

EKONOMIKA INFORMATIKA

vedecký časopis FHI EU v Bratislave a SSHI

2

2024

Ročník XXII.



- **hospodárska informatika**
- **účtovníctvo a audítorstvo**
- **ekonometria a operačný výskum**
- **aplikovaná štatistika**
- **aktuárstvo**

Vydavateľ

Fakulta hospodárskej informatiky Ekonomickej univerzity v Bratislave
a Slovenská spoločnosť pre hospodársku informatiku

IČO vydavateľa 00 399 957

Redakčná rada

Erik Šoltés - predseda

Ekonomická univerzita v Bratislave

Nenad Bjelić

University of Belgrade

Ivan Brezina

Ekonomická univerzita v Bratislave

Tatiana Čorejová

Žilinská univerzita v Žiline

Ferdinand Daňo

Ekonomická univerzita v Bratislave

Christopher D. Daykin

Government Actuary's Department, London

Dana Dluhošová

Vysoká škola báňská - Technická univerzita Ostrava

Richard Farkaš

KPMG Slovensko, spol. s r.o.

Richard Hindls

Vysoká škola ekonomická v Praze

Josef Jablonský

Vysoká škola ekonomická v Praze

Václav Janeček

Univerzita Hradec Králové

Luboš Marek

Vysoká škola ekonomická v Praze

Karol Matiaško

Žilinská univerzita v Žiline

Ladislav Mejzlík

Vysoká škola ekonomická v Praze

Józef Pociecha

Cracow University of Economics

Vincent Šoltés

Technická univerzita v Košiciach

Paweł Ulman

Cracow University of Economics

Gejza Wimmer

Univerzita Mateja Bela v Banskej Bystrici

Emin Zeytinoğlu

Kütahya Dumlupınar University

Marcela Žárová

Vysoká škola ekonomická v Praze

Výkonná rada

Michaela Chocholatá - manažér

Ekonomická univerzita v Bratislave

Michal Páleš

Ekonomická univerzita v Bratislave

Juraj Pekár

Ekonomická univerzita v Bratislave

Marian Reiff

Ekonomická univerzita v Bratislave

Yuliia Serpeninova

Ekonomická univerzita v Bratislave

Peter Schmidt

Ekonomická univerzita v Bratislave

Mária Vojtková

Ekonomická univerzita v Bratislave

Redaktorka: Eva Čerteková

Adresa redakcie: Fakulta hospodárskej informatiky, Ekonomická univerzita v Bratislave

Dolnozemska cesta 1, 852 35 Bratislava

tel.: 02/6729 5723, e-mail: eva.certekova@euba.sk

Dátum vydania periodickej tlače: december 2024

ISSN 1339-987X (online)

ISSN 1336-3514 (online vydanie)

OBSAH 2/2024

VEDECKÉ STATE A DISKUSIE

Michal Bogár	4
EXPLORATÍVNA ANALÝZA ODCHODOVOSTI ZÁKAZNÍKOV: VYUŽITIE VIZUALIZAČNÝCH NÁSTROJOV V PYTHONĚ	
Monika Ferenčáková	18
PREHLAD ENVIRONMENTÁLNYCH MODELOV, KTORÉ RIEŠIA PROBLEMATIKU PREPRAVY	
Lívia Krajčíková, Mária Vojtková	26
REGIONÁLNA ANALÝZA SLOVENSKÝCH DOMÁCNOSTÍ Z HĽADISKA SPOTREBNÝCH VÝDAVKOV V ROKOCH 2021 A 2022	
Martina Podmanická	36
DOPAD APLIKÁCIE ZÁSADY OPATRNOSTI NA VERNÝ A PRAVDIVÝ OBRAZ POSKYTNUTÝ ÚČTOVNOU ZÁVIERKOU ZOSTAVENOU V SÚLADE SO SLOVENSKOU ÚČTOVNOU LEGISLATÍVOU	
Peter Procházka	49
EFEKTIVITA DIFÚZNYCH MODELOV V MULTIMEDIÁLNEJ TVORBE	
Zsolt Simonka, Anna Strešňáková, František Slaninka	60
VYUŽITIE AR V STEM VZDELÁVANÍ – NÁSTROJE, APLIKÁCIE A ASPEKTY ICH VYUŽITIA (VÝBER)	
František Slaninka, Zsolt Simonka	76
VÝPOČET PRAVDEPODOBNOSTI KRACHU PRI APLIKÁCII LCR ZAISTENIA	
Pavol Sojka	86
NÁSTROJ NA APLIKOVANIE MODELOV GENEROVANÝCH PROSTRIEDKAMI AUTOMATICKÉHO STROJOVÉHO UČENIA IMPLEMENTOVANÝ AKO WEBOVÁ APLIKÁCIA	
EXTERNÍ RECENZENTI	94

Exploratívna analýza odchodovosti zákazníkov: Využitie vizualizačných nástrojov v Pythone

Exploratory Analysis of Customer Churn: Utilizing Visualization Tools Available for Python

Michal Bogár¹

Abstrakt

Exploratívna dátová analýza sa ukázala byť dôležitým nástrojom pri snahe lepšie pochopiť odchodovosť zákazníkov telekomunikačného operátora, a to skúmaním údajov o viac ako 7000 zákazníkoch, pričom boli využité nástroje z ekosystému Python, najmä Jupyter Lab, spolu s knižnicami ako pandas, NumPy, Seaborn a Plotly. Tento článok vychádza z myšlienok, ktoré koncipoval John Tukey, a zdôrazňuje význam vizualizácie údajov na odhalenie skrytých vzorov a vzťahov v dátach, ktoré ovplyvňujú správanie zákazníkov. Postupnou analýzou rôznych zákazníckych atribútov, od tých demografických, až po premenné, ktoré popisujú ich predplatené služby sme identifikovali trendy vedúce k odchodovosti, vrátane výrazného vplyvu dĺžky viazanosti, rodinného stavu zákazníka a citlivosti na cenu produktov. Získané výsledky poukazujú na to, že zákazníci so zmluvami bez viazanosti a zákazníci bez partnerov alebo detí sú náchylnejší prerušiť zmluvu. Vytvorené interaktívne grafy poskytujú nielen intuitívne prehľady, ale pomáhajú aj pri hlbšom skúmaní dát, čím vytvárajú solídny základ pre prediktívne modelovanie. Táto analýza zdôrazňuje dôležitosť exploratívnej analýzy pri formulovaní účinných retenčných stratégií na udržanie zákazníkov a ponúka možnosti na pokračovanie vo výskume využívajúc pokročilé analytické techniky, ako sú strojové učenie a kohortová analýza, na predikovanie odchodovosti.

Kľúčové slová

Exploratívna analýza, EDA, Odchodovosť zákazníkov, Python

Abstract

The role of Exploratory Data Analysis (EDA) proved to be important in understanding customer churn in telecommunications by examining a dataset of over 7000 customers, utilizing tools from the Python ecosystem, particularly Jupyter Lab, along with libraries such as pandas, NumPy, Seaborn, and Plotly. Based on John Tukey's foundational concepts of EDA, this paper emphasizes the importance of visualizing data to uncover patterns and relationships that influence customer behavior. By systematically analyzing various demographic and service-related attributes, we identified significant trends, including the disproportionate impact of contract types, customer demographics or marital status, and price sensitivity on churn rates. Obtained results highlight that customers with month-to-month contracts, and those without partners or children, exhibit higher churn tendencies. The generated interactive visualizations provide not only intuitive insights but also assist in a deeper exploration of hidden anomalies and trends, setting a robust groundwork for predictive modeling. Ultimately, this analysis underlines the necessity of EDA in formulating effective customer retention strategies, offering ways for future research employing advanced analytical techniques like machine learning and cohort analysis to predict and mitigate churn.

¹ University of Economics in Bratislava, Faculty of Economic Informatics, Department of Operations Research and Econometrics, Dolnozemska cesta 1, 852 35 Bratislava, michal.bogar@euba.sk

Keywords

Exploratory Data Analysis, EDA, Customer Churn, Python

JEL classification

L86, C88

1 Introduction

Exploratory Data Analysis (EDA) is a critical step in understanding data as stated by John W. Tukey (1977) in his influential book that introduced the concept of exploratory analysis. According to Tukey, the key to EDA is knowing where to look and using the right tools to uncover insights in data. This paper focuses on analyzing customer churn in a telecommunications dataset, that comprises over 7000 customers, including a variety of attributes ranging from demographic details to service preferences. By leveraging Jupyter Lab with Python and popular libraries such as pandas, NumPy, and Plotly, we aim to explore patterns in customer behavior and identify factors influencing churn. This analysis will provide a deeper understanding of the data by providing visually clear graphs that uncover key insights into customer behavior and churn patterns, setting the stage for potential predictive modeling.

2 The Role of Exploratory Data Analysis

The pioneer of exploratory analysis, John W. Tukey, in his 1977 book *Exploratory Data Analysis*, writes that exploratory analysis resembles detective work, where one must look in the right places using the right tools.

Nowadays, Exploratory Data Analysis became a crucial aspect of data science, developed to uncover patterns in data and to form hypotheses in research. EDA offers a framework separate from Confirmatory Data Analysis (CDA), which focuses on hypothesis testing. While CDA is critical for confirming well-defined theories, EDA helps in the initial stage where researchers can ask broader questions about their data, leading to insights that may influence subsequent analyses and models. But to clarify, even Tukey recognizes the importance of both CDA and EDA, as they complement each other, and neither would be as effective without the other one (Tukey, 1980).

At its core, EDA encourages willingness to question the data and utilizing graphical visualizations to help with the examination. Rather than holding strictly to predefined hypotheses, it helps data scientists to explore various propositions and investigate multiple potential explanations for observed patterns. This contrasts with CDA, which is more rigid and often focuses only to confirm or reject a specific hypothesis. Common EDA techniques include graphical displays such as dot plots, box plots, and kernel density estimates, which provide intuitive visual representations of data distributions. For instance, box plots offer a summary that effectively summarizes key elements of data distribution while highlighting outliers. Moreover, modern tools to create interactive graphics have emerged, allowing for dynamic exploration of datasets and enabling the identification of significant trends or anomalies (Behrens, 1997).

The role of Python in EDA is getting more prevalent, and today Python is used in a wide range of domains. Peng and colleagues (2021) focus on the use of Python in EDA for statistical modeling, where they identify the most common EDA tasks for statistical modeling. These tasks include general overview, correlation analysis, missing value analysis, univariate and bivariate analysis.

Graff and his team (2022) in turn describe the use of Python to analyze Twitter data, which allows to investigate trends in language usage and analyze events reflected in Twitter data. In addition, this also allows the analysis of the mobility of Twitter users based on the

geolocation data of the tweets and the comparison of different variants of Spanish language in different countries.

Sahoo and colleagues (2019) describe a wider use of Python in EDA using libraries such as Pandas, Matplotlib and Seaborn. These libraries enable data cleaning, transformation, analysis, visualization and other tasks that are essential in the EDA process.

3 Methodology

The methodology for this paper outlines the steps and tools used to analyze customer churn. It begins by describing the dataset, its origins, and characteristics, followed by a detailed explanation of the development environment and libraries employed to process and visualize the data. The selected tools and techniques, including open-source Python libraries, notably Jupyter Lab for efficient code execution and visualization and key libraries including NumPy for handling multi-dimensional arrays, pandas for data manipulation, Seaborn for static data visualization, and Plotly for interactive charts, ensure efficiency and reliability in handling the data and generating insights.

3.1 Characteristics of the analyzed dataset

We will use a dataset compiled by a foreign technology company as the customer data of an unspecified operator that offers telephone, internet and television services. This dataset is available on kaggle.com, a website that focuses on data analytics, sharing datasets, organizing contests, and bringing together the analytics community. It contains anonymous information on more than 7000 customers, including data such as demographic characteristics, information about their subscribed products and services, monthly fees, length of their contracts, and much more. The customer base in the dataset is heterogeneous and provides an all-round view of the market segment, where we can assume a certain degree of imbalance in the dataset, as most customers usually stay with the operator (BlastChar, 2018).

3.2 Development environment and libraries

Considering all the available alternatives, open-source tools from the Python ecosystem are particularly fitting due to their usually free availability and widespread community support. Their performance and reliability are then highlighted even further by the fact that they are used by many specialists.

3.2.1 Jupyter Lab

The Jupyter project is a group of open-source programs including Jupyter Lab, a tool for writing and sharing source code or entire documents, called notebooks, suited for visualizing data and creating interactive elements such as charts and plots. Its use is widespread in the scientific and analytics community for a variety of workflows, including data cleaning, statistical analysis, and creating machine learning models. With the ability to run code in parts by dividing it into individual cells, it allows for logical separation of different parts of a project, which helps to test and demonstrate the procedures and algorithms more efficiently without having to run the entire laptop. It is primarily based on the Python programming language, but its name is based on three programming languages Julia, Python and R. In addition to these, it supports over 100 different languages such as Java, MATLAB and many others (Barba et al., 2019). In this paper, we have decided to use Jupyter Lab in combination with Python and several additional libraries to analyze the dataset, all of which are presented below.

3.2.2 Numpy

NumPy, is an open-source Python library that offers powerful tools for scientific computing. It provides tools for creating and working with multi-dimensional array objects, providing efficient operations with large volumes of data. It is therefore an integral part of the Python ecosystem of scientific libraries and serves as a foundation of many other libraries, as it supports a rich variety of mathematical operations necessary for solving complex analytical tasks (NumPy Developers).

3.2.3 pandas

The pandas library is one of the core open-source packages of the Python programming language, which is extremely helpful in data analysis and data manipulation. It provides robust data structures such as *Series*, for working with one-dimensional data structures, and *DataFrame*, for working with two-dimensional structures. This makes it an ideal tool for working with different types of datasets. More specifically, due to its abilities for handling missing data or converting data types, the pandas package became nearly ubiquitous in the field of data science (The pandas development team).

3.2.4 Seaborn

Seaborn is primarily a graphics library for creating graphs and other graphical elements, building on the foundations of the Matplotlib library and interfacing with data structures of the pandas package to simplify data visualization. It points out intuitive visualizations, which helps to explore and understand available data. Visualizing functions of the library work with data frames and arrays, performing all the required calculations and statistical aggregations internally to generate informative graphs (Waskom, 2021).

3.2.5 Plotly

Plotly is the second graphical library used in this paper, which, compared to Seaborn, can create interactive graphs. Generating graphs is done in an intuitive interface with good syntax and detailed styling options that range from size customization, text color and font size adjustments, to custom element layouts. It supports a large variety of different chart types, such as bar and pie charts, dendrograms, as well as various 3D charts. Moreover, it integrates seamlessly with scientific computing libraries such as Pandas and NumPy. The difference with most of the packages already mentioned is that this library is not based on a completely open-source license and needs to be licensed for commercial use (Di Méo, 2023).

4 Data file analysis and editing

Dataset used for the analysis was obtained from website Kaggle.com and contains 21 variables describing different customer attributes, which are represented by different types of variables. The name of the attribute, what information it describes and what values it can obtain is explained in more detail below.

- customerID - a unique customer identifier composed of both numbers and letters, formatted as an alphanumeric *string*.
- gender - identifies customer's gender, with values of "Female" for women and "Male" for men and thus represents a binary categorical variable.
- SeniorCitizen - defines whether the client is a pensioner, where "0" stands for no and "1" for yes. It acts as a binary categorical variable.
- Partner - indicates whether the customer has a partner. Possible values are "Yes" and "No", which shows that this is a binary categorical variable.

- Dependents - indicates whether the client has children. Allowed values are "Yes" and "No", and therefore it is another dichotomous variable.
- tenure - represents the number of months a customer has been with the company. Values are numeric and the data type is integer, so it is a numeric variable.
- PhoneService - determines whether the client has subscribed to a phone line. The values are either "Yes" or "No" for no service, so it is a dichotomous variable.
- MultipleLines - complements the attribute PhoneService and tells if the customer has multiple phone lines. Values can be "Yes", "No" or "No phone service", indicating that this is a nominal categorical variable.
- InternetService - defines the type of internet connection that the customer uses. The value can be "DSL", "Fiber optic" or "None". This is a nominal categorical variable with multiple options.
- OnlineSecurity - determines whether the client has subscribed to an online security service. Possible values are "Yes", "No" or "No internet service" and thus it is a nominal categorical variable.
- OnlineBackup - indicates whether the customer has an online backup service. Values are "Yes", "No" or "No internet service". This variable is a nominal categorical variable.
- DeviceProtection - describes whether the customer has subscribed to digital device protection. The values are "Yes", "No" or "No internet service". This is a nominal categorical variable.
- TechSupport - reveals whether the customer is paying for technical support. The values are "Yes", "No" or "No internet service", so it is yet another nominal categorical variable.
- StreamingTV - describes whether the customer has a paid service for streaming TV. Possible values are "Yes", "No" or "No internet service" and can be defined as a nominal categorical variable.
- StreamingMovies - similarly, tells us whether the client has a paid service for streaming movies. The values are "Yes", "No" or "No internet service". This variable is a nominal categorical variable.
- Contract - the type of contract commitment that the customer has agreed to. Values can be "Month-to-month", "One year" and "Two years". This is an ordinal categorical variable.
- PaperlessBilling - determines whether the customer prefers electronic billing. Possible values are "Yes" and "No", so this is a binary categorical variable.
- PaymentMethod - the payment method used by the client to pay invoices. Values can be "Electronic check", "Mailed check", "Bank transfer (automatic)" or "Credit card (automatic)". We can say that this is a nominal categorical variable.
- MonthlyCharges - variable contains information about the customer's monthly subscription fee in monetary units of any amount, so it is a numeric continuous variable.
- TotalCharges - this is another attribute that relates to the subscription amount. In this case, it describes the total amount of money the customer has paid so far. Again, the values in this variable are numeric and continuous.
- Churn - whether a customer left or stayed is defined by either a value of "Yes" when they terminated the contract, or "No" when they stayed.

According to this description, it is clear that the dataset contains different types of variables, seventeen of which are categorical. To go into more detail, there are seven binary variables, nine nominal variables and one ordinal variable. In addition, three numeric attributes are also present, where one is discrete and two are continuous. Finally, there is one alphanumeric variable representing the customer identifier.

4.1 Data preparation and cleanup

After importing all necessary libraries and the file containing data in 'csv' format, we can proceed to the actual analysis process. We will work with data in the Jupyter Lab environment using Python, as described in the methodology section. First, we will check how are the attributes stored and whether there are any faulty or missing observations in the dataset. After retrieving information about the dataset, we see there are exactly 7043 non-zero observations out of the total 7043, which would indicate that all records are correct. However, some variables are listed under the *object* data type, even though we stated above they should represent categorical or numeric attributes, which could cause problems later on. Figure 1 below shows output for the first five attributes.

Figure 1: Verification of the number of observations and data types

#	Column	Non-Null Count	Dtype
0	customerID	7043 non-null	object
1	gender	7043 non-null	object
2	SeniorCitizen	7043 non-null	int64
3	Partner	7043 non-null	object
4	Dependents	7043 non-null	object
5	tenure	7043 non-null	int64

Source: (Own elaboration in Python)

This was confirmed when we encountered a problem with the *TotalCharges* variable, which is marked as an *object* in the dataset when in reality, it contains decimal numbers representing total costs. When we tried to change the data type of this variable to *float* (a format representing decimal numbers), an error message appeared, indicating that there was a problem, even though the NaN value check did not find any missing values. By further procedure, we found that the most frequently occurring value in this variable was " " (a blank white character), to be more precise, it occurred eleven times. From this we conclude that the missing values were stored as blank characters, giving the illusion that the data was correct. In addition, we also noticed an unusual situation for the *tenure* variable, where the minimum value reaches 0, which turned out to be related to faulty values in *TotalCharges*. After displaying only observations that have a *tenure* value equal to zero, it shows that these are exactly the eleven erroneous observations that have non-existent *TotalCharges*, as seen on Figure 2.

Figure 2: Dataset statistics in Jupyter Lab and faulty NaN observations

	customerID	gender	SeniorCitizen	Partner	Dependents	tenure	PhoneService	MultipleLines	InternetService	OnlineSecurity	...
count	7043	7043	7043.000000	7043	7043	7043.000000	7043	7043	7043	7043	...
unique	7043	2	NaN	2	2	NaN	2	3	3	3	...
top	7590-VHVEG	Male	NaN	No	No	NaN	Yes	No	Fiber optic	No	...
freq	1	3555	NaN	3641	4933	NaN	6361	3390	3096	3498	...
mean	NaN	NaN	0.162147	NaN	NaN	32.371149	NaN	NaN	NaN	NaN	...
std	NaN	NaN	0.368612	NaN	NaN	24.559481	NaN	NaN	NaN	NaN	...
min	NaN	NaN	0.000000	NaN	NaN	0.000000	NaN	NaN	NaN	NaN	...
25%	NaN	NaN	0.000000	NaN	NaN	9.000000	NaN	NaN	NaN	NaN	...
50%	NaN	NaN	0.000000	NaN	NaN	29.000000	NaN	NaN	NaN	NaN	...
75%	NaN	NaN	0.000000	NaN	NaN	55.000000	NaN	NaN	NaN	NaN	...
max	NaN	NaN	1.000000	NaN	NaN	72.000000	NaN	NaN	NaN	NaN	...

11 rows × 21 columns

Source: (Own elaboration in Python)

A possible explanation as to why these customers had a contract with duration equal to zero is either a simple mistake or they were indeed brand-new customers who were yet to receive a first invoice. In either case, this information is not very interesting for churn analysis and given the fact that there are only 11 such customers we have decided to remove these observations.

Since all the observations were correct, we were able change the necessary data types. We have converted categorical variables into the *category* data type, which is defined in the pandas library. Numeric variables have been converted to *float* and *int* data types (a format representing integers). Finally, we can proceed to the graphical part of the exploratory analysis.

5 Exploratory analysis


Once it is clear what type of data we will be working with and that all the records are correct, we can take a closer look at the data through exploratory analysis, which tends to be one of the first steps in any data analysis. Exploratory data analysis usually involves statistical and graphical outputs and will help us better understand available data and to build new hypotheses.

We decided to primarily use the Plotly library to create the graphs. All created graphs are interactive and after clicking any option in the legend, the graph is recalculated. There is a plethora of different data combinations to create graphs, so we will show the most interesting ones, first for categorical and then for numeric variables.

5.1 Categorical variables

5.1.1 Churn ratio


To begin with, we look at the ratio of customers leaving and staying with the telecommunication company. In the Figure 3 below, we can see that the proportion of customers who have left is approximately 26.6%, indicating that this is indeed an unbalanced dataset.

Figure 3: Customer churn ratio

Source: (Own elaboration in Python - Plotly)

5.1.2 Male and female churn rates

The difference in the total number of male and female customers is minimal, and the same is true when comparing their churn rates. The proportion of men who have left is 26.2%, while for women it is 26.96%. These numbers suggest that gender does not have a significant impact on customers' decision to leave an operator.

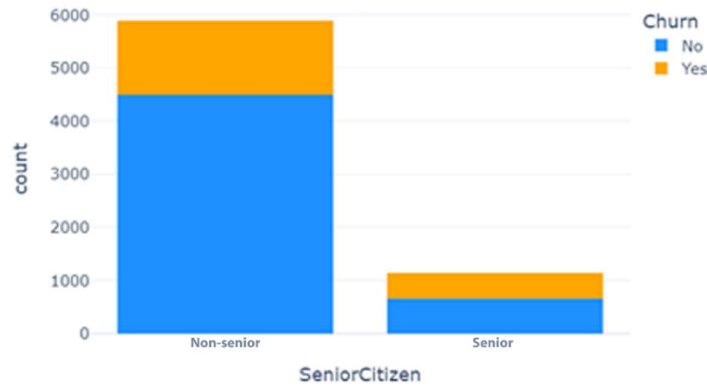
Figure 4: Comparison of male and female churn rates

Source: (Own elaboration in Python - Plotly)

5.1.3 Senior citizen churn rate

On the contrary, the group of senior clients showed a significantly higher churn rate (41.68%) compared to the economically active population (23.65%). Despite the fact that seniors make up only about 16% of the total customer base, they account for 20% of all monthly revenues. This trend shows that seniors represent a group with good purchasing power but at the same time a risky group of customers.

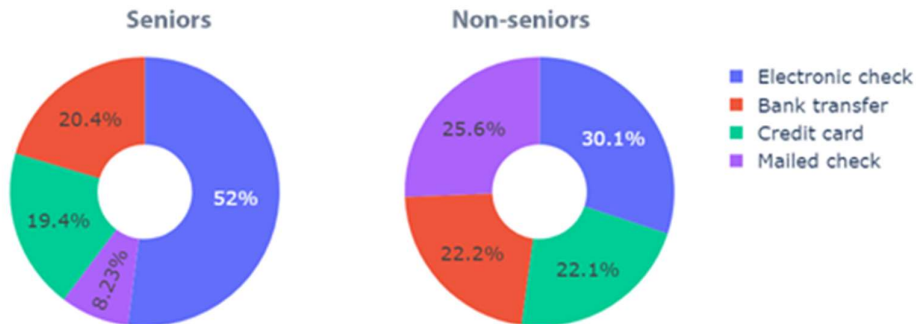
Figure 5: Churn rates for seniors and non-seniors



Source: (Own elaboration in Python - Plotly)

This is followed by pie charts in Figure 6, which compare payment method preferences between senior and non-senior customers. Seniors prefer payment by e-check, used by up to 52% of seniors, while the working population is more divided. Interestingly, for all customers who have left, i.e., not just pensioners, the primary payment method was e-check.

Figure 6: Comparison of payment method

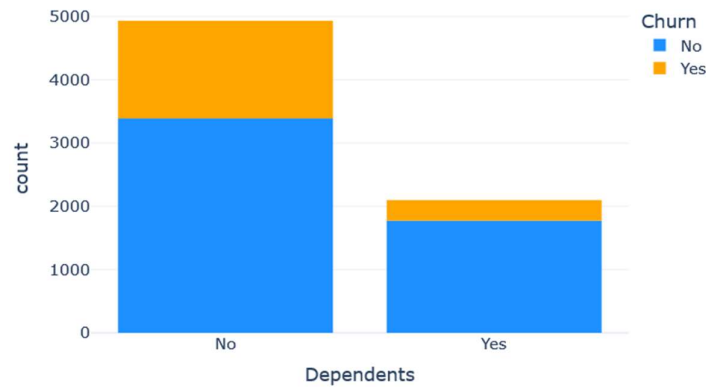


Source: (Own elaboration in Python - Plotly)

5.1.4 Marital status

When it comes to the marital status of clients, variables that describe whether clients have a partner and children can help us to better understand their decision. Clients who do not have children have seen a higher churn rate, which is as high as 31%. This appears to be a sizable difference compared to the churn rate of 15.5% for those with children, so marital status can greatly influence loyalty to a telecommunications service provider.


Figure 7: Churn rate and dependents



Source: (Own elaboration in Python - Plotly)

It is comparable for customers who have a partner. The churn rate for customers with a partner is around 19.7%, but for customers without a partner it is nearly 33%. Besides, both groups, unlike those with dependents, are relatively evenly matched in number of clients, with rates of around 3,000 to 3,500 clients.

Figure 8: Churn rate and partners




Source: (Own elaboration in Python - Plotly)

5.1.5 Contract commitment

Customers with no contract commitment are not only the largest group of customers, but also have by far the highest churn rate and are therefore considered to be a risk group. In contrast, churn rates for one- and two-year contracts are significantly lower, indicating greater loyalty among customers with longer commitment periods.

Figure 9: Comparison of churn rates by the type of contract




Source: (Own elaboration in Python - Plotly)

5.2 Numeric variables

5.2.1 Checking for outliers

Using boxplot plots, we identified that there are no outlier observations present in the dataset that are further than 1.5 times the interquartile range and that could bias the obtained results.

Figure 10: Boxplot for the numerical variables of the dataset




Source: (Own elaboration in Python)

5.2.2 Point charts

Scatter plots of the numerical variables on Figure 11 reveal that there is a relationship between the variables *Tenure*, *MonthlyCharges* and *TotalCharges*. Yellow colored dots represent churned customers, and blue dots represent customers who decided to stay. The relationship between the length of customer loyalty (*tenure*) and the value of monthly payments (*MonthlyCharges*) suggests that customers with shorter tenure and higher monthly payments tend to leave more often. This assumption is reinforced by the dot plot between total costs (*TotalCharges*) and *tenure*, which shows that newer customers (lower *tenure*) who

have paid less in total charges are more inclined to leave. At the same time, according to the last plot, which compares monthly costs (*MonthlyCharges*) and total costs (*TotalCharges*), it seems that those who pay higher monthly fees but have not paid that much in total are more likely to cancel their subscription plan, which would indicate some price sensitivity of customers. These results suggest that for retention, it may be appropriate to focus on customers with higher monthly expenses, especially if they have only been customers for a shorter period of time.

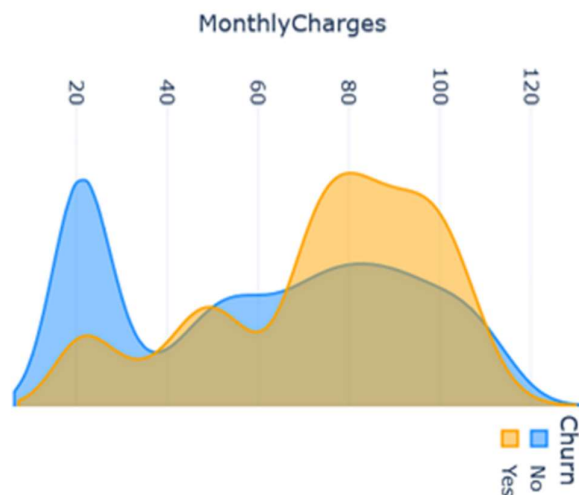
Figure 11: Scatter plots of numerical variables



Source: (Own elaboration in Python - Plotly)

We can also verify our theory about the price sensitivity of customers with a density plot that compares the height of monthly payments separately for customers who decided to leave and those who stayed. The graph below shows that when monthly payments exceed approximately 70 to 80 monetary units, customer churn rises significantly. On the contrary, customer loyalty is higher in the lower price range from 20 to 40 monetary units.

Figure 12: Comparison of churn rates at different monthly payment levels



Source: (Own elaboration in Python - Plotly)

6 Conclusion

In conclusion, utilization of various visualization tools available for Python has proven to be vital for performing exploratory data analysis on churn rates of telecommunication customers. By applying libraries such as pandas, NumPy, Seaborn, and Plotly in a Jupyter Lab environment, we were able to effectively manipulate and visualize complex data relationships, revealing insightful patterns and trends related to customer behavior.

The analysis highlighted the significance of EDA in uncovering factors that contribute to customer churn. By visualizing categorical and numerical variables, we could identify relationships and anomalies that would otherwise remain hidden. The interactive nature of the visualizations allowed us to explore the data dynamically, achieving deeper insights of different customer segments and service preferences.

Therefore, the visualizations created using graphical libraries available for Python have enabled us to uncover important trends in customer behavior, illustrating that demographic factors such as age and marital status or the type of internet service can have a considerable impact on churn rates. Particularly, customers with month-to-month contracts and customers without a partner or children displayed a higher likelihood of leaving the company.

Additionally, our graphical representations, including box plots and scatter plots, not only provided clear insights into the distribution of various customer attributes but also simplified a dynamic exploration of churn patterns, which are crucial for understanding customer retention strategies to mitigate the risk of losing customers.

Finally, this exploratory analysis not only improves our understanding of customer churn but also sets a solid foundation for possible future predictive modeling. By further leveraging the power of Python's visualization and modeling libraries, we can more precisely focus on different customer segments and build strategies to improve customer retention by predicting customer churn with the help of cohort analysis, cluster analysis, machine learning and others.

This work was supported by the Grant Agency of Slovak Republic – VEGA grant no. 1/0047/23 „The importance of spatial spillover effects in the context of the EU's greener and carbon-free Europe priority“.

References

1. Barba, L. A., Barker, L. J., Blank, D. S., Brown, J., Zingale, M., Willing, C., Wickes, E., West, R. H., Watkins, R. R., Niemeyer, K. E., Lippert, D., Moore, J. K., Mandli, K. T., Heagy, L. J., George, T., & Downey, A. (2019). *Teaching and learning with Jupyter*. Jupyter4edu. <https://jupyter4edu.github.io/jupyter-edu-book/>
2. Behrens, J. T. (1997). Principles and procedures of exploratory data analysis. *Psychological Methods*, 2(2), 131–160. <https://doi.org/10.1037/1082-989x.2.2.131>
3. BlastChar. (2018). *Telco customer churn*. Kaggle. <https://www.kaggle.com/datasets/blastchar/telco-customer-churn>
4. Graff, M., Moctezuma, D., Miranda-Jiménez, S., & Tellez, E. S. (2022). A Python Library for Exploratory Data Analysis on Twitter data based on tokens and aggregated origin–destination information. *Computers & Geosciences*, 159, 105012. <https://doi.org/10.1016/j.cageo.2021.105012>
5. Méo, G. D. (2023). Creating interactive visualizations with plotly. *Programming Historian*, (12). <https://doi.org/10.46430/phen0115>
6. NumPy Developers. (n.d.). *What is numpy?*. NumPy v2.1 Manual. <https://numpy.org/doc/stable/user/whatisnumpy.html>
7. The pandas development team. (n.d.). *Package overview*. pandas 2.2.3 documentation. https://pandas.pydata.org/docs/getting_started/overview.html
8. Peng, J., Wu, W., Lockhart, B., Bian, S., Yan, J. N., Xu, L., Chi, Z., Rzeszotarski, J. M., & Wang, J. (2021). DataPrep.EDA: Task-centric Exploratory Data Analysis for statistical modeling in Python. *Proceedings of the 2021 International Conference on Management of Data*, 2271–2280. <https://doi.org/10.1145/3448016.3457330>
9. Sahoo, K., Samal, A. K., Pramanik, J., & Pani, S. K. (2019). Exploratory data analysis using Python. *International Journal of Innovative Technology and Exploring Engineering*, 8(12), 4727–4735. <https://doi.org/10.35940/ijitee.l3591.1081219>
10. Tukey, J. W. (1977). *Exploratory Data Analysis*. Addison-Wesley.
11. Tukey, J. W. (1980). We need both exploratory and confirmatory. *The American Statistician*, 34(1), 23–25. <https://doi.org/10.1080/00031305.1980.10482706>
12. Waskom, M. (2021). Seaborn: Statistical data visualization. *Journal of Open Source Software*, 6(60), 2021. <https://doi.org/10.21105/joss.03021>

Prehľad environmentálnych modelov, ktoré riešia problematiku prepravy

Overview of environmental models that solve the problem of transportation

Monika Ferenčáková¹

Abstrakt

V súčasnej dobe je environmentálny dopad prepravy tovaru kľúčovým aspektom efektívneho riadenia logistiky. Reverzná logistika, ako proces znovuzískavania a spracovania použitých materiálov, zohráva významnú úlohu v oblasti znižovania odpadov a minimalizácie negatívneho dopadu na životné prostredie. Tento článok sa zaoberá prehľadom vybraných environmentálnych modelov, ktoré riešia problémy spojené s prepravou v rámci reverznej logistiky. Analyzujeme rôzne prístupy, ako sú okružné úlohy s obmedzenou kapacitou a variabilnými podmienkami, pričom sa zameriavame na optimalizáciu trás a minimalizáciu emisií. Diskutujeme aj o súčasných trendoch a výzvach v oblasti výskumu, s cieľom podporiť udržateľné logistické riešenia a prax.

Kľúčové slová

Reverzná logistika, problém prepravy, životné prostredie

Abstract

In today's day and age, environmental consideration of the transport of goods is a key aspect of effective logistics management. Reverse logistics, as the process of recovering and processing used materials, plays a significant role in reducing waste and minimizing the negative impact on the environment. This article discusses an overview of selected environmental models that solve the problems associated with reverse logistics transportation. We analyse different approaches, such as round-trips with limited capacity and variable conditions, focusing on route optimization and minimizing emissions. We also discuss current trends and challenges in the field of research, in order to promote sustainable logistics solutions and practices.

Key words

Reverse logistics, vehicle routing problem, environment

JEL classification

R41, Q52

1 Úvod

Keďže znižovanie odpadu sa stáva hlavným problémom vo väčšine krajinách, koncept reverzných materiálových cyklov postupne nahrádza „jednosmerné“ vnímanie ekonomiky. Reverzná logistika je proces znovuzískavania recyklovateľných materiálov a odpadov z miesta spotreby alebo použitia na opravu, prepracovanie alebo zneškodnenie. Cieľom reverznej logistiky je okrem reklamácie, opravy, opätovného použitia aj recyklácia alebo likvidácia v zmysle platných predpisov a smerníc ekologicky žiaducim spôsobom. (Gežík, 2012)


¹ Ekonomická univerzita v Bratislave, Fakulta hospodárskej informatiky, Katedra operačného výskumu, Dolnozemska cesta 1, 852 35 Bratislava, monika.ferencakova@euba.sk.

Je podmnožinou podnikovej logistiky ako vednej disciplíny, od ktorej sa odčlenila v 90. rokoch a vyvíja sa dodnes. Jej hlavné úlohy sú zber, preprava, triedenie, demontáž a spracovanie použitých výrobkov, s cieľom nájsť im nové využitie, pričom sa dbá na ekologický a ekonomický prínos. Ide o proces zasielania nechceného tovaru od zákazníka späť k výrobcovi a teda začína tam, kde mala logistika skončiť. (Škapa, 2005)

Denne smeruje veľká časť tovaru od kupujúcich späť k výrobcovi. Vzniká množstvo obalového odpadu a znehodnoteného tovaru. Zákazníci požadujú rýchle vrátenie, výmenu alebo vybavenie reklamácie a súčasne očakávajú od podnikov minimalizáciu dopadu spomínaného procesu na životné prostredie.

