DEA Cross Efficiency. *Journal of Emerging Trends in Economics and Management Sciences*, 3(5), 553-558.
- Zbranek, P. (2013). Data Envelopment Analysis as a toll for Evaluation of Employees' Performance. *Acta Oeconomica et Informatica*, 16 (1), 12-21.

7 Poďakovanie

Tento príspevok publikuje čiastočné výsledky riešenia projektu VEGA [1/0843/18 Metodologické aspekty aplikácie DEA na hodnotenie efektívnosti produkčných jednotiek.]

Model pre predpovedanie kríz na základe postupu pri makroekonomických nerovnováhach v podmienkach Slovenska

A model for predicting crises on the basis of the macroeconomic imbalance procedure in the conditions of Slovakia

Filip Ostrihoň

Ekonomický ústav Slovenskej akadémie vied, Šancová 56, Bratislava, Slovenská republika
Institute of Economic Research of the Slovak Academy of Sciences, Šancová 56, Bratislava, Slovak Republic
filip.ostrihon@savba.sk

Abstrakt: V rámci príspevku je replikovaná predchádzajúca analýza hodnotiacej tabuľky PMN na prípade jednej krajiny, Slovenska, s využitím štvrťročných údajov opisujúcich obdobie 2007:Q1-2014:Q3. Vzhľadom k nízkemu počtu pozorovaní a vysokému počtu vysvetľujúcich premenných je dôraz venovaný procesu bootstrapu ako aj jeho citlivosti na použité nastavenia. Na základe získaných výsledkov sa v prípade Slovenska javí miera aktivity ako najspoľahlivejší hlavný ukazovateľ s mierou nezamestnanosti a tokom úverov do súkromného sektora ako ďalšími doplňujúcimi ukazovateľmi, ktoré však môžu byť nadmerne zamerané na aktuálnu fázu hospodárskeho cyklu.

Abstract: The paper replicates previous research on the MIP Scoreboard on the case of a single country, Slovakia, using quarterly data for period 2007:Q1 – 2014:Q3. Given the low number of observations and high number of explanatory variables, the emphasis of the analysis is given to bootstrapping procedure as well as its sensitivity to used settings. Based on the obtained results, the activity rate appears to be the most reliable headline indicator in the case of Slovakia, followed by unemployment rate and private sector credit flow which may be overly focused on the current phase of the business cycle.

Kľúčové slová: hodnotiaci tabuľka PMN, systém včasného varovania, lineárny pravdepodobnostný model, blokový bootstrap

Key words: MIP scoreboard, early warning system, linear probability model, block bootstrap

1 Introduction

In the December of 2011 the European Commission has instituted a new mechanism for macroeconomic surveillance and coordination designated as the Macroeconomic Imbalance Procedure (MIP), as part of the six-pack legislation (Domonkos et al. 2017). The procedure is composed of two distinct parts: the preventive arm and the corrective arm. Under the preventive arm the so-called Alert Mechanism Report (AMR) is published each year, which initiates the entire procedure. Since its main function is to reveal possible threats which may jeopardize the functioning of individual members states as well as possibly of the

entire European Union (EU), it may be viewed as a form of early warning system (EWS).

As such, the main component of the AMR named MIP Scoreboard has been investigated by researchers for its properties as an EWS. Among the first endeavors in this direction was the analysis of Cortos and Szalai (2013), who utilized signals approach to test the properties of individual indicators of the MIP Scoreboard as early warning indicators (EWI) for periods when output gap falls below -2 percent. The procedure was also examined by Boysen-Hogrofe et al. (2015) who apart from investigating the predictive performance of individual indicators also elaborated on the effect of the MIP Scoreboard's results on the decision-making process carried out as part of the corrective arm of the MIP.

Another step in this vein of research was the analysis of Domonkos et al. (2017) who employed logit and linear probability model framework to evaluate predictive capabilities of MIP Scoreboard as a single EWS in relation to the drop in output gap already used by Cortos and Szalai (2013). The examination of individual indicators of the MIP Scoreboard was further expanded by Širaňová and Radvanský (2017), who additionally to evaluating the performance of headline and auxiliary MIP indicators in the context of Central and Eastern European Countries as EWI also computed the optimal indicator thresholds with respect to policy-maker's utility maximization.

Presented analysis builds on previous results of Domonkos et al. (2017), by replicating the linear probability model on the foundation of annual data for EU using quarterly data for Slovakia during the period 2007:Q1-2014:Q3. As the observed period is considerably short, extensive part of the paper is dedicated to verification of obtained results via resampling using non-parametric bootstrap as well as its block extension. By doing so, the paper elucidates on how EU-wide results translate to the context of a single member state, i.e. Slovakia, apart from providing country-specific implications.

Subsequent parts of the paper are structured as follows. Section 2 sketches a brief description of the MIP Scoreboard as well as the possibilities how to translate it to level of Slovak data with quarterly frequency. Section 3 details models used, potential issue with high degree of multicollinearity, as well as the bootstrapping procedure and the sensitivity analysis. Section 4 presents the results of the analysis for one, two, and three year time horizon. Section 5 concludes by addressing some of the open issues in regard to the research as well as possible implications of obtained results.

2 MIP on National Level

2.1 The MIP Scoreboard

The most recent issue of the AMR (European Commission, 2018) presents MIP Scoreboard featuring 14 headline indicators. These are further complemented by additional 28 auxiliary indicators, which serve a rather supportive role. As such the auxiliary indicators do not have set thresholds, and are aimed solely to provide further information during the economic reading of the headline indicators. Given their role in the entire procedure, the focus of the paper will be only on the headline indicators as their levels are thoroughly examined during each round of the MIP.

Tab. 1 Headline indicators of the MIP Scoreboard (*Source: European Commission, 2018; Outline based on Domonkos et al., 2017*)

Indicator	Abbreviation	Description and details	Thresholds
External imbalances and competitiveness			
Current account balance	CA	% of GDP, 3 year average	-4/6%
Net international investment position	NIIP	% of GDP	-35%
Real effective exchange rate	REER	42 trading partners, HICP deflator, 3 year % change	±5% (EA) ±11% (Non-EA)
Export market share	EMS	% of world exports, 5 year % change	-6%
Nominal unit labor cost index	NULC	2010=100, 3 year % change	9% (EA) 12% (Non-EA)
Internal imbalances			
House price index	HPI	2015=100, deflated, 1 year % change	6%
Private sector credit flow	PSDF	consolidated, % of GDP	14%
Private sector debt	PSD	consolidated, % of GDP	133%
General government gross debt	GGD	% of GDP	60%
Unemployment rate	UR	3 year average	10%
Total financial sector liabilities	TFSL	non-consolidated, 1 year % change	16.5%
Employment indicators			
Activity rate	AR	% of total population aged 15-64, 3 year change in pp	-0.2 pp
Long-term unemployment rate	LTUR	% of active population aged 15-74, 3 year change in pp	0.5 pp
Youth unemployment rate	YUR	% of active population aged 15-24, (3 year change in pp	2 pp

2.2 Available Quarterly Data for Slovakia

In order to expand available sample for Slovakia, the analysis was conducted on data with quarterly frequency. Hence, also the time horizon used for averaging as well as computation of annual changes of headline indicators were translated to corresponding number of quarters. The headline indicators were in some cases available from the Eurostat (2018a) database, such as in case of Current account balance, Net international investment position, Nominal unit labor costs, House price index, General government gross debt, and Unemployment rate. The indicators of private sector credit flow, private sector debt, and total financial sector liabilities were obtained from Financial balance sheets of Quarterly sectoral accounts (ESA 2010) database available at Eurostat (2018b). The activity rate, long-term unemployment rate, youth unemployment rate as well as the output gap estimates for Slovakia were gathered from the Macroeconomic database of the National Bank of Slovakia (NBS, 2018).

Unfortunately, not all of the indicators were available in the identical specification as their counterparts in the MIP. Therefore, some indicators on quarterly basis were proxied by other series to match the setting of the MIP Scoreboard as much as possible. Real effective exchange rate was obtained from Macroeconomic database of the National Bank of Slovakia (2018), for 15 partners and use of NULC as deflators instead of 42 partners and HICP deflators and the export market shares were compiled using available IMF (2018) data for Balance of Payments and International investment position Statistics (BOP/IIP).

The observations for each of the 14 headline indicators intersect for the period 2007Q1-2014Q3, providing sample of 31 quarterly observations which was used for the analysis.

3 Methodology

3.1 Linear Probability Model and Multicollinearity Issue

As stated in section 1, the paper aims to replicate the analysis of Domonkos et al. (2017) using only data for Slovakia. However, the relatively short sample of 31 observations appears to be too restrictive for application of the maximum likelihood estimation method used for the estimation of probit models by Domonkos et al. (2017), especially for models containing 14 explanatory variables and a constant. Hence, only parts of the original analysis which relied on linear probability models (LPMs) was replicated.

Similarly to Domonkos et al. (2017), LPMs containing all of the headline indicators as explanatory variables were estimated using ordinary least squares method, based on following specification:

$$y_t = \beta_0 + \beta_1 AR_{t-j} + \beta_2 LTUR_{t-j} + \beta_3 YUR_{t-j} + \beta_4 EMS_{t-j} + \beta_5 PSD_{t-j} + \beta_6 UR_{t-j} + \beta_7 GGD_{t-j} + \beta_8 NIIP_{t-j} + \beta_9 REER_{t-j} + \beta_{10} CA_{t-j} + \beta_{11} NULC_{t-j} + \beta_{12} PSCF_{t-j} + \beta_{13} TFSL_{t-j} + \beta_{14} HPI_{t-j}. \quad (1)$$

As in the case of previously mentioned analysis, estimated parameters β_1 - β_{14} in equation (1) should approximate the average marginal effects of each of the headline indicators. Subscript $t-j$ indicates that multiple time horizons of prediction were examined. Following the example of Domonkos et al. (2017), time horizon of one, two, and three years was used, which translated into $j = 4, 8, \text{ and } 12$ quarters, respectively. Likewise the dependent variable y was computed in line with the approach used by Domonkos et al. (2017), thus, it obtains value 1 when output gap is below -2 percent and 0 otherwise.

As part of following the approach of Domonkos et al. (2017), the issue of multicollinearity was handled in similar manner. However, this was not extended to the factor analysis conducted by previous authors due to low number of observations. Nevertheless, the approach of omitting specific indicators with relatively high pair-wise correlation, which is later referred to as adjusted model, was carried out.

In these adjusted models, the indicators for which the pair-wise coefficient of correlation was in absolute value higher than $\rho=0.5$ with the indicator of interest, were omitted from the specification to obtain average marginal effect potentially less affected by high degree of multicollinearity. The table containing these models provides result of different estimation for each indicator examined. Computed correlation matrix for quarterly data of Slovakia (Tab. 2) is, however, rather different from the correlation matrix for annual data of the EU28 presented by Domonkos et al. (2017).

3.2 Bootstrapping Procedure

Given the low number of available observations for the analysis, invoking law of large numbers as well as asymptotic properties of estimators seem inappropriate. Therefore, a bootstrapping approach was employed to investigate the sensitivity of obtained results to selection of relatively short period via the means of bootstrapped parameters. As suggested by Greene (2012), number of bootstraps was set to 1000, for each bootstrapping procedure performed. Additionally, the procedure provides estimates of the standard errors based on the resampled series, which may give additional insight into the reliability of the standard errors based on the limited sample.

As one of the key assumptions for the application of bootstrap, the independence of observation, is most likely violated in quarterly data, the initial results of bootstrapping procedure were complemented by block bootstrap variant. These were conducted for an interval of block lengths ranging from 2 to 15 observations to illustrate how do the results of block bootstrap change with the increasing block length.

This however does not circumvent the issue of observing relatively short period of time, which can be affected by extraordinary development present only in the observed sample. To address this issue, to a certain degree, each bootstrap was performed in total 10 times with different set of random numbers, as a sensitive analysis. Such approach aims to investigate how robust are the results in regard to potential over-selection of extraordinary observations in specific bootstrap.