Analýza jednotlivých prvkov reverznej logistiky sa dostáva do popredia nie len ako súčasť manažérskeho rozhodovania ale aj ako téma minimalizácie nákladov a environmentálnych otázok. Problematike sa okrem samotných podnikov vo veľkej miere venuje aj Európska únia, ktorá prostredníctvom grantov podporuje výskum u oblasti ekológie, riadenia spätných tokov a celkovej recyklácie. Tento článok je zameraný na časť reverznej logistiky, ktorá sa venuje problémom riešiacich prepravu.


Obr. 1: Reverzná logistika



Zdroj: Vlastné spracovanie

Je viacero možností ako sa produkt môže dostať od zákazníka späť do výroby. V tomto procese môže byť zapojených niekoľko subjektov avšak počiatkový a konečný uzol je vopred stanovený. Na obrázku nižšie sú uvedené 4 typy možnej realizácie tohto procesu:

Obr. 2: Typy realizácie spätného toku do výroby



Zdroj: Gežík, 2023

Okružné úlohy sú NP ťažké problémy logistického plánovania, ktoré sa zaoberajú optimalizáciou trás alebo ciest, ktoré prechádzajú cez množstvo bodov alebo uzlov a vracajú sa naspäť do pôvodného bodu. Sú istým priesečníkom bin packing problému a úlohy obchodného cestujúceho. V rámci reverznej logistiky to v praxi znamená, že tieto úlohy v reverznej logistike riešia presun od zákazníkov smerom do výroby. Tieto úlohy orientované na klasickú distribúciu a reverznú logistiku nie sú veľmi odlišné. Jediným rozdielom je smer posunu, teda či sa jedná o distribúciu alebo zber.

Medzi najznámejšie formulácie okružných úloh patria:

- úloha o obchodnom cestujúcom – nájdenie najkratšej cesty medzi všetkými miestami v dopravnej sieti pri minimalizácii počtu najjazdených kilometrov, pričom ich kapacita je neobmedzená.

- úloha čínskeho poštára – nájdenie najkratšej cesty po všetkých komunikáciách v dopravnej sieti pri minimalizácii počtu najjazdených kilometrov,

- úloha rozvozu, resp. zvozu materiálu (ang. Vehical routing problem) – nájdenie najefektívnejšieho rozvozu, resp. zvozu materiálu z centra do miest odberu tovaru pri dodržaní kapacitných ohraničení. (Mieresová , 2013)

Rozvozený problém, známi aj pod názvom Vehical routing problem (VRP), je jedným z najviac študovaných tém o oblasti operačného výskumu. Jedná sa o kombinatorický optimalizačný problém, ktorý vznikol ako generalizácia problému obchodného cestujúceho. Jeho úlohou je nájsť také minimálne trasy vozidla optimálne trasy vozidla tak, aby bol každý vrchol grafu navštívený práve raz a vozidlo ukončilo trasu v rovnakom stredisku, z ktorého trasu začalo, pričom musia byť dodržané vopred známe kapacitné obmedzenia vozidiel. (Čičková 2013)

Cieľom je doručenie tovaru z centrálnych depo na zákazníkov alebo v prípade reverznej logistiky zber tovaru od zákazníkov späť do výroby, pri minimalizácii celkových nákladov na prepravu. S minimalizáciou nákladov na prepravu je spojených viacero vedľajších cieľov ako je minimalizácia dopadu na životné prostredie či zvýšenie rýchlosti procesu vrátenia tovaru a zlepšenia zákazníckeho servisu.

Riešenie problému VRP je náročné kvôli ich NP-ťažkosti, čo obmedzuje efektívnosť matematických metód na riešenie väčších problémov. Z tohto dôvodu sa často využívajú heuristiky a metaheuristiky v praktických aplikáciách, pretože reálne problémy môžu mať obrovský rozsah (napr. zber stoviek vratných tovarov z desiatok domácností, či zberných miest s množstvom vozidiel a obmedzeniami). (Braekers, Ramaekers, Nieuwenhuys, 2016)

Rozšírené verzie VRP zahŕňajú viaceré varianty, ktoré sa snažia reflektovať rôzne reálne podmienky doručovacieho procesu. (Škerlíková, 2012)

Medzi tieto varianty radíme:

- Okružné úlohy s limitovanou kapacitou vozidiel (Capacited VRP),
- Okružné úlohy s viacerými distribučnými centrami (Multi - depot VRP),
- Periodické okružné úlohy (Periodic VRP),
- Okružné úlohy s možnosťou rozdelenia dodávky (Split delivery VRP),
- Okružné úlohy s náhodnými prvkami (Stochastic VRP),
- Okružné úlohy s doručovaním a následným zberom (VRP with backhauls),
- Okružné úlohy s možnosťou vrátenia tovaru (VRP with pick-up and delivering),
- Okružné úlohy s časovými obmedzeniami (VRP with time windows).

2 Vybrané environmentálne modely z oblasti prepravy

Klasickým príkladom rozšírenia úlohy VRP je bežný **kapacitný VRP** (ang. Capacitated Vehicle Routing Problem – CVRP), kde každé vozidlo má jednu trasu, presne stanovenú jeho kapacitu a existuje len jedno depo. (Praveen, Keerthika, Sivapriya, Sarankumar, Boddu, Bhasker, 2022)

Jeho cieľom je nájsť práve tie trasy, pri ktorých sa minimalizujú náklady na prepravu a súčasne neprekračuje kapacita vozidla, ktoré obsluhuje danú trasu. Tento problém má množstvo variantov a komplexných vylepšení, ktoré sa snažia riešiť rôzne reálne problémy s doručovaním a logistikou. Jednou z týchto variant sú Environmentálne okružné úlohy s obmedzenou kapacitou, ktorých cieľ je smerovaný k minimalizácii emisií CO₂, vypúšťaných do ovzdušia pri preprave.

Modifikácia bežného **CVRP s dôrazom na zníženie emisií CO₂** sa odlišuje vo svojom hlavnom cieľovom kritériu. Namiesto zamerania sa na celkovú prejdenú vzdialenosť vozidlami alebo dobu jász, nový cieľ je minimalizácia emisií CO₂ a označujeme ho ako EVRP (ang. Emissions Vehicle Routing Problem – Vehicle Category). Tento prístup berie do úvahy, že spotreba paliva závisí od celkovej hmotnosti vozidla počas jazdy, ich maximálnej nosnosti, a účinnosti spotreby paliva. (Brezina, Šofránková, 2016)

Matematický model úlohy EVRP-VC:

Celkový súčet spotrebovaného paliva:

$$\min \sum_{i \in I} \sum_{j \in J} \sum_{k \in K} p \left(d_{ij} (a_k x_{ijk} + b_k q_{ijk}) \right) \quad (1)$$

Ohraničujúce podmienky:

$$\sum_{i \in I} x_{ijk} = \sum_{i \in I} x_{jik} \quad k \in K, j \in J \quad (2)$$

$$\sum_{i \in I} x_{ijk} = y_{jk} \quad k \in K, j \in J \quad (3)$$

$$\sum_{k \in K} y_{jk} = 1 \quad j \in J \quad (4)$$

$$\sum_{j \in J} x_{0jk} = y_{jk} \quad k \in K \quad (5)$$

$$u_i - u_j + n \sum_{k \in K} x_{ijk} \leq n - 1 \quad i \in I, j \in J \quad (6)$$

$$\sum_{i \in I} \pi_j y_{jk} = Q_k \quad k \in K \quad (7)$$

$$\sum_{i \in I} q_{ijk} - \sum_{i \in I} q_{jik} = \pi_j y_{jk} \quad k \in K, j \in J \quad (8)$$

$$q_{ijk} \leq Q_k x_{ijk} \quad i \in I, k \in K, j \in J \quad (9)$$

$$q_{ijk} \geq 0 \quad i \in I, k \in K, j \in J \quad (10)$$

$$u_i \geq 0 \quad i \in I \quad (11)$$

$$x_{ijk} \in \{0,1\} \quad i \in I, k \in K, j \in J \quad (12)$$

$$y_{ik} \in \{0,1\} \quad i \in I, k \in K \quad (13)$$

kde:

- n - počet uzlov vrátane štartovacieho uzla,
- m - počet vozidiel,
- i - predstavuje označenie uzlu výjazdu vozidla (hodnota 0 je štartovací uzol),
- j - predstavuje uzly príjazdu vozidla,
- k - index vozidiel,
- d_{ij} - vzdialenosti medzi uzlami,

- π_j - požadovaný dopyt zákazníka v uzle j ,
- π_0 - požadovaný nulový dopyt v štartovacom uzle je 0,
- a_k - spotreba na kilometer,
- b_k - spotreba paliva na tonu nákladu,
- Q_k - nosnosť vozidla,
- y_{jk} - určujú, či je alebo nie je uzol j zásobovaný vozidlom k ,
- x_{ijk} - určujú smerovanie vozidla medzi uzlami,
- q_{ijk} - spojité premenná užitočného zaťaženia prepravovaného vozidlom k po trase

Klasické obmedzenia kapacitného problému prepravy sú zahrnuté v ohraničeniach. Obmedzenia určujú aj kapacitné obmedzenia (prebraté z CVRP), avšak bol rozšírený o vzťahy (8) až (10), ktoré zohľadňujú hmotnosť prenášanú vozidlom po trasách rozvozu. (Brezina, Šofránková, 2016)

Okružné úlohy s viacerými skladmi (ang. Multi - depot VRP - MDVRP) je modifikáciou úlohy VRP, pri ktorej predpokladáme, že sa disponuje s viac ako jedným skladom. Ak sú zákazníci blízko skladom, každý sklad má svojich zákazníkov. Ak nie, úloha sa musí modifikovať. Každý sklad má vlastné vozidlá, ktoré obsluhujú len zákazníkov z toho skladu a potom sa vracia. (Škerlíková, 2012)

Cieľom úlohy MDVRP je minimalizovať počet vozidiel, potrebný čas, nájsť najkratšie trasy a pritom zohľadniť množstvo a kapacitu skladov a vozidiel. Riešenie je možné, ak každá trasa spĺňa požiadavky a začína a končí v tom istom sklade. Realizácia tohto cieľa má priamy vplyv aj na životné prostredie, keďže efektívne využitie vozidiel a optimalizované trasy vedú k zníženiu emisií CO₂ a obmedzeniu spotreby paliva. Týmto spôsobom sa prispieva k udržateľnejším logistickým riešeniam a šetrnejšiemu prístupu k životnému prostrediu.

Najdôležitejšie hypotézy tohto problému sú:

- počet dostupných vozidiel je vopred určený,
- kapacita vozidla je pevne definovaná,
- počet a umiestnenie skladov je vopred definovaný,
- počet a lokalita zákazníkov sú vopred definované,
- maximálna rýchlosť vozidla je pevná,
- náklady na dopravu každého vozidla závisia od prejdenej vzdialenosti,
- dopravná sieť sa považuje za symetrickú.

(Mirabi, Shokrib, Sadeghieh, 2016)

Každý deň sa odosiela veľké množstvo vráteného tovaru späť k výrobcovi. **Okružné úlohy s možnosťou vrátenia tovaru** (ang. VRP with pick-up and delivering - VRPSDP) sa stal jednou z najdôležitejších oblastí riadenia logistiky najmä u veľkoobchodov. Táto úloha je obmenou klasickej VRP úlohy. Táto úloha ale predpokladá, že zákazník môže pri doručení komodity aj komoditu vrátiť, pričom sa musí zmestiť do vozidla. Okrem veľkoobchodov sa tento model využíval aj pri jednoduchom rozvoze napr. nápojov, kedy vodič súčasne vezme do vozidla aj prázdne sklenené fľaše do výroby, kde sa môžu znovu zaradiť do výrobného procesu po úprave. Táto dodatočná obmena môže viesť k zväčšeniu prejdenej vzdialenosti vozidiel či potrebe väčšieho množstva vozidiel. (Dethloff, 2001)

Cieľom tejto úlohy je minimalizácia počtu využitých vozidiel a nimi prejdenej vzdialenosti, pričom nesmie byť prekročená kapacita vozidiel pri doručovaní ani preberaní tovaru. (Škerlíková, 2012)

Matematický model úlohy VRPPD

Celkový súčet precestovanej vzdialenosti

$$\text{Min } z = \sum_{i \in J_0} \sum_{j \in J_0} \sum_{v \in V} C_{ij} x_{ijv} \quad (14)$$

Ohraničujúce podmienky:

$$\sum_{i \in J_0} \sum_{v \in V} x_{ijv} = 1 \quad (j \in J) \quad (15)$$

$$\sum_{i \in J_0} x_{isv} = \sum_{i \in J_0} x_{sjv} \quad (s \in J, v \in V) \quad (16)$$

$$l'_v = \sum_{i \in J_0} \sum_{v \in V} D_j x_{ijv} \quad (v \in V) \quad (17)$$

$$l_j \geq l'_v - D_j + P_j - M(1 - x_{0jv}) \quad (j \in J, v \in V) \quad (18)$$

$$l_j \geq l_i - D_j + P_j - M(1 - \sum_{v \in V} x_{ijv}) \quad (i \in J, j \in J, j \neq i) \quad (19)$$

$$l'_v \leq C \quad (v \in V) \quad (20)$$

$$l_j \leq C \quad (j \in J) \quad (21)$$

$$\pi_j \geq \pi_i + 1 - n(1 - \sum_{v \in V} x_{ijv}) \quad (i \in J, j \in J, j \neq i) \quad (22)$$

$$\pi_j \geq 0 \quad (j \in J) \quad (23)$$

$$x_{ijv} \in \{0, 1\} \quad (i \in J_0, j \in J_0, v \in V) \quad (24)$$

kde:

- J - množina všetkých prevádzok zákazníkov,
- J_0 - množina všetkých uzlov, t. j. miest zákazníkov a depa,
- V - množina všetkých vozidiel,
- C - kapacita vozidla,
- C_{ij} - vzdialenosť medzi uzlami,
- D_j - dodacia suma zákazníka
- n - počet uzlov, t. j. $n = |J_0|$
- P_j - množstvo vyzdvihutej dodávky od zákazníka,
- M - veľké číslo,
- L'_v - náklad vozidla pri odchode zo skladu,
- l_j - náklad vozidla po servise zákazníka,
- π_j - premenná používaná na obmedzenie vedľajších ciest,
- x_{ijv} - binárna premenná udávajúca, či vozidlo cestuje priamo z uzla i do uzla j alebo nie

Medzi posledný typ úloh riešiacich prepravu stojí za spomenutie ešte **okružné úlohy s časovými oknami** (ang. VRP with time windows - VRPTW). Toto rozšírenie sa podobá klasickému modelu rozvozu a zvozu, ale s tým, že každý zákazník má stanovený určitý časový interval, v ktorom očakáva doručenie alebo vrátenie tovaru. Tento interval sa nazýva plánovací

horizont. Cieľ tejto úlohy je veľmi podobný ostatným obmenám a to minimalizovať počet vozidiel, ich prejdenú vzdialenosť a čas čakania pri dodržiavaní týchto časových intervalov. (Škerlíková, 2012)

Oproti klasickému rozvozu a zvozu má táto úloha dodatočné obmedzenia:

- Riešenie je neprípustné, ak je zákazník obslužený mimo stanoveného časového intervalu.
- Ak vozidlo dorazí k zákazníkovi predtým, ako má byť obslužený, spôsobí to čakací čas na trase.
- Každá trasa musí začínať a končiť v stanovenom časovom intervale v rámci skladu.
- Pri časových oknách s penalizáciou, oneskorené doručenie neznamená neprípustné riešenie, ale je penalizované pridaním dodatočných hodnôt do celkového riešenia.

Riešenie je akceptovateľné iba vtedy, ak všetky trasy obsluhujú zákazníkov jednou trasou a vozidlá opúšťajú sklad čo najskôr. Tento spôsob pomáha minimalizovať zbytočný čakací čas a prispieva k efektívnemu využitiu vozidiel, čo je prospešné pre životné prostredie.

3 Záver

Zvýšený dôraz na ochranu životného prostredia viedol k hľadaniu efektívnejších spôsobov riadenia dopravy, čím vznikla úzka väzba s problémami spojenými s Vehicle Routing Problem (VRP). Optimalizácia dopravy v rámci VRP umožňuje minimalizovať emisie CO₂ a znižovať množstvo spotrebovanej energie pri efektívnom plánovaní trás a riešiť problémy zvozu odpadu k recyklácii. VRP sa tak stáva dôležitým nástrojom na dosiahnutie cieľov zníženia environmentálneho zaťaženia prostredia a podporuje snahy o udržateľnosť v rámci logistiky a dopravy, čo koreluje s právnymi normami týkajúcimi sa ochrany životného prostredia a spoločenského tlaku na ich dodržiavanie. Je však dôležité poznamenať, že firmy často prezentujú svoje záujmy o životné prostredie iba na povrchu a skutočné zlepšenia sú často implementované kvôli zníženiu nákladov a zvýšeniu zisku.

Príspevok bol spracovaný v rámci riešenia výskumného projektu VEGA – 1/0120/23 „Environmentálne modely ako nástroj ekologicke-ekonomických rozhodnutí“

Literatúra

1. Braekers, K., Ramaekers, K., & Van Nieuwenhuysse, I. (2016). The vehicle routing problem: State of the Art Classification and Review. *Computers & Industrial Engineering*, 99, 300–313. <https://doi.org/10.1016/j.cie.2015.12.007>
2. Brezina, I., Šofránková, B. (2016). Znižovanie emisií v okružných úlohách: Reducing Emissions in Vehicle Routing Problems. *Časopis znalostní společnosti*, 1(4), 11-25. ISSN 2336-2561. Dostupné z: http://jks.euin.org/sites/default/files/jks_2016_01_011-025_Brezina_Sofrankova.pdf
3. Čičková, Z. (2013). *Riešenie okružných ciest* [Habilitationná práca, Ekonomická univerzita v Bratislave].
4. Dethloff, J. (2001). Vehicle routing and reverse logistics: The vehicle routing problem with simultaneous delivery and pick-up. *OR Spektrum*, 23(1), 79–96. <https://doi.org/10.1007/pl00013346>
5. Gežík, P. (2012). *Reverzná logistika a Reverzná logistika a jej modely* [PDF súbor]. Dostupné z: <http://www.fhi.sk/files/katedry/kove/veda-vyskum/prace/2012/Gezik2012d.pdf>
6. Mieresová, L. (2013). *Okružné úlohy s viacerými ohraničeniami* [PDF súbor]. Dostupné z: http://www.fhi.sk/files/katedry/kove/veda-vyskum/prace/2013/Mieresova_Lucia.pdf

7. Mirabi, M., Shokri, N., & Sadeghieh, A. (2016). Modeling and Solving the Multi-depot Vehicle Routing Problem with Time Window by Considering the Flexible end Depot in Each Route. *International Journal of Supply and Operations Management*, 3(3), 1373-1390. doi: 10.22034/2016.3.02
8. Praveen, V., Keerthika, Dr. P., Sivapriya, G., Sarankumar, A., & Bhasker, B. (2022). Vehicle routing optimization problem: A study on capacitated vehicle routing problem. *Materials Today: Proceedings*, 64, 670–674. <https://doi.org/10.1016/j.matpr.2022.05.185>
9. Škapa, R. (2005). *Reverzní Logistika*. Masarykova univerzita.
10. Škerlíková, Z. (2012). *Okružné úlohy s dodatočnými ohraničeniami* [Dizertačná práca, Ekonomická univerzita v Bratislave].

Regionálna analýza slovenských domácností z hľadiska spotrebných výdavkov v rokoch 2021 a 2022

Regional analysis of Slovak households from the point of view of consumption expenditure in 2021 and 2022

Lívia Krajčíková¹, Mária Vojtková¹

Abstrakt

Článok sa zaoberá správaním slovenských domácností z hľadiska spotrebných výdavkov v rokoch 2021 a 2022 s využitím anonymizovaných údajov zo zisťovania rodinných účtov o vybraných slovenských domácnostiach, ich výdavkoch, príjmoch a demografických charakteristikách za roky 2021 a 2022 poskytnutých Štatistickým úradom Slovenskej republiky. Cieľom je regionálna analýza priemerných spotrebných výdavkov slovenských domácností v jednotlivých rokoch. Na overenie vplyvu regiónu podľa klasifikácie NUTS2 na spotrebné výdavky domácností bola použitá metóda analýzy rozptylu. Analýza bola realizovaná prostredníctvom softvéru SAS Enterprise Guide.

Kľúčové slová

rodinné účty, výdavky, domácnosti, spotreba, analýza rozptylu

Abstract

The paper focuses on the behavior of Slovak households from the point of view of consumption expenditure in 2021 and 2022 using anonymized data from the household budget survey on selected Slovak households, their expenditures, income and demographic characteristics for the years 2021 and 2022 provided by the Statistical Office of the Slovak Republic. The aim is to conduct a regional analysis of the average consumption expenditures of Slovak households in individual years. The method of analysis of variance was used to verify the impact of the NUTS2 regions on household consumption expenditures. The analysis was performed by means of the software SAS Enterprise Guide.

Key words

household budget surveys, expenditures, income, households, consumption

JEL classification

R29, C19

1 Úvod

Slovensko je výrazne regionálne diferencované, čo je dané geografickým, kultúrnym, historickým i ekonomickým rozvojom. Regionálne rozdiely možno vnímať v rámci trhu práce i miery nezamestnanosti, čo vyvoláva fenomén vysokých regionálnych rozdielov v mzdovej distribúcii na území Slovenskej republiky. Na Slovensku existujú hlavné mestské oblasti, kde sa sústreďujú ekonomické aktivity a je vysoký dopyt po pracovnej sile a na druhej strane oblasti s absenciou pracovných príležitostí a s vysokou nezamestnanosťou. Výška príjmov

¹ Ekonomická univerzita v Bratislave, Fakulta hospodárskej informatiky, Katedra štatistiky, Dolnozemska cesta 1, 852 35 Bratislava, livia.krajcikova@euba.sk, maria.vojtkova@euba.sk.

jednotlivcov a domácností je tiež determinovaná úrovňou vzdelania a postavením jednotlivcov v štruktúre sociálnych vzťahov a pozíciou na trhu práce (Morvay a kol., 2005).

Skúmanie spotrebiteľského správania v rámci regiónov Slovenska je kľúčové pre lepšie pochopenie ekonomických a sociálnych rozdielov medzi jednotlivými oblasťami krajiny. Regionálne rozdiely v príjmoch, nákladoch a ekonomických podmienkach priamo ovplyvňujú, koľko domácnosti míňajú na spotrebu, a preto je dôležité analyzovať tieto odlišnosti. Takáto analýza môže poskytnúť cenné informácie pre tvorbu verejných politík, ktoré môžu byť prispôsobené špecifickým potrebám rôznych regiónov, napríklad cieľovými opatreniami na zníženie ekonomických nerovností alebo podporu lokálneho rozvoja.

Cieľom našej analýzy je preskúmať, či sa úroveň výdavkov domácností, reprezentovaná strednou hodnotou, líši medzi jednotlivými regiónmi Slovenska alebo je rovnaká. Na identifikáciu týchto rozdielov sme využili analýzu rozptylu, doplnenú o testy mnohonásobného porovnávania. Tieto metódy nám umožnili detailne preskúmať stredné hodnoty výdavkov v rôznych regiónoch a identifikovať štatisticky významné rozdiely medzi nimi. Pracovali sme s údajmi zo zisťovania rodinných účtov o vybraných slovenských domácnostiach za roky 2021 a 2022, ktoré boli poskytnuté Štatistickým úradom Slovenskej republiky. Pri spracovaní a analyzovaní údajov sme pracovali so softvérom SAS Enterprise Guide.

Zisťovanie údajov pre štatistiku rodinných účtov je štátne štatistické zisťovanie, ktoré Štatistický úrad Slovenskej republiky uskutočňuje v súlade s Vyhláškou ŠÚ SR č. 425/2023 Z. z., ktorou sa vydáva Program štátnych štatistických zisťovaní na roky 2024 až 2026 v znení neskorších predpisov (ďalej len „vyhláška“). Podľa tejto vyhlášky je účelom zisťovania rodinných účtov získať informácie o výške, štruktúre a vývoji peňažných výdavkov a príjmov a nepeňažných výdavkov a príjmov fyzických osôb v rôznych typoch domácností, s cieľom použiť získané informácie na tvorbu a monitorovanie verejných politík orgánmi verejnej správy, na plnenie Európskeho štatistického programu a na posudzovanie úprav súm životného minima. Ďalším cieľom zisťovania rodinných účtov je napríklad použiť získané informácie ako jeden z podkladov pre posúdenie stavu ekonomiky spoločnosti, pre analýzu životnej úrovne obyvateľstva a na medzinárodné porovnanie s ostatnými krajinami a pre výpočet váh pre index spotrebiteľských cien (Vlačuha, Hornáček, Vargová, 2023).

Vyhláška vymedzuje za spravodajské jednotky zisťovania rodinných účtov členov domácnosti a určuje mesačnú periodicitu zisťovania. Výsledky zo zisťovania rodinných účtov sú zverejňované v ročných časových intervaloch na Štatistickom úrade SR. V rámci zisťovania informácií o výdavkoch domácností sa sledujú:

- čisté výdavky, ktoré zahŕňajú čisté peňažné výdavky a naturálne výdavky,
- čisté peňažné výdavky, ktoré zahŕňajú spotrebné výdavky a ostatné čisté peňažné výdavky domácnosti.

Pri určovaní spotrebných výdavkov sa používa medzinárodná klasifikácia individuálnej spotreby podľa účelu použitia COICOP, ktorú pre štatistiku rodinných účtov odporúča Eurostat. Podľa tejto klasifikácie sa spotrebné výdavky členia na 12 základných odborov:

1. Potraviny a nealkoholické nápoje (PNN)²,
2. Alkoholické nápoje a tabak (ANTN),
3. Odievanie a obuv (OO),
4. Bývanie, voda, elektrina, plyn a iné palivá (BYV),
5. Nábytok, vybavenie domácnosti a bežná údržba domácnosti (BZ),
6. Zdravie (ZDR),
7. Doprava (DOP),
8. Pošty a telekomunikácie (PT),
9. Rekreačia a kultúra (RK),

² vlastné označenie používané v práci pri analýze spotrebných výdavkov

10. Vzdelávanie (VZD),
11. Reštaurácie a hotely (RH),
12. Rozličné tovary a služby (RH) (Vlačuha, Hornáček, Vargová, 2023).

Hlavným cieľom zisťovania rodinných účtov na národnej úrovni je vypočítať váhy pre index spotrebiteľských cien. Zisťovanie rodinných účtov sa vykonáva vo všetkých krajinách Európskej únie, pričom vo väčšine štátov bolo spustené v 60-tych rokoch 20. storočia. Eurostat zozbierané údaje každej členskej krajiny EÚ zverejňuje v 5 ročných intervaloch (Eurostat). V rámci snahy o zabezpečenie porovnateľnosti údajov zisťovania medzi krajinami i v čase sú využívané metodológie a príručky vydané Eurostatom. Za kľúčový dokument sa považuje Household budget surveys in the EU: methodology and recommendations for harmonisation z roku 2003. Cieľom tohto dokumentu je popísať súčasnú metodológiu používanú pre zisťovanie rodinných účtov a navrhnúť odporúčania pre ďalšiu harmonizáciu a zlepšenie kvality a porovnateľnosti údajov zisťovania na európskej úrovni.

2 Použitá metodológia

Všetky hodnoty spotrebných výdavkov sme pred analýzou prepočítali modifikovanou ekvivalentnou OECD škálou, ktorá sa v súlade s metodikou Eurostatu používa na výpočet ekvivalentnej veľkosti domácnosti. Pri výpočtoch sa používajú koeficienty: 1 pre prvého dospelého člena domácnosti, 0,5 pre druhého a každého dospelého člena domácnosti, 0,5 pre 14-ročných a starších, 0,3 pre každé dieťa mladšie ako 14 rokov (Štatistický úrad SR, 2021).

Pomocou analýzy rozptylu doplnenú o testy mnohonásobného porovnávania sme analyzovali priemerné ročné výdavky na osobu v štyroch regiónoch, ktorých vymedzenie zodpovedá normalizovanej klasifikácii územných celkov NUTS 2³:

- Bratislavský región (SK01),
- Západné Slovensko (SK02),
- Stredné Slovensko (SK03),
- Východné Slovensko (SK04).

Analýzou rozptylu overujeme nulovú hypotézu

$H_0: \mu_1 = \mu_2 = \dots = \mu_k$ (úroveň sledovaného znaku je vo všetkých základných súboroch rovnaká)

oproti alternatívnej hypotéze

H_1 : aspoň dve stredné hodnoty sa nerovnajú.

Analýzu rozptylu možno použiť v prípade, že sú splnené nasledovné podmienky:

1. nezávislosť rozptylu,
2. normalita základných súborov, z ktorých sú robené výbery,
3. homoskedasticita = konštantný rozptyl súborov.

³ Číselník Regionálna štatistická územná jednotka 2 – oblasť, dostupné na:

https://zber.statistics.sk/metaudaje/ciselniky?p_p_id=sk_susr_isis_pub_codelist_portlet_CodelistPortlet_INSTA_NCE_mvcy&p_p_lifecycle=1&p_p_state=normal&p_p_mode=view&_sk_susr_isis_pub_codelist_portlet_CodelistPortlet_INSTANCE_mvcy_javax.portlet.action=showCodelistDetail&_sk_susr_isis_pub_codelist_portlet_CodelistPortlet_INSTANCE_mvcy_navigationType=CODELIST_DETAIL_VIEW&p_auth=w92MsT1x&cIcode=0022&cIversion=1

Na overenie homoskedasticity sa používa viacero testov, pričom sa overuje platnosť nulovej hypotézy:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_k^2 \text{ (náhodná zložka je homoskedastická)}$$

oproti alternatívnej hypotéze

$$H_1: \text{aspoň niektoré rozptyly } \sigma_i^2 \text{ sú rôzne (náhodná zložka je heteroskedastická)} \\ \text{(Pacáková a kol., 2012).}$$

V tabuľke č. 1 analýzy rozptylu sú uvedené vzťahy potrebné k výpočtu hodnoty testovacej štatistiky F , na základe ktorej rozhodujeme o závere analýzy rozptylu. K nasledujúcim vzťahom sú potrebné priemerné hodnoty v i -tej skupine, ktoré vypočítame ako (Kotlebová a kol., 2015):

$$\bar{y}_i = \frac{1}{n_i} \cdot \sum_{j=1}^n y_{ij} \quad (1)$$

a celkový priemer zo všetkých skupín, ktorý vypočítame ako:

$$\bar{y} = \frac{1}{n} \cdot \sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij} \quad (2)$$

Tab. 1: Tabuľka analýzy rozptylu

Zdroj variability	Súčet štvorcov odchýlok	Počet stupňov voľnosti	Priemer štvorcov odchýlok	Hodnota testovacej štatistiky F
Faktor A	$SSA = \sum_{i=1}^k (y_i - \bar{y})^2 \cdot n_i$	$k - 1$	$MSA = \frac{SSA}{k - 1}$	$F = \frac{MSA}{MSE}$
Náhoda E	$SSE = \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_i)^2$	$n - k$	$MSE = \frac{SSE}{n - k}$	
spolu	$SST = \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2$	$n - 1$		

Zdroj: Kotlebová a kol., 2015

Testovacia štatistika F má Fisherovo rozdelenie s počtom stupňov voľnosti $k - 1$ a $n - k$. Nulovú hypotézu zamietame v prípade, ak hodnota testovacej štatistiky F patrí do kritickej oblasti vyjadrenej intervalom $(F_{1-\alpha}; \infty)$ (Kotlebová a kol., 2015).

V prípade, že je pri klasickej analýze rozptylu porušený predpoklad homoskedasticity, podľa Kotlebovej, Sliackeho (2021) možno použiť pre porovnanie priemerov medzi skupinami, ktoré majú rôzne rozptyly, Welchovu analýzu rozptylu. Vzťahy pre výpočet testovacej štatistiky pre Welchovu analýzu rozptylu uvádzajú Kotlebová, Sliacky (2021).

V prípade, že zamietame nulovú hypotézu a prijímame alternatívnu hypotézu o nerovnosti stredných hodnôt súborov, prijímame dosť neurčité tvrdenie, že existuje dvojica (niekoľko dvojíc) stredných hodnôt, ktoré sa od seba líšia. V takom prípade sa analýza dopĺňa metódami

mnohonásobného porovnávania, pomocou ktorých vieme určiť, v ktorých dvojiciach existuje signifikantný rozdiel medzi strednými hodnotami. Na tento účel sa používajú rôzne metódy viacnásobného porovnávania, napr. Scheffého metóda, Tukeyho metóda, Bonferroniho metóda, Duncanova metóda, Kramerova metóda (Pacáková a kol., 2012).

3 Regionálna analýza priemerných spotrebných výdavkov domácností SR

Pred aplikáciou analýzy rozptylu sme overili, či súbory spĺňajú predpoklady potrebné pre použitie metódy analýzy rozptylu.

Podmienka nezávislosti výberov je zabezpečená vhodnou organizáciou výberového zisťovania. Predpoklad o normálnom rozdelení jednotlivých podsúborov je vzhľadom na vysoký počet pozorovaní v súboroch uvedených v tabuľke č. 2 splnený. Na overenie predpokladu homoskedasticity spotrebných výdavkov sme použili Leveneov test a výsledky tohto testu sú uvedené v tabuľke č. 3 pre roky 2021 a 2022.

Tab. 2: Počty domácností výberového súboru podľa regiónov NUTS2

Región	Počet domácností	
	rok 2021	rok 2022
SK01 – Bratislavský región	679	743
SK02 – Západné Slovensko	1619	1799
SK03 – Stredné Slovensko	1159	1201
SK04 – Východné Slovensko	1176	1248

Zdroj: Zisťovanie rodinných účtov, vlastné spracovanie

Tab. 3: *p*-hodnoty pre Leveneov test pre jednotlivé spotrebné výdavky pre roky 2021 a 2022

Leveneov test pre overenie splnenia predpokladu homoskedasticity					
premenné	<i>p</i> -value		premenné	<i>p</i> -value	
	2021	2022		2021	2022
PNN	0,1598	0,0220	DOP	0,5309	0,5170
ANTN	0,0015	0,0042	PT	<,0001	<,0001
OO	<,0001	0,0263	RK	0,0637	0,0025
BYV	<,0001	<,0001	VZD	0,0606	0,3623
BZ	0,1313	0,0603	RH	<,0001	<,0001
ZDR	0,3010	0,6495	RTS	0,4515	0,2270

Zdroj: Zisťovanie rodinných účtov, vlastné spracovanie v SAS EG

Na základe *p*-hodnôt uvedených v tabuľke č. 3 rozhodujeme o výsledku Leveneovho testu pre všetky premenné. Na hladine významnosti 0,01 pre rok 2021 zamietame nulovú a prijímame alternatívnu hypotézu o nerovnosti rozptylov súborov pre premenné výdavky na alkoholické nápoje, tabak a narkotiká; odevy a obuv; bývanie, vodu, elektrinu, plyn a iné palivá; pošty a telekomunikácie; reštaurácie a hotely. Na hladine významnosti 0,01 pre rok 2022 zamietame nulovú a prijímame alternatívnu hypotézu o nerovnosti rozptylov súborov pre premenné výdavky na alkoholické nápoje, tabak a narkotiká; bývanie, vodu, elektrinu, plyn a iné palivá; pošty a telekomunikácie; rekreáciu a kultúru; reštaurácie a hotely. Pre tieto premenné nie je splnený predpoklad o homoskedasticite výdavkov v regiónoch SR, a preto sme sa rozhodli pri overovaní rovnosti stredných hodnôt použiť Welchovu analýzu rozptylu. Pre ostatné premenné je predpoklad o homoskedasticite výdavkov v regiónoch SR splnený, použijeme preto klasickú analýzu rozptylu.

P-hodnoty pre analýzu rozptylu výdavkových premenných sú zhrnuté v tabuľke č. 4, rovnako je uvedený aj typ analýzy rozptylu (ANOVA), ktorý sme pre danú premennú zvolili.

V roku 2021 môžeme na hladine významnosti 0,05 pre premenné výdavky na potraviny a nealkoholické nápoje; výdavky na alkoholické nápoje, tabak a narkotiká; výdavky na odievanie a obuv; výdavky na bývanie, vodu, elektrinu, plyn a iné palivá; výdavky na nábytok, vybavenie domácnosti a bežnú údržbu domácnosti; výdavky na pošty a telekomunikácie; výdavky na vzdelávanie; výdavky na reštaurácie a hotely; výdavky na rozličné tovary a služby (všetky okrem výdavkov na zdravie; výdavkov na dopravu a výdavkov na rekreáciu a kultúru) zamietnuť nulovú a prijať alternatívnu hypotézu, ktorá hovorí o tom, že stredné hodnoty aspoň dvoch súborov sa nerovnajú, a tak môžeme tvrdiť, že medzi regiónmi SR existujú v spotrebných výdavkoch na spomenuté položky štatisticky významné rozdiely. V roku 2022 môžeme na hladine významnosti 0,05 pre všetky premenné okrem výdavkov na dopravu zamietnuť nulovú a prijať alternatívnu hypotézu, ktorá hovorí o tom, že stredné hodnoty aspoň dvoch súborov sa nerovnajú, a tak môžeme tvrdiť, že medzi regiónmi SR existujú vo výdavkoch na spomenuté položky štatisticky významné rozdiely.