Tab. 2 Correlation matrix for headline indicators of the MIP Scoreboard based on Slovak data
(Source: Domonkos et al., 2017, the author)

Ind.	YUR	LTUR	UR	NIIP	EMS	NULC	TFSL	HPI	CA	REER	GGD	PSD	PSCF	AR
YUR	1.00													
LTUR	0.78	1.00												
UR	0.79	0.87	1.00											
NIIP	-0.70	-0.52	-0.67	1.00										
EMS	-0.75	-0.67	-0.71	0.84	1.00									
NULC	0.03	-0.44	-0.23	-0.05	0.10	1.00								
TFSL	-0.05	0.00	0.19	-0.12	-0.17	-0.16	1.00							
HPI	-0.67	-0.43	-0.50	0.82	0.89	-0.11	-0.09	1.00						
CA	0.12	0.46	0.52	-0.36	-0.43	-0.38	0.38	-0.30	1.00					
REER	-0.34	-0.83	-0.65	0.25	0.45	0.75	-0.12	0.16	-0.62	1.00				
GGD	0.39	0.78	0.75	-0.53	-0.68	-0.58	0.15	-0.40	0.73	-0.88	1.00			
PSD	0.64	0.69	0.72	-0.82	-0.92	-0.29	0.12	-0.74	0.49	-0.59	0.80	1.00		
PSCF	-0.77	-0.78	-0.93	0.65	0.76	0.19	-0.29	0.59	-0.51	0.57	-0.70	-0.68	1.00	
AR	0.33	0.37	0.42	-0.42	-0.69	-0.24	0.24	-0.52	0.49	-0.42	0.57	0.72	-0.43	1.00

Note: Pair-wise correlation coefficients between MIP indicators based on quarterly data for Slovakia are presented as entries. Instances when correlation coefficient was in absolute value higher than 0.5 are highlighted in grey. Positions of elements with value higher than 0.5 in the paper of Domonkos et al. (2017) are highlighted with font in bolts and italics.

4 Results

The results of the estimated models with one year horizon as well as of performed bootstrapping procedure (Tab. 3) show that the previously obtained model for EU28 published by Domonkos et al. (2017) are quite different from their Slovak counterparts. Specifically, the baseline models [1] and [3] are in the direction of the effect similar only for first five parameters (namely for indicators YUR, LTUR, UR, NIIP, and EMS). This may be caused by previously described differences in indicators, change from annual to quarterly frequency, or by closing the scope from EU28 to a single country - Slovakia.

Tab. 3 LPM models for drop in output gap in one year horizon (*Sources: models [1]-[2] Domonkos et al., 2017; models [3]-[9] the author*)

	EU	EU-A	SK	SK B(1)	SK B(2)	SK B(3)	SK B(4)	SK-A B	SK-A* B
Indic.	[1]	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]
YUR	-0.011	0.012**	-0.001	-0.001	-0.001	-0.001	-0.001	0.002	-0.002
	(0.323)	(0.041)	(0.042)	(0.118)	(0.299)	(1.789)	(2.894)	(0.109)	(0.029)
LTUR	0.068*	0.023	0.006	0.006	0.006	0.006	0.006	-0.011	-0.086
	(0.057)	(0.118)	(0.164)	(0.374)	(2.06)	(7.394)	(12.451)	(0.213)	(0.098)
UR	-0.014	0.007	-0.014	-0.014	-0.014	-0.014	-0.014	-0.011	-0.189**
	(0.409)	(0.488)	(0.194)	(0.717)	(4.312)	(6.699)	(11.433)	(0.543)	(0.075)
NIIP	-0.001	-0.001	-0.002	-0.002	-0.002	-0.002	-0.002	0.022	0.036
	(0.414)	(0.252)	(0.057)	(0.177)	(0.985)	(1.749)	(2.909)	(0.147)	(0.045)
EMS	-0.001	-0.001	-0.016**	-0.016	-0.016	-0.016	-0.016	-0.010	-0.002
	(0.718)	(0.731)	(0.007)	(0.026)	(0.029)	(0.429)	(0.665)	(0.016)	(0.012)
NULC	0.005	0.000	-0.035	-0.035	-0.035	-0.035	-0.035	-0.003	0.007
	(0.336)	(0.962)	(0.027)	(0.073)	(0.492)	(0.716)	(1.095)	(0.065)	(0.025)
TFSL	0.002	-0.007**	-0.012	-0.012	-0.012	-0.012	-0.012	-0.009	
	(0.479)	(0.039)	(0.017)	(0.042)	(0.326)	(1.31)	(2.199)	(0.734)	
HPI	-	-	0.007	0.007	0.007	0.007	0.007	0.003	-0.023
	0.021***	0.019***							
CA	(0.000)	(0.000)	(0.015)	(0.061)	(0.134)	(1.118)	(1.887)	(0.050)	(0.025)
	-0.005	-0.013	0.045	0.045	0.045	0.045	0.045	0.045	-0.016
REER	(0.638)	(0.120)	(0.027)	(0.118)	(0.086)	(0.835)	(1.429)	(0.587)	(0.049)
	0.001		-0.016	-0.016	-0.016	-0.016	-0.016		0.009
GGD	(0.937)		(0.021)	(0.048)	(0.137)	(0.478)	(0.803)		(0.020)
	0.000	0.001	-0.054	-0.054	-0.054	-0.054	-0.054	-0.021	-0.019
PSD	(0.781)	(0.683)	(0.037)	(0.125)	(0.249)	(0.638)	(0.902)	(0.514)	(0.036)
	0.002***		-0.064	-0.064	-0.064	-0.064	-0.064		-0.011
PSCF	(0.004)		(0.047)	(0.191)	(0.314)	(0.866)	(1.36)		(0.035)
	-		0.303	0.303	0.303	0.303	0.303		0.221**
AR	0.004***								
	(0.000)		(0.204)	(0.699)	(2.74)	(4.126)	(6.289)		(0.093)
N. Ob.	-0.056*		0.138	0.138	0.138	0.138	0.138		0.212
	(0.062)		(0.182)	(0.648)	(1.161)	(9.44)	(16.286)		(0.270)
R ²	213	213	31	31	31	31	31	31	31
CPR	0.389		0.785						
N. Boot.	0.798		0.968						
Block length	-	-	-	1000	1000	1000	1000	1000	1000
	-	-	-	1	5	10	15	5	5

Note: Tab 3. presents results of baseline (EU) and adjusted (EU-A) model estimated by Domonkos et al. (2017), as well as baseline model for the case of Slovakia (SK) with its four different bootstraps of standard errors (SK B(1)-SK B(4)) varying with the block length. Additionally, the adjusted models for original (SK-A) as well as computed (SK-A*) correlation matrix with block bootstrap of standard errors are provided. Standard errors of parameters are presented in parenthesis. Descriptive statistics for each model include number of observations (N. Ob.), coefficient of determination (R^2), correct prediction rate (CPR), number of bootstraps (N. Boot.), and block length.

It appears that ordinary least squares estimates for Slovakia [3] provide parameter statistically significant at 5 percent significance level for indicator of export market share (EMS). However, as this result is burdened by small sample size with addition to expected serial correlation more weight will be given to the

outcomes of bootstrapping procedure (columns [4]-[7]). These unambiguously show that all of the parameters are statistically insignificant. With standard errors of parameters almost monotonously increasing with number of quarters used in the block bootstrap for each parameter, it is highly likely that none of the indicators has a predictive power in a joint model once the autocorrelation has been accounted for.

As in the case of previous research of Domonkos et al. (2017), the insignificance of parameters may be caused by high degree of multicollinearity, considering that the model is composed of 14 considerably related indicators. An attempt to address this issue is presented in column [8] and [9] (Tab. 3).

Column [8] contains results of different regression for each parameter estimated, which included only those indicators which had in absolute value lower pair-wise correlation with variable of interest than 0.5, according to the correlation matrix computed by Domonkos et al. (2017). As the outcome of such approach may be affected by different covariance structure at the level of quarterly data for Slovakia than at the EU level using annual data, similar approach was also used for obtaining parameters in column [9] for the correlation matrix presented in Tab. 2.

Notable changes in the sign of the parameters are apparent for indicators of nominal unit labor cost, and house price index, which are now in line with the estimates of Domonkos et al. (2017). Nevertheless, these as well as others are statistically insignificant, which does not lend much support to them having predictive capabilities in case of Slovakia. Only exceptions are the indicators of unemployment rate and private sector credit flow. However, these exceptions are fairly robust as additional bootstrap means for both parameters are even higher in absolute value than the sample estimates and statistically significant results at 10 percent significance level appear regardless of block length.

Under the assumption that such strong average effects on probability of output gap fall are reasonable, one can hypothesize the channel through which the unemployment rate and private sector credit flow relates to the output gap. A possible explanation for unemployment rate may be that it indicates the current phase of business cycle, for which low unemployment rate may be a sign of expansion as well as an indicator of impending depression. In regard to private sector credit flow, it is possible to devise an argument based on the reasoning in Domonkos et al. (2017), that upsurge in domestic credit is a token of economic boom, one which will inevitably lead to bust.

In case of results for two year horizon (Tab. 4) the similarities between annual EU model [1] and quarterly Slovak model [3] are greater than for the one year horizon (Tab. 3) as estimated parameters for less than a half of indicators differ

in sign (namely indicators LTUR, NIIP, HPI, REER, PSD, and PSCF). Nevertheless, all of the estimated parameters in quarterly Slovak model [3] are statistically insignificant at 10 percent significance level. Additionally, the standard error for each parameter is growing larger with increasing number of quarters used in bootstrap blocks (columns [4]-[7]).

Tab. 4 LPM models for drop in output gap in two year horizon (*Sources: models [1]-[2] Domonkos et al., 2017; models [3]-[9] the author*)

	EU	EU-A	SK	SK B(1)	SK B(2)	SK B(3)	SK B(4)	SK-A B	SK-A* B
Indic.	[1]	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]
YUR	0.001	0.011*	0.072	0.072	0.072	0.072	0.072	0.060	-0.005
	(0.953)	(0.085)	(0.045)	(0.089)	(0.234)	(1.438)	(2.396)	(0.290)	(0.035)
LTUR	0.034	0.005	-0.081	-0.081	-0.081	-0.081	-0.081	0.063	0.036
	(0.384)	(0.745)	(0.173)	(0.331)	(1.777)	(6.102)	(10.355)	(0.196)	(0.072)
UR	-0.024	-0.007	-0.212	-0.212	-0.212	-0.212	-0.212	-0.257	-0.021
	(0.267)	(0.658)	(0.205)	(0.417)	(3.895)	(5.523)	(9.481)	(0.662)	(0.112)
NIIP	-0.002	-0.002*	0.030	0.030	0.030	0.030	0.030	-0.007	0.053
	(0.350)	(0.095)	(0.06)	(0.142)	(0.864)	(1.420)	(2.403)	(0.113)	(0.046)
EMS	0.001	0.011*	0.006	0.006	0.006	0.006	0.006	0.001	0.006
	(0.953)	(0.085)	(0.008)	(0.018)	(0.030)	(0.377)	(0.573)	(0.018)	(0.008)
NULC	0.008	0.003	0.020	0.020	0.020	0.020	0.020	0.005	0.007
	(0.160)	(0.599)	(0.028)	(0.049)	(0.446)	(0.621)	(0.941)	(0.033)	(0.232)
TFSL	0.003	-0.002	0.006	0.006	0.006	0.006	0.006	0.014	
	(0.245)	(0.538)	(0.018)	(0.037)	(0.283)	(1.115)	(1.844)	(0.685)	
HPI	-0.011**	-0.011**	0.018	0.018	0.018	0.018	0.018	0.017	0.028
	(0.011)	(0.018)	(0.015)	(0.037)	(0.128)	(0.940)	(1.576)	(0.050)	(0.021)
CA	-0.013	0.025***	-0.005	-0.005	-0.005	-0.005	-0.005	-0.008	0.007
	(0.324)	(0.008)	(0.029)	(0.086)	(0.089)	(0.695)	(1.187)	(0.587)	(0.034)
REER	-0.014**		0.009	0.009	0.009	0.009	0.009		0.004
	(0.036)		(0.023)	(0.050)	(0.118)	(0.397)	(0.666)		(0.011)
GGD	0.000	0.000	0.062	0.062	0.062	0.062	0.062	0.049	-0.011
	(0.929)	(0.999)	(0.039)	(0.085)	(0.206)	(0.485)	(0.726)	(0.302)	(0.016)
PSD	0.002**		-0.015	-0.015	-0.015	-0.015	-0.015		-0.045
	(0.042)		(0.049)	(0.097)	(0.298)	(0.712)	(1.132)		(0.033)
PSCF	0.000		-0.006	-0.006	-0.006	-0.006	-0.006		0.034
	(0.773)		(0.215)	(0.411)	(2.433)	(3.658)	(5.377)		(0.106)
AR	-0.095**		-0.230	-0.230	-0.230	-0.230	-0.230		-0.362
	(0.010)		(0.192)	(0.395)	(1.208)	(7.842)	(13.538)		(0.251)
N. Ob.	186	186	31	31	31	31	31	31	31
R ²	0.329		0.761						
CPR	0.774		0.968						
Boot. rep.	-	-	-	1000	1000	1000	1000	1000	1000
Block length	-	-	-	1	5	10	15	5	5

Note: Tab 4. presents results of baseline (EU) and adjusted (EU-A) model estimated by Domonkos et al. (2017), as well as baseline model for the case of Slovakia (SK) with its four different bootstraps of standard errors (SK B(1)-SK B(4)) varying with the block length. Additionally, the adjusted models for original (SK-A) as well as computed (SK-A*) correlation matrix with block bootstrap of standard errors are provided. Standard errors of parameters are presented in parenthesis. Descriptive statistics for each model include number of

observations (N. Ob.), coefficient of determination (R^2), correct prediction rate (CPR), number of bootstraps (N. Boot.), and block length.