Tab. 4: *p*-hodnoty klasickej alebo Welchovej analýzy rozptylu pre analyzované premenné spotrebných výdavkov

Analýza rozptylu				
premenné	2021		2022	
	typ ANOVA	<i>p</i> -value	typ ANOVA	<i>p</i> -value
PNN	klasická ANOVA	<,0001	klasická ANOVA	<,0001
ANTN	Welchova ANOVA	0,0045	Welchova ANOVA	<,0001
OO	Welchova ANOVA	<,0001	klasická ANOVA	<,0001
BYV	Welchova ANOVA	<,0001	Welchova ANOVA	<,0001
BZ	klasická ANOVA	0,0003	klasická ANOVA	<,0001
ZDR	klasická ANOVA	0,1273	klasická ANOVA	0,0027
DOP	klasická ANOVA	0,2291	klasická ANOVA	0,1106
PT	Welchova ANOVA	<,0001	Welchova ANOVA	<,0001
RK	klasická ANOVA	0,0982	Welchova ANOVA	0,0128
VZD	klasická ANOVA	0,0007	klasická ANOVA	0,0153
RH	Welchova ANOVA	<,0001	Welchova ANOVA	<,0001
RTS	klasická ANOVA	<,0001	klasická ANOVA	<,0001

Zdroj: Zisťovanie rodinných účtov, vlastné spracovanie v SAS EG

Výsledky Bonferroniho post-hoc testov pre premenné, pre ktoré existujú štatisticky významné rozdiely medzi spotrebnými výdavkami jednotlivých kategórií v regiónoch SR, sú uvedené pre rok 2021 v tabuľke č. 5 a pre rok 2022 v tabuľke č. 6, kde skratka RMP znamená rozdiel medzi priemermi, v tomto stĺpci sú uvedené hodnoty, o koľko eur sa priemerné výdavky na dané položky odlišujú v daných regiónoch, skratka ŠV znamená štatistická významnosť, v tomto stĺpci je symbolom * označená tá dvojica regiónov, medzi ktorými na hladine významnosti 0,05 existuje štatisticky významný rozdiel vo výdavkoch domácností medzi dvojicou regiónov.

Na hladine významnosti 0,05, v rokoch 2021 a 2022, zaznamenávajú domácnosti na západnom Slovensku v porovnaní s Bratislavským regiónom, stredným Slovenskom a východným Slovenskom štatisticky významne vyššie **priemerné výdavky na potraviny a nealkoholické nápoje**. V roku 2022 navyše vznikli štatisticky významne nižšie rozdiely v týchto výdavkoch v Bratislavskom regióne oproti západnému i východnému Slovensku.

Štatisticky významne vyššie rozdiely v **priemerných výdavkoch domácností na alkoholické nápoje tabak a narkotiká** na hladine významnosti 0,05, v roku 2021, existujú na západnom Slovensku v porovnaní s Bratislavským regiónom o 41,00 eur a so stredným

Slovenskom o 35,87 eur. V roku 2022 existujú štatisticky významne nižšie rozdiely v týchto výdavkoch v Bratislavskom regióne v porovnaní s ostatnými regiónmi Slovenska a tiež štatisticky významne vyšší rozdiel na západnom Slovensku oproti východnému.

V rokoch 2021 a 2022 sú **priemerné výdavky domácností na odevy a obuv** na hladine významnosti 0,05 signifikantne vyššie v Bratislavskom regióne oproti západnému, strednému i východnému Slovensku, čo môže byť spôsobené napr. vyššou životnou úrovňou v Bratislave a s tým spojenou vyššou spotrebou a záujmom o kvalitnejšie odevy a obuv, so širšou ponukou a dostupnosťou obchodov s odevmi alebo so špecifickým životným štýlom Bratislavčanov. V roku 2021 sú navyše signifikantne vyššie rozdiely v týchto výdavkoch na strednom Slovensku oproti západnému o 31,81 eur.

Tab. 5: Výsledky Bonferroniho testu pre analyzované premenné spotrebných výdavkov pre dvojice regiónov za rok 2021

dvojica regiónov	RMP	ŠV	RMP	ŠV	RMP	ŠV	RMP	ŠV
	PNN		ANTN		OO		BYV	
SK01 – SK02	-110,46	*	-41,00	*	103,54	*	375,30	*
SK01 – SK03	3,17		-5,13		71,73	*	564,24	*
SK01 – SK04	60,15		-14,18		89,25	*	421,23	*
SK02 – SK03	113,63	*	35,87	*	-31,81	*	188,94	*
SK02 – SK04	170,61	*	26,82		-14,29		45,93	
SK03 – SK04	56,98		-9,05		17,52		-143,01	*
	BZ		PT		VZD		RH	
SK01 – SK02	-130,95	*	135,79	*	-0,38		333,58	*
SK01 – SK03	-39,25		173,43	*	-12,18		272,97	*
SK01 – SK04	-90,96		157,25	*	-15,11	*	301,62	*
SK02 – SK03	91,70	*	37,64	*	-11,80	*	-60,61	*
SK02 – SK04	39,99		21,46	*	-14,73	*	-31,96	
SK03 – SK04	-51,71		-16,19		-2,93		28,65	
	RTS							
SK01 – SK02	204,91	*						
SK01 – SK03	229,76	*						
SK01 – SK04	188,94	*						
SK02 – SK03	24,85							
SK02 – SK04	-15,98							
SK03 – SK04	-40,82							

Zdroj: Zisťovanie rodinných účtov, vlastné spracovanie v SAS EG

Čo sa týka **priemerných výdavkov domácností na bývanie, vodu, elektrinu, plyn a iné palivá**, na hladine významnosti 0,05 pozorujeme v rokoch 2021 aj 2022 v Bratislavskom regióne signifikantne vyššie rozdiely oproti západnému, strednému i východnému Slovensku, čo môže byť spojené s množstvom faktorov, ako sú napríklad vyššie príjmy, vyššie ceny bývania, nehnuteľností a nájomného v Bratislave, väčší dopyt po bývaní vzhľadom na atraktivitu tohto mesta, lepšia infraštruktúra či vyšší životný štandard. Najvyšší rozdiel vznikol medzi Bratislavou a stredným Slovenskom, a to v roku 2021 o 564,24 eur a v roku 2022 o 618,02 eur. Štatisticky významne nižšie rozdiely v priemerných výdavkoch domácností na

bývanie, vodu, elektrinu, plyn a iné palivá pozorujeme aj na strednom Slovensku oproti západnému i východnému Slovensku v oboch rokoch.

Na hladine významnosti 0,05, v rokoch 2021 a 2022 existujú štatisticky významné rozdiely v **priemerných výdavkoch domácností na nábytok a bytové zariadenie** domácnosti medzi západným Slovenskom a Bratislavským regiónom a medzi západným Slovenskom a stredným Slovenskom a v roku 2022 navyše aj medzi Bratislavským regiónom a východným Slovenskom.

Tab. 6: Výsledky Bonferroniho testu pre analyzované premenné spotrebných výdavkov pre dvojice regiónov za rok 2022

dvojica regiónov	RMP	ŠV	RMP	ŠV	RMP	ŠV	RMP	ŠV
	PNN		ANTN		OO		BYV	
SK01 – SK02	-342,91	*	-83,92	*	91,10	*	392,99	*
SK01 – SK03	-230,98	*	-53,76	*	70,34	*	618,02	*
SK01 – SK04	-152,26	*	-49,91	*	80,62	*	426,03	*
SK02 – SK03	111,93	*	30,16		-20,76		225,03	*
SK02 – SK04	190,66	*	34,02	*	-10,48		33,04	
SK03 – SK04	78,73		3,86		10,28		-191,99	*
	BZ		ZDR		PT		RK	
SK01 – SK02	-174,67	*	-35,12		171,07	*	36,72	
SK01 – SK03	-84,30		-46,40	*	209,55	*	50,66	
SK01 – SK04	-105,36	*	-55,01	*	192,94	*	73,94	*
SK02 – SK03	90,37	*	-11,28		38,48	*	13,94	
SK02 – SK04	69,31		-19,88		21,87		37,22	
SK03 – SK04	-21,06		-8,61		-16,61		23,27	
	VZD		RH		RTS			
SK01 – SK02	-5,01		445,83	*	255,70	*		
SK01 – SK03	-10,46		366,93	*	251,59	*		
SK01 – SK04	-18,04	*	441,43	*	252,29	*		
SK02 – SK03	-5,45		-78,89	*	-4,12			
SK02 – SK04	-13,03		-4,39		-3,41			
SK03 – SK04	-7,58		74,50	*	0,71			

Zdroj: Zisťovanie rodinných účtov, vlastné spracovanie v SAS EG

Priemerné výdavky domácností na pošty a telekomunikácie sú na hladine významnosti 0,05 v rokoch 2021 a 2022 signifikantne vyššie v Bratislavskom regióne oproti západnému, strednému i východnému Slovensku a tiež sú vyššie na západnom Slovensku oproti strednému Slovensku. Tieto rozdiely môžu byť spôsobené napr. vyššou životnou úrovňou v Bratislave a na západnom Slovensku oproti strednému a východnému Slovensku a s tým spojeným vyšším dopytom po telekomunikačných technológiách a internete, odlišnou infraštruktúrou a dostupnosťou telekomunikačných sietí, vyššou koncentráciou veľkých spoločností a korporácií. V roku 2021 sú tieto výdavky navyše signifikantne vyššie na západnom Slovensku oproti východnému Slovensku. Najvyšší rozdiel vznikol v Bratislave oproti strednému Slovensku, a to v roku 2021 o 173,43 eur a v roku 2022 o 209,55 eur.

Štatisticky významne vyššie rozdiely v **priemerných výdavkoch domácností na vzdelávanie** na hladine významnosti 0,05 v roku 2021 pozorujeme na východnom Slovensku oproti Bratislavskému regiónu o 15,11 eur a západnému Slovensku o 14,73 eur a tiež na strednom Slovensku oproti západnému Slovensku o 11,80 eur. V roku 2022 sú tieto výdavky štatisticky významne vyššie na východnom Slovensku oproti Bratislavskému regiónu o 18,04 eur.

Priemerné výdavky domácností na reštaurácie a hotely sú v rokoch 2021 a 2022 na hladine významnosti 0,05 signifikantne vyššie v Bratislavskom regióne oproti západnému, strednému i východnému Slovensku a tiež sú vyššie na strednom Slovensku oproti západnému Slovensku. Rozdiely v Bratislave oproti ostatným regiónom Slovenska môžu byť spôsobené napr. vyššou životnou úrovňou, vyššími disponibilnými príjmami, či väčším výberom reštaurácií a hotelov v Bratislave. V roku 2022 sú navyše tieto výdavky štatisticky významne vyššie na strednom Slovensku oproti východnému Slovensku. Najvyšší rozdiel vznikol v Bratislave oproti západnému Slovensku, a to v roku 2021 o 333,58 eur a v roku 2022 o 445,83 eur.

Čo sa týka **priemerných výdavkov domácností na rozličné tovary a služby**, na hladine významnosti 0,05, v rokoch 2021 a 2022, pozorujeme v Bratislavskom regióne signifikantne vyššie rozdiely oproti západnému, strednému i východnému Slovensku, čo môže byť spojené s množstvom faktorov, ako sú napr. vyššie príjmy, vyššie náklady na život v Bratislave, väčšia dostupnosť luxusných tovarov a služieb, vyššia koncentrácia obchodov a zariadení.

V roku 2022, na hladine významnosti 0,05 existujú štatisticky významne nižšie rozdiely v **priemerných výdavkoch domácností na zdravie** v Bratislavskom regióne oproti strednému a východnému Slovensku. V roku 2021 sa v tejto výdavkovej skupine neprejavili žiadne významné regionálne rozdiely.

V roku 2022, štatisticky významne vyššie rozdiely v **priemerných výdavkoch domácností na rekreáciu a kultúru** na hladine významnosti 0,05 pozorujeme v Bratislavskom regióne oproti východnému Slovensku o 73,94 eur. V roku 2021 sa v tejto výdavkovej skupine neprejavili žiadne významné regionálne rozdiely, čo môže byť spôsobené napr. pandémiou COVID-19, keďže v roku 2021 boli kultúrne a rekreačné podujatia ešte prísne regulované, a teda môžeme predpokladať, že domácnosti vo všetkých regiónoch sa správali podobne voči týmto aktivitám, napr. tak, že ich obmedzovali.

Môžeme konštatovať, že analýzou spotrebných výdavkov domácností v jednotlivých regiónoch Slovenska sme v rokoch 2021 a 2022 identifikovali signifikantné rozdiely v spotrebiteľskom správaní domácností medzi regiónmi. Rozdiely sa týkajú takmer všetkých spotrebných výdavkov. Častou skutočnosťou, ktorú sme zistili je, že signifikantne vyššie rozdiely v spotrebných výdavkoch existujú v Bratislavskom regióne oproti západnému, strednému i východnému Slovensku. K zmierneniu regionálnych rozdielov v spotrebných výdavkoch domácností by sme mohli odporučiť napr. podporu lokálnych ekonomík, podporu regionálneho či priemyselného rozvoja, investície do infraštruktúry v menej rozvinutých regiónoch, čo by mohlo viesť k vytváraniu pracovných miest a zvýšeniu zamestnanosti, tiež zabezpečenie rovnakého prístupu k dôležitým službám a tovarom vo všetkých regiónoch alebo poskytnutie finančných stimulov a daňových úľav pre domácnosti v menej rozvinutých regiónoch.

4 Záver

Analýzou výdavkov domácností na základe údajov získaných zo zisťovania rodinných účtov sme identifikovali významné rozdiely v spotrebných vzoroch medzi jednotlivými regiónmi Slovenskej republiky za roky 2021 a 2022. Štatisticky významné rozdiely v priemerných výdavkoch domácností medzi jednotlivými regiónmi sa nevyskytli pri doprave v oboch rokoch. To naznačuje, že výdavky na dopravu zostávajú relatívne stabilné naprieč

celým Slovenskom, bez ohľadu na regionálne rozdiely v iných výdavkových kategóriách. Výsledky analýzy ukázali, že signifikantne vyššie rozdiely v spotrebných výdavkoch existujú najčastejšie v Bratislavskom regióne oproti západnému, strednému i východnému Slovensku. Konkrétne, signifikantne vyššie rozdiely vznikli v Bratislavskom regióne oproti zvyšným regiónom vo výdavkoch na bývanie a energie spojené s bývaním; na odevy a obuv; na pošty a telekomunikácie; na reštaurácie a hotely; na rozličné tovary a služby. Vysoké regionálne rozdiely sme zaznamenali napr. pri porovnaní výdavkov na bývanie a energie spojené s bývaním, ktoré boli v priemere v roku 2021 signifikantne vyššie v Bratislavskom regióne oproti západnému Slovensku o 375,30 eur, oproti strednému Slovensku o 564,24 eur a oproti východnému Slovensku o 421,23 eur. V roku 2022 rozdiely vo výdavkoch na bývanie a energie spojené s bývaním ešte narástli, zaznamenali sme signifikantne vyššie rozdiely v Bratislavskom regióne oproti západnému Slovensku v priemere o 392,99 eur, oproti strednému Slovensku o 618,02 eur a oproti východnému Slovensku o 426,03 eur. Toto rozdielne spotrebiteľské správanie môže byť spôsobené napr. vyššími príjmami, odlišným životným štýlom, či vyšším životným štandardom v Bratislavskom regióne. Tieto zistenia poukazujú na dôležitosť a potrebu ďalšieho prieskumu v oblasti rozpočtových a sociálnych politík s cieľom lepšie porozumieť a riešiť rozdiely v životných podmienkach medzi regiónmi na Slovensku. Tieto rozdiely zdôrazňujú potrebu cielených politík, ktoré by podporovali vyrovnávanie regionálnych rozdielov v životnej úrovni. Zameranie sa na rozvoj infraštruktúry, podpora miestnych ekonomík a dostupnosť cenovo prijateľného bývania by mohlo pomôcť zlepšiť životné podmienky v menej rozvinutých oblastiach.

Príspevok bol spracovaný v rámci riešenia grantovej úlohy VEGA 1/0285/24: *Dopad inflácie na chudobu a sociálne vylúčenie na Slovensku a v EÚ*

Literatúra

1. Eurostat. (2023). *Household budget surveys in the EU: Methodology and recommendations for harmonisation - 2003*. Office for Official Publications of the European Communities.
2. Kotlebová, E. (2015). *Štatistická indukcia v príkladoch*. EKONÓM.
3. Kotlebová, E., & Sliacky, M. (2021). Možnosti porovnávania úrovne hodnôt znaku vo viacerých súboroch pri nesplnení predpokladov analýzy rozptylu. *Slovenská Štatistika a Demografia*, 31, 3-17.
4. Morvay, K. (2005). *Transformácia ekonomiky: Skúsenosti Slovenska*. Ústav slovenskej ekonomiky SAV.
5. Pacáková, V. (2012). *Štatistická indukcia pre ekonómov*. EKONÓM.
6. Štatistický úrad Slovenskej republiky. (2021). Indikátory kvality života. <https://slovak.statistics.sk/wps/portal/ext/themes/living/life/metadata/>
7. Vlačuha, R., Vargová, A., & Hornáček, M. (2023). *Príjmy, výdavky súkromných domácností V SR 2022*.
8. <https://slovak.statistics.sk/wps/portal?urlile=wcm%3Apath%3A%2Fobsah-sk-pub%2Fpublikacie%2Fvsetkypublikacie%2F3a5deb27-ae13-4864-90bd-faf91e354a2d>

Dopad aplikácie zásady opatrnosti na verný a pravdivý obraz poskytnutý účtovnou závierkou zostavenou v súlade so slovenskou účtovnou legislatívou

The impact of prudence principle application on true and fair view provided by financial statements prepared in accordance with Slovak accounting legislation

Martina Podmanická¹

Abstrakt

Zásada verného a pravdivého obrazu je rešpektovaná všetkými formami medzinárodnej harmonizácie i právnymi úpravami účtovníctva jednotlivých krajín. Význam zásady verného a pravdivého obrazu vyplýva z informačnej funkcie účtovníctva, keď účtovníctvo, no najmä jeho výsledný produkt – účtovnú závierku, chápeme ako nástroj efektívneho podávania a sprostredkovania informácií zistených o účtovnej jednotke príslušným používateľom, ktorí na základe týchto informácií vykonávajú rozhodnutia vo vzťahu k tejto účtovnej jednotke. Je preto dôležité, aby účtovná závierka poskytovala svojim používateľom užitočné, neskreslené a neutrálne informácie. Aby používatelia informácií mohli realizovať zodpovedné rozhodnutia, musia vedieť, aké sú východiská pre zostavenie účtovnej závierky, čo ovplyvňuje informácie obsiahnuté v účtovnej závierke. Vo významnej miere má na informácie prezentované v účtovnej závierke vplyv práve aplikácia zásady opatrnosti. Príspevok poukazuje na význam zásady opatrnosti pre dosiahnutie verného a pravdivého obrazu, vysvetľuje vzájomné prepojenie oboch účtovných zásad a objasňuje vplyv aplikácie zásady opatrnosti na rozsah informácií a ocenenie položiek prezentovaných v účtovnej závierke.

Kľúčové slová

zásada opatrnosti, verný a pravdivý obraz, odpisy, rezervy, opravné položky, reálna hodnota

Abstract

The true and fair view principle is respected by all forms of international accounting harmonization and accounting regulations of individual countries too. The importance of true and fair view principle results from the information function of accounting. We understand accounting, primarily its final product – the financial statements, as a tool for the effective submission and mediation of information found about the accounting entity to the relevant users. Users make decisions in relation to this accounting entity based on this information. It is therefore important that financial statements provide their users with useful, unbiased and neutral information. Users of information must know what are the starting points for the preparation of financial statements and must also know what affects the information contained in the financial statements in order to be able to make responsible decisions. It is the application of prudence principle that has a significant impact on the information presented in the financial statements. The paper emphasizes the importance of prudence principle for achieving the true and fair view, explains the interconnection of both accounting principles and clarifies the impact of application of prudence principle on the scope of information and measurement of items presented in the financial statements.

¹ Ekonomická univerzita v Bratislave, Fakulta hospodárskej informatiky, Katedra účtovníctva a audítorstva, Dolnozemska cesta 1, 852 35 Bratislava, martina.podmanicka@euba.sk

Key words

prudence principle, true and fair view, amortization, depreciation, provisions, impairment of assets, fair value

JEL classification

M40, M41

1 Úvod

Najdôležitejším cieľom účtovníctva v trhovej ekonomike je poskytnúť verný a pravdivý obraz o ekonomickej realite účtovnej jednotky. Bezprostredný vplyv na to, ako bude realita o účtovnej jednotke zobrazená v účtovníctve a prezentovaná v účtovnej závierke, majú účtovné predpisy platné v tej ktorej krajine. Verný a pravdivý obraz je teda výsledkom správneho uplatňovania všeobecne uznávaných účtovných zásad a účtovných postupov vymedzených účtovnou legislatívou. Zákon č. 431/2002 Z. z. o účtovníctve v znení neskorších predpisov (ďalej len „zákon o účtovníctve“) prostredníctvom svojich ustanovení zásadu verného a pravdivého obrazu vzťahuje na účtovnú závierku, ako aj na bežné účtovníctvo, pričom pre vecný obsah účtovných informácií významný vplyv majú práve všeobecne uznávané účtovné zásady. Tie určujú pravidlá pre identifikáciu, oceňovanie a vykazovanie základných zložiek účtovnej závierky. Každá krajina má svoje vlastné účtovné predpisy obsahujúce pravidlá pre identifikáciu, oceňovanie a vykazovanie základných zložiek výkazov účtovnej závierky. Zložky výkazov účtovnej závierky sú v účtovných predpisoch jednotlivých krajín rôzne definované, jednotlivé položky majetku a záväzkov sú rôzne oceňované i rôzne vykazované. Preto, ak by tá istá účtovná jednotka s rovnakými transakciami účtovného obdobia zostavovala účtovnú závierku podľa rôznych účtovných predpisov, zobrazenie majetku, záväzkov, vlastného imania, nákladov či výnosov by sa líšilo v závislosti od použitých účtovných predpisov. (Farkaš, 2020)

Zásada opatrnosti patrí k tým všeobecne uznávaným účtovným zásadám, ktorých aplikáciou v účtovníctve sa významne ovplyvňuje identifikácia, oceňovanie i vykazovanie základných zložiek účtovnej závierky (majetku, záväzkov, vlastného imania, nákladov, výnosov, výsledku hospodárenia) a tiež iných aktív a iných pasív. Zásada opatrnosti má univerzálnu platnosť, v rôznom rozsahu a odlišnej intenzite sa uplatňuje v účtovných systémoch prakticky všetkých krajín i v nadnárodnej právnej úprave účtovníctva.

Uplatňovanie zásady opatrnosti v účtovníctve vyplýva z potreby podnikateľa byť pri realizácii svojej podnikateľskej činnosti opatrný, nakoľko podnikateľ neustále svoju činnosť vykonáva v podmienkach značnej neistoty v budúcnosti a z nej plynúcich rizík, ktoré je potrebné premietnuť i do účtovníctva a zvlášť účtovnej závierky. Opatrný podnikateľ sa zároveň nepovažuje za bohatšieho ako v skutočnosti je, v prípade pochybností sa považuje skôr za chudobnejšieho. Z uvedeného vyplýva, že v účtovnej závierke musia byť premietnuté nielen straty, ktoré reálne vznikli, ale aj všetky predpokladané straty a predpokladané riziká. Naproti tomu očakávané, ale neisté výnosy (zisky) sa neúčtujú, a teda v účtovnej závierke nevykazujú, pokiaľ sa nevyžaduje opak. Účtujú a vykazujú sa len vtedy, keď sú skutočne realizované. Tento prístup sa označuje ako realizačný princíp. Z uvedeného je zrejmé, že v dôsledku uplatňovania zásady opatrnosti sa inak posudzujú nerealizované zisky (neúčtujú a nevykazujú sa) a inak sa posudzujú nerealizované straty (účtujú sa a vykazujú sa). Tento princíp sa volá imparitný princíp. (Šlosárová a kol., 2011) Pri zásade opatrnosti sa uplatňuje aj princíp nižšej ceny, podľa ktorého sa majetok vykáže v súvahe v ocenení nižšou cenou, čím sa umožní vykázať nerealizované straty a nevykázať nerealizované zisky. Zásada opatrnosti okrem realizačného princípu, imparitného princípu a princípu nižšej ceny zahŕňa v sebe i princíp osvetľovania hodnoty, ktorý znamená, že v určitých prípadoch nie sú rozhodujúce informácie k závierkovému dňu, ale ku dňu zostavenia účtovnej závierky. Slovenská účtovná legislatíva

pojmy realizačný princíp, imparitný princíp, princíp nižšej ceny ani princíp osvetľovania hodnoty nepoužíva. (Farkaš, 2020)

Zásada opatrnosti zároveň znamená taký prístup účtovnej jednotky k odhadom vykonávaným v neistých podmienkach, pri ktorom sa majetok a výnosy nenadhodnocujú a záväzky a náklady nepodhodnocujú. Opatrnosť v účtovníctve má zabrániť tomu, aby sa riziká a straty prenášali do budúcnosti. (Šlosárová et al., 2011)

Význam zásady opatrnosti pre informácie prezentované v účtovnej závierke je preto nesporný. Všeobecná platnosť zásady opatrnosti znamená nielen jej povinné uplatňovanie pri vedení účtovníctva a zostavovaní účtovnej závierky zo strany jej zostavovateľov, ale aj oprávnené očakávania zo strany znalých používateľov informácií, že účtovná závierka je zostavená v súlade s touto zásadou. (Škoda, 2005)

V Slovenskej republike má na informácie zverejnené v účtovnej závierke zásadný vplyv zákon o účtovníctve, opatrenie MF SR č. 23054/2002-92, ktorým sa ustanovujú podrobnosti o postupoch účtovania a rámcovej účtovej osnove pre podnikateľov účtujúcich v sústave podvojného účtovníctva v znení neskorších predpisov (ďalej len „postupy účtovania“), opatrenia, ktoré upravujú účtovné závierky v nadväznosti na členenie podľa veľkostných skupín a tiež IFRS v prípadoch, keď účtovná jednotka zostavuje účtovnú závierku v súlade s IFRS. Prírodzene najpodrobnejšie informácie v účtovnej závierke musia zverejňovať veľké účtovné jednotky a subjekty verejného záujmu v súlade s opatrením MF SR č. MF/23377/2014-74, ktorým sa ustanovujú podrobnosti o individuálnej účtovnej závierke a rozsahu údajov určených z individuálnej účtovnej závierky na zverejnenie pre veľké účtovné jednotky a subjekty verejného záujmu v znení neskorších predpisov (ďalej len „opatrenie o zostavení účtovnej závierky pre veľké účtovné jednotky a subjekty verejného záujmu“) a účtovné jednotky, ktoré zostavujú účtovnú závierku v súlade s IFRS. Tému predkladanej vedeckej práce riešime najmä v súlade so zákonom o účtovníctve, postupmi účtovania a opatrením o zostavení účtovnej závierky pre veľké účtovné jednotky a subjekty verejného záujmu. Okrem uvedených právnych noriem sme pri zostavovaní predkladanej práce vychádzali i z knižných publikácií a článkov publikovaných v odborných časopisoch, ktoré uvádzame v časti Literatúra.

Cieľom príspevku je poukázať na význam zásady opatrnosti pre dosiahnutie verného a pravdivého obrazu, vysvetliť vzájomné prepojenie oboch účtovných zásad a na podklade ustanovení slovenskej účtovnej legislatívy objasniť vplyv aplikácie zásady opatrnosti na rozsah informácií a ocenenie položiek prezentovaných v účtovnej závierke vo vzťahu k vernému a pravdivému obrazu o skutočnostiach, ktoré sú predmetom účtovníctva.

2 Význam zásady opatrnosti pre dosiahnutie verného a pravdivého obrazu v účtovnej závierke

Zásada verného a pravdivého obrazu je považovaná za najvyššiu zásadu, sú jej podriadené všetky ostatné účtovné zásady, nadobúda tak postavenie nadradeného kritéria a to z toho dôvodu, že má pre rozhodovanie súčasných i potenciálnych vlastníkov, investorov, veriteľov i ostatných používateľov prvoradý význam. Riadna účtovná závierka má byť zostavená za predpokladu nepretržitého pokračovania v činnosti účtovnej jednotky, t. j. účtovná jednotka je povinná použiť účtovné zásady a účtovné metódy spôsobom, ktorý vychádza z predpokladu, že bude nepretržite pokračovať vo svojej činnosti a že u nej nenastáva žiadna skutočnosť, ktorá by ju obmedzovala alebo jej zabraňovala v tejto činnosti pokračovať aj v blízkej budúcnosti, minimálne 12 mesiacov od dátumu, ku ktorému sa zostavila riadna účtovná závierka. V prípade, že účtovná jednotka má informáciu o tom, že u nej takáto skutočnosť nastáva, je povinná použiť tomu zodpovedajúci spôsob účtovania, pričom je povinná uviesť informáciu o použitom spôsobe v účtovnej závierke v poznámkach.

Predpoklad nepretržitého pokračovania v činnosti sa zabezpečuje prostredníctvom aplikácie jednotlivých všeobecne uznávaných účtovných zásad vrátane zásady opatrnosti. Nepretržité pokračovanie v činnosti je vždy spojené s neistotou a rizikom, ktoré so sebou budúcnosť nevyhnutne prináša.

2.1 Vzťah zásady opatrnosti k predpokladu nepretržitého pokračovania v činnosti

Neistota, riziko a tiež snaha o budúcu prosperitu majú viesť účtovnú jednotku k opatrnému vykazovaniu majetku, záväzkov i výsledku hospodárenia, na čo slúžia predovšetkým pravidlá pre oceňovanie a vykazovanie majetku a záväzkov. Uplatnenie predpokladu nepretržitého pokračovania v činnosti ovplyvní rozsah i obsah položiek vykazovaných v účtovnej závierke. V prípade, že účtovná jednotka nebude naďalej pokračovať v svojej činnosti nemá zmysel vytvárať rezervy na budúce výdavky, znižovať výsledok hospodárenia o straty očakávané v budúcnosti, časovo rozlišovať výnosy a náklady. Ďalším dôsledkom prijatia predpokladu nepretržitosti v činnosti a teda perspektívy pokračovať v činnosti účtovnej jednotky je skutočnosť, že používateľov informácií z účtovnej závierky zaujíma nielen aktuálna finančná situácia a výkonnosť účtovnej jednotky, ale aj jej schopnosť získať zo súčasného majetkového potenciálu budúci ekonomický úžitok. Kovanicová (2005) uvádza, že potreba uspokojiť tento záujem vedie k tomu, že napr. súvaha vyjadruje stav majetku, záväzkov a vlastného imania k súvahovému dňu, ale s pohľadom upretým do budúcnosti. To je dôvod, prečo hľadisko zvýšenia či zníženia ekonomického úžitku je zakomponované aj v definíciách majetku, záväzkov, nákladov i výnosov. To ako sú v slovenskej účtovnej legislatíve tieto základné pojmy definované je kľúčové pre identifikáciu a následné vykazovanie základných zložiek účtovnej závierky. Pri definovaní majetku a záväzkov zákon o účtovníctve využíva aj pojmy ako napr. „je takmer isté“, „je pravdepodobné“, „spolahlivé ocenenie“, ktoré už definované nie sú, stotožňujeme si ich však s významom, aký majú v IFRS, pretože IFRS boli východiskom pri tvorbe týchto definícií.

Dôležitým kritériom pri definovaní základných zložiek účtovných výkazov podľa platnej účtovnej legislatívy, a teda i kritériom pri vytváraní a zabezpečovaní verného a pravdivého obrazu o skutočnostiach, ktoré sú predmetom účtovníctva, je spoľahlivosť ich ocenenia. Zásada opatrnosti má kľúčový význam pri úprave historickej ceny na účtovnú hodnotu, nakoľko pri oceňovaní majetku a záväzkov sa ako základná zásada aplikuje zásada oceňovania v historických cenách. Historické ceny sa vzťahujú na obdobie, keď bol majetok obstaraný a keď záväzok vznikol. Historické ceny sú preukázateľné, ľahko overiteľné, a preto spoľahlivé. To je dôvod, prečo je aj v súčasnosti účtovníctvo - až na výnimky - založené na historických cenách. Z dôvodu zrealnenia ocenenia sa ku dňu, ku ktorému sa zostavuje účtovná závierka, ocenenie upravuje na účtovnú hodnotu. V prípadoch ustanovených v zákone o účtovníctve sa zásada opatrnosti neuplatňuje, zrealnenie ocenenia si vyžaduje uplatnenie reálnej hodnoty. Deje sa tak z dôvodu poskytnúť používateľom informácií z účtovnej závierky relevantnejšie informácie ku dňu, ku ktorému sa zostavuje účtovná závierka. (Šlosárová & Blahušiaková, 2017) Užitočnosť informácií obsiahnutých v účtovných závierkach priamo závisí od spôsobu oceňovania tých položiek, ktoré sú predmetom vykazovania. Od zvoleného spôsobu oceňovania jednotlivých položiek majetku a záväzkov závisí vypovedacia schopnosť prakticky všetkých základných veličín zisťovaných v účtovníctve. Spôsob oceňovania ovplyvňuje kvalitu a úroveň finančnej analýzy danej účtovnej jednotky.

Z uvedeného vyplýva, že v rámci slovenskej účtovnej legislatívy je zásada opatrnosti rozpracovaná najmä v definíciách základných pojmov, v ustanoveniach o oceňovaní, odpisoch, opravných položkách a rezervách.

3 Vplyv zásady opatrnosti na rozsah informácií prezentovaných v účtovnej závierke

Zásada opatrnosti je vyjadrená už v definíciách základných pojmov zapracovaných v zákone o účtovníctve, na základe ktorých identifikujeme skutočnosti, ktoré sú predmetom účtovníctva. Účtovná jednotka musí rozpoznať a zistiť, či daná skutočnosť spĺňa definíciu majetku, záväzku, nákladu a výnosu, aby o nej mohla účtovať a vykázat ju v účtovnej závierke. V definíciách majetku a záväzkov existuje istá asymetria, keď pri majetku sa vyžaduje „takmer isté“ zvýšenie ekonomických úžitkov v budúcnosti a pri záväzkoch sa vyžaduje len „pravdepodobné“ zníženie ekonomických úžitkov v budúcnosti, čo zodpovedá predstave opatrného podnikateľa, ktorý sa nebude prezentovať bohatší ako je. Požiadavka „takmer isté“ je prísnejšia ako požiadavka „pravdepodobné“, preto má zásada opatrnosti vplyv na rozsah položiek zahrňovaných do účtovnej závierky.

Tie aktíva a pasíva, ktoré nespĺňajú definíciu majetku a záväzkov, tzv. iné aktíva a iné pasíva sa v súvahe nevykazujú, preto ani nie sú súčasťou vlastného imania. Vykazujú sa len v poznámkach ako tretej súčasti účtovnej závierky. Vykazovanie informácií o iných aktívach a iných pasívach je významné pre posúdenie finančnej situácie, vychádza z povinnosti, aby účtovná závierka poskytovala verný a pravdivý obraz ako aj z predpokladu nepretržitého pokračovania v činnosti účtovnej jednotky. Vo všeobecnosti môžeme skonštatovať, že informácie vykazované v účtovnej závierke sú podriadené vernému a pravdivému obrazu o skutočnostiach, ktoré sú predmetom účtovníctva. Z opatrenia o zostavení účtovnej závierky pre veľké účtovné jednotky a subjekty verejného záujmu vyplýva, že inými aktívami a inými pasívami sa rozumejú podmienený majetok, podmienené záväzky, ostatné finančné povinnosti a skutočnosti sledované na podsúvahových účtoch.

Pri podmienenom majetku (napr. pri právach zo servisných zmlúv, poisťných zmlúv, koncesionárskych zmlúv, licenčných zmlúv) a podmienených záväzkoch (napr. zo súdnych rozhodnutí, z poskytnutých záruk) sa vyžaduje uviesť aj ich hodnota, t. j. suma, o ktorú ide, a to vrátane súvisiacich nákladov. Z hľadiska zásady opatrnosti je dôležitejšie vykazovať podmienené záväzky než podmienené aktíva.

Od podmienených záväzkov je potrebné odlišiť ostatné finančné povinnosti (napr. povinnosti vyplývajúce z operatívneho lízingu, zákonné alebo zmluvné povinnosti odobrať isté množstvo produktu, uskutočniť investície a veľké opravy), pretože sú to dve samostatné a svojím charakterom rozdielne skupiny záväzkov. Tieto povinnosti musia ku dňu, ku ktorému sa zostavuje účtovná závierka už existovať, t. j. zmluvy musia byť už uzatvorené, neuvádzajú sa tu teda také povinnosti, o ktorých účtovná jednotka len uvažuje. (Farkaš, 2019) Vzhľadom na zásadu významnosti je účtovná jednotka povinná uvádzať v poznámkach ostatné finančné povinnosti len vtedy, ak ide o významné položky.

Vykazovaním informácií o ostatných finančných povinnostiach používateľa dostanú informáciu o výdavkoch, ku ktorým sa účtovná jednotka zaviazala v budúcnosti, a preto s istotou ovplyvnia finančnú situáciu účtovnej jednotky v budúcnosti.

Čo sa týka skutočností sledovaných na podsúvahových účtoch (napr. prenajatý majetok, majetok prijatý do úschovy, zmenky na inkaso použité na úhradu do doby ich splatnosti) treba si uvedomiť, že sú to skutočnosti, o ktorých sa neúčtuje v účtovných knihách, ale ktorých znalosť je podstatná na posúdenie majetkoprávnej situácie účtovnej jednotky a jej ekonomických zdrojov, ktoré možno využiť. Vzhľadom na zásadu významnosti je účtovná jednotka povinná uvádzať v poznámkach len informácie o významných položkách.

Významným nástrojom na zabezpečenie zásady opatrnosti sú aj rezervy. Ich špecifické postavenie spočíva v tom, že sú to záväzky s neistým časovým vymedzením alebo výškou. Ich účtovanie a vykazovanie je dôležité z hľadiska úplnosti účtovníctva ako aj správneho vyčíslenia výsledku hospodárenia, nakoľko rezervy predstavujú existujúcu povinnosť účtovnej jednotky, a preto v budúcnosti znížia ekonomické úžitky účtovnej jednotky. Rezervy je potrebné odlišiť

od podmienených záväzkov. Posúdenie či ide o rezervy alebo podmienené záväzky patrí k najťažším vôbec. Je to jedna z oblastí, ktorá si zo strany vedenia účtovnej jednotky vyžaduje úsudok. Rezerva i podmienený záväzok vznikajú ako dôsledok minulej udalosti, pričom rezerva predstavuje súčasnú povinnosť, pri ktorej je pravdepodobné, že v budúcnosti zníži ekonomické úžitky a dá sa spoľahlivo oceniť. Podmienený záväzok vzniká buď ako potenciálny záväzok na základe minulej udalosti alebo ako súčasný záväzok, pri ktorom nie je pravdepodobné, že na splnenie tejto povinnosti bude potrebný úbytok ekonomických úžitkov alebo výška tejto povinnosti sa nedá spoľahlivo oceniť. Rezervy sa v súvahe vykazujú oddelene od ostatných druhov záväzkov.

Rozsah i obsah informácií prezentovaných v účtovnej závierke je tiež ovplyvnený informáciami, o ktorých sa účtovná jednotka dozvedela do dňa zostavenia individuálnej účtovnej závierky. Uplatňuje sa tým jeden z najdôležitejších princípov bilancovania – princíp osvetľovania hodnoty. Osobitný význam má najmä z hľadiska dosiahnutia verného a pravdivého obrazu o skutočnostiach, ktoré sú predmetom účtovníctva. V období medzi dňom, ku ktorému sa zostavuje účtovná závierka a dňom jej skutočného zostavenia účtovná jednotka získava dva typy informácií, a to informácie, ktoré osvetľujú skutočnosti, ktoré nastali do dňa, ku ktorému sa zostavuje účtovná závierka (tieto skutočnosti sa v účtovnej závierke za uplynulé účtovné obdobie musia zohľadniť, ide o tzv. upravujúce závierkové účtovné prípady) a informácie o skutočnostiach, ktoré nastali v čase odo dňa, ku ktorému sa zostavuje účtovná závierka do dňa jej skutočného zostavenia (v účtovnej závierke za uplynulé účtovné obdobie sa nesmú zohľadniť, lebo nastali až v novom účtovnom období). Skutočnosti druhého typu sa z hľadiska vzťahu k účtovnej závierke musia rozčleniť na významné a nevýznamné. V dôsledku uplatnenia princípu osvetľovania hodnoty účtovná jednotka potom uvedie v poznámkach informácie o charaktere a finančnom vplyve významných udalostí, ktoré nastali po dni, ku ktorému sa zostavuje účtovná závierka do dňa jej zostavenia, a ktoré nie sú zohľadnené v súvahe alebo vo výkaze ziskov a strát; vo vzťahu k zásade opatrnosti sú to informácie napr. o mimoriadnych udalostiach, ak majú vplyv na hospodárenie účtovnej jednotky a môžu ohroziť nepretržité pokračovanie v činnosti podniku; o poklese trhovej ceny finančného majetku; o nepriaznivom vývoji kurzov cudzej meny v prípade záväzkov v cudzej mene.

V súvislosti s aplikáciou zásady opatrnosti sa v poznámkach uvádzajú informácie najmä o určení odhadu zníženia hodnoty majetku a následnej tvorbe opravných položiek k majetku; o stanovení odhadu ocenenia rezerv; o úprave výšky opravnej položky a rezerv v prípade získania nových skutočností; o určení reálnej hodnoty finančných nástrojov alebo majetku, ktorý nie je finančným nástrojom; o tvorbe odpisového plánu vrátane predpokladanej doby odpisovania, sadzieb odpisovania a odpisových metód, ktoré vyplývajú z predpokladaného priebehu opotrebenia majetku; informácie o výpočte odloženej daňovej pohľadávky a odloženého daňového záväzku; o aktivácii nákladov na vývoj; informácie o záväzkoch zabezpečených záložným právom a tiež o majetku, na ktorý bolo zriadené záložné právo ako i ďalšie informácie. (Farkaš, 2013) Rovnako by účtovná jednotka mala používateľom v poznámkach poskytnúť informácie o tichých rezervách, pokiaľ sú významné.

4 Vplyv zásady opatrnosti na ocenenie položiek účtovnej závierky

Vo všeobecnosti je zásada opatrnosti založená na subjektívnom posúdení niektorých skutočností účtovnou jednotkou, ktorá účtovnú závierku zostavuje. Základom takéhoto posúdenia musia byť však objektívne a overiteľné fakty. Účtovná legislatíva nestanovuje presnú výšku opravných položiek, odpisov či rezerv. Zákon o účtovníctve len stanovuje, že ku dňu, ku ktorému sa zostavuje účtovná závierka, je účtovná jednotka povinná upraviť ocenenie

hodnoty majetku, vytvoriť rezervy a odpisovať majetok v súlade s účtovnými zásadami a účtovnými metódami.

Ocenenie majetku sa upraví opravnými položkami, ak existuje opodstatnený predpoklad zníženia hodnoty majetku pod jeho účtovnú hodnotu, ktoré nemá trvalý charakter. Vychádza sa pritom z predpokladu, že pri majetku existuje riziko, či suma investovaná na obstaranie majetku sa v nejakej podobe do účtovnej jednotky vráti. Riziko návratnosti je vyjadrené vo formulácii opravných položiek - ocenenie majetku sa upravuje opravnými položkami, ak existuje opodstatnený predpoklad zníženia hodnoty majetku pod jeho účtovnú hodnotu. Predpoklad zníženia hodnoty majetku je opodstatnený, ak nastala skutočnosť, ktorá je dôvodom na odhad zníženia budúcich ekonomických úžitkov z tohto majetku. Opravné položky sa zrušia alebo sa zmení ich výška, ak nastane zmena predpokladu zníženia hodnoty. Opravné položky sa tvoria ku konkrétnemu druhu majetku alebo k rovnorodej skupine majetku. V nadväznosti na spôsob stanovenia výšky a spôsob účtovania opravnej položky sa opravné položky tvoria k týmto skupinám majetku - k odpisovanému dlhodobému hmotnému i dlhodobému nehmotnému majetku, neodpisovanému dlhodobému majetku, dlhodobému i krátkodobému finančnému majetku, zásobám, pohľadávkam, dlhodobým pohľadávkam a dlhodobému finančnému majetku, ktorým sú pôžičky, ak je zostatková doba splatnosti pohľadávky alebo pôžičky dlhšia ako jeden rok. (Sklenka a kol., 2016) Objektívnymi a overiteľnými faktami pre tvorbu odhadu opravnej položky k majetku môžu byť externé či interné faktory majúce vplyv na zníženie hodnoty majetku.

Rezervy sú záväzky s neistým časovým vymedzením alebo výškou. Ak nie je známa presná výška tohto záväzku, rezerva sa ocení odhadom v sume dostatočnej na splnenie existujúcej povinnosti ku dňu, ku ktorému sa zostavuje účtovná závierka pri zohľadnení rizík a neistôt. Objektívnou a overiteľnou príčinou tvorby odhadu rezerv je súčasná povinnosť vyplývajúca zo všeobecne záväzných právnych predpisov, z uzavretých zmlúv s inými právnickými alebo fyzickými osobami či povinnosti vyplývajúce z dobrovoľného rozhodnutia účtovnej jednotky. Pri vyčíslení výšky rezerv má účtovná jednotka brať do úvahy všetky známe riziká a neistoty, vplyv časovej hodnoty peňazí, v prípade dlhodobého záväzku, legislatívne zmeny a technologické zmeny v činnosti, ak existuje objektívny dôkaz, že tieto zmeny vzniknú. Pri tvorbe rezerv a jej ocenení je nutné zdôvodniť výšku vytvorenej rezervy. V prípade, že sa rezerva stanoví len samotným odhadom, odhad by mal byť nestranný a nezaujatý, v sporných prípadoch doložený posudkom znalca. (Sklenka a kol., 2016) Rezerva sa môže použiť len na účel, na ktorý bola vytvorená, t. j. nesmú sa vytvárať bezúčelové rezervy.

Hmotný majetok okrem zásob a nehmotný majetok okrem pohľadávok odpisuje účtovná jednotka počas predpokladanej doby používania zodpovedajúcej spotrebe ekonomických úžitkov z majetku. Každá položka dlhodobého hmotného majetku (s výnimkou neodpisovaného dlhodobého hmotného majetku) a nehmotného majetku sa musí odpisovať, pretože pri každej sa spotrebúvajú ekonomické úžitky. Za odhadom vzťahujúcim sa k odpisom je objektívny a overiteľný fakt spotreby ekonomických úžitkov z opotrebovaného dlhodobého majetku, v dôsledku čoho sa znižuje aj jeho hodnota. Účtovné odpisy majú vyjadrovať skutočné opotrebenie dlhodobého hmotného a nehmotného majetku za dané účtovné obdobie, nakoľko zohľadňujú skutočnú mieru použiteľnosti tohto majetku a jeho reálnu dobu životnosti, resp. skutočné výkony. Účtovná jednotka je povinná zostaviť odpisový plán, na základe ktorého vykonáva odpisovanie. Pri tvorbe odpisového plánu má účtovná jednotka zohľadniť očakávané použitie majetku a intenzitu jeho využitia; očakávané fyzické opotrebenie majetku; technické a morálne zastaranie; zákonné alebo iné obmedzenia na používanie majetku a tiež rôznu dobu použiteľnosti a rôzny priebeh opotrebenia jednotlivých oddeliteľných súčastí dlhodobého majetku podľa potrieb účtovnej jednotky. Treba si tiež uvedomiť, že skutočná miera použiteľnosti aj skutočná doba životnosti sú zriedkakedy totožné s ich odhadmi. Preto je dôležité pravidelne revidovať tak mieru opotrebenia ako i dobu životnosti. V záujme

dosiahnutia verného a pravdivého obrazu je preto treba prehodnotiť odpisový plán a upraviť zostatkovú dobu odpisovania alebo sadzby odpisovania. V minulosti zaúčtované odpisy spätne neupravujeme, lebo predpokladáme, že odhad výšky odpisu, ktorý sme v minulosti zrealizovali, sme urobili podľa najlepšieho vedomia a svedomia, a preto zásah do účtovníctva minulých účtovných období nie je žiaduci. Upravíme výšku odpisov v zostávajúcej dobe používania dlhodobého majetku.

Opravné položky, odpisy i rezervy sa teda musia vykazovať vo výške primeraného subjektívneho odhadu, ktorý vychádza z objektívnych a overiteľných faktov. Práve z dôvodu uplatnenia subjektívneho odhadu pri týchto položkách patria opravné položky, odpisy i rezervy k najdôležitejším nástrojom bilančnej politiky. Keďže všetky tieto položky majú vplyv nielen na ocenenie výšky majetku i záväzkov v súvahe, a teda i na výšku vlastného imania v súvahe, ale i na výšku výsledku hospodárenia, je dôležité, aby vedenie účtovnej jednotky vedome nenadhodnocovalo (prípadne ich tvorilo vtedy, keď na to nie je dôvod, čím by neopodstatnene vytváralo tiché rezervy) a rovnako nepodhodnocovalo (prípadne ich netvorili vtedy, keď na ich tvorbu dôvod je) výšku opravných položiek, odpisov alebo rezerv. Z hľadiska financovania sa opravné položky, rezervy i odpisy považujú za interný zdroj financovania, pretože účtovaním tvorby opravných položiek, rezerv i odpisov do nákladov sa znižuje výsledok hospodárenia, v niektorých prípadoch aj základ dane a s tým súvisiaca daňová povinnosť.

Odhady pri zostavovaní účtovnej závierky zohrávajú významnú úlohu, neznižujú spoľahlivosť a vierohodnosť účtovnej závierky. Každý odhad uskutočnený v účtovníctve sa musí stanoviť na základe úsudku manažmentu účtovnej jednotky, mal by vychádzať zo skúseností s podobnými transakciami v minulých účtovných obdobiach, z očakávaných predpokladov vývoja skutočností, ktoré nastanú v budúcnosti, uzatvorených zmlúv, prepočtov, rozpočtov, vlastnej intuície, ako aj profesionálnej odbornosti resp. môže sa opierať i o odborné stanovisko experta v danej oblasti. Pri stanovení odhadu musí vedenie účtovnej jednotky vziať do úvahy všetky relevantné informácie, ktoré sú známe a súvisia s danou skutočnosťou ku dňu, ku ktorému sa zostavuje účtovná závierka, ako aj informácie vyplývajúce z udalostí, ktoré nastali po tomto dni až do dňa zostavenia účtovnej závierky. Pri stanovení odhadu sa musia tiež zohľadniť všetky známe riziká a neistoty, ktoré nevyhnutne vyplývajú zo súvisiacich udalostí a okolností. Keďže každý odhad je spojený s určitou mierou subjektivity, použitie odhadu, ktorý je náležite odôvodnený a nie je v rozpore s požiadavkou spoľahlivosti ocenenia, je akceptovateľný na dodržanie zásady verného a pravdivého obrazu o skutočnostiach, ktoré sú predmetom účtovníctva. Nie je pritom dôležité, či sa neskôr ukáže, že odhad mal byť vyšší alebo nižší, podľa právnej úpravy sa úprava odhadu ani nepovažuje za chybu. To však neznamená, že v procese stanovenia odhadu nemôže dôjsť k chybe v odhade. Chyba v odhade vzniká vtedy, ak pri jeho stanovení vedenie účtovnej jednotky nezohľadnilo všetky známe relevantné informácie, ktoré ku dňu zostavenia účtovnej závierky boli k dispozícii. K úprave odhadu dochádza vtedy, ak vedenie účtovnej jednotky uskutočnilo odhad na základe všetkých dostupných relevantných informácií ku dňu, ku ktorému sa zostavuje účtovná závierka i ku dňu jej skutočného zostavenia, no v nasledujúcom účtovnom období na základe aktuálneho vývoja udalostí došlo k zmene podmienok, ktoré treba v účtovníctve zohľadniť. Odlíšiť chybu od úpravy odhadu je dôležité z dôvodu ich odlišného účtovania a odlišného vplyvu na výsledok hospodárenia bežného účtovného obdobia.

Zásada opatrnosti v prípade poklesu cien majetku zabezpečí verný a pravdivý obraz o finančnej situácii a výkonnosti účtovnej jednotky. Avšak v prípade nárastu cien majetku, čoho sme takmer neustále svedkami, v dôsledku uplatňovania realizačného princípu, dochádza k nevykázaniu nerealizovaných ziskov a tiež k tvorbe tichých rezerv. Následkom aplikovania realizačného princípu je, že zisky z vlastníctva majetku, pri ktorom v priebehu účtovného obdobia došlo k nárastu cien, sa nevykazujú v účtovnom období, v ktorom vznikli, ale až v období realizácie daného majetku. Na druhej strane platí, že v bežnom účtovnom období je

možné vykázat zisky z vlastníctva (držby) majetku, ktoré vznikli v predchádzajúcich účtovných obdobiach, ale realizované boli až v bežnom účtovnom období. Z uvedeného vidíme, že v situácii výrazného rastu cien majetku sa zásada opatrnosti dostáva do rozporu so zásadou verného a pravdivého obrazu. Z dôvodu minimalizácie tohto rozporu dochádza v slovenskej účtovnej legislatíve k porušeniu realizačného princípu pri určitých druhoch majetku, to najmä takých, pri ktorých existuje aktívny trh, a teda je možné reálnu hodnotu objektívne získať, pričom reálna hodnota umožňuje spoľahlivé ocenenie bez ohľadu na jej výšku. Pri ocenení majetku reálnou hodnotou sa účtovná hodnota mení smerom hore i dolu, na rozdiel od uplatnenia zásady opatrnosti, kedy sa ocenenie majetku môže upravovať len smerom nadol a to pomocou opravných položiek. Spätné zvýšenie ocenenia je možné len do výšky pôvodného ocenenia. Zásada opatrnosti tak neplatí pri presne vymedzenom majetku, pri ktorom sa zmena reálnej hodnoty účtuje s vplyvom na výsledok hospodárenia, napr. pri cenných papieroch určených na obchodovanie (majetkových i dlhových). Zisk z precenenia sa teda považuje za realizovaný. Cenné papiere určené na obchodovanie sú držané za účelom vykonania obchodu na tuzemskej burze, zahraničnej burze alebo inom verejnom trhu s cieľom dosahovať zisk z cenových rozdielov v krátkodobom horizonte. Nakoľko takýto majetok je možné kedykoľvek pomerne rýchlo predat' a nerealizovaný zisk, ktorý je súčasťou ocenenia vyššou reálnou hodnotou aj skutočne dosiahnuť, riziko, že takýto nerealizovaný zisk nebude dosiahnutý, je minimálne. Preto sa i rozdiely medzi prvotným ocenením a reálnou hodnotou, ktorou je tento majetok ocenený ku dňu, ku ktorému sa zostavuje účtovná závierka, účtujú s vplyvom na výsledok hospodárenia. V určitých zákonom o účtovníctve stanovených prípadoch, v ktorých sa zmena reálnej hodnoty neúčtuje s vplyvom na výsledok hospodárenia, ale v nejakej inej položke vlastného imania, zásada opatrnosti platí, nakoľko zisk z precenenia na reálnu hodnotu sa nepovažuje za realizovaný, napr. pri cenných papieroch a podieloch určených na predaj, ak sa účtovná jednotka pri obstaraní rozhodla takéto cenné papiere a podiely oceniť reálnou hodnotou. Nakoľko pri týchto cenných papieroch a podieloch existuje aktívny trh, nie je zložitá zistiť ich reálnu hodnotu. Účtovné jednotky ich však nenakupujú s cieľom dosahovať zisk z cenových rozdielov v krátkodobom horizonte, ale pre podporu svojej podnikateľskej činnosti. Úmysel účtovnej jednotky pri obstaraní tohto typu cenných papierov je iný než pri cenných papieroch určených na obchodovanie. (Farkaš, 2020) V tejto súvislosti treba poznamenať, že v Slovenskej republike by vernému a pravdivému obrazu o finančnej situácii účtovnej jednotky prospela i možnosť preceňovania dlhodobého hmotného majetku na reálnu hodnotu, nakoľko pod vplyvom inflácie, ktorá nie je zanedbateľná, je nielen brutto ocenenie dlhodobého hmotného majetku v účtovníctve, ale aj ocenenie oprávok a odpisov ako ročnej kategórie zníženia hodnoty dlhodobého hmotného majetku značne podhodnotené. Odpisy ako interný zdroj financovania majetku vyčíslované z obstarávacej ceny majetku nedokážu zabezpečiť obnovu používaním opotrebovaného majetku a teda ani zabrániť erózii vlastného kapitálu. Účtovná jednotka musí potom hľadať alternatívne zdroje potrebné na výmenu daného majetku. Okrem uvedeného príkladu, keď sa rozdiel z precenenia majetku a záväzkov na reálnu hodnotu účtuje s vplyvom na výsledok hospodárenia, k porušeniu zásady opatrnosti dochádza napr. i v prípade účtovania kurzových ziskov z prepočtu majetku a záväzkov v cudzej mene ku dňu, ku ktorému sa zostavuje účtovná závierka, v prípade účtovania zisku podľa metódy stupňa dokončenia zákazky, či účtovania odloženej daňovej pohľadávky.

Okrem vyššie spomínaného nárastu cien majetku, ktorý nemôžeme z legislatívnych dôvodov zohľadniť v účtovníctve, k tvorbe tichých rezerv ako nevyhnutnému dôsledku uplatňovania zásady opatrnosti (ak vylúčime možnosť, že sa jedná o bilančný delikt) v účtovníctve dochádza i v prípade nadhodnotenia odpisov dlhodobého majetku, podhodnotenia zásob vlastnej výroby vplyvom neaktivovania časti nákladov, nadmerného premietania známych rizík a neistôt do účtovníctva, nakoľko to môže vyústiť do tvorby nadhodnotených opravných položiek i do tvorby nadmerných rezerv, čím sa účelovo

podhodnotí majetok a nadhodnotia záväzky oproti ich oceneniu v skutočnosti. Tiché rezervy viazané na majetok znižujú v súvahe bilančnú sumu, tiché rezervy viazané na záväzky nemajú na bilančnú sumu vplyv, dochádza len k zmene pomeru medzi vlastným imanom a záväzkami. Tiché rezervy vzniknuté v bežnom účtovnom období umožňujú v nasledujúcich účtovných obdobiach vykázat nižšie náklady a tak umelo zlepšiť nielen výsledok hospodárenia, ale aj ukazovatele rentability. Tiché rezervy tak napomáhajú k efektívnemu presúvaniu výsledku hospodárenia medzi účtovnými obdobiami. Vedenie účtovnej jednotky môže vplyvom tvorby tichých rezerv výsledok hospodárenia znižovať a vplyvom rozpustenia tichých rezerv výsledok hospodárenia zvyšovať, čím môže vedenie účtovnej jednotky stabilizovať výsledok hospodárenia na požadovanej úrovni, zabrániť nadmernému odčerpaniu zisku vo forme dividend, ovplyvniť vnútornú hodnotu akcie svojej účtovnej jednotky alebo trhovú cenu svojich akcií. (Kovanicová, 2005) Tvorba tichých rezerv umožňuje účtovnej jednotke nevykazovať v účtovníctve nerealizované zisky, čím zabráni vyplácaniu časti svojich disponibilných prostriedkov vo forme dividend alebo daní, ktoré môže investovať napr. do svojho rozvoja. O existencii významných tichých rezerv je preto účtovná jednotka svojich používateľov povinná informovať v poznámkach.

Ešte i dnes, v čase, keď zásada opatrnosti je plne akceptovaná a v metodike účtovníctva ukotvená sa stretávame s nedostatočným uplatňovaním tejto zásady v praxi účtovných jednotiek. Účtovné jednotky podceňujú tvorbu opravných položiek, rezerv, ale i účtovných odpisov v správnej výške, resp. ich účtovanie nie je konzistentné a javí sa ako účelové. Vo významnej miere je tento prístup daný i tým, že daňová legislatíva zásadu opatrnosti odmieta, uznáva len časť položiek, ktoré sú prejavom zásady opatrnosti (napr. len opravné položky k pohľadávkam, ale len v rozsahu stanovenom zákonom o dani z príjmov; rezervy na nevyčerpané dovolenky vrátane poistného a príspevkov, ktoré je povinný platiť zamestnávateľ za zamestnanca; na vyprodukované emisie v zmysle osobitného predpisu; na lesnú pestovnú činnosť; na likvidáciu hlavných banských diel, lomov a odpadov pri banskej činnosti; na nakladanie s odovzdaným elektroodpadom z domácností; odpisy dlhodobého majetku len vo výške stanovenej zákonom o dani z príjmov, ktoré nezodpovedajú skutočnej výške opotrebenia dlhodobého majetku). Je zrejme, že ciele daňovej legislatívy reprezentované efektívnym výberom daní sú iné než ciele účtovníckej legislatívy, ktoré spočívajú vo vernom a pravdivom zobrazení ekonomickej reality, a teda že daňová legislatíva rešpektuje iné než účtovné hľadiská, ktoré musia byť v súlade so všeobecne uznávanými účtovnými zásadami vrátane zásady opatrnosti. Mnohé účtovné jednotky pri účtovnom riešení uvedených problémov uprednostňujú kvôli zjednodušeniu daňový prístup riešenia problému. Mnohé účtovné jednotky volia pre účtovné účely daňové riešenie problému a to najmä v prípadoch, keď daňová legislatíva umožňuje zahrnúť do základu dane z príjmov vyššie sumy nákladov než sú tie, ktoré zodpovedajú účtovným zásadám. Existujú totiž prípady, keď i daňová legislatíva je konštruovaná so zámerom pozitívne ovplyvniť investičné rozhodnutia účtovných jednotiek, napr. možnosť zahrnúť obstarávaciu cenu osobného automobilu poháňaného elektromotorom alebo kombináciou elektromotora a spaľovacieho motora v priebehu dvoch zdaňovacích období. Táto možnosť je nepochybne pre účtovné jednotky mimoriadne atraktívna, pretože vyššia čiastka ročných odpisov znamená zníženie daňovej povinnosti, avšak v účtovníctve je takýto prístup neprípustný, nakoľko odporuje všeobecne uznávanej účtovnej zásade vecného a časového priradovania nákladov k výnosom, ktoré sa vzťahujú na to isté účtovné obdobie a z ktorých sa vypočíta výsledok hospodárenia.

V dôsledku odlišného chápania transakcií, ktoré sú predmetom účtovníctva z hľadiska účtovnej a daňovej legislatívy dochádza k dočasným rozdielom medzi účtovnou hodnotou majetku a záväzkov a ich daňovou základňou. Dočasné rozdiely môžu byť zdaniteľné alebo odpočítateľné. Nie je podstatné, kedy sa vyrovnajú. V prípade, keď napr. účtovná hodnota dlhodobého hmotného majetku je vyššia než jeho daňová základňa (v dôsledku toho, že daňový

odpis je vyšší ako účtovný odpis) alebo zákon o dani z príjmov umožňuje vytvoriť opravné položky k majetku vo vyššej výške ako ich vytvorila účtovná jednotka k danému majetku (možno ich ani nevytvorila) alebo majetok je precenený na reálnu hodnotu, ale jeho daňová základňa sa nezmenila alebo účtovná hodnota záväzku je nižšia ako jeho daňová základňa, vznikajú v účtovnej jednotke zdaniteľné dočasné rozdiely. V tomto účtovnom období vykáže účtovná jednotka nižší základ dane z príjmov a nižšiu daňovú povinnosť, než by vykázala z výsledku hospodárenia vyčísleného v účtovníctve. V budúcnosti sa však situácia otočí a účtovná jednotka bude vykazovať vyšší základ dane z príjmov a vyššiu daňovú povinnosť. Z dôvodu uplatnenia opatrnosti preto účtovná jednotka v bežnom účtovnom období zaúčtuje a vykáže odložený daňový záväzok, čím sa zdanený dočasný rozdiel stane nákladom bežného účtovného obdobia (rovnako ako splatná daň z príjmu). Takto dosiahneme vykázanie zdaneného výsledku hospodárenia vyčísleného v účtovníctve a eliminujeme vplyv daňovej legislatívy. Odložený daňový záväzok sa vykazuje vždy, bez ohľadu na to, či je pravdepodobné, že účtovná jednotka v budúcnosti z týchto zdaniteľných rozdielov daň zaplatí alebo nie. Na rozdiel od odloženého daňového záväzku, ktorý sa vykazuje vždy, odložená daňová pohľadávka sa vykazuje len vtedy, ak je pravdepodobné, že sa využije. Dôležité je preto, aby účtovná jednotka zvažila nielen to, či dosiahne dostatočne veľký základ dane, ale aj to, či ho dosiahne v potrebnom účtovnom období. (Farkaš, 2013) Vidíme, že pri odloženej daňovej pohľadávke sú postupy účtovania benevolentnejšie, pracujú s požiadavkou „pravdepodobnosti“, nesprísnil ju na „takmer isté“. Odložená daňová pohľadávka sa okrem iného vzťahuje na odpočítateľné dočasné rozdiely, ktoré vznikajú napr. vtedy, keď účtovná hodnota dlhodobého hmotného majetku je nižšia, než jeho daňová základňa (v dôsledku toho, že účtovný odpis je vyšší než daňový odpis), účtovná hodnota pohľadávky či zásob je nižšia, než je jej daňová základňa (bola vytvorená opravná položka k pohľadávkam alebo zásobám), účtovná hodnota rezerv je vyššia než ich daňová základňa (náklad, na ktorý bola vytvorená rezerva v účtovníctve, ktorej tvorba nie je uznaná za daňový výdavok, sa zahrnie do základu dane v tom zdaňovacom období, v ktorom dôjde k použitiu rezervy, a to do výšky, v akej je tento náklad uznaný za daňový výdavok). Vidíme, že k vzniku odpočítateľných rozdielov dochádza v situáciách, keď účtovné chápanie daných transakcií je „opatrnejšie“ než daňové chápanie týchto transakcií, t. j. výsledkom posúdenia je nižšia účtovná hodnota majetku ako jeho daňová základňa, či vyššia účtovná hodnota záväzku než jeho daňová základňa. V dôsledku vyšších nákladov v účtovníctve, účtovná jednotka dosiahne nižší výsledok hospodárenia. Naopak v dôsledku nižších daňových výdavkov, účtovná jednotka dosiahne vyšší základ dane a vyššiu daňovú povinnosť. V budúcnosti sa však situácia otočí a účtovná jednotka z dôvodu využitia odpočítateľných rozdielov ušetrí na dani z príjmov, bude vykazovať nižší základ dane a tým nižšiu daňovú povinnosť. Túto budúcu úsporu zohľadní už teraz vo forme odloženej daňovej pohľadávky. Účtovná jednotka využije budúcu úsporu na dani z príjmov len vtedy, ak v budúcnosti dosiahne dostatočne veľký základ dane. Preto účtovanie tejto budúcej úspory ako majetku v čase, keď nie je „takmer isté“ (ale len pravdepodobné), že ju dosiahneme, s vplyvom na výsledok hospodárenia, je do istej miery porušením realizačného princípu. Pri odloženej daňovej pohľadávke významnú úlohu zohráva pravdepodobnosť, že sa odložená daňová pohľadávka v budúcnosti aj naozaj využije. Ak by to nebolo pravdepodobné, odložená daňová pohľadávka sa v súvahe nevykáže.

5 Záver

Primárnym dôvodom pre uplatňovanie zásady opatrnosti v účtovníctve je neistota a riziko, ktoré sú prirodzenou súčasťou podnikateľskej činnosti účtovnej jednotky počas celej jej existencie. Neistota a riziko často vyplývajú z faktorov, ktoré účtovná jednotka nemôže ovplyvniť, napr. zmeny úrokových sadzieb, zmeny kurzov zahraničných mien či zmeny cien.

Dôsledné uplatňovanie zásady opatrnosti má za následok vykazovanie majetku a výnosov v nižšej výške a naopak vykazovanie záväzkov a nákladov vo vyššej výške. Z uvedeného vyplýva, že majetok a výnosy by sa nemali nadhodnocovať a naopak záväzky a náklady podhodnocovať a to nielen z hľadiska ich ocenenia v účtovnej závierke, ale i z hľadiska rozsahu položiek prezentovaných v účtovnej závierke. Takáto prezentácia jednotlivých zložiek účtovných výkazov vyhovuje predovšetkým záujmom samotnej účtovnej jednotky a tiež jej veriteľom, ktorí majú záujem o vykazovanie nižšieho ocenenia majetku a menej vyhovuje ostatným používateľom informácií vrátane existujúcich vlastníkov účtovnej jednotky, ktorí majú záujem o vykazovanie čo najvyššej výšky výsledku hospodárenia. Vedenie účtovnej jednotky by v súvislosti s aplikáciou zásady opatrnosti vždy malo uplatniť taký účtovný odhad vybraných položiek, ktorý jednak zabezpečí, že účtovná jednotka z viacerých možností odhadu vyberá ten, ktorý je pre ňu opatrnejší a jednak, že účtovná závierka poskytne verný a pravdivý obraz o skutočnostiach, ktoré sú predmetom účtovníctva a o finančnej situácii i finančnej výkonnosti účtovnej jednotky. V opačnom prípade účtovná závierka poskytne skreslené informácie, a preto nie je vhodná pre prijímanie dôležitých rozhodnutí zo strany používateľov informácií vo vzťahu k účtovnej jednotke. Dôsledkom extrémneho chápania zásady opatrnosti na jednej strane (ak vylúčime úmyselnú manipuláciu informácií), ale aj dodržiavania niektorých ustanovení účtovnej legislatívy na strane druhej, najmä v období výrazného nárastu cien, môže byť vznik neprípustne vysokých tichých rezerv, ktorých existencia a životný cyklus môže prispieť k presúvaniu výsledku hospodárenia medzi účtovnými obdobiami. Cielené využívanie tichých rezerv tak môže patriť nielen k významným nástrojom finančného riadenia účtovnej jednotky, ale byť aj zdrojom významného skreslenia informácií o finančnej situácii a výkonnosti účtovnej jednotky. Sme presvedčení, že aplikácia zásady opatrnosti nemá viesť k vzniku tichých rezerv ani úmyselným podhodnocovaním majetku a výnosov ani nadhodnocovaním záväzkov a nákladov, nakoľko takéto informácie prezentované v účtovnej závierke neposkytujú verný a pravdivý obraz o skutočnostiach, ktoré sú predmetom účtovníctva, a teda nie sú pre používateľa týchto informácií užitočné. Pokiaľ z hocakého aspektu absentuje uplatnenie zásady opatrnosti, používateľ má právo poznať dôvody i finančné dôsledky neuplatnenia tejto zásady. S nedostatočným uplatňovaním tejto zásady v praxi účtovných jednotiek sa často stretávame i z dôvodu, že daňová legislatíva zásadu opatrnosti neakceptuje, uznáva len časť položiek, ktoré sú prejavom zásady opatrnosti. Riziko subjektivismu a nepresnosti spojené s odhadom u položiek, ktoré sú prejavom aplikácie zásady opatrnosti by nemalo byť prekážkou daňovej uznateľnosti nákladov, ktoré sú s tvorbou týchto položiek spojené. Na elimináciu tohto rizika spojeného so subjektivismom a nepresnosťou je potrebné vypracovanie kvalitných vnútorných predpisov pre opravné položky, rezervy, odpisy, vyčíslenie reálnej hodnoty, ktoré sú jednak významným prvkom vnútorného kontrolného systému, a ktoré sú pri daňovej kontrole vnímané ako jeden z najsilnejších a najúčinnějších dôkazov. Nazdávame sa, že existujúca previazanosť medzi účtovnou a daňovou legislatívou bráni dôslednému uplatňovaniu zásady opatrnosti v účtovníctve, čo je škoda, nakoľko účtovná závierka, v ktorej je uplatnená zásada opatrnosti, verne a pravdivo prezentuje skutočnosti, ktoré sú predmetom účtovníctva s dôrazom na nepretržité pokračovanie v činnosti účtovnej jednotky v podmienkach neistoty a rizika, ktoré so sebou podnikateľská činnosť prináša. Uplatnenie zásady opatrnosti totiž zabraňuje vykázaniu vyššieho zisku a jeho prípadnému rozdeleniu, čím prispieva k ochrane nielen veriteľov, ale aj vlastníkov účtovnej jednotky a zabezpečuje nepretržité pokračovanie v činnosti.

Literatúra

1. Farkaš, R. (2013). *Odložené dane v individuálnej a konsolidovanej účtovnej závierke*. 2. prepracované a doplnené vydanie. Bratislava: Iura Edition.
2. Farkaš, R. (2019). *Poznámky účtovnej závierky pre veľké účtovné jednotky a subjekty verejného záujmu v praxi*. 1. vydanie. Bratislava: Wolters Kluwer.
3. Farkaš, R. (2020). *Účtovná závierka obchodných spoločností*. 1. vydanie. Bratislava: Wolters Kluwer.
4. Kovanicová, D. (2005). *Finanční účetnictví. Světový koncept IFRS/IAS*. 5. aktualizované vydání. Praha: Polygon.
5. Opatrenie MF SR č. 23054/2002-92, ktorým sa ustanovujú podrobnosti o postupoch účtovania a rámcovej účtovnej osnove pre podnikateľov účtujúcich v sústave podvojného účtovníctva v znení neskorších predpisov.
6. Opatrenie MF SR č. MF/23377/2014-74, ktorým sa ustanovujú podrobnosti o individuálnej účtovnej závierke a rozsahu údajov určených z individuálnej účtovnej závierky na zverejnenie pre veľké účtovné jednotky a subjekty verejného záujmu, v znení neskorších predpisov.
7. Škoda, M. (2005). Je alebo nie je zásada opatrnosti v rozpore s realizačným princípom? *Dane a účtovníctvo v praxi*, 2005(8), 89-92.
8. Sklenka, M. a kol. (2016). *Účtovníctvo podnikateľských subjektov II*. 1. vydanie. Bratislava: Wolters Kluwer.
9. Šlosárová, A. a kol. (2011). *Účtovníctvo*. 1. vydanie. Bratislava: Iura Edition.
10. Šlosárová, A., Blahušiaková, M. (2017). *Analýza účtovnej závierky*. 1. vydanie. Bratislava: Wolters Kluwer.
11. Zákon č. 431/2002 Z. z. o účtovníctve v znení neskorších predpisov.