The adjusted models [8] and [9], which aim to mitigate the effects of high degree of multicollinearity still provide parameters that are statistically insignificant. Additional robustness checks showed that in case of model [9] the net international investment position is in some cases statistically significant for block length 2 or less. However, as the block length increases and with it the potential bias from serial correlation decreases the parameter becomes statistically insignificant. The same holds true for parameters of house price index and private sector debt, which appear to be statistically significant up to the block length of 3.

In contrast, the parameter for activity rate appears to be statistically significant for cases with block length of 2 or less and also for block length of 10 or more. Additionally, bootstrap mean of the parameter is in absolute value higher than the sample mean, yielding some credence to the suggestion that activity rate might have sufficient predictive capabilities in two year horizon in case of Slovakia.

For the results in three year horizon (Tab. 5) the similarities between annual EU model [1] and quarterly Slovak model [3] are even more prevalent than in previous cases as the signs of parameters differ only 5 instances (specifically indicators UR, NIIP, HPI, CA, and GGD). Additionally, unemployment rate and house price index from among these indicators appear to be statistically significant at 5 percent level in case of Slovak model [3]. However, similarly to one and two year horizon, the standard errors of almost all parameters increase with the extension of bootstrap block length (columns [4]-[7]) rendering both of these parameters statistically insignificant.

In case of adjusted models [8] and [9] the situation remains the same and none of the examined indicators does not appear to provide reliability in predicting falls in output gap in case of Slovakia. Additional robustness checks showed that the parameter for current account may be statistically significant at 10 percent significance level when block length 15 is used but the bootstrap mean is negative, which may be more in line with the results of Domonkos et al. (2017) as opposed to positive sample mean. Similarly, the parameter for activity rate may be statistically significant for block length 14 or more, however, the bootstrap mean of the parameter is in absolute value lower than the sample mean, undermining the notion that this indicator may have predictive power in three year horizon.

Tab. 5 LPM models for drop in output gap in three year horizon (*Sources: models [1]-[2] Domonkos et al., 2017; models [3]-[9] the author*)

	EU	EU-A	SK	SK B(1)	SK B(2)	SK B(3)	SK B(4)	SK-A B	SK-A* B
Indic.	[1]	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]
YUR	0.022**	0.009	0.026	0.026	0.026	0.026	0.026	-0.034	0.011
	(0.048)	(0.155)	(0.037)	(0.083)	(0.232)	(2.068)	(3.554)	(0.519)	(0.024)
LTUR	-0.042	-0.032	-0.257*	-0.257	-0.257	-0.257	-0.257	0.064	0.008
	(0.328)	(0.130)	(0.143)	(0.279)	(1.428)	(8.946)	(15.392)	(0.156)	(0.056)
UR	-0.029	-0.020	0.559***	0.559	0.559	0.559	0.559	0.421	0.067
	(0.213)	(0.312)	(0.169)	(0.362)	(3.122)	(8.220)	(14.198)	(0.598)	(0.091)
NIIP	-0.003	0.003***	0.078	0.078	0.078	0.078	0.078	0.048	0.006
	(0.151)	(0.013)	(0.049)	(0.123)	(0.703)	(2.067)	(3.574)	(0.068)	(0.035)
EMS	0.022**	0.009	0.007	0.007	0.007	0.007	0.007	0.007	0.002
	(0.048)	(0.155)	(0.006)	(0.016)	(0.038)	(0.505)	(0.803)	(0.019)	(0.009)
NULC	0.012*	0.010*	0.001	0.001	0.001	0.001	0.001	-0.021	-0.002
	(0.085)	(0.052)	(0.023)	(0.051)	(0.362)	(0.829)	(1.315)	(0.089)	(0.308)
TFSL	-0.002	0.001	-0.001	-0.001	-0.001	-0.001	-0.001	-0.013	
	(0.523)	(0.649)	(0.015)	(0.033)	(0.235)	(1.613)	(2.713)	(0.772)	
HPI	0.010**	0.005	-0.028**	-0.028	-0.028	-0.028	-0.028	-0.029	0.008
	(0.036)	(0.357)	(0.013)	(0.040)	(0.132)	(1.370)	(2.327)	(0.067)	(0.025)
CA	-0.011	0.029***	0.021	0.021	0.021	0.021	0.021	0.013	0.041
	(0.442)	(0.001)	(0.024)	(0.075)	(0.115)	(1.028)	(1.766)	(0.642)	(0.031)
REER	-0.018**		-0.019	-0.019	-0.019	-0.019	-0.019		-0.001
	(0.022)		(0.019)	(0.035)	(0.100)	(0.585)	(0.994)		(0.012)
GGD	0.001	0.000	-0.014	-0.014	-0.014	-0.014	-0.014	-0.028	-0.012
	(0.792)	(0.810)	(0.033)	(0.074)	(0.245)	(0.644)	(1.064)	(1.264)	(0.020)
PSD	0.002***		0.009	0.009	0.009	0.009	0.009		-0.018
	(0.022)		(0.041)	(0.077)	(0.266)	(1.024)	(1.695)		(0.022)
PSCF	0.000		0.269	0.269	0.269	0.269	0.269		-0.056
	(0.886)		(0.177)	(0.378)	(2.150)	(4.940)	(7.607)		(0.081)
AR	-0.075*		-0.137	-0.137	-0.137	-0.137	-0.137		-0.249
	(0.062)		(0.159)	(0.404)	(1.525)	(11.727)	(20.268)		(0.231)
N. Ob.	159	159	31	31	31	31	31	31	31
R ²	0.294		0.752						
CPR	0.736		1.000						
Boot. rep.	-	-	-	1000	1000	1000	1000	1000	1000
Block length	-	-	-	1	5	10	15	5	5

Note: Tab 5. presents results of baseline (EU) and adjusted (EU-A) model estimated by Domonkos et al. (2017), as well as baseline model for the case of Slovakia (SK) with its four different bootstraps of standard errors (SK B(1)-SK B(4)) varying with the block length. Additionally, the adjusted models for original (SK-A) as well as computed (SK-A*) correlation matrix with block bootstrap of standard errors are provided. Standard errors of parameters are presented in parenthesis. Descriptive statistics for each model include number of observations (N. Ob.), coefficient of determination (R^2), correct prediction rate (CPR), number of bootstraps (N. Boot.), and block length.

5 Concluding Remarks

When summarizing, there are certain patterns which are visible throughout all of the obtained results and may be relevant for future research, thus, should be commented upon.

First, is that the models estimated on country specific quarterly data seems to explain and predict falls in output gap far better than models estimated on EU-wide panel with annual frequency, as all of the models for Slovakia have higher coefficient of determination as well as correct prediction rate.

Additionally, multicollinearity appears to be an issue which has not been entangled in its fullest in the presented analysis as the low number of observations appears to be a constraint also in this dimension. Nevertheless, the adjusted models which deal only with one selected indicator at a time allow more focused view on possible explanatory power of MIP headline indicators.

In that regard, the activity rate appears to be the most solid predictor from MIP Scoreboard in the context of Slovakia, as the changes in probability of fall in output gap is fairly sensitive to its change in two year horizon. Furthermore, unemployment rate and private sector credit flow, which performed considerably well in one year horizon, seems to be capturing in case of Slovakia rather the end of previous phase of the business cycle than the actual probability of impeding crisis.

6 References

- Boysen-Hogrefe, J., Jannsen, N., Plödt, M., Schwarzmüller, T. (2015). *An Empirical Evaluation of Macroeconomic Surveillance in the European Union*. [Kiel Working Paper, No. 2014.] Kiel: Institute for the World Economy.
- Csortos, O., Szalai, Z. (2013). *Assessment of Macroeconomic Imbalance Indicators*. [MNB Bulletin, October 2013, pp. 14 – 24.] Budapest: Magyar Nemzeti Bank.
- Domonkos, T., Ostrihoň, F., Šikulová, I., Širaňová, M. (2017): *Analyzing the Relevance of the MIP Scoreboard's Indicators*. National Institute Economic Review, 239, No. 1, pp. R32 – R52.
- European Commission (2018). *Report from the Commission to the European Parliament, the Council, the European Central Bank and the European Economic and Social Committee. Alert Mechanism Report 2019*. Brussels, 21.11.2018, COM(2018) 758 final.
- Eurostat (2018a). *Macroeconomic Imbalance Procedure, INDICATORS – Eurostat*. [Available at: <http://ec.europa.eu/eurostat/web/macroeconomic-imbances-procedure/indicators>]
- Eurostat (2018b). *Database – Eurostat*. [Available at: <http://ec.europa.eu/eurostat/data/database>]
- Greene, W.H. (2012). *Econometric Analysis*. Edinburgh Gate: Pearson, Seventh Edition, International Edition, 2012, 1238 p.
- IMF (2018). *IMF DATA – IMF*. [Available at: <http://www.imf.org/en/Data>]

NBS (2018). *Makroekonomická databáza - NBS*. [Available at: <https://www.nbs.sk/sk/menova-politika/makroekonomicka-databaza/makroekonomicke-ukazovatele-graf>].

Širaňová, M., Radvanský, M. (2017). *Performance of the Macroeconomic Imbalance Procedure in light of historical experience in the CEE region*. *Journal of Economic Policy Reform*, 21(4) 335-352.

7 Acknowledgement

This research was supported by Scientific Grant Agency (VEGA) of the Ministry of Education of the Slovak Republic (ME SR) and of Slovak Academy of Sciences (SAS) under the project VEGA 2/0158/18 and by Slovak Research and Development Agency (APVV) under the project APVV-14-0787.

Použití výstupního systému SAS pro vytváření pracovních listů programu Microsoft Excel

Using the SAS Output Delivery System to create Microsoft Excel worksheets

Roman Pavelka

Štatistický úrad Slovenskej republiky, Odbor metód štatistických zisťovaní, Miletičova 3, Bratislava, Slovenská republika

Statistical Office of Slovak Republic, Statistical Surveys and Methodology Department, Miletičova 3, Bratislava, Slovak Republic

Roman.Pavelka@statistics.sk

Abstrakt: Pracovní listy sešitu aplikace Microsoft Excel představují nejrozšířenější tabulkový procesor, který efektivně umožňuje uživatelům analyzovat data. Když se zkombinuje výstupní systém programu SAS Output Deliver System (ODS) s funkcemi aplikace Excel, dostáváme výkonnou sadu nástrojů, jejíž pomocí lze snadno využívat výpočetních možností prostředí SAS a manipulovat s daty, včetně formátování či zvýrazňování dat, vkládání vzorců, grafů či vytváření kontingenční tabulky v sešitu Excel. Předkládaný příspěvek, který je určen nejen pro zkušené programátory v prostředí systému SAS, ale i pro začínajícího analytika, na několika příkladech ilustruje možnosti přesměrování výstupů procedur, grafických výstupů a ostatních programových funkcionalit programu SAS do listů pracovního sešitu Microsoft Excel. Při vytváření pracovních sešitů s přesměrovanými výstupy z programu SAS se přiblíží základní programové příkazy a funkcionality programu SAS, které jsou při přesměrování výstupů do sešitu Microsoft Excel využívány, uživatelské formátování přesměrovaných dat i tvorba komplexních reportů.

Abstract: Microsoft Excel worksheets are the most widely used spreadsheets that effectively enable users to analyse data. When the SAS Output Deliver System (ODS) output system combines with Excel, we receive a powerful toolkit that makes it easy to use SAS computing capabilities and data manipulating in an Excel workbook, including formatting or highlighting data, embedding formulas, graphs or creating a PivotTable. The present post, which is designed not only for experienced SAS programmers but also for novice analysts, illustrates on several examples of redirecting outputs of procedures, graphical outputs, and other SAS program functionalities into Microsoft Excel worksheets. When creating workbooks with redirected SAS outputs, the basic program commands and SAS functionalities that are used when redirecting outputs to the Microsoft Excel workbook, user formatting of redirected data, and the creation of complex reports will be approached.