Efektivita difúzných modelov v multimediálnej tvorbe

The effectiveness of diffusion models in multimedia creation

Peter Procházka¹

Abstrakt

Tento výskum sa zameriava na analýzu efektivity generatívnych difúzných modelov v kontexte multimediálnej tvorby. Skúmame vzťah medzi nastavením parametrov týchto modelov, kvalitou generovaného obsahu a výpočtovou náročnosťou. Prostredníctvom série experimentov hodnotíme vplyv rôznych hyperparametrov na kvalitu výstupu a analyzujeme kompromis medzi kvalitou a výpočtovou efektivitou. Naše zistenia poskytujú cenné poznatky pre optimalizáciu využitia difúzných modelov v reálnych aplikáciách a naznačujú smer pre budúci výskum v oblasti generatívnych modelov pre multimediálnu tvorbu.

Kľúčové slová

difúzne modely, generatívne modelovanie, multimediálna tvorba, výpočtová efektivita, kvalita obrazu, umelá inteligencia

Abstract

This research focuses on analyzing the effectiveness of generative diffusion models in the context of multimedia content creation. We examine the relationship between the parameter settings of these models, the quality of generated content, and computational complexity. Through a series of experiments, we evaluate the impact of various hyperparameters on output quality and analyze the trade-off between quality and computational efficiency. Our findings provide valuable insights for optimizing the use of diffusion models in real-world applications and suggest directions for future research in the field of generative models for multimedia content creation.

Key words

diffusion models, generative modeling, multimedia creation, computational efficiency, image quality, artificial intelligence

JEL classification

C45, C61, C63

1 Úvod

V posledných rokoch sme svedkami revolúcie v oblasti umelej inteligencie, pričom generatívne modely založené na difúzných procesoch zaujali popredné miesto v generovaní multimediálneho obsahu. Tieto modely prinášajú nové možnosti v oblasti počítačového videnia, spracovania prirodzeného jazyka a tvorby multimediálneho obsahu (Dhariwal a Nichol, 2021). Ich schopnosť vytvárať realistické a vysoko kvalitné výstupy otvorila nové horizonty v rôznych odvetviach, od umenia a dizajnu až po vedecký výskum a vývoj produktov.

Difúzne modely, ktoré boli pôvodne predstavené Sohlem-Dicksteinom et al. (2015), fungujú na princípe postupného pridávania šumu do dát a následného učenia sa tento proces

¹ Ekonomická univerzita v Bratislave, Fakulta hospodárskej informatiky, Katedra aplikovanej informatiky, Dolnozemska cesta 1, 852 35 Bratislava, peter.prochazka@euba.sk.

zvrátiť. Tento prístup sa ukázal byť mimoriadne efektívny pri generovaní rôznych typov multimediálneho obsahu, vrátane obrazov, zvukov a videí (Ho et al., 2020). Napriek ich nepopierateľnému potenciálu však zostáva mnoho otázok ohľadom optimálneho nastavenia parametrov týchto modelov, ich výpočtovej efektivity a kvality generovaného obsahu.

V kontexte multimediálnych aplikácií sú generatívne modely založené na difúzných procesoch obzvlášť zaujímavé vďaka ich schopnosti zachytiť komplexné štatistické vzory v dátach. Ramesh et al. (2022) demonštrovali ich potenciál v oblasti generovania obrazov na základe textových popisov, čo otvorilo nové možnosti pre interaktívnu tvorbu obsahu. Zároveň však Song et al. (2021) poukázali na výzvy spojené s kontrolou a interpretáciou výstupov týchto modelov, čo zdôrazňuje potrebu ďalšieho výskumu v tejto oblasti.

V tomto článku sa zameriavame na analýzu použitia generatívnych modelov založených na difúzných procesoch v multimediálnych aplikáciách. Naším cieľom je preskúmať, ako rôzne parametre týchto modelov ovplyvňujú kvalitu generovaného obsahu a aký je vzťah medzi výpočtovou náročnosťou a kvalitou výstupu. Taktiež sa zameriame na porovnanie týchto modelov s existujúcimi prístupmi v oblasti generovania multimediálneho obsahu.

2 Ciele výskumu

Hlavným cieľom našej štúdie je vyhodnotiť efektivitu generatívnych difúzných modelov v multimediálnej tvorbe so zameraním na kvalitu výstupu a výpočtovú náročnosť. Tento cieľ sledujeme v kontexte rastúceho významu automatizovanej tvorby multimediálneho obsahu a potreby efektívnych nástrojov v tejto oblasti (Rombach et al., 2022).

Na dosiahnutie nášho hlavného cieľa sme formulovali nasledujúce špecifické výskumné otázky:

1. Ako ovplyvňujú rôzne parametre difúzných modelov kvalitu generovaného multimediálneho obsahu?
2. Aký je vzťah medzi výpočtovou náročnosťou a kvalitou výstupu pri použití týchto modelov?
3. Aké sú hlavné rozdiely medzi navrhovanou metódou a súčasnými postupmi pri tvorbe multimediálneho obsahu?

Prostredníctvom týchto výskumných otázok sa snažíme nielen prispieť k teoretickému pochopeniu difúzných modelov, ale aj poskytnúť praktické poznatky pre ich efektívne využitie v multimediálnych aplikáciách.

3 Teoretické základy a súvisiace práce

Generatívne modely predstavujú kľúčovú oblasť strojového učenia, ktorá sa zameriava na vytváranie nových dát na základe naučených vzorov. V rámci tohto širšieho kontextu, difúzne modely ponúkajú inovatívny prístup založený na princípoch postupnej transformácie dát. Tieto modely využívajú koncepty z teórie Markovových reťazcov a stochastických diferenciálnych rovníc na modelovanie komplexných distribúcií dát. Kľúčovým aspektom je tzv. score-based generovanie, ktoré umožňuje efektívne vzorkovanie z týchto distribúcií.

3.1 Generatívne modely

Oblasť generatívnych modelov v strojovom učení zaznamenala v posledných rokoch výrazný pokrok. Tieto modely sa snažia zachytiť podstatné charakteristiky tréningových dát a využiť ich na tvorbu nového, syntetického obsahu. Na rozdiel od diskriminačných modelov, ktoré sa zameriavajú na klasifikáciu alebo predikciu, generatívne modely sa učia reprezentovať samotnú distribúciu dát. Tieto modely sa v posledných rokoch stali predmetom intenzívneho výskumu vďaka ich schopnosti generovať realistický obsah v rôznych doménach, vrátane obrazov, textu a zvuku (Goodfellow et al., 2014).

Medzi populárne prístupy v oblasti generatívnych modelov patria variačné autoenkodéry (VAE), generatívne adversariálne siete (GAN) a v poslednej dobe aj autoregresívne modely. Každý z týchto prístupov má svoje špecifické výhody a obmedzenia. Napríklad, GAN-y sú známe schopnosťou produkovať vysoko kvalitné výstupy, ale často trpia nestabilitou pri tréňovaní a módomým kolapsom.

V tomto kontexte predstavujú difúzne modely nový a sľubný prístup, ktorý sa snaží prekonať niektoré z limitácií existujúcich metód. Ich unikátny prístup k modelovaniu distribúcie dát ponúka potenciál pre stabilnejšie tréňovanie a lepšiu kontrolu nad procesom generovania.

3.2 Difúzne procesy v generatívnych modeloch

Difúzne modely predstavujú inovatívny prístup v oblasti generatívnych modelov. Ich základný princíp spočíva v postupnom pridávaní šumu do dát a následnom učení sa tento proces zvrátiť. Sohl-Dickstein et al. (2015) predstavili tento koncept ako alternatívu k tradičným generatívnym modelom, pričom poukázali na jeho potenciál pre vytváranie vysoko kvalitných výstupov.

Kľúčovým aspektom difúzných modelov je ich schopnosť modelovať komplexné distribúcie dát prostredníctvom série jednoduchších transformácií. Tento prístup umožňuje efektívne učenie a generovanie v priestoroch s vysokou dimenzionalitou, čo je obzvlášť výhodné pre multimedialne aplikácie (Ho et al., 2020).

3.3 Aplikácie v multimedialnej oblasti

Difúzne modely našli široké uplatnenie v multimedialnej oblasti. Ramesh et al. (2022) demonštrovali ich potenciál v generovaní obrazov na základe textových popisov, čím otvorili nové možnosti pre interaktívnu tvorbu vizuálneho obsahu. Okrem už spomenutého generovania obrazov na základe textových popisov, tieto modely preukázali schopnosť vykonávať komplexné úpravy existujúcich obrazov. Napríklad, Meng et al. (2021) predstavili metódu SDEdit, ktorá umožňuje sémantickú manipuláciu s obrazmi prostredníctvom difúzných modelov. Táto technika dovoľuje užívateľom vykonávať sofistikované úpravy, ako je zmena štýlu obrazu alebo pridávanie či odstraňovanie objektov, pričom zachováva vysokú úroveň realizmu.

V oblasti spracovania zvuku difúzne modely otvorili nové možnosti pre syntézu a konverziu reči. Kong et al. (2021) vo svojej práci o DiffWave ukázali, že tieto modely dokážu generovať vysoko kvalitné zvukové vlny s výnimočnou vernosťou. Tento prístup má potenciál revolucionizovať oblasti ako je syntéza reči pre asistenčné technológie alebo vytváranie realistických zvukových efektov pre filmový a herný priemysel.

Zaujímavou aplikáciou difúzných modelov je aj oblasť umeleckej tvorby. Briot et al. (2022) vo svojej štúdii skúmali využitie týchto modelov pre generovanie hudobných kompozícií. Zistili, že difúzne modely dokážu zachytiť komplexné štrukturálne vzťahy v hudbe, čo vedie k tvorbe koherentných a esteticky príjemných skladieb. Tento výskum otvára nové možnosti pre počítačom asistovanú hudobnú kompozíciu a interaktívne hudobné nástroje.

V oblasti video produkcie Ho et al. (2022) predstavili Video Diffusion Models (VDM), ktoré rozširujú koncept difúzných modelov na generovanie video sekvencií. Tento prístup umožňuje nielen vytváranie krátkych videí na základe textových popisov, ale aj interpoláciu medzi kľúčovými snímkami, čo má potenciálne aplikácie vo filmovej produkcii a vizuálnych efektoch.

Difúzne modely našli uplatnenie aj v oblasti rozšírenej a virtuálnej reality (AR/VR). Saito et al. (2023) vo svojom výskume využili tieto modely pre generovanie realistických 3D textúr a materiálov. Tento prístup významne zlepšuje vizuálnu kvalitu AR/VR prostredí a zároveň znižuje nároky na manuálnu prácu pri tvorbe 3D obsahov.

V neposlednom rade, difúzne modely prispievajú k pokroku v oblasti multimedialnej analýzy a porozumenia. Napríklad, Rombach et al. (2022) ukázali, že tieto modely môžu byť použité pre úlohy ako je sémantická segmentácia obrazov alebo detekcia objektov, čo rozširuje ich potenciálne využitie nad rámec čisto generatívnych úloh.

Tieto rozmanité aplikácie ilustrujú flexibilitu a potenciál difúzných modelov v multimedialnej oblasti. S pokračujúcim výskumom a vývojom očakávame, že sa spektrum aplikácií týchto modelov bude ďalej rozširovať, čo povedie k novým inovatívnym nástrojom a technikám v oblasti multimedialnej tvorby a spracovania.

3.4 Prehľad existujúcich prístupov a ich limitácií

Napriek značnému pokroku v oblasti difúzných modelov existujú stále výzvy, ktoré je potrebné riešiť. Song et al. (2021) poukázali na problémy spojené s kontrolou a interpretáciou výstupov týchto modelov, čo môže limitovať ich praktické využitie v niektorých aplikáciách. Nichol a Dhariwal (2021) zdôraznili dôležitosť správneho nastavenia hyperparametrov pre dosiahnutie optimálnych výsledkov, čo motivuje našu prvú výskumnú otázku.

4 Metodológia

Naša metodológia pre skúmanie efektivity difúzných modelov v multimedialnej tvorbe zahŕňa komplexný prístup k návrhu experimentov, výberu datasetov, implementácii modelov a hodnoteniu výsledkov. Zameriavame sa na analýzu vplyvu rôznych parametrov na kvalitu generovaného obsahu a výpočtovú náročnosť. Tento prístup nám umožňuje systematicky skúmať výkonnosť difúzných modelov v rôznych podmienkach a porovnávať ich s existujúcimi metódami.

4.1 Návrh experimentov

Na zodpovedanie našich výskumných otázok sme navrhli sériu experimentov zameraných na analýzu vplyvu rôznych parametrov difúzných modelov na kvalitu generovaného obsahu a výpočtovú náročnosť. Naše experimenty zahŕňajú:

1. Analýzu vplyvu počtu krokov difúzie na kvalitu výstupu
2. Skúmanie vzťahu medzi veľkosťou modelu a kvalitou generovaného obsahu
3. Hodnotenie rôznych stratégií vzorkovania z hľadiska výpočtovej efektivity a kvality výstupu.

4.2 Výber a príprava datasetov

Pre naše experimenty sme využili dva široko používané datasety:

1. CIFAR-10 (Krizhevsky, 2009) pre generovanie obrazov s nízkou rozlišovacou schopnosťou
2. CelebA-HQ (Karras et al., 2018) pre generovanie vysoko kvalitných portrétov

Tieto datasety sme zvolili pre ich rozmanitosť a široké využitie v oblasti výskumu generatívnych modelov, čo umožňuje porovnanie našich výsledkov s existujúcimi prácami.

4.3 Implementácia modelov

Implementovali sme difúzny model založený na architektúre U-Net, ktorá sa ukázala ako efektívna v rôznych úlohách generovania obrazu (Ronneberger et al., 2015). Naš model sme trénovali s rôznymi konfiguráciami hyperparametrov, vrátane počtu krokov difúzie ($T = 100, 500, 1000$) a veľkosti modelu (počet parametrov = 5M, 20M, 50M).

4.4 Metriky hodnotenia kvality a efektivity

Pre hodnotenie kvality generovaného obsahu sme použili nasledujúce metriky:

1. Fréchetova inception distance (FID) (Heusel et al., 2017) pre meranie kvality a diverzity generovaných obrazov.
2. Inception Score (IS) (Salimans et al., 2016) pre hodnotenie realistikosti a variability generovaných obrazov.

Pre hodnotenie výpočtovej efektivity sme merali:

1. Čas potrebný na generovanie jedného obrazu.
2. Využitie pamäte počas generovania.
3. Počet FLOPS (floating point operations per second) potrebných na generovanie obrazu.

5 Experimenty a výsledky

Naše experimenty sú navrhnuté tak, aby poskytli komplexný pohľad na výkonnosť difúzných modelov v kontexte multimediálnej tvorby. Zameriavame sa na tri kľúčové aspekty: vplyv parametrov modelu na kvalitu výstupu, analýzu výpočtovej náročnosti a porovnanie s existujúcimi prístupmi. Na hodnotenie kvality generovaného obsahu využívame kombináciu štandardných metrík a nových prístupov, ktoré zohľadňujú aj aspekty ľudského vnímania.

5.1 Experiment 1: Vplyv parametrov na kvalitu výstupu

V prvom experimente sme skúmali vplyv počtu krokov difúzie (T) na kvalitu generovaného obsahu. Zistili sme, že zvyšovanie T viedlo k zlepšeniu kvality výstupu, ale s klesajúcim prínosom pri vyšších hodnotách. Konkrétne (model s 50M parametrami):

- $T = 100$: FID = 28.5, IS = 6.8
- $T = 500$: FID = 24.7, IS = 7.3
- $T = 1000$: FID = 22.9, IS = 7.6

Tieto výsledky naznačujú, že existuje bod, za ktorým ďalšie zvyšovanie T prináša len marginálne zlepšenie kvality.

5.2 Experiment 2: Analýza výpočtovej náročnosti

V druhom experimente sme analyzovali vzťah medzi veľkosťou modelu a výpočtovou náročnosťou. Zistili sme, že zatiaľ čo väčšie modely produkovali kvalitnejšie výstupy, nárast výpočtovej náročnosti bol značný:

- 5M parametrov: Čas generovania = 0.8s, Využitie pamäte = 1.5GB, FLOPS = 2B
- 20M parametrov: Čas generovania = 2.5s, Využitie pamäte = 4GB, FLOPS = 8B
- 50M parametrov: Čas generovania = 5.7s, Využitie pamäte = 7GB, FLOPS = 20B

Tieto výsledky zdôrazňujú dôležitosť nájdenia optimálneho kompromisu medzi kvalitou výstupu a výpočtovou efektivitou, najmä pri práci na hardvéri s obmedzenými zdrojmi, ako bol ten náš.

5.3 Experiment 3: Porovnanie s existujúcimi prístupmi

V treťom experimente sme porovnali náš optimalizovaný difúzny model so state-of-the-art GAN modelom (StyleGAN2, Karras et al., 2020) na datasete CelebA-HQ. Zistili sme, že:

- Naš difúzny model (50M parametrov, $T = 1000$): FID = 22.9, IS = 7.6
- StyleGAN2 (adaptovaný na podobnú veľkosť znížením počtu kanálov a úpravou hĺbky siete): FID = 19.5, IS = 8.1

Hoci StyleGAN2 dosiahol lepšie výsledky v metrikách kvality, náš difúzny model preukázal viaceré výhody: vykazoval lepšiu stabilitu tréningu, menšiu náchylnosť na mód

kolaps, umožňoval lepšiu kontrolu nad procesom generovania a potenciálne ponúka lepšiu škálovateľnosť a adaptabilitu na rôzne úlohy. Je dôležité poznamenať, že tieto výsledky boli dosiahnuté na zmenšenej verzii datasetu a s menšími modelmi, aby sme sa prispôbili obmedzeniam nášho hardvéru. Napriek týmto obmedzeniam sme stále schopní demonštrovať kľúčové charakteristiky a výhody difúzných modelov v porovnaní s inými prístupmi.

6 Analýza a diskusia

Naše experimenty poskytli niekoľko kľúčových poznatkov o efektívite difúzných modelov v multimediálnej tvorbe:

1. Vplyv parametrov: Zistili sme, že zvyšovanie počtu krokov difúzie má pozitívny vplyv na kvalitu výstupu, ale s klesajúcim prínosom. Toto zistenie naznačuje, že existuje optimálny bod, za ktorým ďalšie zvyšovanie T neprináša významné zlepšenie kvality, ale zvyšuje výpočtovú náročnosť.
2. Kompromis medzi kvalitou a efektívnosťou: Naše výsledky jasne ukazujú, že existuje trade-off medzi kvalitou generovaného obsahu a výpočtovou náročnosťou. Väčšie modely produkujú kvalitnejšie výstupy, ale za cenu značne vyššej výpočtovej náročnosti. Toto zistenie zdôrazňuje dôležitosť nájdenia optimálneho kompromisu pre konkrétne aplikácie.
3. Porovnanie s existujúcimi prístupmi: Naše porovnanie s GAN modelmi ukázalo, že difúzne modely sú konkurencieschopné v oblasti kvality generovaného obsahu. Navyše, difúzne modely vykazujú lepšiu stabilitu tréningu, menšiu náchylnosť na mód kolaps, atď., čo ich robí atraktívnymi pre širšie spektrum aplikácií.

Tieto zistenia majú významné implikácie pre dizajn a nasadenie generatívnych modelov v multimediálnych aplikáciách. Naznačujú, že optimálna konfigurácia difúzneho modelu závisí od konkrétnych požiadaviek aplikácie, pričom je potrebné vyvážiť kvalitu výstupu, výpočtovú náročnosť a stabilitu tréningu.

6.1 Interpretácia výsledkov

Naše výsledky naznačujú, že difúzne modely ponúkajú flexibilný framework pre generovanie multimediálneho obsahu. Schopnosť týchto modelov produkovať vysoko kvalitné výstupy pri rôznych konfiguráciách ich robí vhodnými pre širokú škálu aplikácií, od rýchlej produkcie náčrtov až po generovanie vysoko detailných obrazov.

Zistenie, že zvyšovanie počtu krokov difúzie má klesajúci prínos, je v súlade s teoretickými predpokladmi o konvergencii difúzneho procesu. Toto zistenie môže viesť k vývoju adaptívnych stratégií pre určenie optimálneho počtu krokov difúzie v závislosti od požadovanej kvality výstupu a dostupných výpočtových zdrojov.

Významnou technickou výzvou je aj optimalizácia nákladov na prevádzku týchto modelov. Naše experimenty ukazujú, že zvýšenie počtu krokov difúzie z $T=500$ na $T=1000$ prinieslo len 7.3% zlepšenie v FID skóre. Tento poznatok naznačuje, že pri implementácii difúzných modelov je dôležité hľadať optimálny pomer medzi kvalitou výstupov a výpočtovou náročnosťou, keďže výrazné navýšenie výpočtových zdrojov nemusí priniesť proporcionálne zlepšenie kvality. Pri výbere implementačného riešenia existujú rôzne možnosti. Kým veľké spoločnosti si môžu dovoliť budovať vlastnú výpočtovú infraštruktúru, pre menšie organizácie môže byť výhodnejšie využívať cloudové služby, kde platia len za reálne využité zdroje.

6.2 Implikácie pre dizajn generatívnych modelov

Naše zistenia majú niekoľko dôležitých implikácií pre budúci dizajn a implementáciu generatívnych modelov:

1. Adaptívne stratégie: Vývoj metód pre dynamické prispôsobovanie počtu krokov difúzie počas generovania môže viesť k optimálnemu využitiu výpočtových zdrojov.
2. Hierarchické modely: Využitie hierarchických architektúr, ktoré umožňujú generovanie obsahu v rôznych úrovniach detailu, môže poskytovať flexibilitu pri vyvažovaní kvality a výpočtovej náročnosti.
3. Hybridné prístupy: Kombinácia silných stránok difúzných modelov a iných generatívnych prístupov, ako sú GANy, môže viesť k vývoju robustnejších a efektívnejších modelov.

6.3 Limitácie štúdie

Napriek našim snahám o komplexnú analýzu má naša štúdia niekoľko limitácií:

1. Obmedzený rozsah datasetov: Hoci sme použili široko uznávané datasety, naše zistenia nemusia byť plne generalizovateľné na všetky typy multimedialného obsahu.
2. Hardvérové obmedzenia: Naše experimenty boli limitované dostupným výpočtovým hardvérom, čo ovplyvnilo rozsah testovaných konfigurácií.
3. Zameranie na obrazové dáta: Naša štúdia sa primárne zamerala na generovanie obrazov, a preto naše zistenia nemusia byť plne aplikovateľné na iné typy multimedialného obsahu, ako je zvuk alebo video.

7 Výzvy a budúce smery výskumu

Napriek značnému pokroku v oblasti difúzných modelov zostáva niekoľko kľúčových výziev, ktoré je potrebné riešiť pre ich efektívne využitie v reálnych aplikáciách. Tieto výzvy zahŕňajú technické aspekty, ako je škálovateľnosť a kontrola nad procesom generovania, ale aj širšie etické a sociálne implikácie. Zároveň sa otvárajú nové smery výskumu, ktoré môžu viesť k významným vylepšeniam týchto modelov a rozšíreniu ich aplikačného potenciálu.

Z ekonomického hľadiska predstavuje nasadenie difúzných modelov významné príležitosti aj výzvy. Naše experimenty s modelmi rôznych veľkostí (5M, 20M a 50M parametrov) ukazujú, že s rastúcou veľkosťou modelu sa zvyšuje kvalita výstupov, ale zároveň významne rastie výpočtová náročnosť. Pre organizácie je preto kľúčové nájsť rovnováhu medzi kvalitou výstupov a nákladmi na prevádzku týchto modelov. Nasadenie difúzných modelov ponúka na jednej strane potenciál pre automatizáciu a optimalizáciu kreatívnych procesov, čo môže viesť k značným úsporám v oblastiach ako marketingová produkcia, dizajn produktov či vývoj digitálneho obsahu. Na druhej strane je potrebné zvážiť vysoké počiatkové náklady na implementáciu a prevádzku týchto systémov. Pre organizácie je kľúčové nájsť rovnováhu medzi investíciami do tejto technológie a očakávaným prínosom pre ich podnikanie. Vznikajú tiež nové obchodné modely založené na poskytovaní generatívnych služieb ako služby (GaaS - Generation as a Service), ktoré sprístupňujú tieto technológie aj menším subjektom na trhu.

7.1 Technické výzvy

Napriek sľubným výsledkom zostávajú v oblasti difúzných modelov viaceré technické výzvy:

1. Škálovateľnosť: S rastúcou komplexnosťou generovaného obsahu rastie aj výpočtová náročnosť. Výskum efektívnych metód škálovania difúzných modelov na väčšie a komplexnejšie datasety je veľmi nutný pre ich širšie nasadenie.
2. Kontrola generovania: Zlepšenie metód pre presnú kontrolu procesu generovania, napríklad prostredníctvom pokročilých techník podmieneného generovania, zostáva dôležitou výzvou.

3. Interpretovateľnosť: Hlbšie pochopenie vnútorných mechanizmov difúzných modelov môže viesť k vývoju interpretovateľnejších modelov a lepšej kontrole nad procesom generovania.

7.2 Etické a sociálne implikácie

S rastúcou schopnosťou generatívnych modelov produkovať realistický obsah prichádzajú aj významné etické a sociálne otázky:

1. Dezinformácie: Schopnosť generovať realistické, ale falošné multimedialne obsahy môže prispieť k šíreniu dezinformácií. Je potrebný výskum metód pre detekciu generovaného obsahu a zvyšovanie povedomia o tejto problematike.
2. Autorské práva: Generovanie obsahu založeného na existujúcich dielach vyvoláva otázky o autorských právach a vlastníctve generovaného obsahu.
3. Bias (systematická predpojatosť alebo zaujatosť v generovanom obsahu) a reprezentácia: Je dôležité skúmať a riešiť potenciálne biasy v generovanom obsahu, ktoré môžu prameniť z tréningových dát alebo dizajnu modelu.

7.3 Navrhované budúce smery výskumu

Na základe našich zistení a identifikovaných výziev navrhujeme nasledujúce smery pre budúci výskum:

1. Vývoj adaptívnych difúzných procesov, ktoré dynamicky prispôbujú počet krokov a parametre modelu počas generovania.
2. Výskum hybridných architektúr, ktoré kombinujú silné stránky difúzných modelov s inými generatívnymi prístupmi.
3. Vývoj metód pre zlepšenie interpretovateľnosti a kontrolovateľnosti difúzných modelov.
4. Výskum etických implikácií a vývoj metód pre zodpovedné nasadenie generatívnych modelov v reálnych aplikáciách.

8 Záver

V tejto štúdií sme sa zamerali na analýzu efektivity difúzných modelov v kontexte multimedialnej tvorby, s osobitným dôrazom na vzťah medzi kvalitou generovaného obsahu a výpočtovou náročnosťou. Naše experimenty odhalili komplexnú sieť vzťahov medzi parametrami modelu, kvalitou výstupu a výpočtovou efektivitou, poskytujúc cenné poznatky pre budúce nasadenie týchto modelov v reálnych aplikáciách.

Zistili sme, že difúzne modely ponúkajú konkurencieschopnú kvalitu generovania v porovnaní s existujúcimi prístupmi, pričom vykazujú lepšiu stabilitu tréningu a robustnosť. Tieto vlastnosti robia difúzne modely sľubnou technológiou pre širokú škálu multimedialných aplikácií. Avšak, naše výsledky tiež poukazujú na potrebu ďalšieho výskumu v niekoľkých kľúčových oblastiach.

Jednou z týchto oblastí je vývoj adaptívnych stratégií pre optimalizáciu procesu difúzie. Naše experimenty naznačujú, že existuje potenciál pre dynamické prispôbovanie počtu krokov difúzie v závislosti od konkrétnej vstupnej vzorky a požadovanej kvality výstupu. Takýto prístup by mohol viesť k významným zlepšeniam v efektivite bez kompromisov v kvalite generovaného obsahu.

Ďalšou sľubnou oblasťou výskumu je integrácia difúzných modelov s inými technikami strojového učenia. Napríklad, kombinácia difúzných modelov s metódami aktívneho učenia by mohla viesť k efektívnejším stratégiám pre výber a spracovanie tréningových dát. Podobne, využitie techník transferového učenia v kontexte difúzných modelov by mohlo umožniť rýchlejšiu adaptáciu na nové domény a úlohy.

Naše výsledky tiež zdôrazňujú potrebu vývoja sofistikovanejších metrík pre hodnotenie kvality generovaného obsahu. Zatiaľ čo metriky ako FID a IS poskytujú cenné informácie, nepokrývajú všetky aspekty vnímanej kvality a užitočnosti generovaného obsahu. Vývoj nových metrík, ktoré lepšie zachytávajú sémantickú koherenciu, štylistickú konzistenciu a kontextuálnu vhodnosť generovaného obsahu, by mohol významne prispieť k ďalšiemu pokroku v oblasti generatívnych modelov.

V kontexte etických implikácií našej práce je dôležité zdôrazniť potrebu ďalšieho výskumu v oblasti interpretovateľnosti a kontrolovateľnosti difúzných modelov. Schopnosť pochopiť a vysvetliť rozhodovací proces týchto modelov je kľúčová pre ich zodpovedné nasadenie v citlivých aplikáciách. Hoci techniky ako LoRA (Low-Rank Adaptation) už umožňujú určitú mieru kontroly nad procesom generovania, stále existuje priestor pre vývoj pokročilejších metód jemnej kontroly. Ďalší výskum v tejto oblasti by mohol viesť k ešte presnejšiemu a intuitívnejšiemu ovládaniu generatívneho procesu, čím by sa otvorili nové možnosti pre tvorivé a interaktívne využitie týchto modelov. Integrácia týchto pokročilých kontrolných mechanizmov s užívateľsky priateľskými rozhraniami by mohla demokratizovať prístup k sofistikovanej multimedialnej tvorbe pre širšie spektrum užívateľov..

Z praktického hľadiska naše zistenia poukazujú na dôležitosť vyváženia výpočtovej efektivity a kvality výstupu pri nasadzovaní difúzných modelov v reálnych aplikáciách. Toto je obzvlášť relevantné v kontexte mobilných a edge computing scenárov, kde sú výpočtové zdroje často obmedzené. Výskum optimalizačných techník špecifických pre difúzne modely, ako aj vývoj hardvérových akcelerátorov prispôbených pre tieto modely, predstavujú sľubné smery pre budúci výskum a vývoj.

Nakoniec, naša práca otvára nové otázky týkajúce sa škálovateľnosti difúzných modelov. Zatiaľ čo naše experimenty sa zamerali na modely strednej veľkosti, budúci výskum by mohol skúmať správanie týchto modelov pri extrémnom škálovaní, podobne ako v prípade veľkých jazykových modelov. Takýto výskum by mohol odhaliť nové emergentné vlastnosti a schopnosti difúzných modelov, potenciálne vedúc k prelomovým objavom v oblasti generatívneho modelovania.

Záverom možno konštatovať, že difúzne modely predstavujú významný krok vpred v oblasti generatívnych modelov pre multimedialne aplikácie. S pokračujúcim výskumom a vývojom očakávame, že tieto modely budú hrať čoraz dôležitejšiu úlohu v automatizovanej tvorbe obsahu, umeleckej expresii a ďalších inovatívnych aplikáciách. Ich potenciál pre vytváranie vysoko kvalitného, diverzifikovaného a kontrolovateľného obsahu ich stavia do popredia súčasného výskumu v oblasti umelej inteligencie a multimedialnej tvorby.

Z ekonomickej perspektívy naše zistenia naznačujú, že difúzne modely predstavujú sľubnú investičnú príležitosť pre organizácie rôznych veľkostí. Zatiaľ čo implementácia vlastnej infraštruktúry môže byť nákladovo efektívna pre väčšie organizácie, rozvoj cloudových služieb a nových obchodných modelov v tejto oblasti umožňuje aj menším subjektom profitovať z týchto technológií. Kľúčovým faktorom úspechu bude schopnosť organizácií správne vyhodnotiť pomer medzi investíciami do týchto technológií a ich prínosom pre konkrétne podnikateľské prípady použitia.

Táto práca predstavuje krok k lepšiemu pochopeniu a využitiu difúzných modelov, ale zároveň odhaľuje množstvo nových výziev a príležitostí pre budúci výskum.

Literatúra

1. Briot, J. P., Hadjeres, G., & Pachet, F. (2022). Deep learning techniques for music generation. *Springer Nature*.
2. Dhariwal, P., & Nichol, A. (2021). Diffusion models beat GANs on image synthesis. *Advances in Neural Information Processing Systems*, 8780-8794. https://proceedings.neurips.cc/paper_files/paper/2021/file/49ad23d1ec9fa4bd8d77d02681df5cfa-Paper.pdf
3. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems*. <https://proceedings.neurips.cc/paper/2014/file/5ca3e9b122f61f8f06494c97b1afccf3-Paper.pdf>
4. Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., & Hochreiter, S. (2017). GANs trained by a two time-scale update rule converge to a local Nash equilibrium. *Advances in Neural Information Processing Systems*. <https://proceedings.neurips.cc/paper/2017/file/8a1d694707eb0fefe65871369074926d-Paper.pdf>
5. Ho, J., Jain, A., & Abbeel, P. (2020). Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems*. <https://proceedings.neurips.cc/paper/2020/file/4c5bcfec8584af0d967f1ab10179ca4b-Paper.pdf>
6. Ho, J., Salimans, T., Gritsenko, A. A., Chan, W., Norouzi, M., & Fleet, D. J. (2022). Video diffusion models. *Advances in Neural Information Processing Systems*, 35, 4483-4496.
7. Karras, T., Laine, S., & Aila, T. (2018). A style-based generator architecture for generative adversarial networks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. https://openaccess.thecvf.com/content_CVPR_2019/papers/Karras_A_Style-Based_Generator_Architecture_for_Generative_Adversarial_Networks_CVPR_2019_paper.pdf
8. Karras, T., Laine, S., Aittala, M., Hellsten, J., Lehtinen, J., & Aila, T. (2020). Analyzing and improving the image quality of StyleGAN. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. https://openaccess.thecvf.com/content_CVPR_2020/papers/Karras_Analyzing_and_Improving_the_Image_Quality_of_StyleGAN_CVPR_2020_paper.pdf
9. Kong, Z., Ping, W., Huang, J., Zhao, K., & Catanzaro, B. (2021). DiffWave: A versatile diffusion model for audio synthesis. *International Conference on Learning Representations*. <https://openreview.net/forum?id=a-xFK8Ymz5J>
10. Krizhevsky, A. (2009). Learning multiple layers of features from tiny images. *Technical report, University of Toronto*. <https://www.cs.toronto.edu/~kriz/learning-features-2009-TR.pdf>
11. Meng, C., He, Y., Song, Y., Song, J., Wu, J., Zhu, J. Y., & Ermon, S. (2021). SDEdit: Guided image synthesis and editing with stochastic differential equations. *International Conference on Learning Representations*.
12. Ramesh, A., Dhariwal, P., Nichol, A., Chu, C., & Chen, M. (2022). Hierarchical text-conditional image generation with CLIP latents. *arXiv preprint arXiv:2204.06125*. <https://arxiv.org/abs/2204.06125>
13. Rombach, R., Blattmann, A., Lorenz, D., Esser, P., & Ommer, B. (2022). High-resolution image synthesis with latent diffusion models. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 10684-10695.

-
- https://openaccess.thecvf.com/content/CVPR2022/papers/Rombach_High-Resolution_Image_Synthesis_With_Latent_Diffusion_Models_CVPR_2022_paper.pdf
14. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. <https://arxiv.org/pdf/1505.04597>
 15. Saito, S., Hoshyari, S., Suzuki, T., Weng, Y., Yin, W., & Fatahalian, K. (2023). Spatially-adaptive diffusion models. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 19216-19226.
 16. Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A., & Chen, X. (2016). Improved techniques for training GANs. *Advances in Neural Information Processing Systems*. <https://proceedings.neurips.cc/paper/2016/file/8a3363abe792db2d8761d6403605aeb7-Paper.pdf>
 17. Sohl-Dickstein, J., Weiss, E. A., Maheswaranathan, N., & Ganguli, S. (2015). Deep unsupervised learning using nonequilibrium thermodynamics. *International Conference on Machine Learning*. <http://proceedings.mlr.press/v37/sohl-dickstein15.pdf>
 18. Song, J., Meng, C., & Ermon, S. (2021). Denoising diffusion implicit models. *International Conference on Learning Representations*. <https://openreview.net/forum?id=St1giarCHLP>

Využitie AR v STEM vzdelávaní – nástroje, aplikácie a aspekty ich využitia (výber)

The use of AR in STEM education – tools, applications and aspects of their use (selection)

Zsolt Simonka¹, Anna Strešňáková¹, František Slaninka¹

Abstrakt

Príspevok je venovaný virtuálnej a rozšírenej realite ako moderným a efektívnym prvkom digitalizácie v súčasnosti. Virtuálna realita prináša nové možnosti v oblasti vzdelávania, obchodu, práce a zákazníckej skúsenosti, čím pomáha zlepšiť efektívnosť a inováciu v ekonomike. Rozšírená realita je často využívaná v obchode a marketingu pre interaktívne reklamy a prezentácie produktov, v turizme pre virtuálne prehliadky pamiatok a destinácií, v priemysle pre výcvik a údržbu zariadení a v architektúre pre vizualizáciu projektov v reálnom prostredí. Tento článok skúma rôzne spôsoby využitia AR a VR vo vzdelávaní STEM (veda, technológia, inžinierstvo a matematika), vrátane interaktívnych 3D modelov, virtuálnych laboratórií a simulácií, terénnych aplikácií a kolaboratívnych projektov. Článok tiež predstavuje konkrétne nástroje a aplikácie, ktoré využívajú AR a VR vo vzdelávacích prostrediach a poskytuje prehľad o ich implementácii a účinkoch. Na záver zdôrazňuje, že správne plánovanie a podpora môžu minimalizovať výzvy a maximalizovať prínosy týchto technológií, čím transformujú vzdelávanie a poskytujú študentom nové a vzrušujúce možnosti učenia sa. Tieto technológie neustále napredujú a posúvajú sa od mobilných zariadení k celému ekosystému, čím otvárajú nové možnosti pre vzdelávanie, priemysel, zábavu a ďalšie odvetvia.