Klíčové slová: list Microsoft Excel, programový systém SAS, tabulkový procesor, výstupní systém programu SAS.

Key words: Microsoft Excel worksheets, programming system SAS, SAS Output Deliver System, spreadsheet.

1 Úvod

Program SAS/BASE 9.4 od své třetí verze (TS1M3) obsahuje výstupní systém (Output Delivery System - dále zkratkou "ODS"), který umožňuje vytvářet a formátovat pracovní sešity aplikace Microsoft Excel. Tato funkcionality programu SAS poskytuje uživatelům rozsáhlé možnosti tvorby přehledů, tabulek i reportů přímo z prostředí programu SAS. Přesměrování výstupů procedur či jednotlivých příkazů do pracovního listu sešitu Excel, uživatelské formátování či zvýrazňování dat, názvy záložek, specifikace buněk, do kterých mají být výstupy z programu SAS umístěny, atd., pomáhají uživatelům ve tvorbě tabulkových a grafických přehledů na vysoké profesionální úrovni. Jednotlivé příklady v předkládaném článku se zaměřují na vytvoření tabulkových výstupů pomocí vybraných programových modulů (procedur) programu SAS. Příklady zahrnují ukázky výstupů z programu SAS do sešitu Microsoft Excel, u kterých jsou uživatelsky přizpůsobeny nejen formáty čísel, barvy jednotlivých buněk, záhlaví, sloupců i řádků, ale i strukturovaný pracovní sešit s hypertextovými odkazy na jednotlivé listy. Vytvořený programový kód u všech příkladů v tomto příspěvku byl testován v programech SAS 9.4 TS1M3 a Microsoft Excel 2010.

Aby se mohli použít metody popsané v příspěvku, je potřebné mít následující software³:

- Program SAS/Base verze 9.4 TS1M3 a novější na libovolném podporovaném operačním systému (Windows, z/OS, UNIX atd.) a
- Microsoft Excel 2010 a novější.

Pro účely tohoto článku byly jako data pro příklady použity následující datové soubory ze systémové knihovny SASHELP programu SAS:

- cars data o automobilech z roku 2004 o 428 pozorováních s 15 proměnnými,
- class informace o fiktivní třídě studentů o 19 pozorováních se 4 proměnnými,
- heart data z výzkumné studie Framingham Heart Study s 5 209 pozorováními a 17 proměnnými,
- orsales obchodní údaje firmy Orion Star Sports and Outdoors za roky 1999–2002 obsahující 912 pozorování s 8 proměnnými,
- prdsale obchodní údaje o prodeji nábytku o 1 440 pozorování s 10 proměnnými,
- prcedata simulovaná data měsíčních obchodů s hierarchií regionální, firemní a produktovou obsahující 1 020 pozorování s 28 proměnnými a

³ Je-li k dispozici starší verze programu SAS, resp. pro starší verze Microsoft Excel, je nutné namísto výstupního systému ODS EXCEL použít doplněk ExcelXP dostupný z WWW stránek Centra pomoci SAS.

- shoes obchodní údaje fiktivního prodejce obuvi o 395 pozorováních se 7 proměnnými.

2 Přesměrování výstupů z programu SAS do sešitu Microsoft Excel

2.1 Obecný tvar příkazu k přesměrování výstupů

Obecný tvar příkazu ke generování výstupu programu SAS ve formátu excelovského sešitu (s koncovkou XLSX) má následující podobu:

```
ods _all_ close;  
ods Excel file='file-name.xlsx' style=style-name ...;  
* programový kód procedur SAS;  
ods Excel close;
```

Příkaz na prvním řádku uzavírá všechny otevřené programové výstupy programu SAS, protože se mají generovat výstupy pouze ve formátu sešitu Excel (s koncovkou XLSX). Druhý příkaz k řízení výstupu otevírá výstup programu SAS do formátu XLSX sešitu do specifikovaného souboru. Parametr STYLE ovlivňuje vzhled a další vlastnosti výstupu, takové jako je písmo, barevné schéma, apod. Poslední příkaz uzavírá otevřený výstup ve formátu XLSX a soubor uvolňuje k dalšímu používání v jiných programech, například k otevření v aplikaci Microsoft Excel.

Přesměrování výstupů programu SAS lze použít pro všechny programové moduly (procedury). Uživatelské formátování či úpravy stylů výstupů lze aplikovat pouze u výstupů z programových modulů (procedur) PRINT, REPORT a TABULATE. Techniky popsané v tomto příspěvku se nedají použít k úpravám již existujících pracovních sešitů Microsoft Excel. V každém běhu přesměrovaného výstupu se vytváří nový pracovní sešit a existující sešity se měnit nedají.

2.2 Parametry příkazu ODS EXCEL pro nastavení vlastností sešitu Microsoft Excel

Příkaz ODS EXCEL obsahuje mnoho parametrů, které kontrolují vlastnosti vytvářeného pracovního sešitu. Při vytváření výstupů ve formátu EXCEL je možné použít některé z nich, případně všechny. Mezi nejdůležitější parametry této skupiny patří:

- AUTHOR= specifikuje jméno autora pracovního sešitu,
- CATEGORY= specifikuje kategorii pracovního sešitu,
- COMMENTS= vkládá komentář do vlastností sešitu,
- FILE= specifikuje jméno souboru (včetně cesty), který obsahuje vytvářený pracovní sešit a
- STYLE= specifikuje uživatelské formáty buněk, listů a ostatních prvků pracovního sešitu.

2.3 Nastavení formátů a struktury parametrem **OPTIONS** příkazu **ODS EXCEL**

Nejdůležitější parametr příkazu ODS EXCEL se nazývá **OPTIONS**⁴. Parametr **OPTIONS** umožňuje specifikovat seznam dalších subparametrů, které uživateli poskytují větší kontrolu nad formátováním a strukturou sešitu a jednotlivých listů aplikace Excel. Parametr **OPTIONS** je bezprostředně následován kulatými závorkami, které obsahují subparametry mající vliv na strukturu a formátování pracovního sešitu. Každý subparametr (v uzavřených kulatých závorkách) je reprezentován dvojicí *jméno_subparametru* = '*hodnota_subparametru*' navzájem od sebe oddělenými mezerou. Dokumentace programu SAS 9.4 TS1M3 uvádí přibližně 45 subparametrů. Zhruba polovina z nich ovládá různé tiskové aspekty pracovního listu. Druhá polovina kontroluje vizuální prvky, které jsou patrné při prohlížení dokumentu na obrazovce. Z tohoto důvodu nemůže tento příspěvek obsahovat úplný popis všech parametrů a budou zde demonstrovány pouze ty nejdůležitější a nejčastěji užívané subparametry.

2.3.1 Subparametry, které kontrolují vlastnosti pracovního listu

Některé charakteristiky pracovního listu je žádoucí nastavit bez ohledu na typ výstupů, které bude list obsahovat. Subparametry, které do této skupiny patří, ilustruje Příklad 1. Jedná se o následující subparametry uvedené v Příkladu 1:

- **EMBEDDED_TITLES** vkládá do listu nadpisy,
- **EMBEDDED_FOOTNOTES** vkládá do listu poznámky pod čarou,
- **TAB_COLOR** mění barvu pozadí názvu listu pracovního sešitu,
- **START_AT** identifikuje buňku, do které je umístěno záhlaví prvního sloupce ve formě dvojice: číslo sloupec, číslo řádku a
- **FROZEN_HEADERS** specifikuje, zda má být ukotveno záhlaví tabulky při posouvání.

Příklad 1 Použití subparametrů, které kontrolují vlastnosti listu pracovního sešitu

```
ods excel file="example01.xlsx" options(embedded_titles='yes'
    embedded_footnotes='yes' tab_color='purple' start_at='2,4'
    frozen_headers='yes');
title 'Tento titul se objeví v pracovním listu';
footnote 'Toto zápatí se objeví v pracovním listu';
proc report data=sashelp.class;
run;
ods excel close;
```

Po spuštění kódu z Příkladu 1 se vytvoří excelovský soubor, který obsahuje pracovní list s obsahem uvedeným na obrázku 1.

⁴ SAS Institute Inc. (2016). SAS® 9.4 Output Delivery System: User's Guide, Fifth Edition. Cary, NC: SAS Institute Inc. s. xxvi+1156. ISBN (neuvedeno) (PDF). s. 301.

	Name	Sex	Age	Height	Weight
7	Alfred	M	14	69	112,5
8	Alice	F	13	56,5	84
9	Barbara	F	13	65,3	98
10	Carol	F	14	62,8	102,5
11	Henry	M	14	63,5	102,5
12	James	M	12	57,3	83
13	Jane	F	12	59,8	84,5
14	Janet	F	15	62,5	112,5
15	Jeffrey	M	13	62,5	84
16	John	M	12	59	99,5
17	Joyce	F	11	51,3	50,5
18	Judy	F	14	64,3	90
19	Louise	F	12	56,3	77
20	Mary	F	15	66,5	112
21	Philip	M	16	72	150
22	Robert	M	12	64,8	128
23	Ronald	M	15	67	133
24	Thomas	M	11	57,5	85
25	William	M	15	66,5	112

Obr. 1 Obsah vytvořeného souboru (Zdroj: vlastní zpracování)

2.3.2 Subparametry, které kontrolují vlastnosti tabulky v pracovním listu

Nastavení vlastností tabulek poskytují další subparametry příkazu OPTIONS, které jsou uvedeny dále v Příkladu 2. Mezi nejčastěji využívané subparametry patří následující:

- HIDDEN_ROWS skrývá specifikovaný počet řádků v pracovním listu,
- AUTOFILTER zapíná filtrování údajů; může být aplikováno na všechny anebo vybrané sloupce,
- ABSOLUTE_COLUMN_WIDTH specifikuje šířku sloupce; může být uvedeno pro všechny anebo vybrané sloupce a
- ABSOLUTE_ROW_HEIGHT specifikuje výšku řádku; může být uvedeno pro všechny anebo vybrané řádky.

Příklad 2 Použití subparametrů, které kontrolují vlastnosti tabulky v listu pracovního sešitu.

```
ods excel file="example02.xlsx"
options(hidden_rows='6' autofilter='1-3' absolute_column_width='16'
absolute_row_height='25');
proc report data=sashelp.cars;
run;
ods excel close;
```

Po spuštění kódu z Příkladu 2 se vytvoří pracovní sešit Excel, jehož pracovní list s obsahuje tabulku v podobě uvedené na obrázku 2.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
	Make	Model	Type	Origin	DriveTrain	MSRP	Invoice	EngineSize	Cylinders	Horsepower	MPG_City	MPG_Highway	Weight	Wheelbase	Length
1	Acura	MDX	SUV	Asia	All	\$36 945	\$33 337	3,5	6	265	17	23	4451	106	189
3	Acura	RSX Type S 2dr	Sedan	Asia	Front	\$23 820	\$21 761	2	4	200	24	31	2778	101	172
4	Acura	TSX 4dr	Sedan	Asia	Front	\$26 990	\$24 647	2,4	4	200	22	29	3230	105	183
5	Acura	TL 4dr	Sedan	Asia	Front	\$33 195	\$30 299	3,2	6	270	20	28	3575	108	186
7	Acura	3.5 RL w/Navigation 4dr	Sedan	Asia	Front	\$46 100	\$41 100	3,5	6	225	18	24	3893	115	197
8	Acura	NSX coupe 2dr manual S	Sports	Asia	Rear	\$89 765	\$79 978	3,2	6	290	17	24	3153	100	174
9	Audi	A4 1.8T 4dr	Sedan	Europe	Front	\$25 940	\$23 508	1,8	4	170	22	31	3252	104	179
10	Audi	A41.8T convertible 2dr	Sedan	Europe	Front	\$35 940	\$32 506	1,8	4	170	23	30	3638	105	180

Obř. 2 Uživatelsky vytvořená tabulka v listu pracovního seřitu (Zdroj: vlastní zpracování)

Porovnáním výstupů z Příkladu 1 a Příkladu 2 je zřetelně vidět rozdíl. Všechny sloupce tabulky Příkladu 2 mají stejnou šířku a každý řádek je dostatečně vysoký, aby poskytl vizuální oddělení mezi datovými hodnotami.