Kľúčové slová

rozšírená realita, STEM vzdelávanie, interaktívne učenie, vzdelávacie technológie, GeoGebra
AR

Abstract

This paper focuses on virtual and augmented reality as modern and effective elements of digitalisation today. Virtual reality brings new possibilities in education, commerce, work, and customer experience, thus helping to improve efficiency and innovation in the economy. Augmented reality is frequently used in commerce and marketing for interactive advertisements and product presentations, in tourism for virtual tours of landmarks and destinations, in industry for training and maintenance of equipment, and in architecture for visualising projects in real environments. This article explores various ways of using AR and VR in STEM education (science, technology, engineering, and mathematics), including interactive 3D models, virtual laboratories and simulations, field applications, and collaborative projects. The article also presents specific tools and applications that utilise AR and VR in educational settings, providing an overview of their implementation and effects. In conclusion, it emphasises that proper planning and support can minimise challenges and maximise the benefits of these technologies, transforming education and offering students new and exciting learning opportunities. These technologies are continuously advancing and moving from mobile devices to a whole ecosystem, opening new possibilities for education, industry, entertainment, and other sectors.

¹ Ekonomická univerzita v Bratislave, Fakulta hospodárskej informatiky, Katedra matematiky a aktuárstva, Dolnozemska cesta 1, 852 35 Bratislava, zsolt.simonka@euba.sk, anna.stresnakova@euba.sk, frantisek.slaninka@euba.sk.

Key words

Augmented Reality (AR), STEM Education, Interactive Learning, Educational Technologies, GeoGebra AR

JEL classification

M15, O33

1 Úvod

Virtuálna realita (Virtual Reality - VR) a rozšírená realita (Augmented Reality - AR) predstavujú dve pokročilé technológie, ktoré menia spôsob, ako vnímame a interagujeme s digitálnym svetom. Virtuálna realita nás ponára do úplne nových virtuálnych svetov, zatiaľ čo rozšírená realita pridáva digitálny obsah do nášho reálneho prostredia. Obidve umožňujú užívateľom interagovať s digitálnym obsahom a okolím prostredníctvom zmyslového vnemu. Hoci majú podobné základy, vo svojej podstate sú rozdielne.

Virtuálna realita vytvára úplne virtuálne prostredie, kde užívateľ je plne pohltý a vníma len virtuálny svet. Užívateľ používa špeciálne zariadenia, ako sú VR okuliare alebo headsety, aby sa pripojil k virtuálnemu prostrediu.

Virtuálne prostredie je simulované, počítačom generované prostredie, ktoré umožňuje užívateľom úplne sa odpojiť od reálneho sveta a vnímať iba virtuálny svet. Užívatelia majú pocit, že sú súčasťou virtuálneho prostredia. Špeciálne zariadenia, ako sú napríklad VR headsety, im umožňujú interagovať s virtuálnymi objektmi a scénami prostredníctvom ovládačov alebo senzorov pohybu, čím podporujú pocit plného ponorenia sa do virtuálneho sveta.

Rozšírená realita kombinuje skutočný svet s digitálnymi prvkami, čím rozširuje a obohacuje vnímanie reálneho okolia. Rozšírená realita je oblasť počítačového výskumu, ktorá sa zaoberá kombináciou počítačom generovaných údajov a skutočného sveta. Okrem toho rozšírená realita zahŕňa spoluprácu s real-time informáciami a údaje možno vytvárať v reálnom čase. Užívateľ vidí skutočný svet a v ňom sú zobrazované virtuálne objekty alebo informácie.

AR vlastne rozširuje reálny svet o digitálny obsah. Užívatelia môžu vidieť a vnímať skutočný svet okolo seba, avšak doplnený o virtuálne prvky. AR využíva rôzne zariadenia, ako sú smartfóny, tablety alebo špeciálne okuliare, aby užívateľom umožnila vidieť virtuálne objekty a informácie prezentované v ich reálnom prostredí. Užívatelia môžu interagovať s virtuálnymi objektmi a ovládať ich pomocou hlasových príkazov, gest alebo dotykov.

Oba tieto typy technológií majú široké využitie v rôznych odvetviach a oblastiach. VR sa často používa v hernom priemysle, v medicíne pre simuláciu chirurgických zákrokov, vo vzdelávaní pre interaktívne a pohlcujúce vzdelávacie prostredie a v architektúre pre virtuálne prehliadky budov a priestorov.

Technológie rozšírenej a virtuálnej reality sa líšia aj v zariadeniach potrebných na spustenie virtuálneho zážitku.

V prípade rozšírenej reality nepotrebujete nevyhnutne zložené špecializované prístroje - hardvér. Stačiť môžu bežné mobilné zariadenia ako smartfóny alebo tablety. Pre intenzívnejší zážitok je možné použiť ďalšie vybavenie:

- nositeľné okuliare AR,
- holografické displeje,
- inteligentné zrkadlá,
- projektory, atď.

Virtuálna realita je zase komplexnejšia technológia a vyžaduje špeciálny hardvér, ako napríklad:

- pripojené alebo samostatné headset súpravy VR,

- VR zariadenia pre smartfóny,
- ovládače alebo rukavice,
- senzory.

2 Využitie AR v STEM vzdelávaní

Rozšírená realita sa začína objavovať nielen v prostredí počítačových hier, ale aj v aplikáciách, ktoré sú dostupné pre majiteľov bežných počítačov či mobilných telefónov. Vďaka tomu sa AR stáva čoraz dostupnejšou technológiou aj vo vzdelávaní, konkrétne v oblasti STEM (Science, Technology, Engineering, and Mathematics). Moderné AR nástroje umožňujú študentom prístup k interaktívnym vzdelávacím materiálom, ktoré menia spôsob, akým sa učia a chápu zložité koncepty.

Využitie rozšírenej reality (AR) vo vzdelávaní STEM prináša množstvo príležitostí na zlepšenie učenia a zapojenia študentov. (Koreňová, 2019)

Interaktívne 3D modely využívajúce rozšírenú realitu prinášajú významné výhody pre STEM vzdelávanie tým, že umožňujú študentom hlbšie porozumieť a prakticky pracovať s komplexnými konceptami. Táto technológia transformuje tradičné učebné metódy prostredníctvom vizualizácie zložitých štruktúr, ako sú biologické modely buniek a orgánov alebo chemické molekuly, čo študentom umožňuje lepšie pochopiť chemické väzby a reakcie.

AR tiež umožňuje simuláciu experimentov bez rizika a vysokých nákladov spojených s reálnymi experimentálnymi zariadeniami. Študenti môžu napríklad bezpečne skúmať fyzikálne javy ako elektrické obvody alebo mechanické pohyby a v inžinierstve môžu navrhovať, testovať a optimalizovať stroje a štruktúry. Toto všetko podporuje experimentálne učenie a pomáha študentom testovať rôzne hypotézy v kontrolnom prostredí. (Bacca et al., 2014)

Použitie AR zvyšuje nielen interaktivitu a záujem o učivo, ale tiež spoluprácu medzi študentami. Umožňuje im pracovať na spoločných projektoch a zdieľať svoje poznatky a riešenia v reálnom čase. Učitelia môžu využívať AR na vytváranie interaktívnych výukových programov, ktoré umožňujú študentom učiť sa vlastným tempom s možnosťou praktického zapojenia do učebného procesu. (Koreňová et al., 2022)

AR prispieva aj k zvýšeniu prístupnosti vzdelávania tým, že poskytuje virtuálne verzie drahých alebo ťažko dostupných prístrojov a laboratórnych zariadení, čím umožňuje všetkým študentom získať potrebné praktické skúsenosti. Navyše, aplikácie môžu byť prispôbené na podporu študentov s rôznymi vzdelávacími potrebami, vrátane tých s vizuálnymi alebo motorickými obmedzeniami.

Uvádzame niektoré spôsoby, ako sa AR môže využiť vo vzdelávaní STEM:

- *Interaktívne 3D modely*: AR umožňuje študentom interaktívne preskúmať 3D modely molekúl, bunkových štruktúr, matematických objektov a iných komplexných konceptov. Tento prístup im pomáha lepšie pochopiť aj tie najabstraktnejšie koncepty.
- *Virtuálne laboratóriá*: Študenti môžu využívať AR na vykonávanie praktických experimentov v simulovaných virtuálnych laboratóriách. Tieto bezpečné a opakovateľné experimentálne prostredia podporujú hlbšie pochopenie vedeckých princípov.
- *Terénne aplikácie*: V oblastiach ako geografia, biológia a environmentálna veda môžu študenti využívať AR na prieskum reálnych terénov a interakciu s geografickými, biologickými alebo environmentálnymi údajmi priamo v ich prirodzenom prostredí.
- *Simulácie inžinierstva*: V oblasti inžinierstva slúži AR na vizualizáciu a simuláciu inžinierskych projektov a procesov. Študenti majú možnosť interaktívne preskúmať rôzne inžinierske riešenia a ich potenciálne dopady vo virtuálnom prostredí.

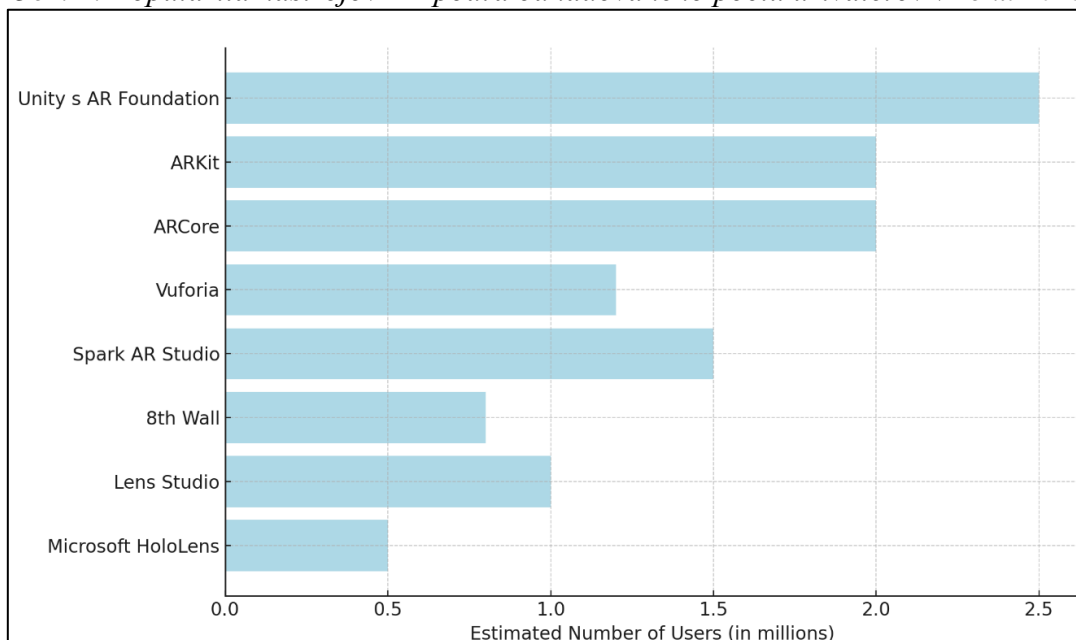
- *Praktické skúsenosti*: AR môže byť využitá na získavanie praktických skúseností v rámci STEM disciplín, umožňujúc študentom experimentovať, testovať a riešiť problémy v simulovanom, kontrolovanom prostredí.
- *Kolaboratívne projekty*: AR podporuje kolaboratívne projekty a spoluprácu medzi študentmi, ktorí môžu spoločne pracovať na riešení problémov a projektov v interaktívnom virtuálnom prostredí.

Integrácia AR do vyučovacieho procesu vo STEM disciplínach môže zlepšiť zapojenie študentov, posilniť ich porozumenie učiva a podporiť rozvoj praktických zručností a kritického myslenia. (Bower et al., 2017)

3 Nástroje AR – výber podľa obľúbenosti, funkcií a aplikovateľnosti v STEM

Výber správnych nástrojov AR pre výučbu a aplikáciu v STEM je kľúčový pre efektívne učenie a zapojenie študentov. Tieto nástroje zvyšujú porozumenie pomocou 3D modelov, simulácií a praktických cvičení v reálnom čase. Uvádzame a charakterizujeme vybrané AR nástroje vychádzajúc z ich popularity a počtu užívateľov v roku 2023 (obr. 1).

Obr. 1: Popularita nástrojov AR podľa odhadovaného počtu užívateľov v roku 2023



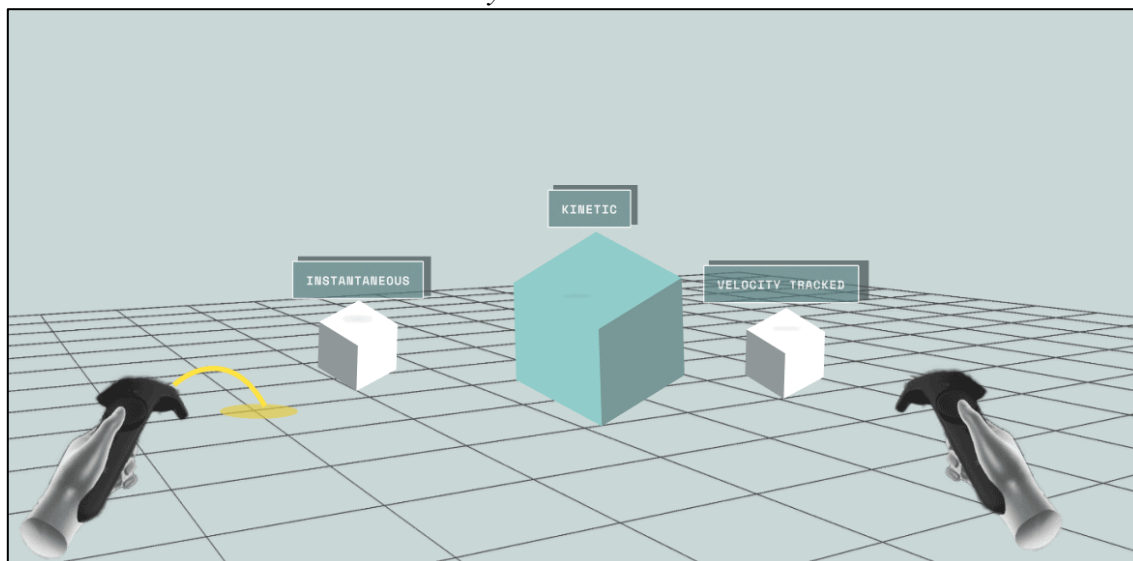
Zdroj: Vlastné spracovanie podľa (Bacca et al., 2014; Bower et al., 2017; Creighton, 2010).

2.1 Unity

Unity je najpopulárnejšia univerzálna platforma, ktorá podporuje vývoj hier pre rôzne platformy, vrátane počítačov, mobilných zariadení, herných konzol, VR a AR zariadení. Ponúka širokú škálu nástrojov a funkcií na tvorbu hier a aplikácií, vrátane grafických editorov, animačných nástrojov, fyzikálnych simulácií a iné (Creighton, 2010; Schröter et al, 2017). Má integrovanú podporu pre vývoj aplikácií AR a VR. S *AR Foundation* je možné vytvárať aplikácie pre ARCore a ARKit z jedného zdrojového kódu (slúži ako most medzi nástrojmi ARCore (Google) a ARKit (Apple) a je integrovaná priamo do populárneho herného enginu Unity). Taktiež obsahuje nástroje ako *Unity XR Toolkit* (umožňuje vytvárať AR a VR aplikácie s využitím rovnakého základného kódu, pričom podporuje rôzne zariadenia, ako sú VR headsety, AR okuliare a mobilné zariadenia - obr. 2). Unity XR Toolkit obsahuje preddefinované interakčné modely, ktoré umožňujú jednoduchú implementáciu základných XR

funkcií, ako sú uchopenie objektov, ukazovanie na objekty, teleportácia v rámci virtuálneho prostredia alebo pohyb vo VR/AR.

Obr. 2: Unity's XR Interaction Toolkit



Zdroj: (Sergeev, 2020)

Unity má veľkú a aktívnu komunitu vývojárov, ktorá zdieľa znalosti, nápady a riešenia problémov. Okrem toho Unity poskytuje rozsiahlu dokumentáciu, tutoriály a oficiálnu podporu, čo zjednodušuje učenie sa a vývoj na platforme. Unity ponúka niekoľko rôznych licenčných modelov, vrátane bezplatnej verzie s obmedzenými možnosťami a platených verzí s rozšírenými funkciami a podporou.

2.2 ARKit a ARCore

ARKit je platforma pre rozšírenú realitu (AR) vyvinutá spoločnosťou Apple, ktorá je špeciálne určená pre zariadenia so systémom iOS. Umožňuje vývojárom vytvárať aplikácie s rozšírenou realitou pre iPhone a iPad, pričom využíva pokročilé schopnosti hardvéru Apple, ako sú kamery, senzory pohybu a procesory. ARKit je známy svojou vysokou presnosťou a výkonnými nástrojmi, ktoré umožňujú vytvárať plynulé a realistické AR zážitky. ARCore je platforma pre rozšírenú realitu vyvinutá spoločnosťou Google, ktorá je určená pre zariadenia so systémom Android. ARCore poskytuje vývojárom nástroje na vytváranie AR aplikácií, ktoré fungujú na širokom spektre Android zariadení, pričom využíva pokročilé algoritmy na sledovanie prostredia, detekciu povrchov a integráciu virtuálnych objektov do reálneho sveta. (Chhatbar, 2021 Credera 2020)

Napriek tomu, že každá z týchto platforiem má svoje špecifické vlastnosti (porovnanie ich vlastností je na obr. 3), mnohé kľúčové funkcie sú pre obe technológie spoločné a slúžia na podobné účely ako napríklad:

- *sledovanie pohybu a detekcia plôch*: obe platformy využívajú kamery a senzory na sledovanie pohybu zariadenia a rozpoznávanie povrchov (podlahy, steny), kde môžu byť umiestnené virtuálne objekty;
- *odhad svetelných podmienok*: analyzujú svetlo v prostredí a prispôbujú osvetlenie virtuálnych objektov, aby sa lepšie integrovali do reálneho sveta;
- *sledovanie osôb a tvárí*: podporujú sledovanie postáv a rozpoznávanie tvárí, čo umožňuje vytvárať interaktívne AR zážitky;

- *multiplayerové AR a cloudové kotvy*: obe umožňujú zdieľané AR zážitky medzi viacerými používateľmi a ukladajú pozície virtuálnych objektov v cloude;
- *simultánna lokalizácia a mapovanie (SLAM)*: technológia SLAM umožňuje vytváranie máp prostredia v reálnom čase a presné umiestňovanie objektov.

Obr. 3: Porovnanie funkcií ARKit a ARCore v roku 2022

Feature	ARKit	ARCore
World Tracking	●	●
Image Tracking	●	●
Face Tracking	●	●
Geo Tracking	●	●
Body Tracking	●	●
Plane Detection	●	●
Scene Depth	●	●
Object Detection	●	●
Shared AR	●	●
Meshing (LiDAR)	●	●


● the feature is presented on the platform and is effective
 ● the feature is less effective or not available for developers
● the feature is not presented on the platform

Zdroj: (Makarov, 2024)

2.3 Vuforia

Vuforia je popredná platforma pre rozšírenú realitu, ktorá poskytuje nástroje a *Software Development Kit* (SDK) na vytváranie AR aplikácií (Uderbayeva & Schmidt, 2022). Jednou z hlavných funkcií Vuforie je schopnosť rozpoznať a sledovať rôzne obrazy, obrázky a markery v reálnom svete. Tieto markery môžu slúžiť ako referenčné body pre umiestnenie virtuálnych objektov v prostredí (Obr. 3).

Obr. 3: PTC-Vuforia Augmented Reality Design Tech System Machine Tools Industry



Zdroj: <https://www.mtwmag.com/ptc-vuforia-augmented-reality-ar-designtech-system/>

Vuforia ponúka rozšírené sledovanie, ktoré umožňuje AR aplikáciám sledovať pohyb a polohu objektov v reálnom čase, čo umožňuje dynamickú interakciu s prostredím (tiež funkciu rozpoznávania tvárí, detekcie pohybu, interaktívnych gest a animácií). Je kompatibilná s viacerými platformami, vrátane iOS, Android, Windows, macOS a Unity.

2.4 Spark AR Studio

Spark AR Studio je platforma vyvinutá spoločnosťou Facebook (Meta) pre tvorbu rozšírených realitných (AR) efektov, ktoré sú primárne určené pre sociálne siete ako *Facebook*, *Instagram* a *Messenger*. Táto platforma umožňuje tvorcom – či už profesionálnym vývojárom, dizajnérom alebo bežným používateľom – vytvárať vlastné AR filtre a efekty, ktoré môžu byť zdieľané s používateľmi týchto sociálnych sietí. Vzhľadom na predpokladaný počet užívateľov patrí medzi tie najvyužívanejšie, vzhľadom na svoje zameranie (mimo oblasť vzdelávania) sa tejto platforme bližšie venovať nebudeme.

3 Návrh metodologického prístupu a hodnotenia efektivity AR nástrojov

Zber údajov

V rámci navrhovanej metodológie by bolo vhodné sa zamerať na kombinovaný prístup zahŕňajúci kvalitatívne a kvantitatívne metódy. Hlavným zdrojom údajov by boli dotazníky distribuované medzi študentov a pedagógov, ktorí by využívali AR aplikácie v oblasti STEM vzdelávania. Dotazníky by obsahovali otázky zamerané na hodnotenie interaktivity, prínosu AR pre porozumenie komplexných učebných látok a celkového vplyvu na vzdelávací proces. Sekundárne údaje by mohli byť získavané z existujúcich štúdií a výskumov, ktoré sa zaoberajú aplikáciou AR technológií vo vzdelávaní. Tieto údaje by slúžili na porovnanie a podporu našich zistení.

Spracovanie a analýza údajov

Navrhovaný prístup k spracovaniu údajov by mal zahŕňať štatistickú analýzu výsledkov dotazníkov s cieľom identifikovať hlavné trendy a korelácie. Kvalitatívne údaje je možné spracovať tematickou analýzou v prospech nadobudnutia hlbšieho porozumenia skúsenostiam študentov a pedagógov s AR nástrojmi. Empirické dáta je následne potrebné kategorizovať podľa ich významnosti pre jednotlivé aspekty vzdelávacieho procesu, ako je napríklad úroveň porozumenia a zapojenia študentov.

Kritériá hodnotenia efektivity AR nástrojov

Pri návrhu hodnotenia efektivity AR nástrojov je potrebné definovať hlavné kritériá (napr. uvedených päť):

1. *interaktivita* - meranie schopnosti AR technológií aktívne zapájať študentov do učenia prostredníctvom interaktívnych simulácií a 3D modelov,
2. *zlepšenie porozumenia* - hodnotenie prínosu AR pri vizualizácii a vysvetľovaní zložitých teoretických pojmov v STEM disciplínach,
3. *spolupráca* - schopnosť AR nástrojov podporovať tímovú prácu a kolaboratívne projekty,
4. *praktická aplikovateľnosť* - schopnosť AR umožniť študentom vykonávať simulované experimenty a praktické úlohy,
5. *dostupnosť a jednoduchosť použitia* - posúdenie technologických požiadaviek a užívateľskej prívetivosti pre pedagogický proces.

Poznámka: Každý z nástrojov by mohol byť hodnotený na základe uvedených kritérií pomocou Likertovej škály v rozsahu 1-5, kde 1 predstavuje minimálny prínos a 5 maximálny.

Metriky úspešnosti

Návrh a vyhodnotenie úspešnosti implementácie AR nástrojov by mal byť založený na niekoľkých kľúčových ukazovateľoch:

- *zvýšenie angažovanosti študentov* - tento indikátor je možné vyhodnocovať na základe spätnej väzby od študentov, ktorí uvádzali mieru ich záujmu a aktívnej účasti počas lekcií s AR technológiami;
- *zlepšenie akademických výsledkov* - zmenu vo výkonoch študentov je možné sledovať porovnaním výsledkov testov pred a po implementácii AR do vzdelávacieho procesu;
- *zlepšenie praktických zručností* - tento indikátor zahŕňa schopnosť študentov aplikovať teoretické vedomosti na praktické úlohy, čo je merateľné prostredníctvom simulácií a experimentov uskutočnených v prostredí AR;
- *spätná väzba pedagógov* - učitelia hodnotia jednoduchú integráciu AR do učebných osnov a jej prínos k výučbe zložitejších a inak nerealizovateľných tém.

Tento metodologický prístup ponúka komplexný rámec na hodnotenie efektivity AR nástrojov vo vzdelávaní STEM a navrhuje konkrétne kritériá pre posúdenie ich vplyvu na učenie a praktické zručnosti študentov.

4 Použitie AR aplikácií v školskom prostredí

V procese učenia a učenia sa je potenciál využitia AR stále nevyčerpaný a ponúka nové a nové možnosti, a to nielen v eLearningových aplikáciách (Sinha, 2024). Mnohí z bežných používateľov počítačov a mobilných zariadení si myslia, že rozšírená realita sa používa iba v počítačových a mobilných hrách, ako je napríklad Pokémon Go alebo na platformách sociálnych sietí, ako je aplikácia Snapchat. Avšak impozantným príkladom rozsiahleho využitia AR aj VR vo vzdelávaní je napríklad Google Expeditions.

Google Expeditions

Google Expeditions predstavuje nástroj rozšírenej reality (AR) a virtuálnej reality (VR), ktorý je široko využívaný v edukačných inštitúciách po celom svete. Tento nástroj ponúka učiteľom a študentom interaktívne a imerzívne vzdelávacie zážitky, ktoré rozširujú tradičné učebné metódy (Radianti et al., 2020). Uvádzame niekoľko príkladov, ako *Google Expeditions* prispieva k vzdelávaniu:

- *Virtuálne výlety a exkurzie*: *Google Expeditions* umožňuje študentom navštíviť historické miesta, múzeá, národné parky a dokonca aj vesmír bez toho, aby opustili triedu. Toto je obzvlášť hodnotné pre školy, ktoré nemôžu financovať skutočné exkurzie. Študenti môžu napríklad prechádzať starovekými ruinami Machu Picchu alebo preskúmať Mliečnu dráhu, čo im umožňuje lepšie porozumieť histórii a vesmírnym vedám. (Alelaimat & Ahmad, 2019)
- *Zlepšenie porozumenia zložitých konceptov*: V oblastiach ako biológia, geológia a environmentálne vedy môže *Google Expeditions* pomôcť študentom vizualizovať zložité procesy. Napríklad, študenti môžu vidieť, ako vyzerá fotosyntéza na molekulárnej úrovni alebo ako sa formujú horské pásma, čo uľahčuje ich porozumenie zložitých prírodných procesov.
- *Podpora globálnej a kultúrnej povedomosti*: *Expeditions* ponúka virtuálne cesty do rôznych krajín a kultúr, čo študentom umožňuje lepšie pochopiť a oceniť globálnu diverzitu. Študenti môžu napríklad navštíviť tradičné dediny v Afrike, preskúmať moderné mestá Ázie alebo sa naučiť o historických udalostiach v Európe.
- *Vzdelávanie v prírodných vedách*: *Expeditions* môže poslúžiť ako nástroj na prehľbovanie znalostí v prírodných vedách, ako sú astronómia, geológia a biológia. Študenti môžu preskúmať vnútro zeme, pozorovať výbuch sopky alebo sledovať životný cyklus živočíchov v ich prirodzenom prostredí.
- *Profesionálne orientácie a kariérny rozvoj*: *Google Expeditions* tiež poskytuje možnosti na preskúmanie rôznych profesijných dráh a pracovných prostredí. Študenti môžu virtuálne navštíviť inžinierske firmy, vedecké laboratóriá alebo umelecké ateliéry, čo im pomáha pri rozhodovaní o svojej budúcej kariére.

V nasledujúcej časti sa pozrieme na najpopulárnejšie aplikácie AR a poukážeme na ich aplikovateľnosť v rôznych oblastiach STEM vzdelávania, pričom zohľadníme ich funkcie, používateľskú základňu a efektívnosť. Vo vzdelávaní sa používa množstvo konkrétnych AR aplikácií, ktoré pomáhajú študentom lepšie porozumieť rôznym konceptom a urobiť učenie interaktívnejším a zábavnejším.

Náš výber obmedzíme na STEM vzdelávanie, kde sa AR aplikácie používajú na zlepšenie porozumenia technických a vedeckých konceptov.

AR aplikácie vhodné pre STEM vzdelávanie

- *Anatomy 4D* - umožňuje študentom preskúmať detaily ľudského tela vo viacerých vrstvách pomocou AR. Môžu vidieť a analyzovať jednotlivé orgánové systémy, ako sú svaly, kosti, krvný obeh a nervový systém, a to v 3D modeloch. Namiesto klasických 2D obrázkov z učebníc študenti môžu detailne preskúmať telo v 3D, čo vedie k hlbšiemu porozumeniu.
Využitie pre STEM: Biológia a medicína.
- *JigSpace* - je aplikácia, ktorá umožňuje študentom objavovať široké spektrum 3D modelov, vrátane strojov, technických mechanizmov, molekulárnych štruktúr, a mnohých ďalších objektov. Používatelia môžu rotovať a skúmať tieto objekty v rozšírenej realite.
Využitie pre STEM: V technológii a inžinierstve aplikácia poskytuje možnosť interaktívne preskúmať zariadenia, ako sú motory, elektronika a rôzne mechanizmy. V chémii môžu študenti preskúmať molekulárne štruktúry a chemické väzby. V biológii môže slúžiť na analýzu buniek alebo iných organických štruktúr.
- *Merge Cube* - je to fyzická kocka, ktorá sa používa na zobrazenie a manipuláciu 3D objektov v rozšírenej realite. Pomocou AR aplikácie môžu študenti vidieť a skúmať objekty, ako sú orgány, vesmírne objekty, chemické prvky alebo geometrické tvary, akoby ich držali v rukách.
Využitie pre STEM: V astronómii môže Merge Cube zobrazit' planetárne systémy alebo iné vesmírne objekty. V biológii môžu študenti preskúmať ľudské orgány v 3D a analyzovať ich funkciu. V chémii môže byť použité na skúmanie molekúl a ich interakcií. V geometrii poskytuje možnosť manipulácie s trojrozmernými objektmi, čo pomáha pochopiť ich tvary a vlastnosti.
- *Quiver* - kombinuje tradičné kreslenie s rozšírenou realitou. Študenti môžu najprv nakresliť alebo vyfarbiť obrázky na papieri, a potom prostredníctvom AR aplikácie ich diela ožijú v 3D. Aplikácia obsahuje vzdelávacie balíky, ktoré pokrývajú vedecké a matematické koncepty.
Využitie pre STEM: V biologických vedách môže Quiver demonštrovať životné cykly organizmov alebo fungovanie rôznych biologických procesov. V matematike môžu študenti objavovať geometrické tvary a zložité vzorce v 3D prostredí, čo pomáha zlepšiť priestorové videnie a porozumenie.
- *Augment* - umožňuje používateľom vytvárať a vizualizovať 3D modely v reálnom prostredí. Aplikácia je univerzálna a podporuje široké spektrum vzdelávacích oblastí, kde je potrebné prezentovať modely objektov alebo simulovať experimenty.
Využitie pre STEM: V technológii a inžinierstve môžu študenti vizualizovať technické modely, napríklad štruktúry mostov alebo častí strojov. V geometrii a matematike môžu manipulovať s geometrickými objektmi. V chémii môžu študenti analyzovať molekulárne štruktúry a reakcie.
- a ďalšie, ako napr. *SkyView*, *Froggipedia*, *Math Ninja AR*, *Chemistry AR*, ...

4.1 Rozšírená realita a virtuálna realita v IT vzdelávaní

Rozšírená realita (AR) a virtuálna realita (VR) v IT vzdelávaní prinášajú inovatívne prístupy k výučbe a rozvíjaniu praktických zručností študentov. Tieto technológie umožňujú

študentom nielen lepšie pochopiť teóriu, ale aj prakticky aplikovať svoje zručnosti v bezpečnom a kontrolovanom prostredí. AR a VR menia spôsob, akým sa študenti učia o programovaní, kybernetickej bezpečnosti, sieťových technológiách a iných oblastiach IT, čím im poskytujú lepšiu prípravu na budúcu kariéru v tejto dynamickej oblasti.

Výber možností využitia AR/VR v IT vzdelávaní:

- *Praktické simulácie a tréningy*
VR umožňuje študentom IT prácu v simulovaných prostrediach, kde môžu napríklad vytvárať siete, spravovať servery alebo simulovať prácu s virtuálnymi dátovými centrami. V prostredí VR môžu bezpečne experimentovať s rôznymi technickými systémami a vidieť okamžité výsledky svojich rozhodnutí bez rizika zlyhania reálnych systémov.
AR umožňuje pridávať digitálne objekty a informácie do reálneho sveta, čo je užitočné pri učení sa, ako napríklad analyzovať hardvérové komponenty, zobrazovať štruktúry kódu alebo vizualizovať dátové toky v skutočnom čase priamo na fyzickom zariadení.
- *Programovanie a vývoj softvéru*
AR môže študentom pomôcť lepšie pochopiť abstraktné koncepty v programovaní tým, že kódy a algoritmy vizualizuje v priestore. Študenti môžu vidieť, ako rôzne časti kódu ovplyvňujú výsledný produkt v reálnom čase, čo môže zjednodušiť porozumenie objektovo orientovanému programovaniu alebo algoritmickým štruktúram.
VR umožňuje vývojárom softvéru testovať svoje aplikácie v simulovaných prostrediach, čo je užitočné napríklad pri vývoji hier alebo iných interaktívnych aplikácií, kde môžu študenti vidieť výsledok svojho programovania v 3D priestore.
- *Kybernetická bezpečnosť*
VR simulácie môžu byť použité na výučbu kybernetickej bezpečnosti, kde môžu študenti analyzovať a reagovať na simulované kybernetické útoky v kontrolovanom prostredí. VR umožňuje simulovať rôzne kybernetické hrozby a incidenty, čo poskytuje reálne skúsenosti v simulovanom prostredí.
AR môže pomôcť v reálnom čase zobrazovať stav sieťových systémov, detegovať potenciálne hrozby alebo poskytovať vizuálnu spätnú väzbu na bezpečnostné prvky v infraštruktúre.
- *Výučba sieťových technológií*
VR môže simulovať kompletné sieťové infraštruktúry, kde môžu študenti vidieť, ako fungujú siete, ako sú zariadenia prepojené a ako funguje prenos dát v sieti. To umožňuje študentom lepšie pochopiť zložité siete a analyzovať rôzne topológie v realistickom prostredí.
AR môže zjednodušiť učenie sa o fyzických prvkoch sietí, ako sú káble, servery a prepínače, tým, že na reálnych zariadeniach zobrazí ich štruktúru a funkciu v interaktívnom formáte.
- *Spolupráca a tímová práca*
VR platformy ako *Engage* alebo *AltspaceVR* umožňujú IT študentom spolupracovať na diaľku v zdieľanom virtuálnom prostredí. Môžu organizovať virtuálne tímové stretnutia, spoločne riešiť projekty alebo simulovať spoluprácu na kódoch a dizajnoch. To podporuje zručnosti tímovej práce a zlepšuje komunikáciu medzi študentmi aj v situáciách, keď sú fyzicky oddelení.
AR môže byť využitá na kolaboratívne riešenie problémov v reálnom čase, pričom každý člen tímu vidí rovnaké virtuálne informácie nad reálnym svetom.
- *Rozšírená vizualizácia dát*
AR a VR umožňujú vizualizovať veľké množstvo dát a komplexné algoritmy v trojrozmernom priestore. V IT vzdelávaní to môže byť obzvlášť užitočné pri analýze veľkých dátových súborov, kde môžu študenti skúmať vzory, vizualizovať dátové toky alebo analyzovať sieťové štruktúry.
- *Virtuálne laboratória a cvičenia*

VR umožňuje vytvárať úplné virtuálne laboratóriá, kde môžu študenti trénovať svoje zručnosti bez potreby fyzického hardvéru. Študenti môžu napríklad simulovať konfiguráciu serverov, programovanie sieťových prvkov alebo správu databáz v plne virtuálnom prostredí.

AR umožňuje študentom používať reálne zariadenia, pričom digitálne prvky poskytujú dodatočné informácie a pokyny na obrazovke, čo im pomáha pri praktickom učení.

4.2 Rozšírená realita vo vyučovaní matematiky


Rozšírená realita (AR) vo vyučovaní matematiky prináša inovatívne možnosti, ako urobiť abstraktné koncepty a zložité témy viac zrozumiteľné a vizuálne prístupné pre študentov. AR umožňuje preklenúť priepasť medzi teóriou a praxou tým, že študentom poskytuje interaktívne a dynamické učebné prostredie.

Jednou z kľúčových výhod použitia AR vo vyučovaní matematiky je interaktivita. Študenti majú možnosť interagovať s matematickými modelmi a konceptami na vizuálnej úrovni. Abstraktné a niekedy ťažko pochopiteľné matematické pojmy môžu byť vizualizované a manipulované v reálnom prostredí, čo výrazne uľahčuje ich pochopenie.

Okrem toho AR pridáva prvok zábavy a interaktivity do vyučovacieho procesu, čo môže zvýšiť angažovanosť študentov. Geometrické tvary, vektory, matice a iné matematické pojmy môžu byť prezentované a skúmané v trojrozmernej realite, čo vytvára dynamické a atraktívne vzdelávacie prostredie.

Ďalším prínosom AR je zjednodušenie učenia sa funkcií a grafov. Študenti môžu pomocou tejto technológie sledovať, ako sa zmeny v rovniciach prejavujú v grafe, čo im poskytuje okamžitú spätnú väzbu. Okrem toho môže AR prinášať matematiku do reálneho sveta tým, že študentom umožňuje merať vzdialenosti, plochy a objemy priamo v prostredí, v ktorom sa nachádzajú, čo pomáha aplikovať matematické poznatky v praktických situáciách.

Obr. 4: 3D graf funkcie $P(x,y)$ s väzbou v GeoGebra AR (bez AR a s AR)

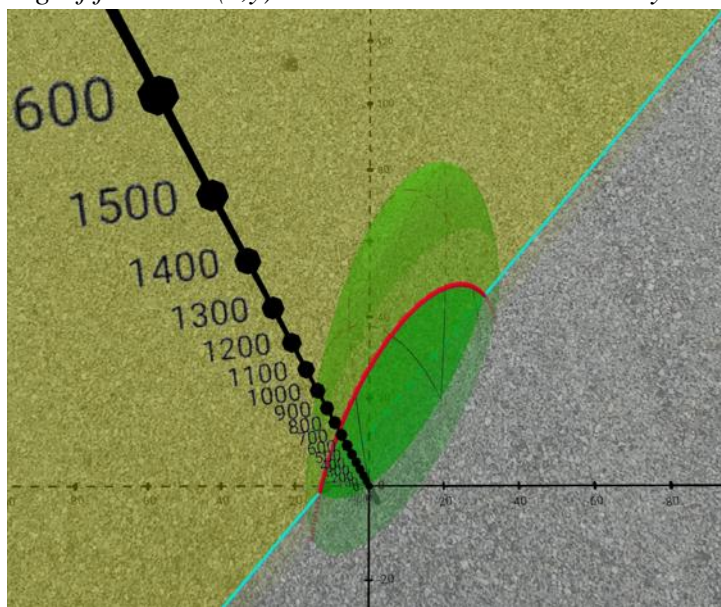


Zdroj: Vlastné spracovanie.

Jednou z konkrétnych efektívnych možností, ako využiť AR priamo vo vyučovaní matematiky na vysokej škole je aplikácia Geogebra AR (Schmid et al., 2023), ktorá ponúka spájanie dynamických matematických modelov s ľubovoľným reálnym prostredím (Obr. 4), napríklad aj priamo v posluchárni.

Poznámka: Z porovnania obrázkov (snímok obrazovky mobilného zariadenia s aplikáciou GeoGebra AR - Obr. 4) je názornosť a využiteľnosť (pravej) snímky s AR na prvý pohľad máta. Menej osvetlené snímané pozadie nemá pozitívny vplyv na názornosť grafu, avšak veľkou výhodou je kotvenie zobrazeného objektu so stredom súradnicovej sústavy do roviny reálneho prostredia a možnosť interaktívne sledovať objekt (v našom prípade graf $P(x,y)$) v rôznych reálnych uhloch pohľadu pri prechádzaní sa okolo neho v rovine kotvenia (Obr. 5).


Obr. 5: 3D graf funkcie $P(x,y)$ s väzbou v GeoGebra AR s dynamikou v AR.



Zdroj: Vlastné spracovanie.

Výsledky pedagogického výskumu potvrdzujú, že využitie AR aplikácií výrazne prispieva k rozvoju priestorového videnia aj u študentov, pre ktorých manuálne 2D náčrt 3D objektov (Obr. 6) je vizuálne málo prínosný resp. neprínosný. (Küçük et al., 2016)

Obr. 6: 3D náčrt grafu (v 2D) ekonomickej funkcie $P(x,y)$ a viazaného extrému



Zdroj: Vlastné spracovanie.

Aplikácie AR v matematike sú rozmanité. V oblasti geometrie môžu študenti skúmať rôzne geometrické tvary a ich vlastnosti v trojrozsomernej realite, čo zlepšuje ich geometrické intuície. V kalkule je AR užitočná pri vizualizácii funkcií, limit a derivácií, čo umožňuje

študentom lepšie pochopiť zložité matematické koncepty. Dokonca aj *štatistika a pravdepodobnosť* môžu byť prezentované prostredníctvom AR, čím sa umožňuje študentom vizualizovať *distribučné krivky, histogramy* a ďalšie štatistické modely.

AR tiež umožňuje personalizované vzdelávanie, pretože aplikácie môžu sledovať pokrok študentov a prispôbovať úlohy podľa ich úrovne vedomostí. Táto technológia tak ponúka dynamické a interaktívne prostredie, ktoré zjednodušuje učenie sa matematiky, uľahčuje pochopenie zložitých pojmov a podporuje kreativitu pri riešení problémov.


Podľa Wu (2013) AR môže pomôcť v prekonávaní abstraktných matematických konceptov tým, že ich vizualizuje a robí viac intuitívnymi pre študentov.

Môžeme konštatovať, že rozšírená realita prináša do vyučovania matematiky nové perspektívy a metódy. Jej schopnosť transformovať abstraktné matematické koncepty do interaktívnych a zrozumiteľných modelov je veľkým prínosom pre efektívnosť a kvalitu matematického vzdelávania.

5 Budúcnosť rozšírenej reality

Globálny trh s rozšírenou realitou (AR) a virtuálnou realitou (VR) zaznamenáva značný rast, najmä v oblasti školení a vďaka rozširovaniu trhu so zariadeniami pre informačno-zábavný priemysel. Okrem toho sa rozšírená realita využíva v rôznych aplikáciách, ako sú prezentácie, televízia, simulácie (napríklad letecké a automobilové simulácie) či videohry s fyzickou interakciou s 3D modelmi. Tieto faktory by podľa predpokladov mali podporiť rast trhu s rozšírenou a virtuálnou realitou v nadchádzajúcom období.

Obr. 7: Predpokladaný podiel zákazníkov jednotlivých krajín používajúcich AR pri nákupe produktov na rok 2025



Zdroj: <https://www.statista.com/statistics/1270070/ar-use-forecast-in-buying-online/>

Využívanie virtuálnej reality v sektore zdravotnej starostlivosti zažíva obrovský rast, čo taktiež výrazne prispieva k celkovému rastu trhu s AR a VR počas prognózovaného obdobia.

Rastúci dopyt po AR zariadeniach v zdravotníctve a rastúci dopyt po AR v sektore maloobchodu a elektronického obchodu sú kľúčovými faktormi, ktoré pravdepodobne podporia ďalší rast tohto trhu

Lahký prístup k cenovo dostupným zariadeniam virtuálnej reality v rôznych odvetviach, narastajúca digitalizácia, pokroky v technológiách a vysoké investície do trhu s virtuálnou realitou budú hlavnými hnacími silami rastu trhu s AR a VR v nasledujúcich rokoch. Okrem toho sa očakáva, že významný rast v odvetví mobilných hier, zvyšujúca sa miera internetového pripojenia a zvyšujúce sa využívanie spotrebnej elektroniky budú ďalšími kľúčovými faktormi, ktoré prispievajú k rozvoju tohto trhu.

Poznámka: Ako z grafu (Obr. 7) vidieť, u mladej generácie je podiel využívania AR a VR pri nákupoch oveľa vyšší, v niektorých krajinách – Nemecko – dokonca dvojnásobný. Veľkosť trhu s rozšírenou realitou sa odhaduje na 42,48 miliardy USD v roku 2024 a očakáva sa, že do roku 2029 dosiahne 248,38 miliardy USD.

6 Záver

Využitie AR v STEM vzdelávaní otvára nové možnosti pre učenie a výuku. Tento prístup nielen zvyšuje zapojenie a záujem študentov, ale aj značne rozširuje hranice tradičného vzdelávania, čím otvára dvere k inovatívnym a efektívnym spôsobom učenia. S rastom technológií AR a neustálym vývojom platforiem podporujúcich AR sa očakáva, že vznikne ešte viac inovatívnych spôsobov využitia AR (nielen) v STEM vzdelávaní. Sinha (2024) poukazuje na to, že AR má potenciál nielen zlepšiť výučbové procesy, ale aj radikálne zmeniť spôsob, akým študenti vnímajú a interagujú s vedomosťami.

Podľa Ezawu (2016) sa VR/AR v priebehu nasledujúcich 10 rokov postupne vyvinie na bežnú technológiu v každodennom živote, vrátane vzdelávania. K jej demokratizácii prispievajú tri faktory: zlepšenie mobilných zariadení, zvýšené investície do virtuálnych technológií a prístup k používateľskému obsahu na sociálnych sieťach. Tým sa VR/AR stane prístupnejšou a cenovo dostupnejšou, podobne ako mobilné technológie, čo uľahčí ich integráciu do vzdelávacích procesov.

Úspešné využitie VR/AR vo vzdelávaní závisí od spôsobu, akým sú tieto technológie implementované. Vďaka konštruktivistickému prístupu k učeniu, ktorý tieto technológie umožňujú, majú študenti príležitosť priamo experimentovať, interagovať s virtuálnymi objektmi a spolupracovať s ostatnými, čo zlepšuje ich schopnosť aplikovať teoretické poznatky v praxi.

AR a VR v STEM vzdelávaní poskytujú študentom neoceniteľné príležitosti pre aktívne učenie a zážitkové poznávanie, otvárajú nové cesty k porozumeniu zložitých vedeckých princípov a podnecujú k inováciám v pedagogických metodikách. Táto integrácia nových technológií do vzdelávania zásadne mení, ako sú budúce generácie študentov pripravené na výzvy a príležitosti 21. storočia.

Príspevok bol spracovaný v rámci riešenia grantovej úlohy KEGA 026UK-4/2022 *Koncepcia konštrukcionizmu a rozšírenej reality v STEM vzdelávaní (CEPENSAR).*

Literatúra

1. Alelaimat, A. M., & Ahmad, M. K. (2019). The Effect of Google Expeditions on Students' Learning Outcomes in Geography Lessons. *Journal of Educational Technology & Society*, 22(3), 59-70.
2. Bacca, J., Baldiris, S., Fabregat, R., & Graf, S. (2014). Augmented Reality Trends in Education: A Systematic Review of Research and Applications. *Educational Technology & Society*, 17(4), 133-149.

3. Bower, M., Lee, M. J. W., & Dalgarno, B. (2017). Collaborative learning across physical and virtual worlds: Factors supporting and constraining learners in a blended reality environment. *British Journal of Educational Technology*, 48(2), 407-430.
4. Chhatbar, K. (2021, March 5). *Comparing Arcore vs arkit vs vuforia: The best augmented reality toolkit*. BlueWhaleApps. <https://bluewhaleapps.com/blog/comparing-arkit-vs-arcore-vs-vuforia-the-best-augmented-reality-toolkit>
5. Credera. (2020, September 14). *The future of mobile AR: A comparison between ARCore, ARKit, AR Foundation, and Vuforia*. Credera. <https://www.credera.com/en-us/insights/the-future-of-mobile-ar-a-comparison-between-arcore-arkit-ar-foundation-and-vuforia>
6. Creighton, R. H. (2010). *Unity 3D Game Development by Example: Beginner's Guide*. Packt Publishing.
7. echo3D. (2021, February 12). *Top 10 AR developer tools every developer should know*. DEV Community. <https://dev.to/echo3d/top-10-ar-developer-tools-every-developer-should-know-3b2d>
8. Ezawa, K. (2016). *Virtual & Augmented Reality*. In *Investment Themes in 2016*. Citi Global Perspectives & Solutions. Citigroup Inc. Retrieved June 15, 2016, from <https://www.citivelocity.com/citigps/ReportSeries.action?recordId=45>
9. Forecast use of AR in online shopping worldwide 2025 | statista. (n.d.-a). <https://www.statista.com/statistics/1270070/ar-use-forecast-in-buying-online/>
10. Koreňová, L. (2019). Research of the use of augmented reality to develop the ability to estimate in STEM education. In *EDULEARN19 Proceedings* (pp. 5719–5724). IATED. <https://doi.org/10.21125/edulearn.2019.1390>
11. Koreňová, L., Gurný, P., Hvorecký, J., Lůžek, P., & Rozehnal, P. (2022). Virtual reality retooling humanities courses: Finance and marketing experience at a Czech university. *Applied Sciences*, 12(19), 10170. <https://doi.org/10.3390/app121910170>
12. Küçük, S., Kapakin, S., & Gökteş, Y. (2016). Learning anatomy via mobile augmented reality: Effects on achievement and cognitive load. *Anatomical Sciences Education*, 9(5), 411-421. <https://doi.org/10.1002/ase.1603>
13. Makarov, A. (2024, February 15). *Augmented reality in iOS apps: ARKit development guide 2024*. MobiDev. <https://mobidev.biz/blog/arkit-guide-augmented-reality-app-development-ios>
14. PTC VUFORIA – Augmented Reality (AR) |. (n.d.-b). <https://www.mtwmag.com/ptc-vuforia-augmented-reality-ar-design-tech-system/>
15. Radianti, J., Majchrzak, T. A., Fromm, J., & Wohlgenannt, I. (2020). A systematic review of immersive virtual reality applications for higher education: Design elements, lessons learned, and research agenda. *Computers & Education*, 147, 103778.
16. Sergeev, A. (2020, July 2). *Workshop on Unity's XR interaction toolkit*. 80 Level. <https://80.lv/articles/workshop-on-unity-s-xr-interaction-toolkit>
17. Schmid, A., Koreňová, L., Cahyono, A. N., Hvorecký, J., & Lavicza, Z. (2023). Geogebra as a constructivism teaching tool for visualization geometry using VR and AR. In E. Smyrnova-Trybulska (Ed.), *E-learning & Artificial Intelligence Scientific Editor Eugenia Smyrnova-Trybulska "E-learning"* (Vol. 15, pp. 253–264). Katowice–Cieszyn. <https://doi.org/10.34916/el.2023.15.20>
18. Schröter, P., Mertens, R., & Meinel, C. (2017). Gamified Lab Activities in STEM Education Using Unity3D. In *Proceedings of the 22nd International Conference on Intelligent User Interfaces* (pp. 589-594). Association for Computing Machinery.
19. Sinha, S. (2024, July 18). *Augmented Reality In Education: Staggering Insight into the Future*. eLearning Industry. Retrieved from <https://elearningindustry.com/augmented-reality-in-education-staggering-insight-into-future>

20. Uderbayeva, N. K., & Schmidt, P. (2022). The Use of Modern Digital Technologies in Education. In *TIEES 2022: Trends and Innovations in E-Business, Education and Security* [elektronický zdroj]: Tenth International Scientific Web-conference of Scientists and PhD. Students or Candidates: Reviewed Proceedings, November 18, 2022.
21. Vantage Market Research. (n.d.). *Augmented reality and virtual reality market size USD 248.16 billion by 2030*. Vantage Market Research. <https://www.vantagemarketresearch.com/industry-report/augmented-reality-and-virtual-reality-market-1448>
22. Wu, H.-K., Lee, S. W.-Y., Chang, H.-Y., & Liang, J.-C. (2013). Current status, opportunities, and challenges of augmented reality in education. *Computers & Education*, 62, 41-49. <https://doi.org/10.1016/j.compedu.2012.10.024>

Výpočet pravdepodobnosti krachu pri aplikácii LCR zaistenia

Ruin probability calculation in LCR reinsurance

František Slaninka¹, Zsolt Simonka¹

Abstrakt

Zaistenie najvyšších škôd (LCR) patrí k menej frekventovaným typom neproporcionálneho zaistenia hlavne z dôvodu zložitosti správy a reportovania. Umožňuje ale ochranu poisťovne pred potenciálne destabilizačnými vysokými škodami. Významnú úlohu v tomto zaistení hrá nastavenie hodnoty určujúcej, koľko škôd uhradí zaistovateľ. Kľúčovým kontrolným prostriedkom pri jej nastavení je pravdepodobnosť krachu vyjadrujúca, či poisťovňa bude schopná kryť svoje záväzky voči poisteným subjektom. Presný výpočet pravdepodobnosti krachu je v prípade LCR zaistenia problematický, preto je vhodné využiť alternatívne metódy. V článku uvádzame spôsob určenia pravdepodobnosti krachu pri aplikovanom LCR zaistení pomocou Monte Carlo simulácií. Výpočet pravdepodobnosti krachu realizujeme na základe definície kolektívneho modelu rizika a zaistenia LCR v jazyku R.

Kľúčové slová

LCR zaistenie, pravdepodobnosť krachu, Monte Carlo simulácie, jazyk R

Abstract

Largest Claims Reinsurance (LCR) is a less commonly used type of non-proportional reinsurance, mainly due to the complexity of administration and reporting. However, it provides insurer's protection against potentially destabilizing large losses. A crucial factor in this type of reinsurance is setting the value that determines which claims will be covered by the reinsurer. A key control mechanism in setting this value is the probability of ruin, which expresses whether the insurer will be able to meet its obligations to policyholders. Given the challenges in calculating the probability of ruin for LCR reinsurance, alternative methods are recommended. In this article, we present a method for calculating the probability of ruin in the context of LCR reinsurance using Monte Carlo simulations. The calculation of the probability of ruin is based on the definition of the collective risk model and LCR reinsurance definition, implemented in the R programming language.

Key words

LCR reinsurance, Ruin probability, Monte Carlo simulation, R programming language

JEL classification

C15, C69, G22

1 Úvod

Zaistenie je proces, pri ktorom poisťovateľ prenáša časť rizík, ktoré na seba prevzal, na inú poisťovňu, nazývanú zaistovateľ. Hlavným cieľom zaistenia je ochrana poisťovateľa pred nadmernými stratami, ktoré môžu vzniknúť z neočakávaných udalostí alebo veľkých poistných

¹ Ekonomická univerzita v Bratislave, Fakulta hospodárskej informatiky, Katedra matematiky a aktuárstva, Dolnozemska cesta 1/b, 852 35, Bratislava, frantisek.slaninka@euba.sk, zsolt.simonka@euba.sk.

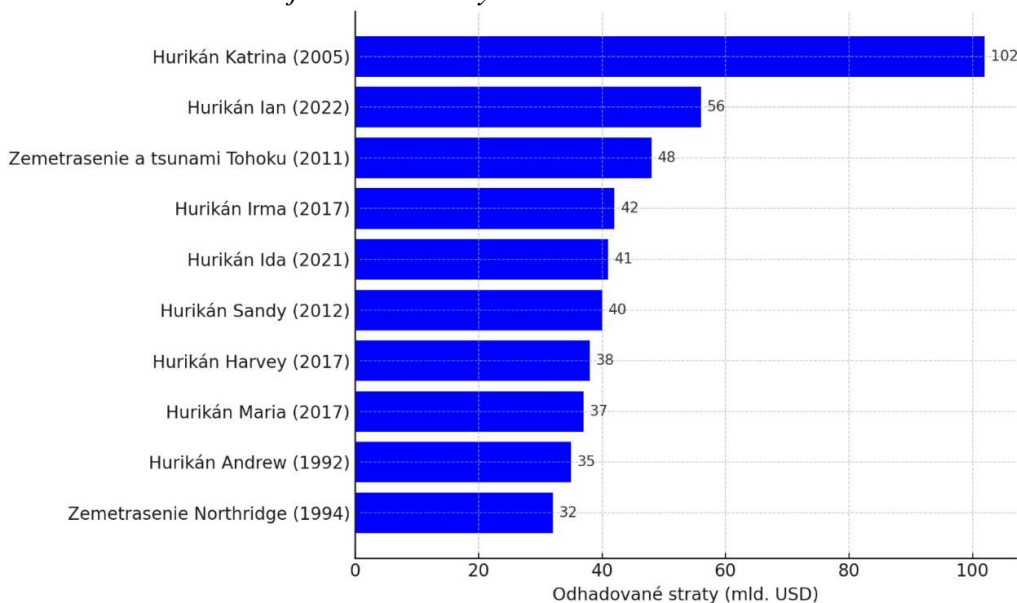
nárokov. To umožňuje poisťovateľovi udržať si finančnú stabilitu a schopnosť kryť veľké škody bez ohrozenia solventnosti. Medzi najdôležitejšie funkcie zaistenia patrí (Cipra, 2004):

- *Rozloženie rizika:* Poisťovňa prenáša časť prevzatého rizika na zaistovateľa, čo jej pomáha zvládať veľké straty, napríklad v prípade katastrofických udalostí (záplavy, zemetrasenia).
- *Homogenizácia poistného kmeňa:* Voľba vhodného zaistenia umožňuje veľký poistný kmeň orezať do homogénnej podoby.
- *Zvýšenie kapacity:* Zaistenie umožňuje poisťovni prijímať viac poistných zmlúv alebo pokrývať riziká s vyššími poistnými sumami, ktoré by inak bez zaistenej ochrany nebola schopná zvládnuť.
- *Stabilizácia finančných výsledkov:* Zaistenie pomáha vyhladzovať výkyvy v ziskovosti poisťovne, ktoré môžu byť spôsobené nepredvídateľnými udalosťami a veľkými stratami.
- *Ochrana solventnosti:* Pomocou zaistenia si poisťovňa môže zachovať svoju finančnú stabilitu aj v prípade veľkých škôd. Zaistovatelia kompenzujú časť strát, čím sa znižuje tlak na kapitál poisťovne.
- *Optimalizácia rizikového manažmentu:* Zaistenie dovoľuje poisťovni efektívnejšie riadiť riziká, poisťovňa môže využiť odborné znalosti a skúsenosti zaistovateľa, napríklad pri modelovaní katastrofických rizík.
- *Plnenie regulačných požiadaviek:* Zaistenie môže poisťovni pomôcť splniť požiadavky regulačných orgánov, ktoré stanovujú minimálne kapitálové rezervy potrebné na krytie rizík.

Zaistenie zohráva významnú úlohu v rámci smernice Solvency II (účinnosť nadobudla v roku 2016), ktorá predstavuje európsky regulačný rámec pre poisťovne a zaistovacie spoločnosti so zameraním na posilnenie ochrany spotrebiteľov a zabezpečenie finančnej stability poisťovacích trhov. Zaistenie v tomto kontexte pomáha poisťovni efektívne riadiť riziká, znižovať kapitálové požiadavky a plniť regulačné požiadavky stanovené smernicou.

Graf na Obr. 1 zobrazuje 10 najväčších škodových udalostí v rokoch 1900 – 2023. Väčšina týchto udalostí viedla k rekordným nárokom na zaistenie, pričom zaistovacie spoločnosti zohrali kľúčovú úlohu pri vyplácaní škôd.

Obr. 1: 10 najväčších škodových udalostí v rokoch 1900 – 2023




Zdroj: <https://www.statista.com/statistics/207424/insured-losses-of-the-largest-world-natural-catastrophes/>

2 LCR zaistenie v kontexte kolektívneho modelu rizika

Zaistenie najvyšších škôd, označované v praxi $LCR(p)$ je zaistenie, pri ktorom zaisťovateľ uhradza p najvyšších škôd z n vzniknutých (p je prirodzené číslo, $p < n$), ktoré nastali v priebehu platnosti zaisťovanej zmluvy (Cipra, 2004).

Na Obr. 2 je zobrazené LCR zaistenie aplikované pre poisťovacie zmluvy, v ktorých došlo k poisťovým udalostiam ak $p = 3$, t. j. zaisťovateľ uhradza 3 najvyššie škody (označené červenou farbou), zvyšné škody (označené modrou farbou) hradí poisťovateľ.

Obr. 2: Příklad LCR zaistenia, ak $p = 3$



Zdroj: vlastné spracovanie podľa (Cipra, 2004)

Uvažujme ďalej postupnosť po sebe idúcich škôd $\{x_1, x_2, \dots\}$, ktorá je výsledkom realizácie postupnosti nezávislých a identicky rozdelených náhodných premenných $\{X_i\}_{i=1}^{\infty}$. Celkovú škodu možno vyjadriť ako súčet všetkých po sebe idúcich vzniknutých individuálnych škôd $\{x_1, x_2, \dots\}$.

Predpokladajme, že po sebe idúce škody vzniknú realizáciou načítacieho procesu škôd $\{N_t, t \geq 1\}$, nezávislého od premenných $\{X_i\}_{i=1}^{\infty}$, kde N_t opisuje počet škôd vzniknutých do času t . Potom náhodnú premennú opisujúcu celkovú škodu do času t vyjadríme vzťahom

$$S_t = \sum_{i=1}^{N_t} X_i, \quad t > 0 \quad (1)$$

Náhodná premenná, ktorá spĺňa uvedené predpoklady má zložené rozdelenie (Horáková et al., 2015), čo zapíšeme v prípade, ak nešpecifikujeme ani jedno z rozdelení ako

$$S_t \sim Co(p_{N_t}(n); F_X(x)) \quad (2)$$

Označme ďalej $(X_1^*, X_2^*, \dots, X_{N_t}^*)$ vzostupne usporiadané štatistiky náhodného vektora $(X_1, X_2, \dots, X_{N_t})$ po sebe idúcich individuálnych škôd do času t . V prípade aplikovania LCR zaistenia zaistovateľ uhradí posledných p najvyšších škôd, poisťovateľ uhradí zvyšných $N_t - p$ vzniknutých škôd. V kontexte vyššie uvedeného celkovú škodu zaistovateľa možno vyjadriť v tvare (Ladoucette & Teugels, 2005)


$${}^z S_t = \sum_{i=1}^p X_{N_t-i+1}^*, \quad 1 \leq p \leq N_t, t > 0 \quad (3)$$

Celková škoda poisťovateľa je daná vzťahom

$${}^p S_t = \sum_{i=1}^{N_t-p} X_i^*, \quad 1 \leq p \leq N_t, t > 0 \quad (4)$$

Na Obr. 3 je zobrazené LCR zaistenie aplikované pre vzostupne usporiadané poistné zmluvy, v ktorých došlo k poistným udalostiam ak $p = 3$, t. j. zaistovateľ uhradza 3 najvyššie škody (označené červenou farbou), zvyšné škody (označené modrou farbou) hradí poisťovateľ.

Obr. 3: Príklad LCR zaistenia v prípade usporiadania škôd, ak $p = 3$



Zdroj: vlastné spracovanie podľa (Cipra, 2004)

Vyjadrenie rozdelenia celkovej škody, pri špecifikácii rozdelení počtu a výšky škody v prípade využitia usporiadaných štatistík predstavuje náročný proces, viac o problematike čitateľ nájde napríklad v (Fan et al., 2017) a (Ladoucette & Teugels, 2005). Na určovanie pravdepodobnosti krachu pri aplikácii LCR zaistenia na uvažované riziko preto využijeme metódu Monte Carlo simulácií.

Pri Monte Carlo simuláciách nahradíme reálny systém jeho simulačným modelom s rovnakými pravdepodobnostnými charakteristikami a opakovanne simulujeme správanie reálneho systému na vytvorenom modeli. Ak vykonáme dostatočný počet simulácií, ich výsledky poskytujú veľmi presné odhady rizikových mier pre rôzne kombinácie primárnych

a sekundárnych rozdelení v rámci zložených rozdelení. Monte Carlo simulácie v prostredí R sú účinným a výkonným nástrojom pri určovaní rozdelenia celkovej škody. Počet simulácií je potrebné zvoliť starostlivo, pričom platí, že $E(S)_{simul} \cong E(S)_{exakt}$ a zároveň zohľadniť variabilitu jednotlivých rozdelení (napríklad lognormálneho). Napriek vysokému počtu simulácií softvér R poskytuje výsledky veľmi rýchlo, zvyčajne v rozpätí 1 až 60 sekúnd (Páleš & Slaninka, 2021).

Pri aplikovaní LCR zaistenia na uvažované riziko je hlavným problémom konštrukcia celkovej škody zaistovateľa a poisťovateľa. Inými slovami budeme konštruovať hodnoty náhodnej premennej rozdelenia celkovej škody zaistovateľa, aj poisťovateľa.

Predpokladajme znalosť rozdelenia počtu škôd aj výšky individuálnej škody. Budeme simulovať množiny individuálnych škôd, ktoré budeme následne triediť podľa zvoleného p medzi zaistovateľa a poisťovateľa. Situácia jednej usporiadanej množiny vzniknutých škôd pre dané p je zobrazená na Obr. 3. Celková škoda zaistovateľa v tomto prípade bude súčtom 3 posledných najvyšších škôd, na grafe zobrazených červenými stĺpcami. V jazyku R na uvedené konštrukcie využijeme vstavané funkcie

- *replicate* – realizuje opakovanie určitého výrazu alebo výpočtu a zhromažďuje výsledky týchto opakovaní s výstupom vo forme vektor, matica alebo zoznam v závislosti od typu vrátených údajov a nastavení,
- *sort* - slúži na usporiadanie prvkov vektora od najmenšieho po najväčší, ale pomocou parametrov je možné zmeniť poradie triedenia,
- *tail* – zobrazuje posledných n prvkov z vektora, alebo dataframe,
- *head* – zobrazuje prvých n prvkov z vektora, alebo dataframe.

Kód v jazyku R simulujúci nastatie jednej škodovej udalosti a realizujúci delenie škody medzi zaistovateľa a poisťovateľa pri aplikácii LCR zaistenia a výpočet výšky škody, ktorú musia uhradiť môžeme zapísať takto (uvažujeme počet škôd $N \sim Po(20)$, výška individuálnej škody $X \sim E(0,1)$, $p = 5$):

```
X<- rexp(rpois(1,20),0.1)           # vzniknuté škody v rámci
                                   # jednej škodovej udalosti

X_usp<- sort(X,decreasing=FALSE)   # usporiadanie vektora X
X_usp

X_z<- tail(X_usp,5)                # škody hradené zaistovateľom
X_z

X_p<- head(X_usp,length(X_usp)-5)  # škody hradené poisťovateľom
X_p
```

Škody hradené zaistovateľom (všetky škody a škody hradené poisťovateľom určíme podobne) získame aj príkazom:

```
X_z<- tail(sort(rexp(rpois(1,20),0.1),decreasing=FALSE),5)
```

Výstupy nasimulovaných individuálnych škôd v rámci jednej škodovej udalosti celkovo X , hradených zaistovateľom X_z a poisťovateľom X_p sú nasledovné:

```
> X
[1] 0.08414212 1.12502589 1.71927269 1.80926344 2.55724180
2.82579898 3.33400143 3.47873264
 [9] 3.61822205 4.28239895 4.71532900 5.29980866 5.37007592
5.48357223 5.52260637 5.97872837
[17] 6.35608871 6.66035761 7.87248398 9.80332463 10.16816903
11.63120387 13.12400168 14.51484418

> X_z
[1] 9.803325 10.168169 11.631204 13.124002 14.514844

> X_p
[1] 0.08414212 1.12502589 1.71927269 1.80926344 2.55724180
2.82579898 3.33400143 3.47873264 3.61822205
[10] 4.28239895 4.71532900 5.29980866 5.37007592 5.48357223
5.52260637 5.97872837 6.35608871 6.66035761
[19] 7.87248398
```

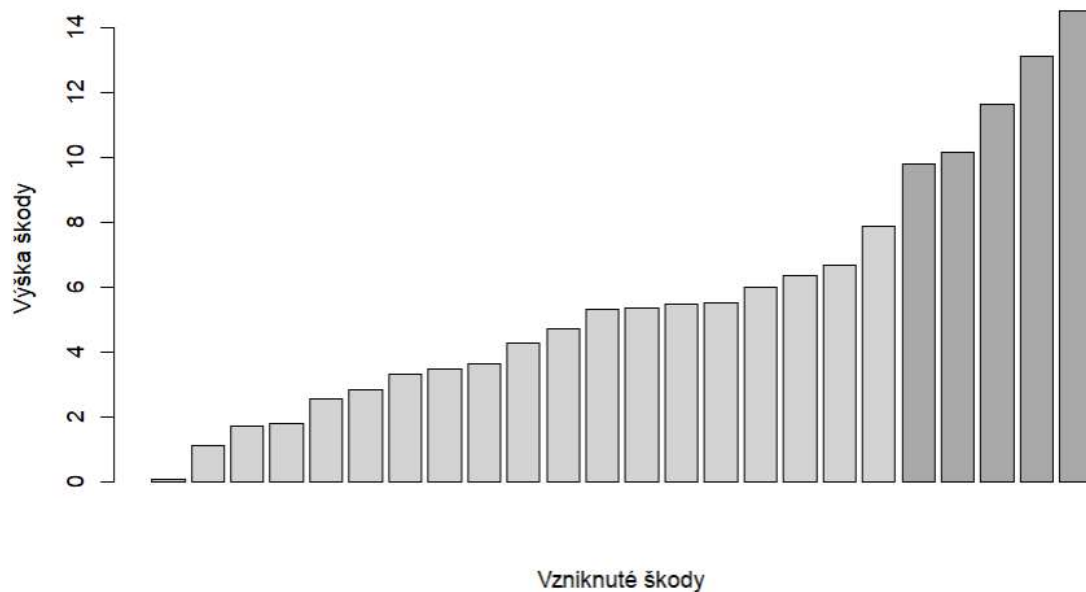
Graficky situáciu zobrazíme príkazmi

```
colors<- c(rep("lightgray", length(X_usp) - 5), rep("darkgray",
5))

barplot(X_usp, col = colors, xlab = "Vzniknuté škody", ylab =
"Výška škody")
```

s výstupom v R (Obr. 4)

Obr. 4: Grafické zobrazenie nasimulovaných individuálnych škôd



Zdroj: vlastné spracovanie v jazyku R

Celkovú vzniknutú škodu, škodu, ktorú uhradza zaistovateľ a poisťovateľ (aj s výstupom) získame príkazom

```
data.frame(sum(X_n), sum(X_p), sum(X_z))

  sum.X_n. sum.X_p. sum.X_z.
1 137.3347 78.09315 59.24154      # výstup v jazyku R
```

3 Pravdepodobnosť krachu pri aplikácii LCR zaistenia

Definujme prebytok poisťovne počas jednej časovej periódy náhodnou premennou $U_1 = U + RP - S$, kde

- U - vyjadruje začiatkové rezervy na začiatku sledovaného obdobia,
- RP - je celkové prijaté rizikové poistné za jednu časovú periódu,
- S - predstavuje celkovú škodu za jednu časovú periódu.

Cieľom poisťovne je, aby prebytok v čase $t = 1$, t. j. na konci časovej periódy bol kladný, respektíve, aby platilo s veľmi malou pravdepodobnosťou

$$P(U + RP - S < 0) = \varepsilon \quad (5)$$

Čo po úprave možno vyjadriť v tvare

$$F_S(U + RP) = 1 - \varepsilon \quad (6)$$

Uvažujme načítací proces počtu škôd $\{N_t\}_{t \geq 0}$, kde náhodná premenná N_t opisuje počet škôd v časovom intervale $\langle 0, t \rangle$. V klasickom načítacom procese je to náhodná premenná s Poissonovým rozdelením a načítací proces sa nazýva Poissonov proces. Proces prebytku $\{U_t\}_{t \geq 0}$ vyjadríme pomocou náhodných premenných opisujúcich prebytok poisťovne do času t

$$U_t = U + RP \cdot t - S_t \quad (7)$$

Pre celkovú škodu S_t čase t podľa (1), (2) a (7) platí

$$S_t \sim CoPo(\lambda \cdot t; F_X(x)) \quad (8)$$

a pravdepodobnosť krachu do času t môžeme vyjadriť v tvare

$$P(U + RP \cdot t - S_t < 0) = \varepsilon \quad (9)$$

respektíve

$$F_{S_t}(U + RP \cdot t) = 1 - \varepsilon \quad (10)$$

V prípade, ak budeme uvažovať, že na prijaté riziko je aplikované zaistenie, prebytok poisťovne do času t je daný vzťahom

$$U_t = U + RP \cdot t - NZ \cdot t - {}^P S_t \quad (11)$$

kde NZ vyjadrujú náklady na zaistenie za jednu časovú periódu a ${}^P S_t$ opisuje škodu poisťovateľa do času t . Pravdepodobnosť krachu v čase t , vyjadruje na základe (10) a (11) vzťah

$$P(U + RP \cdot t - NZ \cdot t - {}^P S_t < 0) = \varepsilon \quad (12)$$

po úprave

$$F_{P, S_t}(U + RP \cdot t - NZ \cdot t) = 1 - \varepsilon \quad (13)$$

Predpokladajme, že počet škôd sa riadi Poissonovým rozdelením $N \sim Po(100)$ a výška individuálnej škody Paretoovým rozdelením I. typu $X \sim Par(3,2)$. Na príslušné riziko aplikujeme LCR zaistenie s parametrom $p=10$, t. j. zaistovateľ hradí 10 najvyšších vzniknutých škôd. Našou úlohou bude určiť pravdepodobnosť krachu pri daných začiatočných rezervách U . Rizikové poistné aj náklady na zaistenie budeme počítat podľa princípu strednej hodnoty s prirážkami $a=0,1$, respektíve $b=0,12$. Kvôli jednoduchosti uvažujeme jednu časovú periódu, t. j. $t=1$.