2.3.3 Subparametry, které kontrolují počet vytvářených pracovních listů v seřitu

Dosud byly příklady zaměřeny na tvorbu pouze 1 tabulky na 1 pracovním listu. Proto další ukázka programové sekvence bude věnována umístění více tabulek na 1 pracovním listu. Výchozím chováním výstupu z programu SAS do seřitu Excel je vložení každé tabulky do svého vlastního pracovního listu. Velmi důležitý je však rozdíl mezi tabulkovým výstupem a výstupem z procedury programu SAS, což zejména platí pro proceduru REPORT. Procedura REPORT ve výchozím nastavení vytvoří pouze jednu tabulku, takže výstup z procedury se umístí pouze na 1 pracovní list. Více tabulek z výstupu procedury REPORT generuje použití příkazu BREAK (zajiřtuje agregaci podle vybrané proměnné) s parametrem PAGE (pro každou hodnotu agregační proměnné bude výstup na novém listu). To způsobí, že každá z těchto tabulek je zapsána do samostatného pracovního listu. Použitý programový kód je ilustrován v Příkladu 3.

Jestli a kdy jsou vytvářeny více pracovních listů, je kontrolováno subparametrem SHEET_INTERVAL. Tento subparametr nabývá 6 možných hodnot, které jsou podrobněji vysvětleny v uživatelském manuálu⁵. Pokud subparamter SHEET_INTERVAL='NONE', jsou generované výstupy umístěny na 1 pracovní list. Jméno pracovního listu lze nastavit subparametrem SHEET_NAME anebo SHEET_LABEL (pokud jsou použity obojí, uplatní se přednostně hodnota SHEET_NAME).

⁵ SAS Institute Inc. (2016). SAS® 9.4 Output Delivery System: User's Guide, Fifth Edition. Cary, NC: SAS Institute Inc. s. xxvi+1156. ISBN (neuvedeno) (PDF). s. 312.

Příklad 3 Generování tabulek na samostatné listy do pracovního sešitu procedurou REPORT

```
ods excel file="example04.xlsx";
proc report data=sashelp.class;
  column sex name age height weight;
  define sex / group;
  break after sex / page;
run;
ods excel close;
```

Sex	Name	Age	Height	Weight
F	Alice	13	56,5	84
	Barbara	13	65,3	98
	Carol	14	62,8	102,5
	Jane	12	59,8	84,5
	Janet	15	62,5	112,5
	Joyce	11	51,3	50,5
	Judy	14	64,3	90
	Louise	12	56,3	77
	Mary	15	66,5	112

Obr. 3 Tabulky na samostatném listu v pracovním sešitu (Zdroj: vlastní zpracování)

Příklad 4 demonstuje použití subparametru SHEET_NAME k nastavení jména pracovního listu.

Make	Model	Type	Invoice
Acura	MDX	SUV	\$33 337
	RSX Type S 2dr	Sedan	\$21 761
	TSX 4dr	Sedan	\$24 647
	TL 4dr	Sedan	\$30 299
	3.5 RL 4dr	Sedan	\$39 014
	3.5 RL w/Navigation 4dr	Sedan	\$41 100
	NSX coupe 2dr manual S	Sports	\$79 978
Audi	A4 1.8T 4dr	Sedan	\$23 508
	A4 1.8T convertible 2dr	Sedan	\$32 506
	A4 3.0 4dr	Sedan	\$28 846
	A4 3.0 Quattro 4dr manual	Sedan	\$30 366
	A4 3.0 Quattro 4dr auto	Sedan	\$31 388
	A6 3.0 4dr	Sedan	\$33 129
	A6 3.0 Quattro 4dr	Sedan	\$36 992
	A4 3.0 convertible 2dr	Sedan	\$38 325
	A4 3.0 Quattro convertible 2dr	Sedan	\$40 075
	A6 2.7 Turbo Quattro 4dr	Sedan	\$38 840
	A6 4.2 Quattro 4dr	Sedan	\$44 936
	A8 L Quattro 4dr	Sedan	\$64 740
	S4 Quattro 4dr	Sedan	\$43 556
	RS 6 4dr	Sports	\$76 417
	TT 1.8 convertible 2dr (coupe)	Sports	\$32 512
	TT 1.8 Quattro 2dr (convertible)	Sports	\$33 891
	TT 3.2 coupe 2dr (convertible)	Sports	\$36 739
	A6 3.0 Avant Quattro	Wagon	\$37 060
	S4 Avant Quattro	Wagon	\$44 446
BMW			

Obr. 4 Ukázka výstupu procedury REPORT na 1 pracovní list (Zdroj: vlastní zpracování)

Příklad 4 Výstup více tabulek procedury REPORT na 1 pracovní list.

```
ods excel file="example05.xlsx" options(sheet_name='Cars by Make'
sheet_interval='none');
proc report data=sashelp.cars;
  by make;
  column model type invoice;
run;
ods excel close;
```

2.3.4 Tvorba více tabulek do několika pracovních listů 1 sešitu

Dalším pokračováním ukázek je vytvoření souboru, který obsahuje více tabulek ve více pracovních listech. Programový systém SAS ve verzi 9.4 TS1M3 a 9.4 TS1M4 nemá subparametr, který by vytvářel nový list pracovního sešitu. Za účelem vytvoření nového listu je nutné generovat tzv. dummy výstupní objekt. I když tento dummy objekt není pozorovatelný, musí být generován pro vytvoření nového pracovního listu. Od verze 9.4 TS1M5 programu SAS lze vygenerovat nový pracovní list pro výstup ve formátu XLSX pomocí subparametru SHEET_INTERVAL='NOW'. Při tvorbě výstupního dummy objektu je nejprve položka SHEET_INTERVAL nastavena na hodnotu OUTPUT. Výstupní dummy objekt je generován příkazem DATA _NULL_. Poté je subparametr SHEET_INTERVAL nastaven zpět na hodnotu NONE. Příkaz ODS EXCLUDE zabraňuje zahrnutí výstupů kroku DATA _NULL_ do sešitu.

Ukázka programového kódu je ilustrována Příkladem 5. Z důvodu lepší přehlednosti a celkové efektivity běhu programu byl použitý programový kód v Příkladu 5 strukturován do programových maker. Makro pod názvem %PRCODE obsahuje kód procedury REPORT. Příkaz DATA _NULL_ ke vzniku výstupního dummy objektu je uvnitř programového makra %newsheet. Každé programové makro se volá a spouští tolikrát, aby se vytvořil jeden sešit obsahující dva listy, každý s dvěma tabulkami. Výsledek činnosti programového kódu z Příkladu 5 je dokumentován na obrázku 5.

Příklad 5 Program na vytvoření pracovního sešitu obsahující 2 listy, každý se 2 tabulkami

```
%macro prcode(sheetname, dsname, grpvar);
ods excel options(sheet_interval='none' sheet_name="%sheetname");
proc report data=&dsname;
    column &grpvar height weight;
    define &grpvar / group;
    define height / mean;
    define weight / mean;
    rbreak before / summarize;
run;
%mend prcode;
%macro newsheet;
ods excel options(sheet_interval='output');
ods exclude all;
data _null_;
    declare odsout obj();
run;
ods select all;
%mend newsheet;

ods excel file="example07.xlsx";
%prcode(Class, sashelp.class, age);
%prcode(Class, sashelp.class, sex);
%newsheet;
%prcode(Heart, sashelp.heart, bp_status);
%prcode(Heart, sashelp.heart, sex);
ods excel close;
```

A	B	C
1	Age	Height
2		Weight
3	11	62,336842
4	12	54,4
5	13	59,44
6	14	61,433333
7	15	64,9
8	16	65,625
9		72
10	Sex	Height
11		Weight
12	F	62,336842
13	M	60,588889
14		90,111111
15		108,95

A	B	C
1	Blood Pressure Status	Height
2		Weight
3	High	64,813185
4	Normal	64,713687
5	Optimal	65,005841
6		149,16768
7		138,7202
8	Sex	Height
9		Weight
10	Female	64,813185
11	Male	62,572586
12		141,38864
13		167,46615
14		
15		

Obr. 5 Pracovní sešit obsahující 2 listy, každý se 2 tabulkami (Zdroj: vlastní zpracování)

2.3.5 Připojení nativního grafu Microsoft Excel do pracovního sešitu

Počínaje programovým systémem SAS 9.4 verze TS1M3 je možné vygenerovat nativní grafy aplikace Excel pomocí nové procedury MSCHART. Bude-li procedura MSCHART vložena do kódu v rámci ODS výstupů do formátu sešitu Microsoft Excel dá se vygenerovat skutečně nativní grafiku aplikace Excel, nikoli pouze obrázek (jako u ostatních procedur systému SAS). Tento aspekt odlišuje proceduru MSCHART od jiných procedur (například procedur statistické grafiky nebo SAS/GRAPH), jejichž výstupem jsou zpravidla soubory obrázků.

V následujícím příkladu se procedura MSCHART používá k propojování grafiky s tabulkou. Proto každá změna v tabulkových datech také aktualizuje graf. Tato akce umožňuje používat interaktivní funkce nativního grafu tak, aby se přidávaly styly, filtrovali a upravovali prvky grafu.


Příklad 6 Program na připojení nativního grafu Microsoft Excel do pracovního sešitu

```
proc sql;
    create table summary as
        select (region), sum(sales) format=dollar14.2 as sales
        from sashelp.shoes
        group by region;

run; quit;
ods excel file="example14.xlsx";
title "Sales by Region";
proc mschart data=work.summary category=region width=4in position="$D$1";
    where region in("Africa", "Asia", "Canada", "Pacific", "United States");
    vcolumn sales;

run;
ods excel close;
```

Výsledkem běhu programu z Příkladu 6 je vytvoření pracovního sešitu s listem s vloženou tabulkou a grafem, což je ilustrováno na obrázku 6.



Obr. 6 Sešit s listem s tabulkou s údaji a interaktivním grafem (Zdroj: vlastní zpracování)

2.3.6 Vytvoření pracovního listu se seznamem odkazů na následující listy sešitu

Výstup programu SAS pomocí ODS Excel umožňuje snadné vytváření vlastní tabulky obsahu (TOC). Obsah TOC lze uživatelsky přizpůsobit dle požadavků, protože SAS obsahuje ve výstupním systému metody pro úpravu zobrazeného textu a stylu. Například je možné změnit styl pro každou položku v tabulce obsahu nebo bude jedna tabulka obsahu zahrnovat odkazy do více než jednoho pracovního sešitu (externí odkazy). Uživatel může také podle potřeby nastavit cílovou buňku, kde má po kliknutí na odkaz v obsahu odskočit na propojeném pracovním listu. Uvedené a další možnosti dovoluje uživateli výstupní systém programu SAS. Přizpůsobený obsah lze také doplnit libovolným textem. Následující příklad používá proceduru ODSTEXT a výstup do pracovního sešitu k vygenerování uživatelského obsahu, který obsahuje seznam s vloženými texty a odkazy na následující pracovní listy.

Příklad 7 Program na tvorbu pracovního listu se seznamem odkazů (obsahem)

```
ods excel file="example13.xlsx" options(embedded_titles="yes" sheet_name="Table of Contents");
proc odstext;
  p 'Table of Contents by Region' / style={font_weight=bold font_size=20pt};
  list;
  item "Detail for Region Africa" / style={font_size=15pt url="#Africa!A1" color=blue tagattr="mergeacross:4"};
  item "Summary for Region Africa" / style={font_size=15pt url="#Africa!E62" color=red};
  item "Detail for Region Asia" / style={font_size=15pt url="#Asia!A1" color=blue};
  item "Summary for Region Asia" / style={font_size=15pt url="#Asia!E20" color=red};
  item "Detail for Region Canada" / style={font_size=15pt url="#Canada!A1" color=purple};
  item "Summary for Region Canada" / style={font_size=15pt url="#Canada!E43" color=red};
  item "Detail for Region Central America-Caribbean" / style={font_size=15pt url="#'Central America-Caribbean'!A1" color=blue};
  item "Summary for Region Central America-Caribbean" / style={font_size=15pt url="#'Central America-Caribbean'!E36" color=red};
  /*. . .více příkazů ITEM. . .*/
end;
```

```

p ' ';
p 'The Table of Contents information links to both the detail records and the
summary of sales for this region.';
p ' ';
p '* Items that are listed in purple were not profitable over the last fiscal
year.' / style=systemfooter[color=purple];
run;

ods excel options(sheet_name="#byval(region)" sheet_interval="bygroups");
proc sort data=sashelp.shoes out=regions;
  by region;
run;

proc print data=regions;
  by region;
  sum sales;
run;
ods excel close;

```

	A	B	C	D	E	F	G	H	I	J	K	L
1	Table of Contents by Region											
2												
3												
4												
5												
6												
7												
8												
9												
10												
11	Tato Table of Contents odkazuje na informace jak na detailní záznamy, tak i na shrnutí obrátů pro tento region.											
12												
13												
14												

Obr. 7 Pracovní list se seznamem odkazů a uživatelskými texty (Zdroj: vlastní zpracování)

K vytvoření uživatelského seznamu jsou použity příkazy ITEM a P procedury výstupního systému ODS TEXT, které vytvářejí požadovanou strukturu seznamu a vkládají popisy a texty. Odkazy jsou nastaveny pomocí atributu URL= tak, že odkazují na detailní data a souhrny podle regionů (každý region má samostatný list). Pozice kurzoru v jednotlivých odkazech je odkazována na název pracovního listu a na cílovou buňku podle vzoru (URL='#jmeno_listu!adresa_buňky'). Na různé vlastnosti (velikost, tloušťka a barva písma, atd.) textu v příkazech P a ITEM jsou aplikovány styly pomocí parametru STYLE=. V odkazu na první tabulku (na druhém listu sešitu) je použit hodnota MERGEACROSS:4 v parametru TAGATTR=. Tato hodnota zajišťuje, že aktivním odkazem není pouze počáteční buňka položky, ale odkaz je aktivní i pro další 3 buňky v řádku s odkazem.

2.4 Vytvoření jednoduchého reportu na listu pracovního sešitu

Vytváření souhrnné sestavy v programu SAS a její výstup ve formě přehledného a uživatelsky přizpůsobeného reportu zpravidla nebývá jednoduchou záležitostí. Realizovaný report na listu pracovního sešitu má spoustu různých částí a funkcí. Každá z těchto individuálních charakteristik musí být promyšlená a naprogramována. I když se může uživatelům programový kód reportu pro výstup do Excelu zdát docela složitý, je nutné mít na paměti, že

mnohdy pro tvorbu stejného reportu je práce s nástroji v Excelu daleko náročnější.

Následující příklad tvorby reportů do pracovního sešitu, který porovnává hodnoty aktuální s hodnotami předpovídanými, používá dříve popsané techniky přidávání stylů a formátování, včetně vložených výpočtů.

Příklad 8 Program na vytváření jednoduchého reportu na listu pracovního sešitu

```
ods escapechar="^";
ods excel file=" example16.xlsx" style=statistical options(start_at="2,2"
tab_color="blue");
proc report data=sashelp.prdsale(where=(country="GERMANY")) spanrows;
  column country product year, (actual predict) indicator1 indicator2;
  define year / across;
  define actual / style(column)={tagattr="format:accounting" width=.8in};
  define predict / style(column)={tagattr="format:accounting" width=.8in};
  define country / group style(column)={tagattr="rotate:90" just=center
vjust=middle color=blue};
  define product / group;
  define indicator1 /
style(column)={tagattr='formula:=IF(RC[-4]>RC[-3], "á", "â") '
fontfamily=wingdings just=center};
  define indicator2 / style={just=center};
  compute indicator2 / length=100 character;
    if _c5_ > _c6_ then indicator2="^{style[color=blue]^ {unicode 1F603}}";
    else indicator2="^{style[color=green]^ {unicode 1F620}}";
  endcomp;
  rbreak after / summarize
style(summary)={fontweight=bold borderstyle=solid bordertopwidth=5pt
bordertopcolor=black};
run;
ods excel close;
```

Příkaz na prvním řádku programového kódu se používá k definování znaku, po kterém následuje řádková formátovací funkce. Tato funkce poskytuje možnost interpretovat textové řetězce, které používají příkazy a proměnné. V Příkladu 8 je řádková formátovací funkce UNICODE pro výpočet, resp. interpretaci znakové proměnné INDICATOR1 a INDICATOR2. Parametrem ROTATE, který se nastavuje v atributu TAGATTR=, se hodnoty proměnné COUNTRY otáčí o 90 stupňů. Parametrem FORMAT v atributu TAGATTR= se zajistí pro vybrané proměnné ACTUAL a PREDICT účetní formát. Hodnotou parametru OPTIONS je nastaven pravý horní roh a barva výsledné tabulky. Podobu vytvořeného reportu na listu pracovního sešitu ilustruje Obrázek 8.

		Year					
		1993		1994			
Country	Product	Actual Sales	Predicted Sales	Actual Sales	Predicted Sales	indicator1	indicator2
GERMANY	BED	\$ 23 518,00	\$ 23 040,00	\$ 22 616,00	\$ 20 756,00	☺	☹
	CHAIR	\$ 23 145,00	\$ 22 991,00	\$ 23 960,00	\$ 21 078,00	☺	☹
	DESK	\$ 25 158,00	\$ 19 821,00	\$ 23 344,00	\$ 24 818,00	☺	☹
	SOFA	\$ 30 728,00	\$ 27 040,00	\$ 24 332,00	\$ 22 477,00	☺	☹
	TABLE	\$ 24 855,00	\$ 24 227,00	\$ 24 342,00	\$ 25 306,00	☺	☹
		\$ 127 404,00	\$ 117 119,00	\$ 118 594,00	\$ 114 435,00	☺	☹

Obrázek 8 Pracovní list s uživatelsky formátovaným reportem (Zdroj: vlastní zpracování)

3 Závěr

Cílem tohoto příspěvku je informovat odbornou veřejnost o možnosti programového systému SAS přesměrovat výstupy procedur, maker a ostatních částí programového kódu nejen na obrazovku monitoru, ale i ukládat výsledky činnosti programu SAS ve strukturované podobě do pracovního sešitu Microsoft Excel. Využitím funkcionality výstupního systému programu SAS lze vytvářet uživatelské výstupy-tabulky, reporty i grafy a vzorce a rovnice-přímo na listy pracovního sešitu Excel, a to včetně požadovaného formátování jednotlivých buněk, pracovních listů i celého sešitu.

I když předkládaný příspěvek nemůže postihnout veškerou rozmanitost potřeb praktického života, uvedené příklady programového kódu reprezentují typické modelové úkoly, které uživatelé nejčastěji realizují. Každý příklad je ilustrován nejen svým programovým kódem, ale i předpokládaným výstupem. Z tohoto důvodu je možné si každý příklad nejen přečíst, ale i vyzkoušet v praxi.

Užší integrace programu SAS a aplikace Microsoft Excel (a jiných dalších programů) představuje významný prvek pro zefektivnění práce většiny datových analytiků i ostatních uživatelů, čemuž má napomoci i předkládaný příspěvek.

4 Literatura

- SAS Institute Inc. (2016). SAS® 9.4 Output Delivery System: Procedures Guide. Third Edition. Cary, NC: SAS Institute Inc. s. xiv + 952. ISBN 978-1-62960-836-5 (PDF). Dostupné na: https://documentation.sas.com/?cdcid=pgmsascdc&cdcVersion=9.4_3.4&docsetId=odsproc&docsetTarget=titlepage.htm&locale=en
- SAS Institute Inc. (2016). SAS® 9.4 Output Delivery System: User's Guide. Fifth Edition. Cary, NC: SAS Institute Inc. s. xxvi + 1156. ISBN (neuvedeno) (PDF). Dostupné na: https://documentation.sas.com/?cdcid=pgmsascdc&cdcVersion=9.4_3.4&docsetId=odsug&docsetTarget=titlepage.htm&locale=en
- SAS Institute Inc. (2016). SAS® 9.4 Output Delivery System: Advanced Topics. Third Edition. Cary, NC: SAS Institute Inc. s. xii + 442. ISBN 978-1-62960-832-7 (PDF). Dostupné na: <https://documentation.sas.com/api/docsets/odsadvug/9.4/content/odsadvug.pdf?locale=en#nameddest=n0pg2pc6qv5vzhn160f8j7ap4uv1>
- SAS Institute Inc. (2016). Sashelp Data Sets. Cary, NC: SAS Institute Inc. s. ii + 160. ISBN (neuvedeno) (PDF). Dostupné na: https://documentation.sas.com/?cdcid=pgmmvacdc&cdcVersion=9.4&docsetId=statug&docsetTarget=statug_sashelp_toc.htm&locale=en

Nitrianske štatistické dni 2019 Informácia o konaní udalosti SŠDS

Statistical Days in Nitra 2019 Information about an event by SŠDS

V dňoch 4. a 5. apríla 2019 sa na pôde Katedry matematiky (KM), Fakulty prírodných vied Univerzity Konštantína Filozofa v Nitre (FPV UKF) konalo pod záštitou dekana FPV UKF, prof. RNDr. Františka Petroviča, PhD., už desiate stretnutie slovenských matematikov a štatistikov s názvom *Nitrianske štatistické dni*. Konferenciu organizovala Slovenská štatistická a demografická spoločnosť spolu s Katedrou matematiky FPV UKF v Nitre, s Pracoviskom Štatistického úradu Slovenskej republiky (ŠÚ SR) v Nitre a tiež aj s Inštitútom zamestnanosti.



Obr. 1 Účastníci konferencie v rokovacej miestnosti

Po slávnostnom otvorení pokračovala konferencia panelovou diskusiou na tému Zamestnanosť a starnutie populácie, v rámci ktorej boli prezentované výsledky projektu Politiky zamestnanosti realizovaného Inštitútom zamestnanosti. Tento projekt je podporený z Európskeho sociálneho fondu v rámci OP EVS. V rámci panelovej diskusie odznela pozvaná prednáška RNDr. Viliama Pálenika, PhD., h.doc. z Ekonomického ústavu Slovenskej akadémie vied v Bratislave s názvom *Dlhodobá starostlivosť ako súčasť striebornej ekonomiky – riziká a príklad riešenia*. Na prednášku tematicky nadviazali ďalšie príspevky venujúce sa regionálnej štatistike a demografii. Program po prestávke

pokračoval druhou panelovou diskusi, o vyučovaní a štatistike. Panelová diskusia začala prednáškou doc. Ing. Ivety Stankovičovej, PhD. s názvom *Nové trendy v univerzitnom vyučovaní štatistiky* a pokračoval príspevkami, ktoré využívali aparát štatistiky vo výskume v teórii vyučovania matematiky.

Piatkový program sa už tradične konal na pracovisku Štatistického úradu SR v Nitre. Hneď v úvode Ing. Renáta Dušová, riaditeľka Pracoviska ŠÚ SR v Nitre privítala hostí a program potom pokračoval workshopom. Celý workshop pripravili aj zabezpečovali pracovníci ŠÚ SR. Počas workshopu sa účastníci mohli okrem iného oboznámiť s dátami, ktoré sprostredkúva ŠÚ SR, databázami STATdat a DATAcube a tiež aj s prácou s uvedenými databázami. Na workshope sa zúčastnili nielen pracovníci, doktorandi a študenti Katedry matematiky, ale aj pracovníci, doktorandi a študenti iných katedier UKF v Nitre.



Obr. 2 Účastníci workshopu na Pracovisku ŠÚ SR v Nitre

Organizátori konferencie by chceli touto cestou vysloviť poďakovanie vedeniu Fakulty prírodných vied Univerzity Konštantína Filozofa v Nitre za podporu a pomoc pri organizovaní konferencie, zvlášť dekanovi FPV UKF v Nitre, prof. RNDr. Františkovi Petrovičovi, PhD., ktorý konferenciu osobne uviedol a tiež aj všetkým účastníkom konferencie za aktívnu účasť. Na záver by sme ešte chceli poďakovať všetkým pracovníkom a doktorandom KM, ktorí sa na príprave a úspešnom priebehu konferencie podieľali.

Janka Medová, Anna Tirpáková
Katedra matematiky, Fakulta prírodných vied
Univerzita Konštantína Filozofa v Nitre

Pohľady na ekonomiku Slovenska 2019 Informácia o konaní udalosti SŠDS

Views on the Slovak Economy 2019 Information about an event by SŠDS

Dňa 25. apríla 2019 sa konal 19. ročník konferencie ***Pohľady na ekonomiku Slovenska 2019*** (PES 2019) na pôde Ekonomickej univerzity v Bratislave. Konferenciu organizuje Slovenská štatistická a demografická spoločnosť (SŠDS) každoročne už od roku 2001. Jej tradíciu založil docent Jozef Chajdiak, dlhoročný vedecký tajomník a predseda SŠDS, ktorý bol počas 16 rokov aj predsedom programového a organizačného výboru.