Výpočet pravdepodobnosti krachu realizujeme simuláciami Monte Carlo v jazyku R pomocou funkcie *replicate*. Hodnoty náhodnej premennej celkovej škody sú simulované v súlade s definíciou kolektívneho modelu rizika a triedenie individuálnych škôd medzi zaistovateľa a poisťovateľa je realizované podľa kódu v Kapitole 2 (Páleš & Slaninka, 2021).

```
p<- 10          # p = 10, parameter LCR zaistenia
lambda<- 100    # parametre rozdelení
scale<- 3
shape<- 2

U<- 50          # začiatočné rezervy
a<- 0.1         # prirážky
b<- 0.12

S<- replicate(10000, sum(sort(rpareto(rpois(1, lambda),
scale, shape), decreasing=FALSE))) # hodnoty premennej
                                celkovej škody

S_z<- replicate(10000, sum(tail(sort(rpareto(rpois(1, lambda),
scale, shape), decreasing=FALSE), p))) # celková škoda zaistovateľa

S_p<-replicate(10000, sum(head(sort(rpareto(a<-rpois(1, lambda),
```

```

scale, shape), decreasing=FALSE), a-p))) # celková škoda
                                         poistovateľa

RP<- mean(S)+a*mean(S)                   # rizikové poistné
NZ<- mean(S_z)+b*mean(S_z)              # náklady na zaistenie

PK<- 1-length(subset(S, S<U+RP))/length(S)
                                         # pravdepodobnosť krachu
                                         bez zaistenia

PK_LCR<- 1-length(subset(S_p, S_p<U+RP-NZ))/length(S_p)
                                         # pravdepodobnosť krachu po
                                         aplikácii LCR zaistenia

```

Odhady pravdepodobnosti krachu bez aj po aplikovaní LCR zaistenia získame v jazyku R nasledujúcim príkazom a výstupom:

```

data.frame(U, PK, PK_LCR)

  U      PK  PK_LCR
1 50 0.1127 0.0551 # výstup v jazyku R

```

Z uvedeného výstupu vidíme, že pri začiatkových rezervách $U = 0$ je odhadovaná pravdepodobnosť krachu bez zaistenia 0,1127, LCR zaistenie s parametrom $p = 10$ pravdepodobnosť krachu redukuje na hodnotu 0,0551.

4 Záver

Neproporcionálne LCR zaistenie sa javí ako vhodný prostriedok na ochranu poistovateľa hlavne v prípadoch, že výška škody je opísaná pomocou rozdelení s tzv. ťažkým chvostom (Paretovo, Weibullovo, lognormálne, alebo napríklad log-gama rozdelenie). V takom prípade poistovateľ môže vhodne nastaveným parametrom p preniesť časť nebezpečných škôd na zaistovateľa. Pravdepodobnosť krachu je dôležitou mierou, ktorá môže pomôcť pri nastavovaní parametra p . Článok uvádza spôsob odhadu pravdepodobnosti krachu, ak na riziko aplikujeme LCR zaistenie. Výpočet sme realizovali pomocou simulácií Monte Carlo s využitím programovacieho jazyka R. S dosiahnutých výsledkov vidieť, že napríklad v prípade, ak uvažujeme výšku škody opísanú Paretovým rozdelením, LCR zaistením a vhodnou voľbou parametra p dokážeme škodu poistovateľa efektívne eliminovať.

Príspevok bol spracovaný v rámci riešenia grantovej úlohy VEGA 1/0431/22 Implementácia inovatívnych prístupov modelovania rizík v procese ich riadenia v interných modeloch poisťovní v kontexte s požiadavkami direktívy Solvency II.

Literatúra

1. Cipra, T. (2004). *Zajištění a přenos rizik v pojišťovnictví*. Grada Publishing.
2. Fan, Y., Griffin, P. S., Maller, R., Szimayer, A., & Wang, T. (2017). The effects of Largest claim and Excess of loss reinsurance on company's ruin time and valuation. *Risks*. MDPI. <https://www.mdpi.com/2227-9091/5/1/3>

3. Horáková, G., Páleš, M., & Slaninka, F. (2015). *Teória rizika v poistení*. Wolters Kluwer.
4. Ladoucette, S. A., & Teugels, J. L. (2005). Reinsurance of large claims. *Journal of Computational and Applied Mathematics*, 186, 163–190. <https://www.sciencedirect.com/science/article/pii/S0377042705001950>
5. Mucha, V., & Páleš, M. (2018). *Teória pravdepodobnosti pre ekonómov (S podporou jazyka R)*. Letra Edu.
6. Páleš, M., & Slaninka, F. (2021). *Teória rizika v poistení (Riešené príklady v jazyku R a Maxima)*. Letra Edu.
7. Statista. (n.d.). *Insured losses of the largest world natural catastrophes*. [Online]. Dostupné na: <https://www.statista.com/statistics/207424/insured-losses-of-the-largest-world-natural-catastrophes/>

Nástroj na aplikovanie modelov generovaných prostriedkami automatického strojového učenia implementovaný ako webová aplikácia

A tool for applying models generated by means of automatic machine learning implemented as a web application

Pavol Sojka¹

Abstrakt

V dnešnej dobe existuje množstvo dátových zdrojov, ktoré môžu svojim majiteľom priniesť dodatočné informácie. Ale len málo z nich je schopných vyhodnotiť tieto zdroje kvôli nedostatku vedomostí vo vedeckých oblastiach, ako je štatistika, matematika atď. Náš príspevok má za cieľ sčasti vyriešiť tento druh problému a vytvorili sme nástroj, ktorý implementuje kroky na uľahčenie tohto procesu. V našej predchádzajúcej práci sme implementovali nástroj na čistenie dát. Druhým krokom je výber vhodného modelu podľa daných údajov v procese automatického generovania vhodného modelu a tretím krokom je aplikovanie nájdeného modelu na dáta. V prvej kapitole popisujeme problém na celkovej úrovni, v druhej kapitole predstavujeme použitú metodiku, tretia kapitola popisuje samotný projekt a získané modely, použitie vygenerovaného modelu a posledná obsahuje záver.

Kľúčové slová

Python, web aplikácia, scikit-learn, dataset

Abstract

Nowadays, there are many data sources that can bring additional information to their owners. But few of them are able to evaluate these resources due to lack of knowledge in scientific fields such as statistics, mathematics, etc. Our paper aims to partially solve this kind of problem, and we have created a tool that implements steps to facilitate this process. In our previous work, we implemented a data cleaning tool. The second step is to select a suitable model according to the given data in the process of automatically generating a suitable model, and the third step is to apply generated model to the data. In the first chapter we describe the problem at the overall level, in the second chapter we present the methodology used, the third chapter describes the project itself and the obtained models, the use of the generated model and the last one contains the conclusion.

Key words

Python, web application, scikit-learn, dataset

JEL classification

M15

1 Úvod

V posledných rokoch sme svedkami rýchleho nástupu nových technológií a modernizácie existujúcich a tým aj obrovského množstva nimi generovaných dát. Na trhu je k dispozícii množstvo riešení, niektoré sú zadarmo a niektoré sú platené. Tieto aplikácie nebudeme v tomto

¹ Ekonomická univerzita v Bratislave, Fakulta hospodárskej informatiky, Katedra aplikovanej informatiky, Dolnozemska cesta 1, 852 35 Bratislava, pavol.sojka@euba.sk.

článku detailne popisovať z dôvodu širokého rozsahu a to nie je cieľom nášho príspevku. Viac o bezplatných a platených riešeniach nájdete napríklad na Mueller et al. 2019, Baumer a kol. 2017 alebo Gearheart 2020. Títo autori pokrývajú dva najpoužívanejšie jazyky v dátovej vede (R a Python) a posledný sa týka plateného softvérového riešenia s názvom SAS. Tieto tri sú veľmi dobre známe a používané, ale existuje mnoho ďalších ako SPSS od spoločnosti IBM a mnoho ďalších. Ďalej v texte predstavíme niektoré z najpoužívanejších technológií, no našim hlavným cieľom je použiť na tvorbu našej aplikácie jazyk *Python* so špecializovanými knižnicami. Naším cieľom bolo vytvoriť a implementovať takú aplikáciu, do ktorej si používateľ so štandardnými možnosťami (má internetový prehliadač a má k dispozícii dáta) môže nahráť svoj dataset a vykonávať na ňom všetky základné operácie ako čistenie dát a základnú analýzu datasetu, následne uloženie datasetu so spracovanými úpravami, generovanie modelu a testovanie vygenerovaného modelu. Pri spracovaní údajov je dôležité pracovať s konzistentnými údajmi, ale v scenári reálneho sveta to nie je možné z dôvodu možnosti duplicity, chybných údajov, abnormálnych alebo nekonzistentných údajov (Wang et al., 2019).

1.1 Prvé kroky vo vede o údajoch (Data Science)

Ako je uvedené vyššie, Wang a kol. popisali celý proces prípravy dát pre ďalšie vyhodnotenie. Bez týchto dôležitých krokov by mohol byť konečný výsledok skreslený, a preto by prijaté rozhodnutie na základe týchto dát mohlo byť nesprávne a celý proces by bol stratou času. Prvé kroky podniknuté na poskytnutom súbore údajov (datasete) by sa mali týkať deduplikácie údajov, vymazania chybných údajov, hľadania chýbajúcich údajov a ich opravy podľa existujúcich údajov napríklad ich priemernými hodnotami. Mohli by existovať aj iné metódy, ale v našom článku používame tri formy nahradenia chýbajúcich údajov, prvá je vloženie nulových hodnôt, druhá vloženie priemerných hodnôt a tretia je vymazanie celých riadkov údajov, keď iné metódy nie sú vhodné. Používateľ si môže všetky metódy sám vyskúšať, aby zhodnotil, ktorá metóda je vhodná pre jeho potreby. Po spracovaní všetkých údajov sme pripravení vybrať vhodný model aplikovaný na náš súbor údajov.

1.2 Jazyk R

R je programovací jazyk a prostredie určené na štatistickú analýzu dát a ich grafické zobrazenie. Ide o implementáciu programovacieho jazyka S pod bezplatnou licenciou. Keďže je zadarmo, R už predbehlo komerčné S z hľadiska počtu používateľov a stalo sa de facto štandardom v mnohých oblastiach štatistiky. Funkcie prostredia R je možné rozšíriť pomocou knižníc nazývaných balíky. Pre verziu 3.6.2 ich bolo k januáru 2020 v centrálnom úložisku CRAN dostupných 15 325. Príkladom často používaného balíka je ggplot2 na vizualizáciu dát. R sa používa z príkazového riadku, ale existuje niekoľko rozhraní GUI, ako napríklad RKWard, RStudio a R Commander. R je tiež prepojené alebo používané v komerčnom softvéri, napr. v prostredí SPSS môžu používatelia priamo písať a spúšťať programy v jazyku R cez otvorené dáta.

R poskytuje širokú škálu štatistických a grafických techník vrátane lineárneho a nelineárneho modelovania, klasických štatistických testov, analýzy časových radov, klastrovania a ďalších. R je ľahko rozšíriteľný o funkcie a balíky a komunita R je známa svojimi aktívnymi aktualizáciami (Kaplan et al., 2017). Mnoho štandardných funkcií R je napísaných v samotnom jazyku R, čo používateľom uľahčuje sledovanie vykonaných zmien v algoritme. Pre výpočtovo náročné úlohy môže byť kód prepojený s C, C++ a Fortran a volaný za behu. Pokročilí používatelia môžu použiť C, C++, Java, .NET alebo Python na priamu manipuláciu s R objektmi. Ďalšou silnou stránkou R je statická grafika, ktorá dokáže generovať grafy vhodné pre vedecké publikácie vrátane napríklad matematických symbolov. Dynamická a interaktívna grafika je dostupná prostredníctvom dodatočných balíkov (Lewin-Koh, 2015).

1.3 Aplikácia SAS

SAS (predtým Statistical Analysis System) je integrovaný systém softvérových produktov vyrábaných spoločnosťou SAS Institute. Slúži ako databázový systém vo firmách, ako nástroj na analýzu a obchodné využitie dát a na druhej strane sa využíva aj na štatistickú analýzu dát vo vede a technike. Ide o modulárny softvér, takže zákazník môže využívať len časti, ktoré mu vyhovujú. SAS obsahuje vlastný programovací jazyk, označovaný aj ako SAS. Softvér SAS implementuje celý životný cyklus analýzy. Zahŕňa správu údajov, ktorá zahŕňa čistenie a prípravu údajov. Druhým krokom je analytická platforma, ktorá pozostáva z rôznych softvérových nástrojov a umelej inteligencie a posledným krokom je manažment kvality dát (Blokdyk, 2019). Táto platforma je platená a jednotlivci si ju nevyberajú často, ale v komerčnej oblasti je veľmi rozšírená.

1.4 Jazyk Python

Python je dynamicky interpretovaný jazyk. Niekedy sa zaraďuje medzi takzvané skriptovacie jazyky. Jeho možnosti sú však väčšie. *Python* bol navrhnutý tak, aby umožňoval vytváranie veľkých plnohodnotných aplikácií (vrátane grafického používateľského rozhrania – pozri napr. wxPython, ktorý využíva wxWidgets, alebo PySide a PyQt pre Qt, alebo PyGTK pre GTK+).

Python je hybridný (alebo multiparadigmatický) jazyk, to znamená, že umožňuje používať pri písaní programov nielen objektovo orientovanú paradigmu, ale aj procedurálnu a v obmedzenej miere aj funkčnú, podľa toho, čo vyhovuje, alebo je pre danú úlohu najlepšie. Z tohto dôvodu má *Python* vynikajúce vyjadrovacie schopnosti. Programový kód je krátky a ľahko čitateľný v porovnaní s inými jazykmi.

Charakteristickým rysom jazyka *Python* je produktivita z hľadiska rýchlosti písania programov. Platí to pre najjednoduchšie programy aj veľmi rozsiahle aplikácie. V prípade jednoduchých programov sa táto vlastnosť prejavuje najmä stručnosťou zápisu. Pri veľkých aplikáciách je produktivita podporovaná funkciami, ktoré sa využívajú pri rozsiahlom programovaní, ako je natívna podpora menných priestorov, používanie výnimiek, štandardné nástroje na písanie testov (testovanie jednotiek – unit testy) a ďalšie. Vysoká produktivita je spojená s dostupnosťou a jednoduchosťou používania širokej škály knižničných modulov, umožňujúcich jednoduché riešenia úloh z množstva oblastí (Jaworski et al., 2021).

Vzhľadom na všetky podmienky, ktoré musia byť splnené, sme sa rozhodli používať jazyk *Python* so všetkými poskytovanými balíkmi, tiež širokú podporu komunity vývojárov a posledným faktom bolo, že tento jazyk je rozšírený aj v komerčnej sfére.

1.5 Balík Streamlit

Streamlit je bezplatný, open-source, all-python rámeč, ktorý umožňuje vedcom z údajov rýchlo vytvárať interaktívne dashboards a webové aplikácie strojového učenia bez toho, aby boli potrebné skúsenosti s vývojom webu. “Ak poznáte *Python*, potom ste všetci pripravení používať *Streamlit*” (Li, 2022). Je to bezplatný produkt a pozostáva zo všetkého, čo je potrebné na vytvorenie interaktívnych webových stránok s grafmi, mapami, posuvníkmi a ďalšími užitočnými nástrojmi. Pomocou niekoľkých riadkov kódu môžete vytvárať informačné panely a ďalší interaktívny obsah. Využíva svoj vlastný webový server, takže aplikácia je okamžite pripravená na spustenie.

1.6 Balíky Pandas a matplotlib

V našej aplikácii sme okrem iného použili balíky s názvom *Pandas* a *Matplotlib*. *Pandas* je balík *Python* s otvoreným zdrojovým kódom, ktorý poskytuje množstvo nástrojov na analýzu

údajov. Balík sa dodáva s niekoľkými dátovými štruktúrami, ktoré možno použiť na mnoho rôznych úloh pri manipulácii s dátami. Má tiež rôzne metódy, ktoré možno použiť na analýzu údajov, čo je užitočné pri práci na problémoch vo vede o údajoch a strojového učenia v *Pythone*. Tento balík je široko používaný pri analýze údajov a tiež je určený na prácu s externými údajmi, ako sú excelovský pracovný hárok, súbory JSON (JavaScript Object Notation), súbory CSV (comma separated values - hodnoty oddelené čiarkou) a iné. Balík obsahuje rozšírené možnosti pre prácu s riadkami a stĺpcami bez toho, aby sme museli používať cykly (loops), namiesto nich sa používajú funkcie, takže tento typ programovacej paradigmy môžeme nazvať funkcionálnym programovaním. V *Pythone* ide o kombináciu procedurálneho, objektovo orientovaného a funkčného prístupu, ako už bolo spomenuté.

Matplotlib je grafická knižnica dostupná pre programovací jazyk *Python* ako súčasť *NumPy*, balíka na spracovanie numerických údajov. *Matplotlib* používa objektovo orientované API (Application Programming Interface) na vkladanie grafov do *Python* aplikácií (Nelli, 2018). V našej aplikácii sa používa na zobrazenie grafu, tzv. histogramu.

2 Metodológia

Na základe prehľadu literatúry sme zvolili rámec už spomenutý v predchádzajúcom texte. Podľa Richardsa „Streamlit skracuje čas vývoja na vytváranie webových aplikácií zameraných na údaje, čo umožňuje vedcom z údajov vytvárať prototypy webových aplikácií pomocou *Pythonu* za hodiny namiesto dní.” (Richards, 2021). Podľa Nokeri „Zabezpečte webové aplikácie a nasadte ich na cloudové platformy“ (Nokeri, 2021) sme sa tiež rozhodli nasadiť našu aplikáciu do cloudovej infraštruktúry v cloude spoločnosti Oracle. Teraz si popíšme kroky k naplneniu nášho cieľa.

1. Rozhodli sme sa vyvinúť aplikáciu, ktorá umožní používateľom nahrávať svoje dátové súbory a vykonávať základné úlohy pri ich čistení, resp. doplnení o chýbajúce dáta. Tento prístup sa nazýva „čistenie údajov“ a podľa Naumana „Čistenie údajov je komplexný súbor úloh, ktorý berie ako vstup jeden alebo viacero súborov s údajmi a vytvára ako výstup jeden čistý súbor údajov“ (Nauman et al., 2022). Tento proces si zjavne vyžaduje veľké množstvo času, preto sme sa rozhodli tento čas skrátiť znížením niektorých úloh spojených s čistením údajov. Po vyčistení údajov sa pokúsime nájsť vhodný klasifikačný model aplikovaný na náš súbor údajov.
2. Po vykonaní prieskumu sme sa rozhodli použiť pre aplikáciu webovú technológiu kvôli jej rozšírenosti a jednoduchému použitiu s webovými prehliadačmi.
3. Preto sme sa rozhodli použiť webový framework *Streamlit* založený na technológii jazyka *Python*.
4. Vývoj zdrojového kódu na implementáciu aplikácie.
5. Testovanie a nasadenie na lokálnom serveri.
6. Finálne nasadenie aplikácie na cloudovej infraštruktúre Oracle na virtuálnom stroji Linux.

3 Príprava prostredia

3.1 Predpoklady

Na dosiahnutie konečného cieľa sme potrebovali urobiť povinné kroky. V prvom rade si musíme stiahnuť knižnicu (rámec - framework) *Streamlit* z domovskej stránky projektu. Na stránke sú inštalátory vhodné pre rôzne operačné systémy a architektúry. Po výbere vhodného sa odporúča postupovať podľa pokynov na úplné dokončenie procesu inštalácie. Na dosiahnutie

tejto úlohy by si implementátori mali byť vedomí správy operačných systémov *Windows*, *Linux* alebo *MacOS*. Po úspešnej inštalácii môžeme spustiť *Streamlit* framework. Ak všetko funguje dobre, dostaneme webový odkaz a číslo portu, na ktorom webový server počúva. Používateľ je potom presmerovaný do webového prehliadača, kde sa aplikácia po dokončení nachádza. Vyššie popísané kroky je potrebné vykonať, inak nebude implementácia možná.

3.2 Výber vhodného súboru údajov

Naša aplikácia je teraz vhodná pre prácu s rôznymi množinami údajov (datasets). Využitie tejto aplikácie sme zamerali na datasets, ktoré väčšinou obsahujú číselné hodnoty usporiadané do riadkov a stĺpcov. Preto uprednostňujeme štandardnú formu súboru údajov, ktorá je všeobecne známa ako napríklad hárok Excel alebo hárok LibreOffice, ale exportovaný do formátu CSV. Iné typy datasetov, ktoré väčšinou obsahujú textové hodnoty, nie sú vhodné. Pre kategoriálne hodnoty implementujeme rôzne kódovače (enkóbery), ktoré budú využívať algoritmy, ktoré konvertujú kategoriálne hodnoty na skupiny čísel, čo im umožní správne fungovať. Použili sme súbor údajov *sonar.csv* používaný pre tento typ výpočtov strojového učenia získaných z repozitára *Github*. Dataset *sonar.csv* obsahuje údaje, ktoré popisujú, či odrazené akustické signály zo sonaru patria k odrazovému vzoru *míny* (M) alebo *horniny* (R).

3.3 Výber vhodného modelu

Náš projekt je rozdelený do niekoľkých častí, prvá je čistenie dát a jednoduchá stručná grafická analýza na základe histogramových grafov, druhá časť je výber modelu a záverečná časť zahŕňa testovanie modelu.

Výber vhodného modelu je veľmi zložitý a náročný proces, ktorý zahŕňa výber vhodného typu estimátora, vhodného algoritmu, výber hyperparametrov a ich hodnôt a tiež ich rôznych kombinácií a pod. Odvetvie strojového učenia je teda veľmi zložitá na to, aby ho pochopil jeden človek bez nutnosti dlhodobého štúdia problematiky. Keď sa pozriete na algoritmy strojového učenia, neexistuje žiadne jedinečné riešenie ani jeden prístup, ktorý by vyhovoval všetkým scenárom použitia. Existuje niekoľko faktorov, ktoré môžu ovplyvniť rozhodnutie zvoliť si algoritmus strojového učenia (Harlalka, 2018). Strojové učenie je metóda analýzy údajov, ktorá automatizuje vytváranie analytických modelov. Ide o odvetvie umelej inteligencie založené na myšlienke, že systémy sa môžu učiť z údajov, identifikovať vzory a robiť rozhodnutia s minimálnym zásahom človeka (Gradillas, 2021).

Naša aplikácia je napísaná ako webová aplikácia s veľmi jednoduchým a intuitívnym rozhraním, takže každý používateľ s minimálnymi znalosťami štatistických metód alebo algoritmov strojového učenia ju môže použiť pre svoje vlastné dáta. Rozhodli sme sa implementovať klasifikátory s predpripravenými klasifikačnými značkami v tréningovom dátovom súbore, toto sa nazýva supervízne učenie (s učiteľom), ďalšie typy učenia, ktoré sme v našej práci nepoužili, sú učenie bez učiteľa a posilňovacie učenie.

Pre komplexnosť takejto aplikácie sme implementovali iba klasifikačný algoritmus, ale implementácia iných algoritmov je plánovaná v budúcom rozšírení aplikácie. Naša aplikácia ponúka čistenie dát, vyhľadávanie modelov a aplikáciu modelov nájdených automatizovaným strojovým učením. Ako je znázornené na obrázku 1, používateľ musí poskytnúť súbor vo formáte CSV (hodnoty oddelené čiarkou) s vopred klasifikovaným súborom údajov, na ktorom bude model trénovať. Následne sa súbor údajov nahrá na server a spustí sa vyhľadávanie modelu.

V tomto bode musíme mať na pamäti, že táto časť je veľmi citlivá, pretože musíme zvoliť aspoň približne správne množstvo primeraného času na vykonanie výpočtov. Automaticky vybrané modely sme testovali do limitu piatich minút určených na testovanie jednotlivých variácií modelov, pretože sme trénovali modely na malých súboroch údajov a boli sme obmedzení hardvérovými zdrojmi poskytnutými serveru v cloude. Tento typ výpočtu je veľmi

závislý od počtu procesorov počítača a veľkosti operačnej pamäte. Naše výpočty sme testovali aj na notebooku s ôsmimi jadrami a šesnástimi gigabajtmi pamäte, ale server, ktorý sme použili, má jedno jadro a šesť GB pamäte. Preto musíme zvoliť parametre, aby sme sa vyhli neprímeranému času na získanie výsledkov. Naše riešenie je v podstate pripravené na serverové použitie vzhľadom na typ služby - webovej aplikácie. Naše odporúčanie je používať našu aplikáciu v serverovom prostredí s minimálne štyrmi jadrami a ôsmimi gigabajtmi pamäte, aby sa dosiahli primerané výsledky v primeranom časovom rozpätí pre väčšie súbory údajov.

Obr. 1: Používateľské rozhranie výberu najlepšieho modelu

Find best model

Choose a file:

Drag and drop file here
Limit 200MB per file

Browse files

sonar.csv 85.7KB ×

Find best model ensemble

Zdroj: vlastné spracovanie

Po skončení hľadania najlepšieho modelu podľa zvolenej metriky, v našom prípade *accuracy* (presnosť) môžeme následne hneď v aplikácii otestovať aj presnosť vybudovaného modelu v časti určenej na nahratie testovacieho súboru s dátami (obr. 2).

Obr. 2: Používateľské rozhranie pre aplikovanie modelu

Apply model on new dataset

Choose a file (.in suffix):

Drag and drop file here
Limit 200MB per file

Browse files

Apply model on dataset

Zdroj: vlastné spracovanie

3.4 Krátky pohľad na kód

Pre väčšiu prehľadnosť sme zvolili možnosť, aby mal súbor koncovku *in*, aby aplikácia vedela jednoduchšie odlíšiť vstupy od výstupov, tento proces sa v ďalšej verzii aplikácie pravdepodobne zmení, aby nemusel používateľ premenovávať súbor - hoci stačí len pridať za názov súboru príponu *in*. Vo vstupnom súbore sa už nachádzajú dáta, ktoré nemajú klasifikované jednotlivé pozorovania (riadky) a práve na nich otestujeme náš model, a konkrétne to, či dokáže tieto dáta klasifikovať správne. My sme model otestovali aj na tréningových dátach, ale klasifikačné značky sme predtým zmazali. Tým pádom sme overili presnosť modelu, kde bola úspešnosť klasifikácie 100%, čo sa dalo očakávať, keďže bol model na týchto dátach trénovaný pri použití klasifikátora *RandomForestClassifier*.

Obr. 3: Ukážka kódu v Pythone

```
loaded_model = pickle.load(open('file.pickle', "rb"))
list_of_files = glob.glob('*in')
latest_file = max(list_of_files, key=os.path.getctime)
print("IN (CSV) file currently using:", latest_file, "\n")
dataframe = read_csv(latest_file, header=None)
data = dataframe.values
X = data
ynew = loaded_model.predict(X)
```

Zdroj: vlastné spracovanie

Ako vidíme na obrázku 3, do objektu (premennej) *loaded_model* sa uloží (deserializuje) obsah binárneho súboru *file.pickle*, kde máme uložený predtrénovaný model, ktorý sme predtým hľadali (obr. 1). Ďalej systém hľadá všetky súbory s príponou *in* a následne vloží obsah najnovšieho súboru *in* do premennej *data*. Do premennej *ynew* sa uložia výsledky predikcie (obr. 4), ktoré sa uložia zároveň aj do súboru a ten je ponúknutý používateľovi na stiahnutie.

Obr. 4: Získaná predikcia podľa aplikovaného modelu

```
X=[0.02 0.0371 0.0428 0.0207 0.0954 0.0986 0.1539 0.1601 0.3109 0.2111
0.1609 0.1582 0.2238 0.0645 0.066 0.2273 0.31 0.2999 0.5078 0.4797
0.5783 0.5071 0.4328 0.555 0.6711 0.6415 0.7104 0.808 0.6791 0.3857
0.1307 0.2604 0.5121 0.7547 0.8537 0.8507 0.6692 0.6097 0.4943 0.2744
0.051 0.2834 0.2825 0.4256 0.2641 0.1386 0.1051 0.1343 0.0383 0.0324
0.0232 0.0027 0.0065 0.0159 0.0072 0.0167 0.018 0.0084 0.009 0.0032], Predicted=0
X=[0.0453 0.0523 0.0843 0.0689 0.1183 0.2583 0.2156 0.3481 0.3337 0.2872
0.4918 0.6552 0.6919 0.7797 0.7464 0.9444 1. 0.8874 0.8024 0.7818
0.5212 0.4052 0.3957 0.3914 0.325 0.32 0.3271 0.2767 0.4423 0.2028
0.3788 0.2947 0.1984 0.2341 0.1306 0.4182 0.3835 0.1057 0.184 0.197
0.1674 0.0583 0.1401 0.1628 0.0621 0.0203 0.053 0.0742 0.0409 0.0061
0.0125 0.0084 0.0089 0.0048 0.0094 0.0191 0.014 0.0049 0.0052 0.0044], Predicted=0
X=[0.0262 0.0582 0.1099 0.1083 0.0974 0.228 0.2431 0.3771 0.5598 0.6194
0.6333 0.706 0.5544 0.532 0.6479 0.6931 0.6759 0.7551 0.8929 0.8619
0.7974 0.6737 0.4293 0.3648 0.5331 0.2413 0.507 0.8533 0.6036 0.8514
0.8512 0.5045 0.1862 0.2709 0.4232 0.3043 0.6116 0.6756 0.5375 0.4719
0.4647 0.2587 0.2129 0.2222 0.2111 0.0176 0.1348 0.0744 0.013 0.0106
0.0033 0.0232 0.0166 0.0095 0.018 0.0244 0.0316 0.0164 0.0095 0.0078], Predicted=0
X=[0.01 0.0171 0.0623 0.0205 0.0205 0.0368 0.1098 0.1276 0.0598 0.1264
0.0881 0.1992 0.0184 0.2261 0.1729 0.2131 0.0693 0.2281 0.406 0.3973
0.2741 0.369 0.5556 0.4846 0.314 0.5334 0.5256 0.252 0.209 0.3559
0.626 0.734 0.612 0.3497 0.3953 0.3012 0.5408 0.8814 0.9857 0.9167
0.6121 0.5006 0.321 0.3202 0.4295 0.3654 0.2655 0.1576 0.0681 0.0294
0.0241 0.0121 0.0036 0.015 0.0085 0.0073 0.005 0.0044 0.004 0.0117], Predicted=1
```

Zdroj: vlastné spracovanie

4 Záver

Cieľom nášho príspevku bolo umožniť ľuďom s menšími znalosťami strojového učenia uľahčiť proces prípravy modelu. Naším sekundárnym cieľom bolo tiež vytvoriť aplikáciu, ktorá by bola nezávislá od množiny údajov (teda dataset bez špeciálnych názvov stĺpcov a riadkov), takže každý, kto má množinu údajov uloženú vo formáte CSV, bude môcť tento dataset nahráť na náš server. Tieto ciele boli naplnené a teda máme kompletný nástroj, ktorý zahŕňa transformáciu datasetu tak, aby neobsahoval chýbajúce alebo inak poškodené dáta, zahŕňa hľadanie príslušného modelu pomocou balíka *auto-sklearn* a nakoniec umožňuje model otestovať na dátach pomocou *Python* knižnice *scikit-learn*, kde sa po dokončení úlohy ponúkne súbor na stiahnutie s výsledkami klasifikácie. Ďalšími možnosťami rozvoja aplikácie je rozšíriť možnosti hľadania vhodných modelov nielen pre klasifikačné estimátory ale aj iné estimátory, čo bude samé o sebe výzvou, lebo všetky oblasti, ktorých sa týka oblasť strojového učenia, sú pomerne obsiahle a náročné na spracovanie nových informácií.

Literatúra

1. Blokdyk, G. (2019). SAS Software a Complete Guide - 2019 Edition. Emereo Pty Limited.
2. Gearheart, J. (2020). End to end data science with Sas: A hands on programming guide. Sas Institute.
3. Gradillas, R. (2021). Machine Learning Algorithms: How to Choose the Right Kind of Machine Learning Model. Independently Published.
4. Harlalka, R. (2019, April 2). Choosing the right machine learning algorithm - HackerNoon.com - medium. Medium. <https://medium.com/hackernoon/choosing-the-right-machine-learning-algorithm-68126944ce1f>
5. Jaworski, M., & Ziadé, T. (2021). Expert python programming: Master python by learning the best coding practices and advanced programming concepts. Packt.
6. Kaplan, D., & Horton, N. J. (2017). Modern Data Science with R. CRC Press, Taylor & Francis Group.
7. Lewin-koh, Nicholas. (2015). CRAN Task View: Graphic Displays & Dynamic Graphics & Graphic Devices & Visualization. cran.r-project.org.
8. Li, S. (2022, January 14). Streamlit Hands-On: From zero to your first awesome web app. Medium. <https://towardsdatascience.com/streamlit-hands-on-from-zero-to-your-first-awesome-web-app-2c28f9f4e214>
9. Mueller, J. P., & Massaron, L. (2019). Python for data science for dummies. Wiley.
10. Nauman, F., & Herschel, M. (2022). An introduction to duplicate detection. Springer Nature.
11. Nelli, F. (2018). Python data analytics: With pandas, NumPy, and Matplotlib. Apress.
12. Nokeri, T. (2022). Web App Development and Real-Time Web Analytics with Python: Develop and Inte-grate Machine Learning Algorithms into Web Apps. Apress.
13. Richards, T. (2021). Getting Started with Streamlit for Data Science: Create and deploy Streamlit web applications from scratch in Python. Packt Publishing Ltd.
14. SPRINGER Verlag, SINGAPORE. (2018). Data science: 4th International Conference of Pioneering Computer scientists.
15. Wang, D., Guo, Y., Dong, W., Wang, Z., Liu, H., & Li, S. (2019). Deep Code-Comment understanding and assessment. IEEE Access, 7, 174200–174209. <https://doi.org/10.1109/access.2019.2957424>

EXTERNÍ RECENZENTI

Peter Červenka

Petr Fiala

Ján Gunčaga

Pavol Kita

Martina Kuncová

Patrik Mihalech

Gabriella Szedlák

Lea Škrovánková

POKYNY PRE AUTOROV

Rozsah:

- vedecké state a diskusie 10 až 15 strán. Základnou požiadavkou je originalita príspevku a komplexnosť jeho spracovania. Prijímame príspevky v slovenskom, českom a anglickom jazyku (uprednostňujú sa príspevky v anglickom jazyku);
- informácie maximálne 2 strany;
- recenzie maximálne 2 strany.

Forma:

Použite textový editor MS WORD, verzia 2 000 a vyššia. Šablóna pre písanie článkov je na webovej stránke:

<https://fhi.euba.sk/veda-a-vyskum/vedecke-casopisy/ekonomika-a-informatika/o-casopise>

a v elektronickom systéme na stránke:

<http://ei.fhi.sk/index.php/EAI>

Príspevky predkladajú autori elektronicky vo formáte .doc/.docx do systému na stránke <http://ei.fhi.sk/index.php/EAI>. Príspevky sú recenzované. Redakčná rada zabezpečí interné a externé posúdenie textu príspevku. Autor príspevku je povinný zapracovať pripomienky z posudkov najneskôr do 2 týždňov od doručenia e-mailov so žiadosťou o vykonanie oponentských posudkov v elektronickom systéme časopisu a zaslať príspevok so zapracovanými pripomienkami vo formáte .doc/.docx prostredníctvom elektronického systému časopisu *Ekonomika a informatika*. Konečné rozhodnutie o publikovaní príspevku urobí redakčná rada časopisu. Autor pred zverejnením príslušného čísla časopisu *Ekonomika a informatika* odsúhlasí formátovanie elektronickej verzie článku. Fakulta hospodárskej informatiky si vyhradzuje právo zverejniť príspevky schválené redakčnou radou v elektronickej forme časopisu *Ekonomika a informatika*.

Autorské honoráre sa neplatia. Predložením príspevku do elektronického systému vedeckého časopisu *Ekonomika a informatika* dáva autor príspevku vydavateľovi právo, aby bezplatne publikoval text príspevku v časopise *Ekonomika a informatika* v elektronickej forme vo formáte .pdf.

EKONOMIKA A INFORMATIKA

Vedecký časopis Fakulty hospodárskej informatiky Ekonomickej univerzity v Bratislave a občianskeho združenia Slovenská spoločnosť pre hospodársku informatiku.

Poslaním vedeckého časopisu je publikovať teoretické a aplikačné poznatky získané v ekonomickom výskume a hospodárskej praxi z oblastí hospodárskej informatiky, účtovníctva a audítorstva, ekonometrie a operačného výskumu, aplikovanej štatistiky a aktuárstva, s akcentom na aktuálne otázky harmonizácie, integrácie a kompatibility s európskou a svetovou metodológiou a praxou.

Uverejňuje vedecké state a diskusie, recenzie a informácie o dizertačných a habilitačných prácach, inauguračných prednáškach a vedeckých podujatiach v slovenskom, českom alebo anglickom jazyku, ktoré sú výsledkom vedeckovýskumnej činnosti autorov, vedeckých aktivít doktorandov, medzinárodnej výskumnej a pedagogickej spolupráce a ich aplikácie v ekonomickej praxi.

ECONOMICS AND INFORMATICS

A scientific journal of the Faculty of Economic Informatics of University of Economics in Bratislava and the Slovak Economic Informatics Association.

Mission of the scientific journal is to publish theoretical and application knowledge acquired in economic research and practice in the areas of economic informatics, accounting and auditing, applied statistics, actuarial science, econometrics and operations research, with emphasis on the current issues of harmonization, integration and compatibility with the European and global methodology and practice.

The journal publishes scientific articles and paper discussions, reviews and information on doctoral and habilitation theses, inauguration lectures and scientific events in Slovak, Czech or English language, which are results of scientific and research activity of authors, scientific activities of doctoral students, international research and educational cooperation and their application in the economic practice.

EKONOMIKA A INFORMATIKA

Vydáva: Fakulta hospodárskej informatiky Ekonomickej univerzity v Bratislave a Slovenská spoločnosť pre hospodársku informatiku

Vychádza: 2x ročne