Záštitu nad podujatím opäť prevzal predseda Štatistického úradu SR (ŠÚ SR) Ing. Alexander Ballek. Spoluorganizátorom konferencie bola aj Slovenská akadémia vied (SAV). Priestory poskytla a zabezpečila Fakulta hospodárskej informatiky na Ekonomickej univerzite v Bratislave, Dolnozemska cesta č. 1, v spoločenskej miestnosti V-1. Podpredseda ŠÚ SR Ing. František Bernadič sa ujal vedenia programového výboru a celú konferenciu aj moderoval. Programový výbor zvolil pre tento ročník vysoko aktuálnu tematiku: ***Starnutie obyvateľstva na Slovensku a výzvy pre náš dôchodkový systém.***



Obr. 1 Pohľad na účastníkov konferencie PES 2019 v sále EU Bratislava

V prvej časti boli prednesené strednodobé makroekonomické prognózy ekonomiky Slovenska. Prognostici z vybraných prognostických skupín (Ján Beka z NBS, Ján Haluška z Infostat, Marek Radvanský a Ivan Lichner z EÚ SAV) prezentovali výsledky doterajšieho ekonomického vývoja SR (za rok 2018), ale aj prognózy vývoja HDP na ďalšie obdobie (2019-2022). Diskutovalo sa o alternatívnych scenároch vývoja ekonomiky na Slovensku.

Druhá časť konferencie bola venovaná trendom starnutia obyvateľstva v SR (Branislav Šprocha, Infostat) a diskutovalo sa aj o výzvach, problémoch a riešeniach pre náš dôchodkový systém (Igor Melicherčík z FMFI UK Bratislava a Viliam Páleník z EÚ SAV).

Na konferenciu boli pozvaní zástupcovia ministerstiev SR, zamestnávateľských zväzov a odborov, predstavitelia hospodárskej sféry, bankovní analytici, vedci, učitelia, študenti a aj mnohí ďalší. Programový a organizačný výbor konferencie je presvedčený, že konferencia bola vhodnou príležitosťou na podnetnú výmenu vedeckých a odborných názorov. Zborník článkov s prezentovanými prognózami makroekonomického vývoja SR a abstraktov o starnutí obyvateľstva SR a aktuálnych výzvach pre náš dôchodkový systém z konferencie sa nachádza na stránke našej spoločnosti:

http://www.ssds.sk/casopis/konferencie/ZBORNIK_PES_2019.pdf.

Iveta Stankovičová

členka programového a organizačného výboru

EKOMSTAT 2019

Informácia o konaní udalosti SŠDS

EKOMSTAT 2019

Information about an event by SŠDS

V dňoch 2. až 5. júna 2019 sa konalo tradičné podujatie EKOMSTAT, ktorý každoročne organizuje Slovenská štatistická a demografická spoločnosť (SŠDS). Podujatie sa uskutočnilo v priestoroch Domova speváckeho zboru slovenských učiteľov v Trenčianskych Tepliciach. Témou tohtoročnej vedeckej konferencie EKOMSTAT boli Kvantitatívne metódy na podporu rozhodovania vo vedecko-výskumnej, odbornej a hospodárskej praxi. Tento rok sa konal už 33. ročník podujatia a v príjemnom prostredí kúpeľného mesta sa stretlo celkovo 20 účastníkov. Organizačne tohtoročný EKOMSTAT výrazne podporil Ekonomický ústav SAV a významnou mierou aj Profini, n.o. a Inštitút zamestnanosti.

Počas prvého dňa podujatia sa okrem tradičných blokov prezentácií uskutočnil aj workshop pod patronátom zástupcov Profini, v ktorom bola účastníkmi diskutovaná problematika odvetvových štandardov pre subjekty účtujúce v podvojnom účtovníctve. V doobedňajšom bloku prezentujúci diskutovali priestorové aspekty inflačných očakávaní (M. Širaňová), príjmové nerovnosti a ich súvis s ekonomickým rastom (T. Domonkos) a limity rastu slovenskej ekonomiky v najbližších rokoch (M. Radvanský). Po plenárnej sekcii nasledoval spomínaný workshop. V poobednom bloku prezentácií, organizovanom pod záštitou Inštitútu zamestnanosti, boli diskutované aktuálne problémy slovenského zdravotníctva. Na úvod bolo poukázané na nelichotivý vývoj v oblasti vzdelávacej prípravy zdravotníckych pracovníkov (V. Páleník), následne bol prezentovaný príspevok mapujúci možný vplyv starnutia na situáciu v zdravotníctve (R. Priesol). V ďalšej príspevku A. Dobroľubov prezentoval možné opatrenia smerujúce k zvýšeniu atraktivity sektoru zdravotníctva. Na záver poobedného bloku M. Páleník poukázal na výrazný nárast počtu pracujúcich oficiálne dlhodobo poberajúcich mesačnú odmenu nižšiu ako minimálna mzda.

Počas druhého dňa podujatia boli prezentované príspevky popisujúce regionálne rozdiely v štruktúre spotrebných výdavkov (I. Stankovičová) a metodické a aplikačné aspekty tvorby regionálnych input-output tabuliek a input-output modelu v SR (J. Zachar). Nasledujúce príspevky sa venovali analýze profilu poistného v prípade dôchodkov vyplácaných z druhého piliera (G. Szücs) a príčinám a dôsledkom zaostávania v čerpaní prostriedkov fondov EÚ v aktuálnom programovom období (I. Lichner).



Obr. 1 Účastníci konferencie počas workshopu

Príspevky prezentované v tretí deň podujatia sa zamerali na stanovenie zásadných rozdielov vo význame efektívnosti, účinnosti apod. (S. Koróny) a štatistické prístupy k vykazovaniu údajov v systéme ESSPROS (A. Petrášová). Následne boli diskutované možnosti regionalizácie integrovaného ekonometrického input-output modelu v slovenských podmienkach (I. Lichner). Na záver organizátori poďakovali účastníkom konferencie za hodnotné príspevky.

Tohtoročný EKOMSTAT sa niesol aj v znamení spomínania na dlhoročných organizátorov podujatia doc. Jozefa Chajdiaka a dr. Janka Luhu. Vedecká konferencia už tradične poskytla priestor na konštruktívnu odbornú diskusiu aktuálnych metodických prístupov a riešenia aplikačných problémov. Účastníci podujatia si vymenili poznatky z viacerých príbuzných oblastí a boli utužené vzťahy a nadviazané nové kontakty pre možnú budúcu spoluprácu.

Ivan Lichner
predseda organizačného výboru

17. slovenská demografická konferencia

Informácia o udalosti SŠDS

17th Slovak Demographic Conference

Information about an event by SŠDS

V dňoch 13 a 14. júna 2019 sa uskutočnila 17. Slovenská demografická konferencia v krajskom meste Trnava. Po dvoch rokoch tak konferencia zostala na západnom Slovensku, v roku 2017 sa konala v Nitre. V roku 2021 by sa mala uskutočniť v Žilinskom kraji.

Organizačný výbor pracoval pod vedením Branislava Blehu, predsedníčky spoločnosti Ivety Stankovičovej a riaditeľky trnavského pracoviska ŠÚ SR Jely Gažovej. Konferencia sa uskutočnila v priestoroch Univerzity sv. Cyrila a Metoda v Trnave (UCM) na Bučianskej ulici. Trnava, podobne ako zvyšok Slovenska, sa topila vo vysokých teplotách. Určite to bola jedna z „najhorúcejších“ konferencií za posledné dve dekády. Konferenciu poctil osobnou účasťou predseda Trnavského VÚC Jozef Viskupič. Štatistický úrad SR zastupoval jeho podpredseda František Bernadič. Po otvorení nasledovalo už tradičné predstavenie hostujúceho kraja pani riaditeľkou Jelou Gažovou.



Obr. 2 Otvorenie konferencie - pohľad na predsednícky stôl
(zľava: B. Bleha, J. Viskupič, I. Stankovičová, F. Bernadič)

Vedecká časť programu konferencie prebiehala formou prezentácií a diskusií. Ústrednou témou konferencie bola pokračujúca transformácia rodinného, reprodukčného a migračného správania, v zhode s témou konferencie boli aj prezentované výskumy. Prvý deň odborný program otvoril plenárnou

prednáškou Boris Vaňo (Infostat), ktorý komplexne zhrnul demografickú transformáciu Slovenska v kontexte 2. demografického prechodu. Nasledovali prezentácie zamerané na vývoj plodnosti (K. Pastor), sobášnosti (M. Kočiš, V. Krišková), vzťah plodnosti a úrovne spoločenského rozvoja (P. Ďurček), a napokon aj rozvodovosti (A. Garajová). Druhý deň sa témy dotkli aj ďalších demografických procesov – klimaticky podmienenej migrácie (D. Kusendová, L. Belušák), úmrtnosti (M. Brisudová, G. Szűcs), štruktúry spotrebných výdavkov slovenských domácností (I. Stankovičová), a napokon dopadov demografickej transformácie na spoločnosť (B. Vaňo, B. Bleha).



Obr. 3 Plenárna prednáška Borisa Vaňa (Infostat)

Záverečnou časťou odborného programu bola diskusia a formulovanie záverov, ktoré sú dostupné aj na webe Slovenskej štatistickej a demografickej spoločnosti, a ktoré boli odoslané formou listu aj predsedovi vlády Slovenskej republiky. V záveroch sa plénum účastníkov konferencie o. i. jednoznačne zhodlo na potrebe prijatia (ďalších) opatrení v rovine ovplyvňovania demografického vývoja na Slovensku, ale aj v rovine adaptácie na niektoré nezvratné zmeny, ktorých existenciu a nespochybniteľnosť viaceré prezentácie opäť potvrdili.

Poslednou časťou programu konferencie bola exkurzia so sprievodcom po „slovenskom Ríme“. Trnava svojím návštevníkom ponúka veľké množstvo (nielen) sakrálnych pamiatok. Napriek horúčave bola návšteva mesta príjemným spestrením a doplnkom po odbornom programe.

Branislav Bleha
predseda organizačného výboru

Príloha/Supplement

Závery 17. slovenskej demografickej konferencie

Conclusions of the 17th Slovak Demographic Conference

Plénium účastníkov 17. Slovenskej demografickej konferencie v Trnave v dňoch 13. - 14. 6. 2019 na svojom záverečnom zasadnutí sformulovalo nasledovné konštatovania a závery:

1. Demografický vývoj na Slovensku prešiel po roku 1989 razantnými transformačnými zmenami a jeho charakter sa v mnohých ohľadoch priblížil charakteru reprodukcie v Západnej Európe. Po viac ako troch dekádach možno transformáciu považovať v zásade za ukončenú, hoci v niektorých regiónoch a sociálnych skupinách tomu tak úplne nie je.
2. To, že transformácia je na konci neznamena, že nebudú prebiehať ďalšie zmeny, pretože demografický vývoj je pomerne dynamický jav. Vývoj (predovšetkým) za posledných 30 rokov položil základy niektorých nezvratných resp. ťažko ovplyvniteľných budúcich trendov, ktoré napriek spochybňovaniu niektorými predstaviteľmi rozhodovacej sféry, sú vysoko pravdepodobné. Sú to nasledovné trendy:
 - a) *Stagnujúci resp. v horizonte niekoľkých dekád klesajúci počet obyvateľov.* Pokles počtu obyvateľov nenastane iba v prípade mimoriadne priaznivo sa vyvíjajúcej plodnosti a najmä v prípade výrazného kladného migračného salda. *Každopádne, počet obyvateľov v týchto intenciách nepredstavuje závažný demografický problém.*
 - b) *Populačné starnutie* už je a aj bude najviac relevantnou črtou budúceho demografického vývoja. Ďalej sa bude zvyšovať priemerný vek, počet neproduktívnych osôb vzhľadom na počet osôb produktívnych, index starnutia. *Konštatujeme, že populačné starnutie je nezvratné a nastane s pravdepodobnosťou hraničiacou s istotou.* Ani výrazný prílev migrantov, ani výrazne vyššia ako predpokladaná úhrnná plodnosť populačnému starnutiu nezabráni.
 - c) *Výrazné regionálne rozdiely v demografickom vývoji* sú taktiež fundamentálnou črtou demografického vývoja na Slovensku.
3. **Vyššie uvedené skutočnosti podľa názoru pléna konferencie majú nasledovné implikácie:**
 - a) Slovensko potrebuje jednoznačnú, koherentnú a najmä *reálne aplikovateľnú populačnú politiku* – to znamená systémový súbor opatrení zameraný na ovplyvnenie populačného vývoja prostredníctvom sociálnej, rodinnej, migračnej, bytovej i zdravotnej politiky. Populačná politika je teda predovšetkým súbor opatrení iných existujúcich politík, ktoré sú ale

aplikované za účelom ovplyvnenia populačného vývoja. *Každopádne treba aplikovať široké spektrum opatrení.*

- b) *Populačná politika sa týka aj priamych a nepriamych pronatalitných opatrení.* Hoci efektívnosť pronatalitných opatrení je obmedzená, treba ich realizovať, pretože aj nárast úhrnnej plodnosti o 0,1 dieťaťa má určitý vplyv na budúce starnutie. Zároveň je dôležité, aby išlo o dlhodobu udržateľné a stabilné opatrenia. Populačné politiky možno rozdeliť na tie, ktoré sa pokúšajú *demografický vývoj priamo ovplyvniť* (imigrácia, pronatalitné nástroje). Tieto sú veľmi dôležité, ale rovnako netreba zabudnúť na tzv. *adaptačné opatrenia*. Tie sa pokúšajú zmierniť dopady demografického vývoja.
- c) **Ukazuje sa, že napriek tomu, že demografi na tieto skutočnosti poukazujú už minimálne dve dekády, opatrenia na centrálnej, regionálnej i lokálnej úrovni sú nedostatočné, v niektorých oblastiach v podstate žiadne, a niektoré dokonca idú proti reálnej adaptácii na niektoré nezvratné demografické zmeny. Je potrebné zdôrazniť, že neriešenie týchto problémov dopadne nie na súčasných dôchodcov, ale na budúce generácie, ktoré sú v súčasnosti mladšími pracujúcimi, deťmi, a na generácie, ktoré sa ešte ani nenarodili.**

V Trnave dňa 14.6.2019

Za prof. RNDr. Jozefom Komorníkom, DrSc.

(* 28-04-1950 † 30-06-2019)

Smútočný oznam

In memory of prof. RNDr. Jozef Komorník, DrSc.

(* 28-04-1950 † 30-06-2019)

Obituary

V nedeľu 30. júna vo veku 69 rokov náhle zomrel bývalý dlhoročný dekan Fakulty managementu Univerzity Komenského v Bratislave Jozef Komorník. Dekanom na FM UK bol 4 funkčné obdobia, konkrétne v rokoch 2000 – 2007 a po prestávke aj 2011 – 2018. Posledná rozlúčka s prof. Jozefom Komorníkom sa konala v stredu 3. júla 2019 na cintoríne v Lamači.



Niektoré fakty z jeho životopisu

Prof. RNDr. Jozef Komorník, DrSc. absolvoval štúdium matematiky na Univerzite Komenského v Bratislave, Prírodovedeckej fakulte, kde obhájil aj titul doktora prírodných vied. Internú ašpirantúru absolvoval v roku 1978 v odbore pravdepodobnosť a matematická štatistika na Univerzite Komenského v Bratislave, Prírodovedeckej fakulte. Habilitačné konanie úspešne ukončil v roku 1981 v odbore pravdepodobnosť a matematická štatistika na Univerzite Komenského v Bratislave, Matematicko-fyzikálnej fakulte. O sedem rokov neskôr mu bol udelený titul doktora vied na tej istej fakulte v rovnakom odbore. Inauguračné konanie ukončil v roku 1989 získaním titulu profesor na Univerzite Komenského v Bratislave, Matematicko-fyzikálnej fakulte.

V roku 1991 spoluzakladal Fakultu managementu na UK v Bratislave, prvú fakultu v Slovenskej republike, ktorá začala pôsobiť v študijnom odbore manažment a špecializuje sa na výučbu manažmentu a medzinárodného manažmentu. Na tejto fakulte pôsobil nepretržite na pozícii vedúceho Katedry ekonómie a financií od roku 1993. V roku 2008 inicioval vznik študijného programu Medzinárodný manažment, ktorý na magisterskom stupni štúdia aj garantoval. Dekanom na tejto fakulte bol spolu 16 rokov, t.j. spolu 4 funkčné obdobia, konkrétne to bolo v rokoch 2000 – 2007 a 2011 – 2018.

V rámci jednotlivých stupňov štúdia bol zodpovedný za prednášky v nasledujúcich predmetoch:

- Štatistika (predmet vyučovaný v anglickom jazyku), 1. stupeň štúdia,
- Štatistické metódy (predmet vyučovaný v anglickom jazyku), 1. stupeň štúdia,
- Základy finančného manažmentu (predmet vyučovaný v anglickom jazyku), 1. stupeň štúdia,
- Medzinárodné financie (predmet vyučovaný v anglickom jazyku), 2. stupeň štúdia,
- Štatistika (predmet vyučovaný v slovenskom aj anglickom jazyku), 3. stupeň štúdia,
- Smery rozvoja jednotlivých oblastí manažmentu (predmet vyučovaný v slovenskom jazyku), 3. stupeň štúdia.

V rámci svojej prednáškovej činnosti zaznamenal takmer 30 pozvaných prednášok na medzinárodnej úrovni, ako hosťujúci profesor pôsobil v Taliansku (International Institute for European Studies, Trieste), Poľsku (Inštitút Stefana Banacha, Waršava), Francúzsku (Univerzita Bordeaux II), Holandsku (Univerzita Groningen) a Spojených štátoch amerických (Katz Graduate School of Business, Pittsburgh).

Profesor Jozef Komorník dostal 11. apríla 2014 aj významné francúzske ocenenie Rád Oficiera Akademických paliem (Palmes Académiques). Tento rád udeľuje minister školstva Francúzskej republiky za výnimočnú pedagogickú činnosť, ktorá prispieva k šíreniu a publicite francúzskeho jazyka a kultúry. Akademická palma zdobí významných pedagógov už od roku 1808, kedy ju založil Napoleon Bonaparte. Vo Francúzsku je najvyšším ocenením pedagogickej práce. Rád môžu získať aj akademici z iných krajín.

Profesor Jozef Komorník bol dlhé roky aktívnym členom našej vedeckej spoločnosti a do roku 2018 aj členom Výboru SŠDS.

Češť jeho pamiatke.

Iveta Stankovičová
predsedníčka SŠDS




Publikačná etika a vyhlásenie k nekalým praktikám

Redakčná rada Forum Statisticum Slovacum (ďalej len RR FSS) sa v plnom rozsahu stotožňuje s princípmi etiky publikovania deklarovanými Výborom pre publikačnú etiku. RR FSS prijíma štandardy publikačnej etiky a zavádza opatrenia proti akejkoľvek publikácii s nekalými praktikami. Autori predkladajú svoje práce do časopisu na publikovanie s vyhlásením, že predložené práce sú príspevky autorov a neboli kopírované alebo plagizované z iných prác. Editori posudzujú rukopisy na základe ich intelektuálneho obsahu, bez ohľadu na rasu, pohlavie, sexuálnu orientáciu, náboženské vyznanie, etnický pôvod, štátnu príslušnosť alebo politickú filozofiu autorov. RR FSS očakáva, že všetky strany podieľajúce sa na FSS dodržia publikačnú etiku. RR FSS nebude tolerovať plagiátorstvo alebo iné neetické správanie a neuverejní rukopis, ktorý nespĺňa tieto normy.

Zodpovednosť autorov: Autori potvrdzujú, že ich rukopis je ich pôvodnou prácou, že nebol doteraz uverejnený v rovnakej podobe a zároveň nie je v súčasnej dobe podaný na uverejnenie inde. Autori musia bezodkladne oznámiť RR FSS všetky strety záujmov. Autori musia uviesť všetky zdroje použité pri tvorbe svojho rukopisu. Autori musia bezodkladne nahlásiť všetky chyby, ktoré objavia vo svojom rukopise RR FSS.

Zodpovednosť recenzentov: Recenzenti musia oznámiť RR FSS všetky strety záujmov. Recenzenti musia uchovávať informácie týkajúce sa rukopisu ako dôverné. Recenzent musí upozorniť predsedu RR FSS na informácie, ktoré môžu byť dôvodom na zamietnutie vydania rukopisu. Recenzenti posudzujú rukopisy len na základe ich intelektuálneho obsahu.

Zodpovednosť RR FSS: RR FSS musí uchovávať informácie o podaných rukopisoch ako dôverné. RR FSS musí posúdiť rukopisy len na základe ich intelektuálneho obsahu. RR FSS rozhoduje o zverejnení predložených rukopisov. RR FSS odmietne príspevok, ktorý nie je v súlade s požiadavkami etiky publikovania.



Publication ethics and malpractice statement

The Editorial Board of Forum Statisticum Slovacum (hereinafter abbreviated as EB/FSS) is fully associated with the principles of ethics of publication declared by the Committee of Publication Ethics. The EB/FSS is committed to upholding the highest standards of publication ethics and takes all possible measures against any publication malpractices. Authors submitting their works to the journal for publication as original articles attest that the submitted works represent their authors' contributions and have not been copied or plagiarized in whole or in part from other works. An editor at any time evaluate manuscripts for their intellectual content without regard to race, gender, sexual orientation, religious belief, ethnic origin, citizenship, or political philosophy of the authors. The EB/FSS expects all parties participating in the publication of Forum Statisticum Slovacum commit to these publication ethics. The EB/FSS does not tolerate plagiarism or other unethical behaviour and will remove any manuscript that does not meet these standards.

Author responsibilities: Authors certify that their manuscripts are their original work unpublished previously elsewhere in the same form and not currently being considered for publication elsewhere. Authors must notify the EB/FSS of any conflicts of interest without any delay. Authors must identify all sources used in the creation of their manuscript. Authors must report any errors they discover in their manuscript to the EB/FSS without any delay.

Reviewer responsibilities: Reviewers must notify the EB/FSS of any conflicts of interest. Reviewers must keep information pertaining to the manuscript confidential. Reviewers must bring to the attention of the head of EB/FSS any information that may be reason to reject publication of a manuscript. Reviewers must evaluate manuscripts only for their intellectual content.


Editorial responsibilities: The EB/FSS must keep information pertaining to submitted manuscripts confidential. The EB/FSS must evaluate manuscripts only for their intellectual content. The EB/FSS is responsible for making publication decisions for submitted manuscripts. EB/FSS refuses the manuscript, which is not in accordance with the requirements of publishing ethics.

Obsah / Table of contentsVedecké články / Full papers

Časovo-prostorová statistická analýza finančných dát Spatio-temporal statistical analysis of financial data	
Marej Brabec, Marek Malý	1
Predikcia finančného zdravia vybraných podnikov v Slovenskej republike Predicting financial health of selected companies in the Slovak Republic	
Mária Danišovská, Mária Stachová	10
Hodnotenie výkonnosti zamestnancov pomocou DEA: prípadová štúdia Performance evaluation of employees by using DEA: a case study	
Viera Mendelová	29
Model pre predpovedanie kríz na základe postupu pri makroekonomických nerovnováhach v podmienkach Slovenska A model for predicting crises on the basis of the macroeconomic imbalance procedure in the conditions of Slovakia	
Filip Ostrihoň	41
Použití výstupního systému SAS pro vytváření pracovních listů programu Microsoft Excel Using the SAS Output Delivery System to create Microsoft Excel worksheets	
Roman Pavelka	54

Zo života SŠDS / From the life of SŠDS

Nitranské štatistické dni 2019 [informácia o konaní udalosti SŠDS] Statistical Days in Nitra 2019 [information about an event by SŠDS]	
Janka Medová, Anna Tirpáková	67
Pohľady na ekonomiku Slovenska 2019 [informácia o konaní udalosti SŠDS] Views on the Slovak Economy 2019 [information about an event by SŠDS]	
Iveta Stankovičová	69
Ekostat 2019 [informácia o konaní udalosti SŠDS] Ekostat 2019 [information about an event by SŠDS]	
Ivan Lichner	71
17. slovenská demografická konferencia [informácia o konaní udalosti SŠDS] vrátane záverov z konferencie 17th Slovak Demographic Conference [information about an event by SŠDS] including the conclusions of the conference	
Branislav Bleha	73
Za prof. RNDr. Jozefom Komorníkom, DrSc. (*28/04/1950 † 30/06/2019) [smútočný oznam] In memory of prof. RNDr. Jozef Komorník, DrSc. (*28/04/1950 † 30/06/2019) [obituary]	
Iveta Stankovičová	77



Cena / price: 25 €
 Ročné predplatné / annual subscription: 50 €
 Publikované / published: July 2019